STRUKTURALNO MODELIRANJE UTJECAJA BIHEVIORALNIH FAKTORA NA ODLUČIVANJE I PERFORMANSE INVESTITORA NA FINANCIJSKOM TRŽIŠTU

Vuković, Marija

Doctoral thesis / Disertacija

2022

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Split, Faculty of economics Split / Sveučilište u Splitu, Ekonomski fakultet**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:124:188803

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-04-19**

Repository / Repozitorij:

REFST - Repository of Economics faculty in Split

SVEUČILIŠTE U SPLITU
EKONOMSKI FAKULTET

MARIJA VUKOVIĆ

STRUKTURALNO MODELIRANJE UTJECAJA BIHEVIORALNIH FAKTORA NA ODLUČIVANJE I PERFORMANSE INVESTITORA NA FINANCIJSKOM TRŽIŠTU

DOKTORSKA DISERTACIJA

Split, 2022.

SVEUČILIŠTE U SPLITU
EKONOMSKI FAKULTET

POSLIJEDIPLOMSKI SVEUČILIŠNI STUDIJ
EKONOMIJE I POSLOVNE EKONOMIJE

Marija Vuković

STRUKTURALNO MODELIRANJE UTJECAJA BIHEVIORALNIH FAKTORA NA ODLUČIVANJE I PERFORMANSE INVESTITORA NA FINANCIJSKOM TRŽIŠTU

Mentor: prof. dr. sc. Snježana Pivac

Split, 2022.

SADRŽAJ

1. UVOD 1

1.1 Problem i predmet istraživanja 1

1.2 Svrha i ciljevi istraživanja 5

1.3 Istraživačke hipoteze 6

1.4 Metode istraživanja 16

1.5 Očekivani znanstveno-spoznajni i aplikativni doprinosi istraživanja 19

2. POJMOVNE KATEGORIJE FINANCIJSKOG TRŽIŠTA 22

2.1 Regulatorni okvir financijskog tržišta 22

2.2 Trend pretvaranja burzi u virtualne financijske institucije 27

2.3 Manipulacije na tržištima kapitala 32

3. BIHEVIORALNE FINANCIJE 40

3.1 Razvoj bihevioralnih financija 40

3.2 Bihevioralni faktori na financijskom tržištu 46

3.2.1 Heuristike i predrasude 46

3.2.2 Prospektna teorija 50

3.2.3 Ponašanje krda 53

3.2.4 Emocije i raspoloženje 54

3.2.5 Faktori osobnosti 57

3.3 Aktualnost biheviorističke teorije u cikličkom kretanju financijskih tržišta 59

4. MODELIRANJE STRUKTURALNIM JEDNADŽBAMA 67

4.1 Modeliranje strukturalnim jednadžbama temeljeno na kovarijanci (CB-SEM) 67

4.1.1 Karakteristike SEM metode 67

4.1.2 Specifikacija i identifikacija modela 80

4.1.3 Metode procjene modela 89

4.1.4 Analiza mjernog modela 95

4.1.5 Analiza strukturalnog modela 110

4.1.6 Medijacija, moderacija i analiza više grupa 113

4.1.7 Napredne tehnike 119

4.2 Modeliranje strukturalnim jednadžbama metodom parcijalnih najmanjih kvadrata (PLS-SEM) 123

4.2.1 Razlike između CB-SEM i PLS-SEM metode 123
4.2.2 Specifikacija modela 130
4.2.3 Analiza reflektivnog mjernog modela 134
4.2.4 Analiza formativnog mjernog modela 141
4.2.5 Analiza strukturalnog modela 148
4.2.6 Analiza medijacije i moderacije 159
4.2.7 Pregled naprednih tehnika 170
5. EMPIRIJSKO ISTRAŽIVANJE 184
5.1 Instrument istraživanja i prikupljanje podataka 184
5.2 Opis uzorka 186
5.3 Analiza CB-SEM modela 202
5.3.1 Analiza CB-SEM mjernog modela bihevioralnih financija 207
5.3.2 Analiza CB-SEM strukturalnog modela bihevioralnih financija 212
5.3.3 Analiza CB-SEM alternativnog mjernog modela bihevioralnih financija 215
5.3.4 Analiza CB-SEM alternativnog strukturalnog modela bihevioralnih financija 220
5.4 Analiza PLS-SEM modela 223
5.4.1 Analiza PLS-SEM mjernog modela bihevioralnih financija 223
5.4.2 Analiza PLS-SEM strukturalnog modela bihevioralnih financija 229
5.4.3 Analiza PLS-SEM alternativnog mjernog modela bihevioralnih financija 234
5.4.4 Analiza PLS-SEM alternativnog strukturalnog modela bihevioralnih financija 240
5.5 Usporedba rezultata CB-SEM i PLS-SEM modela i odabir adekvatnog SEM modela 244
6. ZAKLJUČNA RAZMATRANJA 249
6.1 Rasprava o rezultatima istraživanja 250
6.2 Ograničenja provedenog istraživanja 256
6.3 Implikacije za primjenu u praksi 257
6.4 Preporuke za daljnja istraživanja 257
POPIS LITERATURE 259
POPIS KRATICA I OZNAKA 281
POPIS SLIKA I TABLICA 286
PRILOZI 289
SAŽETAK RADA 295

SUMMARY **296**
ŽIVOTOPIS **297**

1. UVOD

Zbog sve većeg interesa za bihevioralnom ekonomijom, pa tako i bihevioralnim financijama, uočena je potreba za analizom dodatnih utjecajnih faktora na investicijske odluke. Naime, osim različitih brojčanih pokazatelja koji se odnose na dionice u koje bi investitori mogli potencijalno ulagati, njihove odluke su također pod utjecajem psiholoških faktora, s obzirom da ljudi ne mogu isključiti svoje emocije, raspoloženje i karakteristike osobnosti te odlučivati strogo prema matematičkim modelima. Također je prepoznat drugačiji metodološki pristup ovoj analizi, koji se može pronaći u modeliranju strukturalnim jednadžbama, jer je u analizu potrebno uključiti faktore ponašanja, tj. latentne varijable, koje nisu direktno mjerljive, već se mjere putem određenih indikatora. Stoga, kao predmet istraživanja razmatrano je utvrđivanje utjecaja bihevioralnih faktora na donošenje odluka investitora i njihove performanse na financijskom tržištu. Na temelju prethodnih teorijskih i empirijskih istraživanja, predložit će se konceptualni model istraživanja, koji će uključivati brojne bihevioralne faktore kao varijable za koje se pretpostavlja da utječu na investicijske odluke i performanse. Strukturalnim modeliranjem definirat će se model koji najbolje opisuje pretpostavljene uzročne veze navedene u predmetu istraživanja.

1.1 Problem i predmet istraživanja

Područje financija razvijalo se od davnih vremena u svom predznanstvenom obliku, dok se 18. stoljeće smatra periodom formiranja i učvršćivanja financijske znanosti te njezinog razvoja kao neovisnog znanstvenog smjera (Tissen, 2012; Neal, 2015). S vremenom su razvijene brojne teorije, principi i tehnike za proučavanje tržišta novca i kapitala. Za razliku od bihevioralnog pristupa, prema teoriji efikasnog tržišta, tržište je racionalno, a cijene vrijednosnica odražavaju njihovu intrinzičnu vrijednost. Efikasno tržište je ono tržište na kojem prosječni povrati ne mogu biti veći od onoga što je zajamčeno za njihov rizik, unatoč primijenjenoj strategiji ulaganja (Phuoc Luong i Thi Thu Ha, 2011). Dakle, smatra se da će investitori zaraditi ravnotežnu stopu povrata te da nitko ne može ostvariti iznadprosječne profite, ako pritom ne preuzme natprosječan rizik ili ako se to ne dogodi slučajno (Šonje, 2014). Prema Statmanu (2014), klasične financije temelje se na četiri pretpostavke: ljudi su racionalni; tržišta su efikasna; portfelji se kreiraju prema pravilima moderne teorije portfelja i razlike u očekivanim povratima određene su samo razlikama u riziku.

Miller i Modigliani (1961) opisali su investitore kao racionalne, koji uvijek preferiraju veće bogatstvo i indiferentni su prema tome je li dano povećanje njihovog bogatstva u obliku novčane isplate ili povećanja tržišne vrijednosti njihovih dionica. Dakle, tradicionalno gledište na financije zapravo pretpostavlja potpunu racionalnost investitora, kojima je u interesu isključivo maksimiziranje bogatstva, dok nikakvi drugi čimbenici ne utječu na njihove odluke (Jurevičiene i Ivanova, 2013). Međutim, na tržištu se javljaju određene anomalije, koje ukazuju da emocije i različiti psihološki faktori, kao i osobine ličnosti, igraju veliku ulogu u donošenju odluka investitora na financijskim tržištima (Abul, 2019). S obzirom da ljudi nisu uvijek racionalni, njihove financijske odluke mogu biti vođene bihevioralnim faktorima, odnosno faktorima ponašanja, te se u praksi ponašanje pojedinaca razlikuje u odnosu na pretpostavke klasičnih financijskih modela. Pretpostavku o racionalnosti trebalo bi odbaciti te izgraditi modele na realnim pretpostavkama o ljudskom ponašanju (Šonje, 2014). Ključni cilj modeliranja u bihevioralnoj ekonomiji je zadržati preciznost i općenitost klasične ekonomske teorije, istovremeno povećavajući njezinu empirijsku točnost i uvjerljivost (Prelec, 2006). Stoga, proučavanje bihevioralnih financija igra važnu ulogu u financijama, gdje je upotrijebljena kognitivna psihologija da bi se razumjelo ljudsko ponašanje (Jurevičiene i Ivanova, 2013; Abul, 2019).

Područje istraživanja bihevioralnih financija ispočetka nije bilo široko prihvaćeno, no danas postaje sve važnije (Kim i Nofsinger, 2008). Početkom razvoja ovog područja istraživanja mnogi autori smatraju početak i sredinu 1980-ih godina, kao pokušaj unaprjeđenja i otklanjanja nedostataka teorije klasičnih financija (Waweru, Gitau Mwangi i Parkinson, 2014; Statman, 2018), iako je već 1896. godine francuski sociolog Le Bon prvi uočio karakteristike iracionalnog ponašanja (Le Bon, 1896). Šonje (2014) smatra kako je Keynes bio prvi bihevioralni ekonomist, s porukom da u trenutku prestanka rizika u budućnosti, nastupa neizvjesnost. Upravo ta neizvjesnost i nedostatak informacija otvaraju put djelovanju poriva. Prema Langeru (1975), iracionalne odluke su pod utjecajem tzv. iluzija kontrole, tj. precjenjivanja svoje sposobnosti kontroliranja događaja. Prikupljanjem sve većeg broja empirijskih dokaza koji nisu u skladu s teorijom efikasnog tržišta, potaknut je zaokret u ekonomskim teorijama. U daljnjim istraživanjima je dokazano da tržište dionica pretjerano reagira na informacije, što posljedično utječe na cijene dionica i njihove povrate (De Bondt i Thaler, 1985). Također, Shefrin i Statman (1985) ističu da su dioničari više voljni prodati svoje „dobitne“ dionice nego dionice koje nose gubitak, čak i kada je stavljanje takvih dionica na prodaju najbolji izbor.

Bihevioralne financije definiraju se kao teorije utemeljene na psihologiji, koje pokušavaju razumjeti kako emocije i kognitivne pogreške utječu na ponašanje investitora, odnosno imaju za cilj objašnjavanje anomalija na financijskim tržištima (Phuoc Luong i Thi Thu Ha, 2011; Kumar i Goyal, 2016; Dolfin, Leonida i Outada, 2017). Osnovna ideja kognitivne teorije jest da ponašanje pojedinca određuje njegov vlastiti um, tj. razmišljanje i samo-percepcija određuju ponašanje i emocije (Jurevičiene i Ivanova, 2013). Prema tome, istraživači tvrde da na odluke investitora snažno utječu psihološki poticaji koji su povezani s financijskim ponašanjem (Bikas i Saponaite, 2018). Naime, psihološke pristranosti čine investicijske odluke pojedinaca iracionalnima te uzrokuju da se njihovo donošenje odluka temelji na intuiciji i osjećajima (Kübilay i Bayrakdaroğlu, 2016). Bihevioralne financije pokušavaju razumjeti i objasniti stvarno ponašanje investitora, naspram teoretskih pretpostavki o tome kako bi se trebali ponašati (Pompian, 2016). One nude sljedeće alternativne temelje (Statman, 2014): ljudi su normalni; tržišta nisu efikasna, čak i ako ih je teško pobijediti; ljudi kreiraju portfelje prema pravilima bihevioralne teorije portfelja i razlike u očekivanim povratima nisu određene samo razlikama u riziku, već temeljem više faktora. Interes za bihevioralnom ekonomijom raste toliko brzo, da se na nju nadograđuje i neuroznanost pa nastaju neuroekonomija (Camerer, Loewenstein i Prelec 2004; Zelić, 2017) i neurofinancije, čiji je cilj pružiti alternativno objašnjenje očiglednog neuspjeha klasičnih teorija financija, kombiniranjem eksperimenata s računalnim modelima (Miendlarzewska, Kometer i Preuschoff, 2017; Ardalan, 2018).

Usprkos navedenim prednostima, bihevioralni pristup financijskom tržištu ima i svoje kritičare. Oni priznaju da postoje sustavne pogreške u prosudbi, tj. pristranosti. Međutim, tvrde da postoji ograničenje stvarnog utjecaja ove sustavne prosudbe. Jedan od najvećih zagovaratelja teorije efikasnog tržišta, koja je u suprotnosti s bihevioralnom teorijom, je Fama (1998), koji stavlja naglasak na empirijsko okruženje i dominirajuću teoriju. On tvrdi da su bihevioralne financije skup anomalija koje su zapravo samo poboljšanje rezultata, a podrška anomalijama nestaje s promjenama u načinu njihovog mjerenja. Prema Wessels, Goedhart i Koller (2005), značajne razlike između tržišne i intrinzične vrijednosti investicije su rijetke. Smatraju da su zablude samo privremene pojave koje se javljaju samo u posebnim okolnostima, a s promjenom okolnosti, racionalni ulagači će vratiti cijene dionica do stvarne vrijednosti. Lo (2004) tvrdi da je utjecaj iracionalnog ponašanja na financijsko tržište općenito zanemariv i nevažan, jer tržišne snage uvijek djeluju kako bi cijene vratile na racionalne razine, dok je Curtis (2004) istaknuo brojna

metodološka ograničenja u istraživanjima bihevioralnih financija koje koriste eksperimentalna istraživanja. Među ograničenjima je činjenica da su sudionici eksperimenata znali da su u eksperimentu, zbog čega su se neprirodno ponašali tako da udovolje (ili ne udovolje) istraživaču. Isto tako, sudionici ne slijede uvijek upute, a očekivanja provoditelja eksperimenta od ishoda mogu utjecati na ponašanje sudionika. Osim toga, u istraživanjima na području neuroznanosti koriste se metode poput snimanja mozga, gdje etički kodeks zahtijeva da svaki sudionik mora biti informiran o mogućim štetnim utjecajima na njegovu sigurnost te o vrsti informacija koje se mogu o ispitaniku otkriti, a da ih on nije svjestan i nema nad njima kontrolu. Poseban bioetički problem mogu biti slučajna saznanja o ispitaniku do kojih istraživači mogu doći, pa je potrebno raditi na sprječavanju mogućih zlouporaba i očuvanju prava na privatnost, autonomiju i dostojanstvo (Jelić, 2014). Neovisno o navedenim kritikama, u novije vrijeme sve je više zagovornika ovog pristupa, koji se suprotstavljaju klasičnoj ekonomskoj teoriji temeljenoj na potpunoj racionalnosti.

Uloga psihologije na burzi je izrazito velika te se poneke reakcije mase doista mogu naslutiti ili pogoditi (Kostolany, 2008). Osim ekonomskih faktora, na ciklička kretanja na financijskim tržištima, uostalom, utječu ljudi svojom kupnjom i prodajom, a oni su po prirodi emotivni i često neracionalni pa vrijednost financijskih instrumenata ili pretjerano raste ili pretjerano pada. Kostolany (2008) burzu naziva džunglom i konstatira da burza može učiniti čovjeka ovisnikom te da i najinteligentniji ljudi „ostavljaju svoju inteligenciju u garderobi prije ulaska u burzovnu dvoranu, baš kao i u kockarnicu". Pesimistima naziva ljude rođene za špekulaciju na pad cijena, ljude s lihvarskom dušom, škrtce i sve one bolesnog želudca, a optimistima ljude rođene za špekulaciju na rast cijena, nasrtljivce, pustolove, rasipnike, lakomislenike i romantičare.

Ako većina investitora na tržištu posjeduje neke pristranosti, to može utjecati na cjelokupno tržište (Lin, 2011a). Na te pristranosti utječu razne demografske varijable te tzv. velikih 5 varijabli osobnosti (eng. *big 5 personality*), koje uključuju: ekstraverziju, neuroticizam (ili emocionalnu stablinost), otvorenost, ugodnost i savjesnost. Upravo te pristranosti smatraju se bihevioralnim faktorima. Najčešći faktori koji se navode su: heuristike, prospektna teorija i ponašanje krda, a ponekad se analiziraju i tržišni faktori, koji mogu uvelike utjecati na odluke investitora (De Bondt i Thaler, 1985; Phuoc Luong i Thi Thu Ha, 2011). Neki autori među utjecajne faktore grupiraju i emocije (Jurevičiene i Ivanova, 2013; Charles i Kasilingam, 2014a). Unutar bihevioralnih faktora također postoji i nekoliko komponenti koje se mogu i zasebno analizirati.

Istraživanjima na polju biheviorističke teorije može se pomoći ulagateljima da bolje sagledaju određenu gospodarsku situaciju i razine rizika, što im olakšava donošenje boljih investicijskih odluka u danom vremenu. Već i ranije naglašena je važnost psihologije investitora, uz tvrdnju da je investitoru najveći problem i njegov najveći neprijatelj upravo on sam sebi te da rizik ne leži u tome kakvu vrstu ulaganja investitor ima, već kako dobro on razumije investiciju i kako procjenjuje svoje ulagačke sposobnosti, odnosno kakva vrsta investitora on jest, kojeg uostalom određuje i njegov temperament (Graham, Zweig i Buffett, 2003).

1.2 Svrha i ciljevi istraživanja

Budući da interes za bihevioralnim financijama raste, povećava se broj empirijskih istraživanja na tu temu, no još uvijek ne postoji jedinstven zaključak o načinu na koji određeni faktori ponašanja utječu na donošenje odluka te investicijske performanse. Osim toga, neka istraživanja bihevioralnih financija na svjetskim i europskim tržištima temelje se na teoriji izbora ili na analizi numeričkih podataka, poput kretanja cijena dionica i volumena trgovanja (Statman, 2008; Sowinski, Schnusenberg i Materne, 2011; Pimenta i Fama, 2014; Toma, 2015; Liu, Qi i Li, 2019). Ovo istraživanje naglasak stavlja na same psihološke karakteristike investitora, jer se smatra da bolje objašnjavaju ponašanje pojedinaca, nego što to mogu objasniti trendovi kretanja cijena dionica, volumena trgovanja te različitih indeksa.

Cilj ovog rada je, putem strukturalnog modela, utvrditi koji bihevioralni faktori i s kojim intenzitetom utječu na donošenje investicijskih odluka i performanse. Prethodna istraživanja koristila su samo neke bihevioralne faktore ili njihove komponente kao utjecajne varijable u svojim modelima, dok se ovim istraživanjem želi definirati adekvatna metodologija modeliranja strukturalnim jednadžbama (eng. *structural equation modeling*, SEM) te kreirati sveobuhvatni model utjecaja različitih bihevioralnih faktora na odlučivanje i performanse individualnih investitora na financijskom tržištu. U cilju je pronaći odgovarajući model koji najbolje opisuje teoretski pretpostavljene veze između latentnih varijabli (bihevioralnih faktora i investicijskih performansi) i manifestnih varijabli (indikatora) putem kojih se ove latentne varijable definiraju, kao i između različitih latentnih varijabli. Isto tako, u cilju je i testiranje alternativnih modela te usporedba modela bihevioralnih financija bez uključivanja tržišnih eksternih faktora te s uključivanjem tih faktora. Osim toga, **metodološki cilj istraživanja je definiranje adekvatne metodologije te pronalazak najprikladnijeg strukturalnog modela bihevioralnih financija**,

uvažavajući sve dane smjernice za pravilnu provedbu modeliranja, uz usporedbu rezultata dobivenih putem SEM-a temeljenog na kovarijanci (eng. *covariance-based SEM*, CB-SEM) i putem strukturalnog modeliranja metodom parcijalnih najmanjih kvadrata (eng. *partial least squares SEM*, PLS-SEM).

Operacionalni ciljevi rada obuhvaćaju empirijsku analizu podataka, odnosno utvrđivanje ponašaju li se investitori na financijskom tržištu u Hrvatskoj iracionalno u donošenju odluka o ulaganju; koji čimbenici utječu na iracionalnost investitora u donošenju odluka o ulaganju na financijskom tržištu u Hrvatskoj; utječu li investicijske odluke na investicijske performanse investitora na financijskom tržištu u Hrvatskoj; na koji način i u kojoj mjeri se očituje utjecaj bihevioralnih faktora na donošenje odluka investitora na financijskom tržištu u Hrvatskoj te na koji način i u kojoj mjeri se očituje utjecaj investicijskih odluka na investicijske performanse investitora na financijskom tržištu u Hrvatskoj. Isto tako, ispitat će se koje varijable u strukturalnom modelu najbolje opisuju vezu između bihevioralnih faktora, odluka investitora i njihovih performansi na financijskom tržištu u Hrvatskoj, kao i postoje li alternativni modeli koji jednako dobro opisuju vezu između bihevioralnih faktora, odluka investitora i njihovih performansi na financijskom tržištu u Hrvatskoj. Također, u konačnici je cilj utvrditi postoje li razlike u procijenjenom CB-SEM modelu i PLS-SEM modelu te odrediti metodu procjene i strukturalni model za utvrđivanje utjecaja bihevioralnih faktora na donošenje odluka i investicijske performanse investitora na financijskom tržištu s najpouzdanijim rezultatima.

1.3 Istraživačke hipoteze

S obzirom na to da se u ovom radu želi istražiti utjecaj bihevioralnih faktora na investicijske odluke i performanse investitora, sukladno tome definirane su i istraživačke hipoteze, koje se sastoje od ispitivanja uzročno-posljedičnih veza. Polazna istraživačka hipoteza glasi:

H0: Strukturalnim modeliranjem identificira se utjecaj bihevioralnih faktora na donošenje odluka i investicijske performanse investitora na financijskom tržištu.

U skladu s ciljevima istraživanja te s obzirom na činjenicu da se promatra više bihevioralnih faktora te njihovi utjecaji na odlučivanje i performanse investitora, polazna istraživačka hipoteza provjerit će se kroz više hipoteza, sukladno broju promatranih uzročnih veza. Konceptualni model istraživanja s varijablama i vezama koje će se ispitivati prikazan je na slici 1.1. Model će se sastojati

od šest bihevioralnih faktora, a to su: heuristike, faktori prospektne teorije, ponašanje krda, emocije i raspoloženje te konačno stabilnost i prilagodljivost kao dva faktora osobnosti. Svi navedeni faktori predstavljaju nezavisne varijable. Alternativni model uključivat će i tržišne faktore kao sedmu nezavisnu varijablu. U modelu će se promatrati utjecaj svih bihevioralnih faktora na investicijske odluke, a simultano će se, kroz SEM metodu, procijeniti i utjecaj investicijskih odluka na investicijske performanse. Na slici 1.1. vidljive su i strelice koje pokazuju smjer utjecaja varijabli, s naznakom o kojoj se istraživačkoj hipotezi radi kod svake pojedine uzročne veze. Strelica koja povezuje tržišne faktore s investicijskim odlukama obojena je u plavu boju, s obzirom da će se analizirati kao dodatni eksterni faktor u alternativnom modelu.

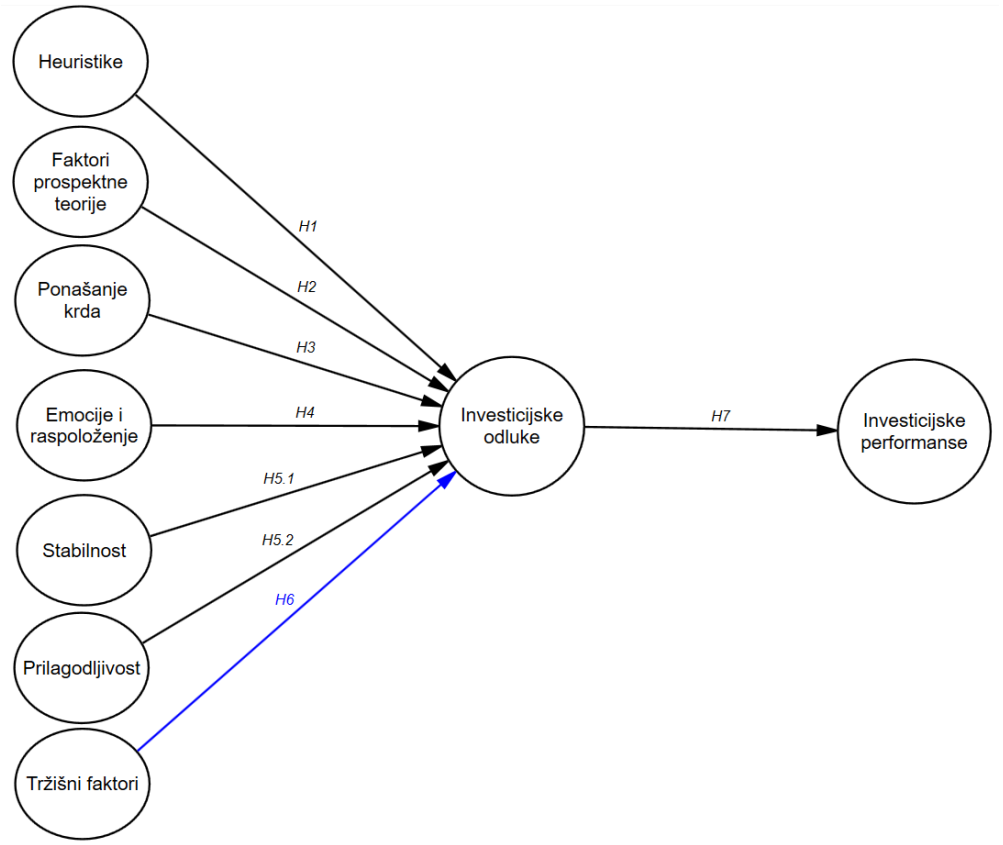

Slika 1.1. Konceptualni model istraživanja

Izvor: izrada autorice

Uz pregled prethodne literature vezane za svaki pojedini faktor, u formiranju hipoteza vrlo je važno obratiti pažnju i na same indikatore svake izabrane nezavisne te zavisne varijable. Indikatore predstavljaju anketna pitanja korištena u svrhu prikupljanja podataka, koja su već korištena i u pilot istraživanju. Pilot istraživanje provedeno je na uzorku od 223 studenta diplomskog studija

Ekonomije, Poslovne ekonomije te Turizma i hotelijerstva, koji imaju usvojene ishode učenja u skladu s predmetom istraživanja, stoga se njihovi odgovori smatraju relevantnima. U nastavku su predložene istraživačke hipoteze.

- ***H1: Korištenje heuristika značajno smanjuje broj dugoročno korisnih odluka o ulaganju investitora na financijskom tržištu.***

Investitori se često koriste heuristikama kako bi olakšali teret procesiranja kompleksnih i dvosmislenih informacija pri prosudbi i donošenju odluka u nesigurnom okruženju (Wang, Shi i Fan, 2006; Raut, Das i Mishra, 2020). One obuhvaćaju: reprezentativnost, dostupnost, sidrenje (Kahneman i Tversky, 1974; Wang, Shi i Fan, 2006; Phuoc Luong i Thi Thu Ha, 2011; Allameh et al., 2015; Khan et al., 2017), igračevu zabludu te samouvjerenost (Waweru, Munyoki i Uliana, 2008). Kada ljudi imaju tendenciju kategorizirati događaje kao tipične za neki fenomen i zanemarivati druge čimbenike koji mogu utjecati na vrijednost ulaganja, javlja se reprezentativnost, koja ponekad može voditi pogrešnim odlukama o ulaganju (Waweru, Munyoki i Uliana, 2008; Khan et al., 2017; Raut, Das i Mishra, 2020). Oslanjanje na dostupnost vodi predvidivom iracionalnom ponašanju, jer podrazumijeva pretjerano korištenje lako dostupnih tržišnih informacija, što može uzrokovati preslabu ili prejaku reakciju u očekivanjima, a time i u cijenama (Kahneman i Tversky, 1974; De Bondt i Thaler, 1985). Sidrenje na financijskim tržištima nastupa kada je početna točka procjene investitora fiksirana nedavnim opažanjima, pa se više pažnje pruža nedavnim trendovima dionica, zanemarujući dugoročne podatke o njima (Kahneman i Tversky, 1974; Phuoc Luong i Thi Thu Ha, 2011; Khan et al., 2017; Raut, Das i Mishra, 2020). To rezultira nedovoljnom reakcijom na neočekivane promjene. Ukoliko pojedinci precjenjuju pouzdanost svog znanja i vještina na financijskom tržištu, očituje se njihova samouvjerenost, kao mjera razlike stvarnog i percipiranog znanja pojedinaca (Kübilay i Bayrakdaroğlu, 2016; Raut, Das i Mishra, 2020). Pogrešno predviđanje promjena tržišnih trendova može dovesti do igračeve zablude. Tako investitori mogu (pogrešno) očekivati i predviđati kraj ciklusa dobrih ili loših tržišnih prinosa (Waweru, Munyoki i Uliana, 2008).

Dosadašnja istraživanja imaju različite zaključke o utjecaju heuristika na odluke i performanse investitora. Osim toga, istraživanja se razlikuju i u svojim metodama prikupljanja podataka te njihove analize, što može utjecati na kontradiktorne zaključke. Allameh et al. (2015) zaključili su kako ponašanja na temelju heuristika ne utječu statistički značajno na investicijske performanse u

Teheranu. S druge strane, Khan et al. (2017) utvrdili su da reprezentativnost, dostupnost i sidrenje značajno utječu na odluke o kupnji dionica na tržištima u Maleziji i Pakistanu. Phuoc Luong i Thi Thu Ha (2011) došli su do zaključka da samouvjerenost i igračeva zabluda imaju jak pozitivan utjecaj na investicijske performanse individualnih investitora u Vijetnamu. Slično tome, Alquraan, Alqisie i Al Shorafa (2016) zaključili su da samouvjerenost značajno pozitivno utječe na donošenje odluka individualnih investitora na saudijskom tržištu dionica. Njihovi zaključci potvrđuju se i u radu Qasim et al. (2019) na uzorku ispitanika u Pakistanu. Osim toga, dokazano je da su muškarci više samouvjereni od žena, što može dovesti do njihovih lošijih performansi uslijed češćeg trgovanja (Barber i Odean, 2001; Lin, 2011a; 2011b; Kumar i Goyal, 2016) te da je samouvjerenost, osim pod utjecajem demografskih varijabli, također pod velikim utjecajem različitih karakteristika osobnosti, primarno ekstraverzije i optimizma (Lin, 2011a; Charles i Kasilingam, 2014a). Mushinada (2020) smatra kako investitori postaju iracionalni zbog samouvjerenosti, no ipak se pokušavaju prilagoditi tržištu temeljem njegove dinamike. Prema Zhang i Zheng (2015), samouvjerenost može pridonijeti pojavi novih ideja, što je korisno za gospodarstvo i financijsko tržište. Daljnja istraživanja (Rekha, 2020) pokazala su kako faktori heuristika (samouvjerenost, reprezentativnost, sidrenje) pozitivno utječu na donošenje dugoročno korisnih investicijskih odluka. Slične zaključke donijeli su i Bakar i Yi (2016) za faktore samouvjerenosti i dostupnosti. Osim toga, za indijsko tržište također je pronađen pozitivan utjecaj sidrenja, samouvjerenosti i reprezentativnosti na investicijske odluke, što je posljedično utjecalo na veću iracionalnost i neefikasnost tržišta (Raut, Das i Mishra, 2020). S druge strane, Shah, Ahmad i Mahmood (2018) dokazali su negativan utjecaj na investicijske odluke za sve elemente heuristika. Odnosno, investitori pri donošenju odluka u nesigurnim uvjetima žele izbjeći rizike, što dovodi do pogrešnih prosudbi, s obzirom da koriste „prečice“ u odlučivanju. Rahman i Gan (2020) donijeli su isti zaključak za samouvjerenost investitora generacije Y, zaključujući da su investicijske odluke manje pouzdane kod više samouvjerenih investitora. Nastavno na sve navedeno, istovremeno promatrajući indikatore heuristika te investicijskih odluka, kao i rezultate pilot istraživanja, može se pretpostaviti kako heuristike negativno utječu na donošenje odluka o dugoročnom investicijskom ulaganju. Naime, korištenje „prečicama“ u odlučivanju dovodi do neefikasnosti tržišta. Investitori zbog sklonosti heuristikama stoga donose lošije i više nepromišljene odluke koje ne dovode do dugoročnih koristi od investicija.

- ***H2: Odlučivanje pod utjecajem elemenata prospektne teorije značajno povećava broj dugoročno korisnih odluka o ulaganju investitora na financijskom tržištu.***

Prospektna teorija (teorija očekivanog izbora) temelji se na ideji da ljudi drugačije ocjenjuju vrijednosti dobitaka i gubitaka te da temelje svoje odluke na dobitcima više nego na gubitcima, pa su tako dioničari više voljni prodati svoje „dobitne“ dionice nego dionice koje nose gubitak, čak i kada je njihovo stavljanje na prodaju najbolji izbor (Shefrin i Statman, 1985; Brajković i Radman Peša, 2015; Jabeen et al., 2020). Prvi su je razvili Kahneman i Tversky (1979) kao alternativu klasičnoj teoriji očekivane korisnosti. Prospektna teorija uključuje: nesklonost žaljenju, nesklonost gubitku i mentalno računovodstvo, tj. sklonost investitora da organiziraju svoj portfelj u različite račune, kako bi bili odvojeno tretirani (Phuoc Luong i Thi Thu Ha, 2011). Prema Charles i Kasilingam (2014b), takve karakteristike nazivaju se i uokvirivanjima, koja su određena individualnom tolerancijom prema riziku i vrijednosti povrata. Oni su u svom istraživanju u indijskoj regiji Tamil Nadu zaključili da okvir anksioznosti i okvir izbjegavanja rizika imaju umjeren utjecaj na određivanje investicijske osobnosti. Istraživanje Allameh et al. (2015) u Teheranu pokazalo je da elementi prospektne teorije ne utječu statistički značajno na investicijske performanse ulagača. Suprotno tim zaključcima, na saudijskom tržištu dionica, Alquraan, Alqisie i Al Shorafa (2016) utvrdili su da nesklonost gubitku utječe pozitivno, a percepcija rizika negativno na investicijske odluke, s obzirom da se investitori u situacijama velikih rizika povlače od ulaganja u svrhu minimiziranja gubitaka zbog nesigurnosti povrata. Nesigurnije povrate nose volatilniji vrijednosni papiri, koji su rizičniji, a prepoznaju se po značajnim promjenama cijena i volumena trgovanja u kratkom vremenskom razdoblju (Dabić i Penavin, 2009). Phuoc Luong i Thi Thu Ha (2011) u istraživanju u Vijetnamu dokazali su da elementi prospektne teorije negativno utječu na investicijske performanse upravo zbog različitog doživljaja gubitaka i dobitaka. Alshamy (2019) čak tvrdi kako su investitori koji imaju averziju prema riziku racionalniji i logičnije razmišljaju i zaključuje kako zbog toga postoji pozitivan utjecaj ovoga elementa na odlučivanje. Upravo iz navedenih razloga, istovremeno promatrajući odabrane indikatore faktora prospektne teorije te investicijskih odluka, može se zaključiti da će investitori koji su manje skloni riziku, nisu skloni gubitcima i oprezno razmatraju svoje portfelje, donositi bolje odluke u smislu da će trgovati s dionicama koje će im donijeti više dugoročnih koristi.

- ***H3: Ponašanje krda značajno povećava broj dugoročno korisnih odluka o ulaganju investitora na financijskom tržištu.***

Na tržištima dionica pojedinci često slijede ponašanje drugih investitora na tržištu. Ovakvo ponašanje poznato je pod nazivom ponašanje ili efekt krda (Abul, 2019; Raut, Das i Mishra, 2020). Investitori ponekad preferiraju ponašanje krda, ako vjeruju da će im ono pomoći da izvuku korisne i pouzdane informacije za svoje investicijske odluke (Phuoc Luong i Thi Thu Ha, 2011; Ghalandari i Ghahremanpour, 2013). Investitori imitiraju druge sudionike tržišta da bi izbjegli dodatne napore u analizi informacija, a ne nužno jer su odluke drugih optimalne (Raut, Das i Mishra, 2020). Ovakvo ponašanje investitora stvara stanje neefikasnih tržišta, prepoznato po špekulativnim mjehurićima (Kumar i Goyal, 2016), a određene karakteristike osobnosti, i to neuroticizam, ekstraverzija i otvorenost, pozitivno i značajno utječu na ponašanje krda (Lin, 2011a; Kübilay i Bayrakdaroğlu, 2016). Za različita tržišta donesen je zaključak da individualni investitori umjereno prate odluke drugih investitora o trgovanju (Phuoc Luong i Thi Thu Ha, 2011; Ghalandari i Ghahremanpour, 2013; Wamae, 2013; Cuong i Jian, 2014; Abul, 2019). U istraživanju na uzorku u Saudijskoj Arabiji, Alquraan Alqisie i Al Shorafa (2016), kao i Alshamy (2019) na uzorku investitora u Iraku te Bakar i Yi (2016) na uzorku malezijskih investitora, zaključuju da ponašanje krda ne utječe značajno na donošenje odluka investitora. Rahman i Gan (2020) su pretpostavili pozitivan utjecaj ponašanja krda na investicijske odluke generacije Y, no njihov model nije dao statistički značajan rezultat. Qasim et al. (2019) i Rekha (2020) pronašli su značajan pozitivan utjecaj ponašanja krda na investicijske odluke. Istraživanje na malezijskom tržištu dionica (Brahmana, Hooy i Ahmad, 2012) pokazalo je da su investitori bili pogođeni psihološkim predrasudama te se nisu oslanjali na temeljne informacije pri donošenju odluka samo ponedjeljkom, ali ne i drugih dana. Phuoc Luong i Thi Thu Ha (2011) zaključili su kako ponašanje krda pozitivno utječe na zadovoljstvo investicijskim performansama. Dodatno, tvrde kako investitori pod utjecajem efekta krda u odlukama drugih vide sigurnost, koja im stoga može donijeti barem prosječne prinose. Međutim, investitori koji slijede ponašanje drugih teže biti dobri kao i ostali sudionici tržišta, dok oni koji nisu pod efektom krda žele biti bolji od ostalih. To se može povezati sa samouvjerenosti, zaključujući tako da investitori pod utjecajem tuđih odluka ipak ne pretjeruju nužno s trgovanjem. Dosadašnja istraživanja nisu suglasna u smjeru i intenzitetu utjecaja ponašanja krda na donošenje investicijskih odluka, a razlog se može pronaći ponajprije u načinu mjerenja određenih varijabli, kao i u razlikama u razvijenosti analiziranih tržišta. Stoga, uzimajući

u obzir i indikatore relevantnih faktora te provedeno pilot istraživanje, može se pretpostaviti kako ponašanje krda kod investitora značajno povećava broj dugoročno korisnih odluka o ulaganju investitora na financijskom tržištu. Naime, iako takvi investitori nemaju dovoljno znanja o trgovanju dionicama, oni reagiraju na akcije drugih investitora upravo da bi izvukli korisne informacije od onih iskusnijih, što često funkcionira dok je financijsko tržište stabilno. Čak i Buffet, u predgovoru Grahamovom *Inteligentnom investitoru* (2003), tvrdi da uspješno investiranje ne zahtijeva izuzetno visok kvocijent inteligencije, neobičnu poslovnu pronicavost ni insajderske informacije, već emocionalnu disciplinu za zadržavanje u pouzdanom okviru.

- ***H4: Pozitivne emocije i raspoloženje značajno povećavaju broj dugoročno korisnih odluka o ulaganju investitora na financijskom tržištu.***

Emocije predstavljaju psihološko stanje uzbuđenja, koje modificira individualna uvjerenja o nekim specifičnim djelima (Ackert, Church i Deaves, 2003). To su intuitivna djelovanja, koja pojedinca ponekad nagrađuju, a ponekad povrjeđuju (Charles i Kasilingam, 2014a; 2014b; Statman, 2014). Iako se ljude često savjetuje da ostave emocije po strani pri donošenju odluka o ulaganju, to nije ni izvedivo ni pametno, jer emocije upotpunjuju razum te je interakcija emocija i razuma većinom korisna (Statman, 2014). Među različitim emocionalnim stanjima autori prepoznaju: ljutnju, mržnju, krivnju, žaljenje, strah, ponos, ushićenje, radost i ljubav (Charles i Kasilingam, 2014a). Elster (1998) razvrstava ova emocionalna stanja u šest slučajeva: kognitivni preduvjeti, namjera, fiziološka uzbuđenja, fiziološki izražaji, valencija i tendencije djelovanja. Charles i Kasilingam (2014a) zaključili su da intuitivnost temeljena na emocijama investitora utječe na njihovu investicijsku osobnost te da su emocije važan faktor koji utječe na heuristike i uokvirivanja (Charles i Kasilingam, 2016). Prema Loewensteinu (2000), u modele ekonomskog ponašanja za predviđanje intuitivnog ponašanja potrebno je inkorporirati intuitivne čimbenike, koji podupiru svakodnevno funkcioniranje, ali također često pokreću ponašanje u smjerovima koji su različiti od onoga što je diktirano mjerenjem dugoročnih troškova i koristi različitih djelovanja. Zhou, Xu i Zhao (2018) zaključili su da emocije koje se očituju putem društvenih mreža mogu predvidjeti trendove na tržištu dionica u Kini. Uz emocije se veže i raspoloženje. Ti pojmovi u suštini su slični i često se naizmjenično koriste, no razlika je u ekspresiji pa se raspoloženje ne može izraziti, dok emocije mogu (Charles i Kasilingam, 2016). Jabeen et al. (2020) povezali su emocionalna stanja i raspoloženja s kognitivnim predrasudama te su zaključili da je anksioznost značajan prediktor

ponašanja krda, depresija je povezana s averzijom prema gubitku, stres sa heuristikom reprezentativnosti, a socijalna interakcija utječe na samouvjerenost investitora. Dakle, različite emocije i raspoloženja i indirektno utječu na investicijske odluke (Jabeen et al., 2020). Nadalje, strah i tuga negativno utječu na averziju prema riziku. Naime, investitori zbog osjećaja tuge često neće željeti ponovno ulagati u nešto od čega su ostvarili gubitak, kao ni zbog straha od nesigurnosti (Aren i Nayman Hamamci, 2020). Slično averziji prema riziku, logično je da će investitori pod utjecajem negativnih emocija i raspoloženja biti manje voljni za ulaganja i tržišne aktivnosti. S druge strane, pod utjecajem sreće, nade, optimizma, tj. pozitivnog pogleda na život, očekivano je da pojedinci budu više motivirani za ulaganja te da će nastojati postići dugoročne koristi. Stoga, četvrta hipoteza pretpostavlja da pozitivne emocije i raspoloženje značajno povećavaju broj dugoročno korisnih odluka o ulaganju investitora na financijskom tržištu.

- ***H5: Karakteristike osobnosti investitora donose značajno veći broj dugoročno korisnih odluka o ulaganju na financijskom tržištu***

Na investitore na financijskom tržištu mogu uvelike utjecati i karakteristike njihove osobnosti, koje mogu oblikovati njihovo ponašanje u određenim situacijama. Kroz petu istraživačku hipotezu analizirat će se utjecaj karakteristika osobnosti, a s obzirom da se te karakteristike mogu podijeliti u više dimenzija, i ova hipoteza je podijeljena na dvije pomoćne hipoteze, koje su opisane u nastavku.

- ***H5.1: Investitori sa stabilnijom osobnošću donose značajno veći broj dugoročno korisnih odluka o ulaganju na financijskom tržištu.***
- ***H5.2: Investitori s više prilagodljivom osobnošću donose značajno veći broj dugoročno korisnih odluka o ulaganju na financijskom tržištu.***

Karakteristike osobnosti opisuju individualne razlike u učestalosti i intenzitetu različitih emocionalnih, motivacijskih, kognitivnih i bihevioralnih stanja. Okvir u kojem se može razvijati integrativna teorija osobnosti nudi se kroz kibernetiku, tj. proučavanje ciljno usmjerenih sustava (DeYoung, 2014). Osobnost se može promatrati kao kibernetski sustav koji obuhvaća: (a) skup ciljeva, koji su definirani kao svjesni i nesvjesni prikazi željenog budućeg stanja; (b) skup svjesnih i nesvjesnih evaluacijskih tumačenja sadašnjeg stanja, uokvirenih u odnosu na te ciljeve; i (c) skup strategija, planova i automatiziranih rutina korištenih za pretvaranje sadašnjeg stanja u željeno

buduće stanje (DeYoung, 2010). Najčešće se osobnost promatra kroz tzv. velikih pet varijabli osobnosti, a to su: ekstraverzija, neuroticizam, otvorenost, ugodnost i savjesnost (John i Srivastava, 1999). Međutim, neki autori ističu kako te varijable ipak nisu u potpunosti međusobno nezavisne te da postoje dva faktora višeg reda, tzv. alfa i beta faktori osobnosti, koji obuhvaćaju spomenutih pet varijabli (Blackburn et al., 2004; DeYoung, 2006; 2010; Erdle et al., 2010). Spomenuti faktori mogu se nazvati faktorima stabilnosti (eng. *stability*) i prilagodljivosti (eng. *plasticity*). Stabilnost obuhvaća savjesnost, ugodnost i emocionalnu stabilnost (suprotnost neuroticizmu) te odražava stupanj u kojem se sustav opire zamjeni operativnih ciljeva užim, neposrednim ciljevima koji bi mogli ometati dugoročne ciljeve. S druge strane, prilagodljivost obuhvaća ekstraverziju i otvorenost te reflektira eksplorativnu tendenciju, gdje je pojedinac aktivno uključen u stvaranje i doživljaj novih iskustava. Dakle, važno je održavati stabilnost u svrhu ostvarivanja svojih ciljeva, dok je istovremeno važno imati sposobnost prilagodbe kompleksnim, promjenjivim i nepredvidljivim okolnostima (DeYoung, 2010). Pojedini autori promatrali su karakteristike osobnosti u kontekstu bihevioralnih financija. Kübilay i Bayrakdaroğlu (2016) povezali su elemente heuristika, ponašanje krda i averziju prema riziku s karakteristikama osobnosti. Slično tome, Charles i Kasilingam (2016) ispitivali su model međuzavisnosti heuristika, uokvirivanja, kockarskog ponašanja, emocija i osobnosti, a prethodno su ispitivali i utjecaj uokvirivanja na investicijsku osobnost, gdje su za varijable investicijskih osobnosti također uzimali tzv. *big 5 personality* model (Charles i Kasilingam, 2014b). Mayfield, Perdue i Wooten (2008) su također promatrali velikih pet varijabli osobnosti, ali su istraživali njihov utjecaj na kratkoročne i dugoročne namjere investiranja te su zaključili kako averzija prema riziku negativno utječe na kratkoročno i dugoročno ulaganje, dok na dugoročno ulaganje pozitivno utječe i otvorenost. Yadav i Narayanan (2021) su zaključili da sve varijable osobnosti, izuzev neuroticizma, značajno utječu na samouvjerenost investitora te da je za sve karakteristike osobnosti taj utjecaj negativan, osim kod savjesnosti. Također su ispitivali utjecaj ovih varijabli na ponašanje krda, gdje je ustanovljen pozitivan utjecaj savjesnosti i neuroticizma, a negativan utjecaj ekstraverzije, ugodnosti i otvorenosti (Yadav i Narayanan, 2021). U istraživanju utjecaja osobnih karakteristika na perceptivne faktore te njihovog utjecaja na namjeru ulaganja u dionice, pronađen je indirektan pozitivan utjecaj savjesnosti, ugodnosti i otvorenosti na namjeru ulaganja (Lai, 2019). Utjecaj velikih pet varijabli osobnosti na bihevioralne sklonosti, i to samouvjerenost, efekt dispozicije i ponašanje krda, istraživali su i Jamshidinavid, Chavoshani i Amiri (2012), dok su Tauni, Yousaf i

Ahsan (2020) zaključili da sličnosti u osobinama savjetnika i investitora pozitivno utječu na performanse trgovanja dionicama za sve faktore velikih pet varijabli osobnosti, izuzev neuroticizma. Uzevši u obzir povezanost karakteristika osobnosti s obrascima ponašanja općenito, u smislu bihevioralnih financija može se pretpostaviti da stabilnije ponašanje, kojem je putem savjesnosti prioritet stabilnost dugoročnih ciljeva, značajno pozitivno utječe na dugoročno korisne odluke investitora (DeYoung, 2010). Isto tako, prilagodljivost može voditi otkriću korisnih mogućnosti koje su bitne za postizanje dugoročnih ciljeva. Stoga, pretpostavlja se da i prilagodljivost značajno pozitivno utječe na dugoročno korisne odluke investitora.

- ***H6: Analiziranje tržišnih faktora značajno povećava broj dugoročno korisnih odluka o ulaganju investitora na financijskom tržištu.***

Tržišni faktori nisu uključeni u bihevioralne faktore, no mogu bitno utjecati na ponašanje investitora kod donošenja odluka, pa ih je prikladno uključiti u razmatranje. Stoga će u ovom radu, uz bihevioralne faktore, alternativni model uključivati i tržišne faktore. Među ovim faktorima mogu se istaknuti: promjene cijena, tržišne informacije, prethodni trendovi dionica, preferencije kupaca, pretjerana ili preslaba reakcija na promjene cijena ili tržišne novosti, manjak pažnje na fundamentalnu osnovu dionice te fokus na popularne dionice i ciklusi sezonskih cijena (Waweru, Munyoki i Uliana, 2008; Phuoc Luong i Thi Thu Ha, 2011). Različita istraživanja potvrdila su pretpostavku da ove tržišne varijable pozitivno utječu na odluke investitora o ulaganju i, posljedično, na investicijske performanse (Phuoc Luong i Thi Thu Ha, 2011; Ghalandari i Ghahremanpour, 2013; Allameh et al., 2015). Sukladno tim zaključcima, pretpostavlja se da će analiziranje tržišnih faktora značajno povećati broj dugoročno korisnih odluka za investitore.

- ***H7: Dugoročno korisne odluke o ulaganju pozitivno utječu na zadovoljstvo investicijskim performansama investitora na financijskom tržištu.***

Investicijske odluke promatrane su u kontekstu raspodjele novčanih sredstava i preferencija prema kratkoročnim ili dugoročnim investicijama (Rekha, 2020). Smatra se da dobre investicijske odluke vode dobrim investicijskim performansama. Dobra odluka investitora reflektira se u dugoročnoj koristi od određene investicije. Investicijske performanse, odnosno uspješnost ulaganja, odražavaju se kroz povrat na investiciju, te se smatra da na njih utječu različiti bihevioralni faktori. Phuoc Luong i Thi Thu Ha (2011) stopu povrata dioničkog ulaganja procijenili su putem ankete, gdje su investitori uspoređivali svoje ostvarene stope povrata s očekivanim i s prosječnim stopama povrata

tržišta kapitala te izražavali zadovoljstvo vlastitim investicijskim odlukama. Rezultati su pokazali da ponašanje krda i heuristike imaju pozitivan, a prospektni faktori negativan utjecaj na investicijske performanse. Istraživanja u Iranu na teheranskoj burzi pokazala su da i tržišne varijable i efekt krda pozitivno značajno utječu na investicijske performanse, bilo direktno, ili indirektno putem odluka o ulaganju (Ghalandari i Ghahremanpour, 2013; Allameh et al., 2015), dok ponašanja na temelju heuristika i prospektne teorije ne utječu statistički značajno. Alrabadi, Al-Abdallah i Aljarayesh (2018) utvrdili su postojanje pozitivnog utjecaja heuristika, faktora prospektne teorije i ponašanja krda na investicijske performanse, koje su također mjerili putem zadovoljstva investitora. Slične zaključke donio je i Siraji (2019), potvrđujući pozitivan utjecaj sidrenja, dostupnosti i reprezentativnosti, te negativan utjecaj samouvjerenosti na investicijske performanse. Razmatrajući pojedinačni utjecaj bihevioralnih faktora na investicijske odluke te utjecaj tih odluka na investicijske performanse, kao i njihove izabrane indikatore, logično je da će bolje investicijske odluke dovesti do veće razine zadovoljstva ostvarenom stopom povrata te odlukama o kupnji i prodaji dionica, što je pokazalo i pilot istraživanje. Naime, bolje odluke za investitora označavaju odluke o dugoročno korisnom investiranju. Samim time, investicija koja donosi korist na dugi rok, kod investitora izaziva višu razinu zadovoljstva svojim performansama.

1.4 Metode istraživanja

Uzevši u obzir prirodu i cilj istraživanja, kao i vrstu varijabli te izabranu statističku metodologiju, podaci će biti prikupljeni anketnim upitnikom. Pitanja koja će anketni upitnik sadržavati bit će preuzeta iz postojećih izvora te prilagođena za kontekst istraživanja.

Varijable u istraživačkom modelu nisu direktno mjerljive, odnosno predstavljaju latentne varijable (faktore, konstrukte), koje se mjere posredno putem odabranih indikatora. Anketna pitanja predstavljat će indikatore, a bit će formirana kao određene tvrdnje, s odgovorima ponuđenim kao skala, tj. razina slaganja s određenom tvrdnjom na ljestvici od 1 do 5. Ciljana populacija su investitori, tj. mali ulagatelji koji trguju vrijednosnim papirima na uređenom tržištu. Prema podacima Statističkog biltena za II. tromjesečje 2021. godine, Središnjeg klirinškog depozitarnog društva, broj aktivnih klijenata u tom razdoblju iznosio je 7481, s tim da je to kumulativan podatak dobiven od svih članova Fonda za zaštitu ulagatelja, zbog čega ulagatelj, ako je klijent više članova, u statističkom podatku može biti prikazan više puta (Središnje klirinško depozitarno društvo, 2021). Uz signifikantnost testa od 0.05 predviđena veličina uzorka je 360 ispitanika. Anketa će biti

distribuirana investitorima putem investicijskih društava (Zagrebačka burza), u svrhu prikupljanja potrebnih podataka.

Od dijela kontaktiranih investicijskih društava povratno je dobiven pristanak za sudjelovanje u istraživanju. Iako su neka istraživanja koristila eksperimente za donošenje zaključaka (Kahneman i Tversky, 1974; 1979; Duxbury, 2015; Cueva et al., 2019), u ovakvoj vrsti istraživanja to nije moguće provesti. Naime, neka investicijska društva, a najčešće banke, pozivaju se na stroge interne akte vezane za poslovnu tajnu te Zakon o zaštiti podataka, koji ih sprječavaju da svojim investitorima šalju bilo što nevezano za njihovo poslovanje. S obzirom na stroge okvire u kojima posluju, pojedina investicijska društva su čak bila prisiljena odbiti slanje poveznice na anonimni anketni upitnik svojim investitorima. Kako eksperimentalno istraživanje zahtijeva izravan kontakt s investitorima, takva vrsta istraživanja u ovakvim okolnostima i zakonskim okvirima trenutno nije provediva. Stoga se istraživanje nastavlja uz anketu kao instrument istraživanja.

Anketni upitnik najprije je sastavljen za pilot istraživanje koje je provedeno indirektnom metodom online putem Google obrasca u periodu od 28. listopada do 19. studenog 2020. godine na uzorku od 223 studenta diplomskog studija Ekonomije, Poslovne ekonomije te Turizma i hotelijerstva na Ekonomskom fakultetu u Splitu. Anketa je, uz pitanja o demografskim karakteristikama, sadržavala 20 pitanja za faktor heuristika, koja su formirana prema Waweru, Munyoki i Uliana (2008), Lin (2011b), Phuoc Luong i Thi Thu Ha (2011), Shah, Ahmad i Mahmood (2018) i Rekha (2020). Pitanja vezana za faktore prospektne teorije formirana su prema Waweru, Munyoki i Uliana (2008), Phuoc Luong i Thi Thu Ha (2011) i Rekha (2020) i bilo ih je 13. Skupina pitanja koja su se odnosila na ponašanje krda sadržavala je 8 pitanja formiranih prema Lin (2011b), Phuoc Luong i Thi Thu Ha (2011) i Rekha (2020). Za emocije i raspoloženje kao relevantan izvor postojećih pitanja uzeto je istraživanje Charles i Kasilingam (2016) s 22 pitanja. S obzirom da se faktor osobnosti promatra kroz više dimenzija, korištene su 44 tvrdnje iz istraživanja John i Srivastava (1999), kako bi ispitanici što objektivnije dali uvid u svoje karakteristike osobnosti. Istraživanja koja su proveli Phuoc Luong i Thi Thu Ha (2011) i Rekha (2020) bili su temelj za formiranje 11 pitanja koja se odnose na tržišne faktore, a prema Rekha (2020) je formirano i 6 pitanja koja se odnose na faktor investicijskih odluka. Investicijske performanse obuhvaćale su 4 pitanja, preuzeta iz istraživanja Phuoc Luong i Thi Thu Ha (2011) i Trang i Tho (2017). Budući da je poznato kako previše kompleksan SEM model ne može dati pouzdane rezultate, broj anketnih pitanja reduciran

je za većinu faktora. Međutim, s obzirom na sposobnost PLS-SEM metode da dobro radi i s kompleksnijim modelima, za neke faktore broj pitanja nije značajno smanjen. Najznačajnije je smanjenje broja pitanja za faktore emocija i raspoloženja te osobnosti, s obzirom da postoji dovoljan broj pitanja koja mogu dobro reflektirati odgovarajuće faktore te pružaju bolji pokazatelj interne konzistentnosti u odnosu na pokazatelj koji se dobije uključivanjem svih pitanja korištenih u anketi za pilot istraživanje. Nastavno na navedeno, nakon provedbe pilot istraživanja i analize rezultata, u konačnom anketnom upitniku, umjesto 20 pitanja, zadržano je 18 pitanja vezanih za heuristike te svih 13 pitanja za faktore prospektne teorije. Umjesto 8 pitanja za ponašanje krda, izdvojeno je 6 pitanja, a od 22 pitanja koja su povezana s emocijama i raspoloženjem, izabrano ih je 13. Od 44 pitanja vezano za karakteristike osobnosti, izabrana su 23 pitanja, od kojih se 9 odnosi na prilagodljivost, a 14 na stabilnost. Broj pitanja za tržišne faktore smanjen je s 11 na 7 pitanja, a za investicijske odluke ostalo je 6 pitanja te za investicijske performanse 4 pitanja, odnosno tvrdnje.

Kako je već ranije naglašeno, s obzirom na metodološki doprinos rada, istraživački model će se procijeniti putem CB-SEM i PLS-SEM metode. Naime, kroz ove metode, uzimajući pitanja iz ankete kao relevantne indikatore, svaki faktor u modelu postaje indirektno mjerljiv te putem SEM metode može procijeniti smjer i intenzitet, kao i značajnost utjecaja svakog izabranog faktora na nezavisnu varijablu. Sve uzročno-posljedične veze procjenjivat će se simultano, tj. istovremeno, što omogućuje upravo SEM metoda. Ova se metoda najčešće provodi u dva koraka. U prvom koraku se analizira mjerni model, putem kojeg se ispituje konvergentna i diskriminantna validnost faktora, kao i njihova pouzdanost. Druga faza označava analizu strukturalnog modela, odnosno analizu samih uzročnih veza između nekoliko faktora (latentnih varijabli) po svom smjeru, intenzitetu i značajnosti. Uz ovu analizu, CB-SEM model daje i pokazatelje prilagodbe modela, koji će pokazati koliko dobro se istraživački model prilagođava teoretskim pretpostavkama. S druge strane, PLS-SEM nema jasno utvrđene mjere prilagodbe modela, a može se upotrebljavati i u prognostičke svrhe, umjesto samo za potvrđivanje teorije. Iz tog razloga, za analizu adekvatnosti ovakvog modela koriste se mjere eksplanatorne i prediktivne snage (sposobnosti) modela. Standardno se, uz bilo kakvu SEM analizu, prikazuje i dijagram putanje (eng. *path diagram*), kao neizostavni dio analize koji grafički pregledno prikazuje cjeloviti model s jasno označenim uzročnim vezama i njihovim koeficijentima. Detaljan opis ovih dviju metoda bit će prikazan u četvrtom poglavlju rada.

1.5 Očekivani znanstveno-spoznajni i aplikativni doprinosi istraživanja

S obzirom na sve veći interes za proučavanjem bihevioralnih financija, može se očekivati da će ovo istraživanje doprinijeti razvoju postojećih spoznaja o bihevioralnim financijama, kao i dati doprinos praksi. Isto tako, vrlo je važan i sam metodološki doprinos rada.

Naime, različiti autori u dosadašnjim istraživanjima koristili su različite metode i tehnike, a stoga i varijable, za donošenje istraživačkih zaključaka. Neki autori (Statman, 2008; Kallinterakis, Munir i Radović-Marković, 2010; Sowinski, Schnusenberg i Materne, 2011; Pimenta i Fama, 2014; Toma, 2015; Zhou, Xu i Zhao, 2018; Liu, Qi i Li, 2019; Bergsma, Fodor i Tedford, 2020; Griffith, Najand i Shen, 2020) koristili su tehnike analize numeričkih podataka, ispitujući na taj način emocije ili ponašanje krda investitora. Međutim, pouzdanost ovakvih analiza ne mora biti velika, s obzirom da se ne ispituju direktno investitori te bilo kakva kretanja financijskih pokazatelja ne moraju nužno biti odraz djelovanja karakteristika osobnosti ili bihevioralnih faktora. Druga skupina istraživanja bila je većinom fokusirana na direktno ispitivanje investitora putem anketnih upitnika, dajući određene tvrdnje, gdje su odgovori postavljeni u smislu razine slaganja s određenom tvrdnjom na nekoj skali, najčešće od 1 do 5 (Mayfield, Perdue i Wooten, 2008; Waweru, Munyoki i Uliana, 2008; Lin, 2011a; Lin, 2011b; Phuoc Luong i Thi Thu Ha, 2011; Babajide i Adetiloye, 2012; Jamshidinavid, Chavoshani i Amiri, 2012; Ghalandari i Ghahremanpour, 2013; Charles i Kasilingam, 2014b; Allameh et al., 2015; Zhang i Zheng, 2015; Alquraan, Alqisie i Al Shorafa, 2016; Bakar i Yi, 2016; Charles i Kasilingam, 2016; Kübilay i Bayrakdaroğlu, 2016; Chopde i Kulkarni, 2017; Khan et al., 2017; Alrabadi, Al-Abdallah i Aljarayesh, 2018; Alshamy, 2019; Bruhn, 2019; Lai, 2019; Qasim et al., 2019; Rekha, 2020). Međutim, nisu svi anketni upitnici međusobno usporedivi u smislu indikatora promatranih varijabli. Stoga se doprinos ovog rada ogleda u **izradi jedinstvenog anketnog upitnika**, koji obuhvaća kombinaciju različitih postojećih već testiranih anketnih pitanja (Bulmer, Gibbs i Hyman, 2006), prilagođenih za kontekst istraživanja, kako bi varijable što preciznije odražavale svoju bit. Metodološki gledano, različita istraživanja u području bihevioralnih financija koristila su različite metode u svrhu dobivanja odgovora na istraživačka pitanja, poput analize trenda, hi-kvadrat testa o nezavisnosti obilježja, analize varijance (ANOVA), modela višestruke i logističke regresije, eksplorativne i konfirmatorne faktorske analize (Kallinterakis, Munir i Radović-Marković, 2010; Wamae, 2013; Alquraan, Alqisie i Al Shorafa, 2016; Bakar i Yi, 2016; Kübilay i Bayrakdaroğlu, 2016; Khan et al., 2017; Zhou, Xu i Zhao, 2018; Abul, 2019; Qasim et al., 2019; Rekha, 2020) te modeliranja strukturalnim

jednadžbama (Lin, 2011a; 2011b; Ghalandari i Ghahremanpour, 2013; Charles i Kasilingam, 2014a; Cuong i Jian, 2014; Allameh et al., 2015; Kumar i Goyal, 2016). Iako su sve korištene metode prihvatljive i primjenjive, one imaju i svoje nedostatke. Naime, promatraju li se bihevioralne financije, pretpostavka je da se promatra ponašanje ljudi i njihove psihološke karakteristike, što iz analiza financijskih trendova ne mora dati ispravne zaključke. Nadalje, hi-kvadrat test pruža odgovor samo o (ne)postojanju ovisnosti između varijabli, no ne i odgovor o prirodi njihove povezanosti. ANOVA i regresijski modeli analiziraju samo izolirani dio varijabli te ih je, ovisno o njihovom broju, potrebno provoditi više puta, dok se faktorskom analizom iz više međusobno povezanih varijabli utvrđuje manji broj faktora, no ne i odnosi među njima. Stoga, uzevši u obzir činjenicu da faktori ponašanja nisu konkretno mjerljivi te se želi istražiti njihovo simultano djelovanje na investicijske odluke, definirat će se adekvatna metodologija **modeliranja strukturalnim jednadžbama** (eng. *structural equation modeling*, SEM) te će se izgraditi model koji na prikladan način definira spomenute uzročne veze. SEM je multivarijatna tehnika koja omogućava simultano istraživanje niza međusobno povezanih odnosa ovisnosti među manifestnim (opaženim, indikator) varijablama i latentnim varijablama (faktorima, konstruktima), kao i među nekoliko latentnih varijabli (Hair et al., 2010). SEM može procijeniti više međusobno povezanih odnosa ovisnosti, ima sposobnost prikazivanja latentnih nemjerljivih varijabli u tim vezama i korigiranja pogreške mjerenja u procesu procjene (Tomarken i Waller, 2005; Hair et al., 2010). S obzirom da može doći do pogrešne specifikacije modela uslijed slabo objašnjene teoretske pozadine modela, istraživači mogu pomoću modifikacijskih indeksa napraviti respecifikaciju modela, koja se ne bi smjela raditi bez teoretske podloge. Isto tako, istraživači ponekad kod testa prilagodbe modela uzimaju samo pokazatelje koji zadovoljavaju potrebne kriterije (McDonald i Ho, 2002; Schreiber et al., 2006; Kline, 2011; De Carvalho i Chima, 2014; Goodboy i Kline, 2017; Tarka, 2018). Promatrajući problematiku vrste analiziranih varijabli te njihove mjerne ljestvice (Carifio i Perla, 2007; Awang, Afthanorhan i Mamat, 2016; Newsom, 2018), kao i rigoroznih preduvjeta za testiranje SEM modela, otvara se prostor za razvoj strukturalnog modeliranja metodom parcijalnih najmanjih kvadrata (eng. *partial least squares SEM*, PLS-SEM). PLS-SEM ima za cilj maksimizirati objašnjenu varijancu zavisnih latentnih konstrukata, što je u suprotnosti s ciljem minimiziranja razlika opažene i procijenjene matrice kovarijanci SEM-a temeljenog na kovarijanci (eng. *covariance-based SEM*, CB-SEM). U skladu s navedenim, definirat će se adekvatna metoda strukturalnog modeliranja, gdje je cilj predviđanje, a ne samo objašnjavanje

teorije, s obzirom na djelomično eksplorativnu prirodu istraživanja. PLS-SEM metoda mnogo je fleksibilnija u smislu preduvjeta za samu analizu što se tiče normalnosti distribucije podataka, a prikladnija je i za analizu modela s manjim uzorcima, kao i za analizu kompleksnijih modela (Hair, Ringle i Sarstedt, 2011; Hair et al., 2017b; Hair et al., 2019b). Upravo iz navedenih razloga, oslanjajući se i na rezultate provedenog pilot istraživanja, pretpostavka je da će PLS-SEM metoda biti prikladnija za procjenu modela bihevioralnih financija. Iako postoje teoretske pretpostavke temeljem kojih je model specificiran, sveobuhvatni model u ovom obliku dosad nije testiran. Iz tog razloga, može se zaključiti kako je istraživanje u određenoj mjeri eksplorativno, a u tom slučaju, između dvije navedene metode, sugerira se upotreba PLS-SEM metode.

U istraživanjima još uvijek ne postoji jedinstven zaključak o načinu na koji određeni faktori ponašanja utječu na donošenje odluka te investicijske performanse, a kontradiktorni rezultati mogu se objasniti upravo različitim načinom mjerenja i analize varijabli. Osim toga, bihevioralne financije relativno su neistraženo područje, gdje se otvara prostor za kreiranje **sveobuhvatnog modela** utjecaja različitih bihevioralnih faktora na odlučivanje i performanse investitora na financijskom tržištu. Takav model mogao bi doprinijeti postojećim spoznajama o bihevioralnim financijama te biti uporište za buduća istraživanja na tu temu. Dodatno, prikazat će se i alternativni modeli te usporedba modela bihevioralnih financija bez uključivanja tržišnih eksternih faktora te s uključivanjem tih faktora.

U **praksi** rezultati ovakvog tipa istraživanja mogu pomoći investitorima u razumijevanju svog ponašanja u svrhu donošenja boljih odluka, koje bi posljedično rezultirale boljim performansama. Isto tako, u području financijskog savjetovanja, upotreba spoznaja bihevioralnih financija može prepoznati brojne koristi, kao što su: jačanje veze s klijentima, pomoć klijentima u odlučivanju i upravljanju njihovim očekivanjima, smanjenje kratkoročnog i emocionalnog odlučivanja klijenata, pomoć u ostvarivanju boljih investicijskih performansi, zadržavanje klijenata u investiranju tijekom perioda volatilnosti, bolje razumijevanje razine prihvaćanja rizika, visoko prilagođeno pružanje usluga, privlačenje novih klijenata zbog diferenciranog programa dodavanja vrijednosti te povećana imovina ili *walletshare* (udio zarade po pojedinom kupcu) (Cheses, 2019).

2. POJMOVNE KATEGORIJE FINANCIJSKOG TRŽIŠTA

2.1 Regulatorni okvir financijskog tržišta

Osnovni propis koji uređuje odnose između svih sudionika financijskog tržišta u Hrvatskoj je **Zakon o tržištu kapitala**. Prvi Zakon o tržištu kapitala (NN 88/08) doživio je više značajnih izmjena i dopuna, pa je donesen potpuno novi Zakon 6. srpnja 2018. godine (NN 65/18), koji je dopunjen i izmijenjen 6. veljače 2020. godine (NN 17/20). U Zakon su prenesene i odgovarajuće direktive i uredbe Europske unije.

Temelj regulacije financijskih tržišta u Europskoj uniji je **Direktiva o tržištima financijskih instrumenata ili MiFID (eng. *Markets in Financial Instruments Directive*)**, najprije kao Direktiva 2004/39/EZ Europskog parlamenta i Vijeća i Uredba Komisije (EZ) br. 1287/2006 na snazi od 31. siječnja 2007. do 2. siječnja 2018. godine, a zatim od 3. siječnja 2018. godine kao revidirana direktiva Direktiva 2014/65/EU Europskog parlamenta i Vijeća i nova Uredba (EU) br. 600/2014 Europskog parlamenta i Vijeća, odnosno MiFID II/MiFIR (eng. *Markets in Financial Instruments Directive 2/Markets in Financial Instruments Regulation*). Propisi se primjenjuju na cijelom području Europske unije, s ciljem poboljšanja konkurentnosti stvaranjem jedinstvenog tržišta za investicijske usluge i aktivnosti osiguranja visokog stupnja zaštite za ulagače u financijske instrumente. Slabosti u transparentnosti koje su otkrivene tijekom financijske krize 2008. godine, potaknule su reviziju i donošenje novog pravnog okvira, paketa MiFID II/MiFIR, kojim bi se uredilo financijsko tržište Europske unije. Naime, porast broja aktivnih ulagatelja na financijskim tržištima, kao i povećani izbor usluga i instrumenata učinili su kompleksnim postojeći sustav tržišta kapitala, u kojem su se razvili i neki sustavi trgovanja koji nisu bili na odgovarajući način obuhvaćeni regulatornim režimom (Direktiva 2014/65/EU; Uredba (EU) br. 600/2014).

Stoga se Direktiva MiFID II prvenstveno razlikuje od Direktive MiFID uvođenjem većih regulatornih zahtjeva, uzimajući u obzir razvoj tehnologije i pojavu novih trgovinskih platformi i rast visokofrekventnih i algoritamskih trgovanja. Osim toga, proširuje se potreba za transparentnošću i izvještavanjem s dionica i na druge financijske instrumente: fondove čijim se udjelima trguje na burzi – ETF (eng. *exchange traded funds*), izvedenice, certifikate, strukturirane financijske proizvode, dužničke vrijednosne papire itd., kako bi se omogućilo lakše vrednovanje i učinkovito formiranje njihovih cijena. Trgovanje standardiziranim OTC-ovim izvedenicama (eng. *over-the-counter*), koje predstavlja trgovanje „preko pulta", tj. direktno između trgovaca

umreženih internetskom mrežom, prema ovoj Direktivi treba provoditi na burzama ili elektroničkim trgovinskim platformama, na način sličan onome koji se primjenjuje na ugovore o valutnim izvedenicama. Pri tome, nadzornim tijelima daje se ovlast za utvrđivanje prihvatljivosti određenih izvedenica, ograničenje njihovog broja ili zahtijevanje smanjenja pozicije u određenom derivatnom ugovoru (Milošević, 2016).

Novost je također osnaživanje uloge upravljačkih tijela investicijskih društava, uređenih tržišta i pružatelja usluga dostave podataka, kako bi se izbjeglo grupno razmišljanje te olakšala neovisna mišljenja. Upravljačka tijela institucija trebala bi biti dovoljno različita što se tiče starosti, spola, geografskog podrijetla, obrazovanja i struke. Raznolikost bi općenito trebala biti zastupljenija u politikama zapošljavanja ovih društava. Broj direktorskih pozicija koje član upravljačkog tijela jedne institucije istodobno može imati u različitim subjektima ograničen je kako bi mogli dovoljno vremena posvetiti svojoj dužnosti te kako bi uprava mogla osigurati da društvo posluje na pouzdan i razborit način, promičući integritet tržišta i interes svojih klijenata (Direktiva 2014/65/EU).

Mnoga investicijska društva istodobno obavljaju sve veći obujam aktivnosti, što povećava mogućnost sukoba interesa između različitih aktivnosti i interesa klijenata, pa je potrebno predvidjeti pravila po kojima bi se vršilo utvrđivanje, sprječavanje i upravljanje sukobom interesa te ublažavanjem mogućih utjecaja tih rizika na interese klijenata. Mjere za zaštitu ulagatelja novom Direktivom su osnažene i prilagođene specifičnostima svake kategorije ulagatelja (mali ulagatelji, profesionalni ulagatelji, kvalificirani nalogodavatelji), pri čemu se sa svakim klijentom primjenjuju načela poštenog djelovanja i obaveze davanja istinitih i jasnih informacija koje ne dovode klijente u zabludu. Zabranjeni su dodatni poticaji prilikom pružanja usluga investicijskog savjetovanja i upravljanja portfeljem, a klijenta je potrebno pravodobno obavijestiti je li savjet pružen na temelju uže ili šire analize tržišta, na užem ili širem rasponu financijskih instrumenata (Direktiva 2014/65/EU; Milošević, 2016). Direktiva predviđa i načela općeg režima koji se odnosi na snimanje telefonskih razgovora ili evidentiranja elektroničke komunikacije koja se odnosi na naloge klijenata, a usklađeno je s Poveljom o temeljnim pravima Europske unije, kako bi se ojačala zaštita ulagatelja, poboljšao nadzor tržišta i povećala pravna sigurnost u interesu investicijskih društava i njihovih klijenata. S obzirom na složenost i stalne inovacije investicijskih proizvoda, važno je osigurati dovoljno resursa da osoblje koja pruža savjete o investicijskim proizvodima

razvije odgovarajuću razinu znanja i kompetencija koje će primjenjivati prilikom pružanja usluga klijentima (Direktiva 2014/65/EU).

Obaveze investicijskih društava i operatera platformi vezane za transparentnost i izvještavanje odnose se na prijavu nadležnom tijelu svih naloga i trgovanja svim svojim transakcijama financijskim instrumentima te vođenje evidencija o svim nalozima koji su zaprimljeni u njihovim sustavima. Nadležno tijelo je tijelo kojem je zakonodavac dao ovlasti za nadzor tržišta kapitala, a u slučaju Republike Hrvatske tu funkciju obavlja Hrvatska agencija za nadzor financijskih usluga – HANFA. Europsko nadzorno tijelo za vrijednosne papire i tržišta kapitala – ESMA (eng. *European Securities Markets Authority*) bi trebalo koordinirati razmjenu informacija među nadležnim tijelima te nadzirati aktivnosti investicijskog društva kako bi se osiguralo da se na tržištu posluje pravedno, iskreno, profesionalno te promovirati cjelovitost tržišta i učiniti dostupnim javnosti podatke o transparentnosti (Milošević, 2016).

MiFID II uvodi nove tržišne strukture, čime se osigurava da se sva organizirana trgovanja odvijaju na a) uređenim multilateralnim mjestima trgovanja: 1) uređenim tržištima, 2) multilateralnim trgovinskim platformama (MTP) i 3) organiziranim trgovinskim platformama (OTP) ili b) bilateralnom mjestu, tj. posredstvom sistematskog internalizatora (SI).

Novom Direktivom i Uredbom MiFIDII/MiFIR na svim mjestima trgovanja postavljaju se jednaki zahtjevi za transparentnošću prije i nakon trgovanja te jednaka organizacija i nadzor, kako bi se osnažilo povjerenje u transparentnost tržišta i smanjili poremećaji tržišnog natjecanja na području cijele Unije.

Uređena tržišta i MTP predstavljaju isti način organiziranog trgovanja kojima ne bi trebalo biti dopušteno izvršavanje naloga klijenata korištenjem vlastitog kapitala. Okupljanje interesa za kupnju i prodaju unutar sustava vrši se pomoću nediskrecijskih pravila koje postavlja operater sustava, što znači da interese okuplja na takav način da dovede do sklapanja ugovora, bez diskrecijskog prava u vezi s mogućom interakcijom interesa (Direktiva 2014/65/EU).

Nova kategorija mjesta trgovanja, uvedena radi povećanja transparentnosti i učinkovitosti financijskih tržišta Europske unije, je organizirana trgovinska platforma (OTP) za obveznice, strukturne financijske proizvode, emisijske kvote, izvedenice i koja je široko definirana radi mogućnosti obuhvaćanja u budućnosti svih oblika organizirane provedbe i dogovaranja trgovanja

izvedenicama koje su prihvatljive za poravnanje i koje su dovoljno likvidne. Dok uređena tržišta i MTP izvršavanje transakcija vrše nediskrecijskim pravilima, OTP može koristiti diskrecijsko pravo kod odlučivanja o neuparivanju određenog naloga s nalozima koji su dostupni u sustavu u određenom trenutku, ako je to u skladu s uputama klijenta i u obavezi najpovoljnijeg izvršavanja naloga. Također, dopušteno je korištenje diskrecijskog prava prilikom odlučivanja o davanju ili povlačenju naloga za trgovanje na OTP-u. S druge strane, operater platforme ili investicijsko društvo koje upravlja OTP-om mora biti neutralan pa ne može izvršavati naloge klijenta koristeći vlastiti kapital, budući da je OTP stvarna trgovinska platforma (Direktiva 2014/65/EU).

Dok se na mjestima trgovanja kao što su uređena tržišta, MTP i OTP spaja ili omogućava spajanje više zainteresiranih trećih strana za kupnju i prodaju financijskih instrumenata, sistematskom internalizatoru (SI) nije dopušteno spajanje trećih strana za kupnju i prodaju. Sistematskim internalizatorom se smatra investicijsko društvo koje na organiziran, učestao i sustavan način trguje korištenjem vlastitog kapitala, izvršavajući naloge klijenata izvan mjesta trgovanja. Sistematski internalizator odlučuje kojim će investitorima na objektivan i nediskriminirajući način dati pristup svojim ponudama, uzimajući u obzir kategoriju klijenata u odnosu na kreditni rizik (Direktiva 2014/65/EU).

Mjesto trgovanja koje spaja ponudu i potražnju za financijskim instrumentima u Hrvatskoj naziva se **uređeno tržište** (popularno nazivano burza), kojim upravlja Zagrebačka burza d.d. te jedina u Hrvatskoj ima odobrenje HANFE (Hrvatske agencije za nadzor financijskih usluga) za upravljanje tim tržištem, a sastoji se od tri segmenta: Vodećeg tržišta, Službenog tržišta i Redovitog tržišta. Redovito tržište obvezuje izdavatelja financijskih instrumenata na dostavu samo minimalnih informacija propisanih Zakonom o tržištu kapitala, dok za Službeno i Vodeće tržište postoje dodatne obveze propisane Pravilima Burze, pri čemu je Vodeće tržište najzahtjevniji tržišni segment u pogledu postizanja uvjeta za uvrštenje. Prelaskom u viši i transparentniji trgovinski segment često se intenzivira trgovanje dionicom, što također može pozitivno utjecati i na njenu cijenu (ZSE).

Zagrebačka burza upravlja i multilateralnom trgovinskom platformom u Hrvatskoj i Sloveniji, pod nazivom Progress tržište, koje je namijenjeno malim i srednjim poduzećima, s nižim zahtjevima transparentnosti u odnosu na uređeno tržište, što bi trebalo doprinijeti lakšem pristupu kapitala za rast i razvoj malim i srednjim poduzećima. S druge strane, manja transparentnost posljedično može

predstavljati veći rizik ulaganja u financijske instrumente kojima se trguje na Progress tržištu (ZSE).

Sudionici tržišta kapitala u Republici Hrvatskoj su: ulagatelji u financijske instrumente (građani, trgovačka društva, investicijski i mirovinski fondovi, društva za osiguranje, banke i drugi); posrednici (investicijska društva, kreditne institucije i ostali); izdavatelji vrijednosnih papira i ostalih financijskih instrumenata; Zagrebačka burza d.d. Zagreb i Središnje klirinško depozitarno društvo d.d. Zagreb (SKDD) (HANFA).

Financijski instrumenti kojima se trguje na financijskom tržištu predstavljaju čitav niz različitih instrumenata: instrumenti tržišta novca (npr. trezorski i blagajnički zapisi); prenosivi vrijednosni papiri (dionice i obveznice); jedinice ili udjeli u subjektima za zajednička ulaganja kojima se upravlja unutar jednog fonda; izvedenice ili derivati koji svoju vrijednost izvode iz vrijednosti nekih drugih instrumenata (HANFA).

Zagrebačka burza u Hrvatskoj objedinjuje i tržišta dionica i tržišta duga. Iako se termin „tržište“ i „burza“ često upotrebljavaju kao sinonimi, treba naglasiti da to nije isto, već svako od njih ima svoju ulogu i svoja pravila ponašanja i poslovanja pa će tržište kroz svoju alokativnu funkciju omogućiti susretanje ponude i potražnje, dok je burza poduzeće koje organizira tržište i pruža mu lakoću funkcioniranja (Andrijanić i Vidaković, 2015). Upravo je nova regulativa MIFID II (Direktiva 2014/65) redefinirala pojam burze, uvodeći pojam mjesta trgovanja (eng. *trading venue*), pa burza kao trgovinsko mjesto gotovo više ne postoji. Transparentnost se zahtijeva na svim platformama, zbog čega se utvrđuju jasna i nediskriminirajuća pravila za pristup sustavu na svim mjestima trgovanja, odnosno na uređenom tržištu, multilateralnoj platformi (MTP) i organiziranoj trgovinskoj platformi (OTP). Burza posluje vodeći se načelima zaštite javnog interesa i stabilnosti tržišta kapitala te za sve sudionike nužno mora osigurati: učinkovitost, ažurnost, nepristranost i jednakost. Trgovanje financijskim instrumentima odvija se putem posrednika, a to su investicijska društva i kreditne institucije po odobrenju Hrvatske narodne banke, a kojima je HANFA odobrila suglasnost u skladu sa Zakonom o tržištu kapitala. Burza (poduzeće koje organizira tržište) određuje svoju strukturu i organizaciju, pa je ukupan broj članova burze preko kojih se vrši trgovanje ograničen njenom veličinom. Uređena tržišta i MTP-ovi podliježu sličnim zahtjevima u pogledu toga koga smiju primiti kao člana ili sudionika, a OTP-ovi mogu odrediti i ograničiti pristup, između ostalog, na temelju uloge i obveza koje imaju u odnosu na

svoje klijente (Direktiva 2014/65). Članstvo na burzi donosi privilegije direktnog pristupa parketu burze ili elektroničkom sustavu burze, čime im je omogućeno neposredno trgovanje uz niže naknade, ali im donosi i obaveze ispunjavanja zakonski propisanih uvjeta, kao i prava sudjelovanja na skupštini burze koja bira svoj upravni odbor (Andrijanić i Vidaković, 2015). Mjesta trgovanja utvrđuju parametre za upravljanje sustavom, pod uvjetom da se to čini otvoreno i transparentno i da ne uključuje diskriminaciju operatera platforme (Direktiva 2014/65). Na Zagrebačkoj burzi trenutno je 13 članova burze, tj. investicijskih društava i kreditnih institucija, koji imaju članstvo mjesto i preko kojih se može odvijati trgovanje financijskim instrumentima (ZSE). Članovi su dužni postupati s pažnjom dobrog stručnjaka te u svom poslovanju izbjegavati aktivnosti koje bi mogle uzrokovati štetu ugledu uređenog tržišta (Zakon, 2018).

Za svakog ulagatelja otvara se račun u Središnjem klirinškom depozitarnom društvu d.d. (SKDD), na kojem se evidentiraju njegovi financijski instrumenti. SKDD je dioničko društvo osnovano 1997. godine, a posluje kao središnji depozitorij vrijednosnih papira, odnosno nematerijaliziranih vrijednosnih papira, gdje se u obliku elektroničkog zapisa vode podaci o izdavateljima, vrijednosnim papirima, računima vrijednosnih papira i imateljima vrijednosnih papira, a sve temeljeno na Zakonu o tržištu kapitala te pod nadzorom Hanfe u skladu sa Zakonom o Hanfi (SKDD).

2.2 Trend pretvaranja burzi u virtualne financijske institucije

Burza je tijekom povijesnog razvoja izrastala iz sajmova na kojima su se trgovci sastajali i sklapali kupoprodajne ugovore o trgovanju robom i vrijednosnim papirima. Ime burza vjerojatno potječe od imena obitelji Van de Burse u čijoj su se kući i pred kućom, na trgu u Bruggeu, obavljali trgovački poslovi s mjenicama i obveznicama. Prve burze se spominju u 12. stoljeću u Lyonu, a od sredine 16. stoljeća i u drugim europskim metropolama. U 18. stoljeću, kao rezultat ekspanzije kapitala i špekulativnih poslova u prekomorskim kolonijalnim zemljama, velikom brzinom raste broj dioničkih društava te trgovina vrijednosnim papirima doživljava svoj procvat, da bi potom 1929. godine pad burze u New Yorku ostao zabilježen kao najpoznatiji burzovni krah u povijesti, koji se odrazio na krizu burze, ali i na gospodarsku krizu u cijelom svijetu. Prema tome, burze vrijednosnih papira značajno utječu na stanje u svjetskom gospodarstvu (Andrijanić i Vidaković, 2015). Promet na burzi je ujedno indikator kolikim iznosom slobodnog kapitala raspolaže tržište, a koji je pokretač gospodarskog rasta jedne ekonomije (Bazdan, 2006).

Slika koju većina ljudi o trgovanju na burzi ima je najvjerojatnije slika fizičkog prostora, burzovnog parketa (eng. *floor*) organiziranog u ringove u kojima je gužva i buka, uokolo na ekranima prolazi burzovna tečajna traka, a samouvjereni muškarci u jednoobraznim odijelima, mašući rukama, uzvikuju nešto nerazumljivim rječnikom jedni prema drugima (Lewis, 2016).

Investiranje i poslovanje na burzama koristi svoj vlastiti jezik, pa se netko tko je u optimističnom raspoloženju i vjeruje da će cijene rasti te kupuje danas, da bi u budućnosti prodao po višoj cijeni, naziva „bik" (eng. *bull*), a netko tko je u pesimističnom raspoloženju i vjeruje da će cijene pasti, pa prodaje danas da bi u budućnosti kupio jeftino, naziva „medvjed" (eng. *bear*). Članovi su burze oni ljudi koji „mašu i viču na parketu za trgovanje", član burze kojem se plaća nagrada za izvršenje naloga je „broker na parketu" (eng. *Floor Broker*), a član koji trguje za svoj račun je „trgovac na parketu" (eng. *Floor Trader*). *Trader* ne može preuzeti nalog od klijenta, a *Broker* to može i ima ovlasti regulatornih agencija da obavlja trgovanje za klijenta. *Broker* ne može trgovati za sebe prije nego izvrši nalog klijenta. Biti u „dugoj poziciji" (eng. *Long*) označava situaciju u kojoj se kupuje financijski instrument očekujući rast vrijednosti, a izlazak iz pozicije se očekuje prodajom po višoj cijeni od one po kojoj je instrument kupljen. Suprotno od toga, „kratka pozicija" (eng. *Short*), označava situaciju u kojoj je financijski instrument prodan, a očekuje se kupiti ga nazad po nižoj cijeni od one po kojoj je prodan. „Špekuliranje" (eng. *Speculate*) je pokušaj predviđanja i profitiranja na temelju smjera kretanja cijena. „Kreator tržišta" (eng. *Market Maker*) će, kada postoji samo ponuda ili samo potražnja, stvoriti tržište nudeći drugu stranu transakcije. *Market makeri* imaju moć određivanja raspona cijena preko ponude za kupnju (eng. *bid*) i ponude za prodaju (eng. *ask*), a s obzirom da je *bid* cijena niža, a *ask* cijena viša, zarađuju na razlici. Razlika između *bid* i *ask* cijene pokazuje kolika je dubina tržišta (eng. *market depth*). Uloga *market makera* je važna jer smanjuje oscilacije na tržištu. Ujedno, određenim instrumentima koji nemaju veliku likvidnost, bilo bi nemoguće trgovati da nema *market makera* (Andrijanić i Novaković, 2015).

Iako se običnom gledatelju *trgovanje na parketu* može činiti kao nerazumljivo nadvikivanje, takvo trgovanje se odvija po savršeno organiziranoj strukturi trgovanja. Prostor je podijeljen na krugove, tzv. *pitove* (ringove, jame, prstenove, arene) pa se na taj način točno zna čime se trguje u kojem dijelu burze. Unutar krugova članovi burze imaju svoja mjesta, a boja jakni i bedževa s jedinstvenim inicijalima dodatni su znak identifikacije, tako da se eliminira potencijalna zabuna o tome tko je zaključio određenu transakciju. Oko krugova su redovi sjedala na kojima sjede „trkači"

(eng. *runners*) – djelatnici zaduženi za prenošenje naloga, koji primaju narudžbe od klijenata i drugih brokera. Oko „arena" s velikim volumenom trgovanja ima puno više „trkača", nego oko „arena" s manjim volumenom. Kada *broker na parketu* zaprimi nalog, vremenski ga označava i upisuje u poseban obrazac. Također, izvršavanje naloga se vremenski označava u obrascu u koji upisuje količinu i cijenu po kojoj je izvršen nalog te *brokera na parketu* koji je zauzeo suprotnu stranu transakcije, a zatim šalje obavijest o izvršenju svom lokalnom brokeru u uredu. Ispod dojma kaosa, koji nastaje izvršavanjem naloga otvorenim izvikivanjem (eng. *open outcry*), stoji dobro uređen sustav prema kojemu se ne može ponuditi na kupnju cijena koja je niža od nečije ponuđene cijene, niti se može ponuditi na prodaju nešto po višoj cijeni od nečije ponuđene cijene prodaje. Nadalje, čitav niz kodova i ručnih signala olakšavaju proces, ispružena ruka s dlanovima prema sebi signalizirat će namjeru kupnje, a s dlanovima prema van namjeru prodaje. Tipično izvikivanje ponude za kupnju je „cijena za količinu", a inverzni način izvikivanja ponude za prodaju „količina po cijeni" čime se izbjegava zabuna zbog buke na parketu. Svaki put kada se dogodi trgovina, cijena će se pojaviti na oglasnoj ploči burze. Informacija se putem kotacijskog sustava šalje dalje po čitavom svijetu, a na monitorima koji su postavljeni uokolo prikazuju se i stalno obnavljaju informacije te se na svim mjestima može znati što se događa izvan granica prostora u kojem netko trguje, a kako bi na temelju toga mogli donositi odluke o investiranju. Zbog velikog broja informacija na burzovnoj traci – *tickeru* – upotrebljavaju se simboli: slovna oznaka jedinstvena za svaki instrument, broj koji označava iznos zadnje cijene po kojoj se trgovalo, te (+ ili -) postotak promjene u odnosu na zadnji dan u kojem se trgovalo (Andrijanić i Novaković, 2015).

Prelazak s trgovanja na podiju burze na elektroničko trgovanje nije promijenio način poslovanja na burzi, koji se i dalje odvija jednako organizirano i standardizirano, već je, uslijed razvoja tehnologije i pojave informatizacije, samo omogućeno da se ovi poslovi obavljaju putem računala i računalnih mreža. Slika klasičnog burzovnog podija zamijenjena je slikom poredanih blokova radnih stolova s računalima, ispred kojih sjede ležerno obučeni članovi burze (Bazdan, 2006), koji promatrajući na zaslonu svojih računala situaciju na burzi, reagiraju u optimalnom trenutku.

Od uvođenja prvog teletipkaćkog stroja, tzv. *tickera,* 1867. godine (Bazdan, 2006) na najvećoj i najpoznatijoj burzi na svijetu, New York Stock Exchange (NYSE), čiji su prostori za trgovanje u najprepoznatljivijoj ulici Wall Street, tehnologija komuniciranja i brzina dobivanja informacije dobivala je sve više na značaju. Ipak, NYSE nije prva burza na kojoj je uvedeno elektroničko

trgovanje. Naime, kao najprestižnija burza, NYSE je imala i najrigoroznije uvjete za uvrštavanje, s obzirom da su mnogobrojna poduzeća radi postizanja svjetskog rejtinga željela izlistati svoje dionice baš na toj burzi. Većina internetskih poduzeća koja su tada bila u nastajanju, kao što su Apple, Microsoft, Dell i dr., tada nisu zadovoljavala uvjete za NSYE (a danas su tehnološki divovi), pa svoje burzovne aktivnosti započinju na NASDAQ burzi (Andrijanić i Novaković, 2015). S druge strane, *National Association of Securities Dealers Automated Quotations* – NASDAQ je, upravo koristeći pojavu nove tehnologije, otvorena 1971. godine, kao prva svjetska elektronička burza, odnosno tržište na kojem ne postoji *floor* ni *open-outcry* sustav trgovanja (Sajter, 2013). Nakon toga, 80-ih i 90-ih godina 20. stoljeća, mnoge vodeće burze u svijetu prelaze na trgovanje u elektroničkom prostoru. Nadalje, kako bi se spriječio duopol koji je stvoren između NYSE i NASDAQ, krajem 1990-ih godina, američko regulatorno tijelo SEC – *Securities and Exchange Commission*, omogućilo je otvaranje alternativnih trgovinskih sustava, uslijed čega se otvaraju elektroničke komunikacijske mreže – ECNs (eng. *electronic communication networks*), koje su omogućavale trgovanje izvan tradicionalnih burzi te decentralizaciju trgovanja (Sajter, 2013). Elektroničko trgovanje započelo je i na NYSE 1995. godine, pa iako je radno vrijeme burze ostalo isto, prije i poslije radnog vremena omogućeno je elektroničko trgovanje brokerima koji imaju posebne licencije za takva trgovanja. Radno vrijeme na NASDAQ burzi je podijeljeno na razdoblja: prije otvaranja, redovno vrijeme i nakon zatvaranja, što omogućava postojanje tržišta nesputano vremenskim okvirom (Andrijanić i Novaković, 2015). Kostolany (2008) burze vidi kao „carstvo poput onoga cara Karla V., u kojem sunce nikada ne zalazi", koje su povezane kao komunikacijske cijevi i pritiskom na dugme u jednom kraju svijeta, posljedice se mogu osjetiti na najudaljenijim dijelovima svijeta.

Hrvatska svoju tradiciju trgovanja na burzi započinje 1907. godine, ali ne u kontinuitetu te s najdužim prekidom od 1945. do 1991. godine, zbog socijalističkog društvenog sustava, u kojem nije bilo moguće organizirati takve ustanove. Osamostaljivanjem Hrvatske nastavljaju se burzovne aktivnosti, pa je ustrojeno Zagrebačko tržište kapitala i Zagrebačka burza te Varaždinsko tržište vrijednosnica (koje je kasnije, kao Varaždinska burza d.d., pripojeno Zagrebačkoj burzi d.d.). Prvi sustav trgovanja na Zagrebačkoj burzi zahtijevao je fizičku prisutnost brokera koji su provodili javne dražbe u ime Hrvatskog fonda za privatizaciju, uz korištenje nove programske podrške. Isticanje ponuda i transakcija bilježilo se u računalo, kako bi se bitni podaci mogli prikazati na zaslonima razmještenim po dvorani, a u jednom trenutku moglo se trgovati samo jednim

vrijednosnim papirom (ZSE). Ovo razdoblje je karakteristično po pojavi mešetarenja paketima dionica (tzv. „torbarenje”), s obzirom da je tadašnje tržište kapitala bilo doslovno u svojim začetcima bez pravoga institucionalnog okvira (Altaras Penda, 2019). Svoj prvi elektronički sustav trgovanja, TEST-1 (Telekomunikacijski Sustav Trgovine), Zagrebačka burza uvodi 1994. godine, koji je po prvi put omogućavao članovima izravno trgovanje iz svojih ureda, korištenjem osobnog računala i modema. Glavna prednost bila je dostupnost u vrijeme kada je komunikacijska infrastruktura u Hrvatskoj bila vrlo nerazvijena. Zagrebačka burza je 1995. godine bila prva burza u Europi i jedna među prvima na svijetu s vlastitim službenim internetskim stranicama na kojima je objavljivala redovita dnevna izvješća o trgovanju i kretanju cijena. Prvi elektronički sustav za trgovanje u realnom vremenu, TEST-1.5., uvodi se 1997. godine, a trećom generacijom svog elektroničkog sustava MOST (Multioperativni Sustav Trgovine), 1999. godine, uvodi se automatsko sklapanje transakcija te 2000. godine sustav MOSTich, koji omogućava praćenje trgovanja u realnom vremenu putem interneta, namijenjen najširem krugu investitora. MOSTich Master uveden je 2003. godine i namijenjen je institucionalnim investitorima. Novi trgovinski sustav Xetra® T7 uvodi se 2017. godine, putem kojeg se trenutno odvija trgovanje, i predstavlja platformu koja se temelji na nalozima sudionika tržišta (eng. *order driven model*) i na ponudama održavatelja tržišta (eng. *quote driven model*), a instrumentima se može trgovati kontinuirano ili putem dražbi. Na Zagrebačkoj burzi ne postoji klasično mjesto na kojem se trguje, već se cjelokupno trgovanje odvija putem računala i računalnih mreža (ZSE).

U posljednjem desetljeću na svjetskim burzama, odnosno mjestima trgovanja, do izražaja dolazi nova tranzicija u povijesti financijskih tržišta, jer se najveći dio obujma trgovine sada odnosi na trgovinu u virtualnom prostoru, ali između računala, bez izravnog upliva ljudi. Algoritamsko trgovanje (eng. *algorithmic or algo-trading*) podrazumijeva računalno trgovanje, pri kojem algoritmi mogu samostalno donositi odluke o tome koji financijski instrument, kada, koliko i na koji način kupiti, odnosno prodati (Sajter, 2013). Direktiva MiFID II naglašava potrebu uređivanja rizika koji proizlaze iz algoritamskog trgovanja. Poseban podskup algoritamskog trgovanja je visokofrekventno trgovanje (eng. *high frequency trading*) u kojem sustav za trgovanje velikom brzinom analizira podatke ili signale s tržišta, temeljem čega šalje veliku količinu naloga u vrlo kratkom vremenu. Tehniku visokofrekventnog trgovanja obilježava mrežna infrastruktura koja na najmanju moguću mjeru skraćuje mogućnost za algoritamski unos naloga: kolokaciju, držanje datoteka na poslužitelju u neposrednoj blizini ili vrlo brz izravan elektronički pristup (Zakon,

2018). Napredak tehnologije općenito je omogućio koristi tržištu i sudionicima na tržištu, kao npr. povećanje likvidnosti, manji raspon cijena, smanjenje kratkoročne volatilnosti cijena i postizanje boljeg izvršenja naloga za klijente. Međutim, upotreba tako sofisticirane tehnologije može dovesti do povećanog rizika od preopterećenja sustava zbog velikog volumena naloga, rizika stvaranja dupliciranih ili neispravnih naloga ili da algoritamsko trgovanje ne funkcionira učinkovito te tako doprinese stvaranju neurednog tržišta te rizika mogućeg korištenja za zlouporabu (Direktiva 2014/65/EU). Izdanak visokofrekventnog i algoritamskog trgovanja su tzv. „mračni bazeni" (eng. *dark pools*), tj. zatvorena financijska tržišta u kojima nema potpune transparentnosti o identitetu sudionika, obujmu trgovine i postignutim cijenama. Prijavljivanje svih trgovanja koje se provodi putem *dark poolsa* čini se s dovoljnim odmakom vremena, da je nemoguće znati što se doista u *dark poolu* događa, naročito uzevši u obzir da se evidencije burze vode u sekundama, a da je jedinica trgovanja u mikrosekundama, milijuntnim dijelovima sekunde. Nova skupina u financijskoj industriji koja dobiva na važnosti su tzv. kvanti (engl. *quants*), koji se bave područjem matematike, statistike, informatike ili fizike, koji su ključni za uspostavljanje algoritamskih i visokofrekventnih kodova. Zgrade su dobile novu ulogu, jer umjesto podija za trgovanje, prostor je sada potreban za usluge kolokacije (eng. *co-location*), jer je za postizanje što veće brzine potrebno omogućiti smještaj računala što je moguće bliže računalu burze. Često se usluge kolokacije pružaju u izvana neatraktivnim zgradama na tajnim lokacijama, u kojima je osigurano neprestano i autonomno napajanje svim potrebnim resursima, uz najveće mjere osiguranja, kako bi trgovanje bilo apsolutno neometano (Sajter, 2013; Lewis, 2016).

2.3 Manipulacije na tržištima kapitala

Svaku manipulaciju tržištima kapitala kroz povijest uzrokovala je pohlepa za brzom zaradom. Kada je pohlepa prisutna, onda će se i gradnja „kula u zraku" činiti kao pretpostavka za ostvarivanje velikog uspjeha, a investitori čiji je stav brzo bogaćenje će zagristi u bilo koji mamac (Malkiel, 2006). Jedna od temeljnih pretpostavki na koju računaju svi koji trguju na burzi je ostvariti profit, bilo na način da nastoje „kupiti jeftino – prodati skupo" ili u obrnutom smjeru „prodati skupo – kupiti jeftino" (Andrijanić i Novaković, 2015).

Grahamov i Doddov pristup investiranju temeljio se na intrinzičnoj vrijednosti, što se čini kao jednostavan način za savladavanje strategije investiranja. Međutim, osim Warrena Buffeta, vrlo malo je primjera bogaćenja temeljenih na ovoj teoriji čvrstih temelja. Iako je Graham definirao

investiranje kao operaciju koja, nakon temeljite analize, obećava sigurnu glavnicu i primjeren prinos, dojam je da špekuliranje postaje prevladavajuća kultura, kojoj je teško izbjeći iskušenje kupovine koja obećava brzo bogaćenje. Sjećanja na „špekulativna ludila" kratko traju, a upozorenja na visokorizične dionice (Malkiel, 2006) imaju isti učinak kao i upozorenje na kutijama cigareta, koje ne sprječavaju mnoge ljude da puše. Malkiel dopunjava Grahama definicijom vremenskog razdoblja za povrat investicije, koje čini razliku između investitora i špekulanta, pa investitor kupuje dionice koje će vjerojatno tek nakon mnogo godina ili desetljeća proizvesti siguran budući priljev u novcu i povećanje kapitala, dok špekulant kupuje dionice nadajući se dobitku u kratkom roku, tijekom idućih dana ili tjedana (Malkiel, 2006).

Određeni događaji iz povijesti burzovnog poslovanja potakli su vlade svih zemalja u kojima se organiziraju burze da se kontrolira i nadzire njihov rad preko nadležnih ministarstava i posebnih državnih agencija, kako bi se spriječilo manipulativno ponašanje i nekontrolirano i nerealno špekulativno poslovanje, koje najčešće izazove prodajnu paniku. Ponašanje na burzi odražava se na ukupnu gospodarsku situaciju, a također svi važniji politički i ekonomski događaji povratno se odražavaju na poslovanje na burzi (Andrijanić i Novaković, 2015).

Varljivi pothvat engleske kompanije South Sea Company 1720. godine jedna je od prvih špekulacija dionicama koja završava kolapsom (u kojoj je među gubitnicima bio i Isaac Newton), po kojoj su i svi kasniji pothvati koji su nudili nadu u ogromne dobitke dobili prikladan naziv „mjehurići", s obzirom da bi se obično u kratkom roku nakon napuhavanja rasprsnuli kao mjehurići sapunice (South Sea Bubble), a nakon čega je proglašen i tzv. Zakon o varljivim pothvatima – Bubble Act, koji je zabranjivao izdavanje dioničkih certifikata (opozvan 1825. godine) (Malkiel, 2006). Slično tome, iste godine, pothvat poduzeća Mississippi Company, kojem je cilj bio zamijeniti metal kao novac i stvoriti veću likvidnost putem papirnatog novca za koji jamči država, privukao je špekulante, ali nakon vrtoglavog rasta uslijedio je još strmoglaviji pad, kada je javnost shvatila da višak papirnatog novca ne stvara bogatstvo, već inflaciju (Malkiel, 2006).

Uvjeti za „špekulativno ludilo" ponovili su se nakon Prvog svjetskog rata u Americi, u vrijeme povećanja prosperiteta, koje je stvorilo klasu poslovnih ljudi i veliku koncentraciju bogatstva, što je utjecalo na rekordni rast vrijednosnica i pomamu za takvom vrstom profita. Osim gospodarskih i političkih okolnosti, koje su tema mnogih istraživanja uzroka Velike depresije, dodatna okolnost koja je utjecala na špekulativni duh je mogućnost kupovanja dionica na marginu uz vrlo labave

provjere financijske sposobnosti (na povjerenje). „Crni četvrtak", 24. listopada 1929. godine, po intenzitetu panike jedan je od najkatastrofalnijih dana u povijesti burze. Sličan intenzitet panike na burzi pamti se kao „crni ponedjeljak", 19. listopada 1987. godine (ili 20. listopada „crni utorak", zbog razlike u vremenskoj zoni), za koje se pokazalo da je do negativnog vala došlo zbog računalnog programa, koji je kod određenih visina cijena automatski izbacivao prodajne i kupovne naloge na pojedinim burzama, pri čemu su opet špekulanti iskoristili situaciju panične prodaje po niskim cijenama. Ipak, ovaj događaj nije pokrenuo svjetsku krizu, kako se na prvi pogled očekivalo, ali je sigurno pokrenuo proces koji je omogućio lakšim da računala postepeno zamjenjuju ljude, pri čemu je i FIX protokol (*Financial Information eXchange*), koji je uveden 1992. godine, služio kao međunarodno dogovoreni način komuniciranja između računala u stvarnom vremenu, s ciljem unaprjeđivanja razmjene informacija na financijskim tržištima, a mnoge trgovce vrijednosnicama pretvorio u konzultante (Malkiel 2006; Kostolany, 2008; Sajter 2013; Andrijanić i Vidaković, 2015; Lewis 2016).

Nakon burzovnog kraha 1929. godine osnovana je Komisija za vrijednosne papire i burze – SEC (*Securities and Exchange Commission*), u cilju zaštite ulagača i održavanja pravednih, urednih i učinkovitih tržišta. To ipak nije uspjelo spriječiti da se „varljivi pothvati" događaju i tijekom 60-ih godina (manija novih emisija rastućih poduzeća elektroničke industrije), gdje ni upozorenje SEC-a (koje je otkrilo da je veliki dio ponude novih emisija alociran upućenim osobama, da bi sačekale trenutak porasta cijena po kojima su ih mogle prodati), nije pomoglo da „kupce spasi od njih samih" (Malkiel, 2006). Ni 70-e nisu bile pošteđene, premda su se profesionalci s Wall Streeta orijentirali na investiranje prema „razumnim principima" i investiranje u dionice poduzeća za koje se smatralo da neće nikada doživjeti slom. Međutim, opet je ignorirana činjenica da ni jedno poduzeće ne može toliko brzo rasti da bi opravdalo multiplikatore po kojima se trgovalo njihovim dionicama, a kada su institucionalni investitori, nakon što su nagomilali portfelje „prvoklasnim dionicama", „odlučili da dionice imaju previsoku cijenu" te donijeli odluku prodati ih, 1972. godine dionice s najvećim rastom doživjele su najveći pad (Malkiel, 2006). Očigledan primjer zaboravljanja lekcija iz prošlosti je entuzijazam ulaska u nove emisije tijekom 80-ih i 90-ih godina u obećavajuće pothvate koji bi propadali, od kojih su neki od njih, poput zzzz-Best, Enron, WorldCom, Tyco, primjeri skandalozne, sistematske i kreativno planirane računovodstvene prijevare. Boom internetskih dionica doveo je do vrhunca napuhavanja „dot.com balona" u ožujku 2000. godine, kada je započelo njegovo ispuhivanje, a kriza, premda kratkotrajnog karaktera, imala

je globalne implikacije. Ovi skandali su doveli do reformi (Sarbanes-Oxley Act iz 2002. godine, a u Hrvatskoj se tada donosi Zakon o tržištu vrijednosnih papira 2002. godine), koje su trebale umanjiti sukobe interesa menadžera, knjigovođa, uprava i analitičara vrijednosnih papira, a zaštititi ulagače zahtijevajući unutarnje računovodstvene provjere i osigurati točno financijsko izvještavanje i transparentnost (Malkiel, 2006; Andrijanić i Novaković, 2015).

Poremećaji na tržištu hipotekarnih obveznica uzrokovali su slom burze 2008. godine, koja je po intenzitetu bila vrlo slična krizi 30-ih godina 20. stoljeća. Naime, odredbe saveznog zakona, poznatog kao Glass-Steagall Act, koje su uvedene nakon Velike depresije, ukinute su 1999. godine, čime je komercijalnim bankama dopušteno da se bave investicijskim bankarstvom. To je dovelo do toga da se u potrazi za visokim profitima upuštaju u visoko rizične poslove, čemu je doprinio i dogovor SEC-a s velikim investicijskim bankama iz 2004. godine, kojim su banke praktički oslobođene ograničenja iznosa duga s kojim se mogu nositi. Nekontrolirana kreditna ekspanzija omogućila je stjecanje vlasništva nad nekretninama i kućanstvima s niskim prihodima, što je poticano i iz političkih razloga, a kako se činilo da cijene nekretnina, koje su kontinuirano rasle u dugom vremenskom periodu, neće nikada pasti, ta nerealna očekivanja, nakon što se 2006. godine nekretninski balon počeo ispuhivati, uzrokovala su slom tržišta drugorazrednih hipoteka te krizu 2008. godine, koja je zahvatila svjetsko gospodarstvo (Mlikotić, 2010).

S razvojem tehnologije u kojem se sekunde dijele i na milijardu dijelova, a računala samostalno donose odluke o trgovanju, složeniji je i pristup tržištu, a svakodnevne implozije i eksplozije tržišta se događaju toliko brzo da ih čovjek ne stigne opaziti pa se i ne pojavljuju u burzovnim izvješćima. Od 2006. do 2011. godine u istraživanju koje su proveli Johnson et al. (2012) zabilježeno je čak 18520 takvih ekstremnih događaja. Jedan od značajnijih takvih mikro-slomova, koji je pokrenuo lavinu i izašao iz mikro okvira je tzv. *flash crash* 6. svibnja 2010. godine. Dow Jones indeks u šest minuta ostvario je najveći jednodnevni pad u cijeloj svojoj 114-godišnjoj povijesti, da bi se za dvadesetak minuta oporavio i vratio na prethodnu razinu, s naglaskom da je slom prekinut tek intervencijom čovjeka, tj. emocionalno-razumnog entiteta (Johnson et al., 2012; Sajter, 2013; Lewis, 2016).

Karakteristika panike na burzi u ožujku 2020. godine, koja je uzrokovala oštar pad vrijednosti dionica te ogromne financijske gubitke smanjenjem tržišne kapitalizacije, je ta da nije nastala uslijed ekonomskih, već izvanjskih faktora, gdje je pojava koronavirusa utjecala na zaustavljanje

ekonomskih aktivnosti i neizvjesnost oko krajnjih posljedica po pitanju ljudskih života. Dodatna posljedica pandemije je porast koncentracije vlasništva na globalnoj razini u rukama velikih institucionalnih ulagača. Također, mnoge tvrtke nisu mogle ispuniti određene zakonske i regulatorne obveze te je došlo do velikog broja izvrštenja, koja nisu nadoknađena novim uvrštenjima na burzu. Poduzeća su tijekom pandemije prolazila kroz dugotrajne pregovore s bankama oko odgoda otplate obveza, a oni koji su se okrenuli nebankarskim kanalima financiranja imali su puno bolju financijsku stabilnost te su lakše prebrodili to razdoblje. Kreatori politike i regulatori moraju osigurati ulagačima pristup dosljednim, usporedivim i pouzdanim materijalnim informacijama (Žigman, 2021).

Posebno je važno osigurati sprječavanje manipulacije i pokušaja manipulacije tržišta i zakonski sankcionirati zlouporabe tržišta. Uredba Komisije EU 2016/522, nastavno na Uredbu (EU) br. 596/2014 Europskog parlamenta i Vijeća od 16. travnja 2014. godine o zlouporabi tržišta, kao propis prve razine, izravno se primjenjuju u Hrvatskoj, dok se kroz Zakon o tržištu kapitala detaljnije uređuje njihova provedba i imenuje HANFA (Hrvatska agencija za nadzor financijskih usluga) kao nadležno tijelo. Zlouporaba tržišta obuhvaća nezakonite postupke na financijskim tržištima, a prema ovoj Uredbi trebalo bi smatrati da se sastoji od: 1) trgovanja na temelju povlaštenih informacija, 2) nezakonitog objavljivanja povlaštenih informacija i 3) manipuliranja tržištem.

Trgovanje na temelju povlaštenih informacija obilježava ostvarivanje nepravedne prednosti i koristi na temelju povlaštenih informacija na štetu trećih osoba koje nisu svjesne tih informacija te narušavanje integriteta financijskih tržišta i povjerenja ulagatelja. Pri tome, istraživanja, analize i procjene temeljene na javno dostupnim podacima ne smatraju se povlaštenim informacijama. Povlaštene informacije smatraju se legitimno objavljenima ako su objavljene u normalnom tijeku obavljanja posla, profesije ili dužnosti osobe. Objavljivanje povlaštenih informacija od strane izdavatelja ključno je za izbjegavanje trgovanja na temelju povlaštenih informacija i osiguravanje da ne dođe do obmanjivanja ulagatelja. U posebnim okolnostima trebalo bi biti dopušteno odgođeno objavljivanje, kada su pregovori još u tijeku, a kada bi objavljivanje moglo utjecati na ishod pregovora (Uredba (EU) br. 596/2014).

Pokazatelji manipulativnog ponašanja obuhvaćaju: 1) aktivnosti povezane s lažnim ili obmanjujućim signalima i držanjem cijena i 2) upotrebu fiktivnih postupaka ili svaki drugi oblik obmane i prijevare.

Prakse kojima se određuje pokazatelj manipulativnog ponašanja mogu biti (Delegirana uredba Komisije EU 2016/522):

- kupnja pozicija od strane osoba koje surađuju u tajnosti, nakon uvrštenja, kako bi se stvorio interes drugih ulagača i cijena postavila na određenu razinu;
- stvaranje donje ili gornje granice strukture cijene transakcijama ili nalozima, tako što cijene padaju ispod ili rastu iznad određene razine;
- unošenje malih naloga za trgovanje, kako bi se utvrdila razina skrivenih naloga i procijenilo stanje – tzv. „sondiranje" (eng. *ping orders*);
- istiskivanje zlouporabom vladajućeg položaja (eng. *abusive squeeze*), kako bi se poremetile cijene po kojima druge osobe moraju realizirati trgovanje;
- izvršenje naloga za trgovanje ili niza naloga za trgovanje, kako bi se otkrili nalozi drugih sudionika – tzv. „lažno predstavljanje" (eng. *phishing*), a potom unošenje naloga za trgovanje kako bi se iskoristile pribavljene informacije;
- manipulacija među mjestima trgovanja, tj. trgovanje na jednom mjestu trgovanja ili izvan mjesta trgovanja, kako bi se nepropisno postavila cijena financijskog instrumenta na drugom mjestu trgovanja ili izvan mjesta trgovanja;
- manipulacija među proizvodima, tj. trgovanje financijskim instrumentom, kako bi se nepropisno postavila cijena povezanog financijskog instrumenta na drugom ili istom mjestu trgovanja ili izvan mjesta trgovanja;
- sklapanje aranžmana za prodaju ili kupnju među osobama koje djeluju usklađeno ili surađuju u tajnosti, kod kojih ne dolazi do prijenosa vlasništva, tj. „fiktivna trgovanja" (eng. *wash trades*), a koja se mogu otkriti ako se neuobičajeno ponavljaju transakcije među malim brojem osoba tijekom određenog razdoblja;
- stvaranje umjetnog dojma o aktivnosti ili kretanju cijene (eng. *painting the tape*) neuobičajenom koncentracijom transakcija i/ili naloga za trgovanje, od strane osobe koja upotrebljava jedan ili različite račune, ili od strane ograničenog broja osoba;

- transakcije izvršene kao posljedica unošenja naloga za kupnju i prodaju u isto vrijeme ili gotovo u isto vrijeme, s vrlo sličnom količinom i sličnom cijenom, koje izvršava ista osoba ili različite osobe koje surađuju u tajnosti, što se obično naziva „nepravilno sklopljeni poslovi" (eng. *improper matched orders*);
- transakcija ili niz transakcija suradnjom u tajnosti, koje su osmišljene u svrhu prikrivanja vlasništva nad financijskim instrumentom;
- zauzimanje duge pozicije u financijskom instrumentu, a potom poduzimanje daljnje aktivnosti kupnje i/ili širenje obmanjujućih pozitivnih informacija u cilju povećanja cijene privlačenjem drugih kupaca, a kada se dosegne umjetno visoka razina, izvršava se prodaja – tzv. „umjetno povećanje cijene i prodaja" (eng. *pump and dump*);
- zauzimanje kratke pozicije u financijskom instrumentu, a nakon prodaje, širenje obmanjujućih negativnih informacija o tom financijskom instrumentu, u cilju smanjenja cijene, privlačenjem drugih prodavatelja, a kada cijena padne, pozicija se unovčava prodajom – tzv. „obezvrjeđenje i unovčenje" (eng. *trash and cash*);
- unošenje velikog broja naloga za trgovanje i/ili otkazivanje i/ili ažuriranje naloga za trgovanje, radi stvaranja nesigurnosti za druge sudionike, usporavanja njihovih postupaka, a prikrivanja vlastite strategije – tzv. „bombardiranje kotacijama" (eng. *quote stuffing*);
- unošenje naloga za trgovanje ili niza naloga za trgovanje, ili izvršenje transakcija ili niza transakcija, kojima će se vjerojatno pokrenuti ili pojačati trend i potaknuti druge sudionike da ubrzaju ili prošire taj trend – tzv. „zapaljenje" (eng. *momentum ignition*);
- kupovanje ili prodavanje financijskog instrumenta u referentno vrijeme dana trgovanja (početak, zaključenje, namira), kako bi se referentna cijena (početna cijena, zaključna cijena, cijena namire) povećala, smanjila ili održala na određenoj razini, što se obično naziva „utjecanje na zaključnu cijenu" (eng. *marking the close*);
- podnošenje višestrukih ili velikih naloga za trgovanje na jednoj strani knjige naloga, radi izvršavanja trgovanja na drugoj strani knjige naloga, za koje ne postoji nikakva namjera da budu izvršeni („davanje naloga bez namjere da ih se izvrši"), već služe da bi se stvorio privid ponude ili potražnje, a nakon izvršenja trgovanja na drugoj strani, brišu se i uklanjaju, što se obično naziva „uslojavanje i zavaravanje" (eng. *layering and spoofing*);

- unošenje naloga koji se povlače prije izvršenja, što ima ili bi moglo imati učinak davanja obmanjujućeg dojma da postoji potražnja – tzv. „povećanje potražnje” (eng. *advancing the bid*);
- davanje naloga za trgovanje kako bi se privukli „spori trgovci”, a potom brzo mijenjanje tih naloga na manje povoljne uvjete, u nadi da će se ostvariti dobit od priljeva naloga za trgovanje, što se obično naziva „zadimljavanje” (engl. *smoking*);
- širenje lažnih ili obmanjujućih informacija putem medija, uključujući i internet, ili nekim drugim načinom, koje rezultira ili bi moglo rezultirati kretanjem cijene financijskog instrumenta u smjeru koji je povoljan za osobu (ili više osoba) zainteresiranih za širenje informacija;
- otvaranje pozicije i neposredno zatvaranje nakon njezina objavljivanja javnosti i isticanja dugog razdoblja držanja ulaganja;
- izrada ili proširivanje istraživanja ili preporuke za ulaganje od povezanih osoba, a koji su suprotni od javno dostupnih istraživanja i preporuka.

Zakonom se propisuje zabrana trgovanja na temelju povlaštenih informacija i nezakonitog objavljivanja povlaštenih informacija i zabrana manipuliranja i pokušaja manipuliranja tržištem.

3. BIHEVIORALNE FINANCIJE

3.1 Razvoj bihevioralnih financija

Bihevioralne financije su relativno mlada teorija, a čiji formalni početci sežu u 1980-e godine (Barberis i Thaler, 2005), koja u početku nije privukla značajniju pažnju javnosti. Međutim, tijekom 1990-ih, bihevioralna ekonomija, kao i bihevioralne financije, sa sve većim brojem znanstvenih radova i eksperimenata, uvođenjem psihologije i drugih društvenih znanosti u ekonomiju, dobivaju na značaju te se počinju smatrati revolucionarnim pravcem, posebno u odnosu prema, do tada prevladavajućoj, teoriji efikasnog tržišta (Shiller, 2015). Posebno jak učinak na ekonomske odjele i poslovne škole imala su istraživanja koje su provodili Daniel Kahneman i Amos Tversky, a kojima su oborili stajališta ekonomista o tome da se investitori ponašaju racionalno. Ipak je trebalo više od dvadeset godina da se to stajalište šire prihvati u akademskim krugovima te je tek nakon smrti Tverskya 1996. godine ta teorija postizala veću vjerodostojnost, a 2002. godine dodijeljena je Nobelova nagrada za ekonomske znanosti Danielu Kahnemanu za njihov zajednički doprinos prospektnoj teoriji (Malkiel, 2005). Kahneman i Tversky su svoju prospektnu teoriju, tj. teoriju očekivanja (eng. *prospect theory*), zamislili kao alternativu teoriji očekivane korisnosti (eng. *expected utility theory*) Johna von Neumanna, jednog od najvećih matematičara dvadesetog stoljeća, koja je kreirana polazeći od aksioma o racionalnim izborima, prema kojima netko tko preferira A u odnosu na B te preferira B u odnosu na C, tada mora preferirati A u odnosu na C. Njihov cilj nije bio ponuditi upute za donošenje racionalnih odluka, nego ponuditi točna predviđanja kakve će odluke ljudi u stvarnosti donijeti. Rezultati istraživanja doveli su u nezgodnu situaciju pristalice racionalnog pristupa, u kojem su ispitanici preferirali A u odnosu na B, ali u alternativnoj verziji, preferirali su D u odnosu na C, iako je A=C, a B=D, tj. naočigled su se neracionalno ponašali (Thaler, 2020).

Iako se činilo da se radi o logičnom nastavku na tradicionalne teorije, ekonomisti nisu prihvatili mogućnost neracionalnog ponašanja. Herbert Simon bio je preteča Kahnemana i Tverskya, koji je tvrdio da ljudi imaju ograničene racionalnosti (eng. *bounded rationality*), zbog čega su kognitivne sposobnosti donositelja odluke često nedovoljne pri pronalasku optimalnih rješenja stvarnih problema. Međutim, nije definirao na koji način se razlikuju ograničeno racionalni ljudi od potpuno racionalnih ljudi te su mnogi ekonomisti to ignorirali kao nebitnu ideju (Zelić i Lukavac, 2018; Thaler, 2020). Teorija efikasnog tržišta (eng. *Efficient Market Hypothesis,* EMH), čiji je

najznačajniji predstavnik Eugene Fama, kao i teorija modernog portfelja (eng. *Modern Portfolio Theory*, MTP), koju je utemeljio Harry Markowitz, dvije su najznačajnije teorije koje pretpostavljaju racionalnog investitora, koji donosi razumne procjene vrijednosti dionica, s ciljem maksimiziranja svoga bogatstva, a ograničava ih samo visina rizika kojeg su spremni snositi (Malkiel, 2005). Hipoteza efikasnog tržišta je prezentirana tek kasnih 1970-ih. Naime, financije su u poslovnim školama bile znanstveno zapušteno područje, za koje nije bilo dostupno mnogo teorijske podloge niti empirijskih istraživanja. Prekretnica nastaje s teoretičarima moderne financijske ekonomije, poput Harryja Markowitza, Mertona Millera i Williama Sharpea, zatim Eugenea Fame, Michaela Jensena, Richarda Rolla te Myrona Scholesa, a modeli koji su se temeljili na racionalnim očekivanjima predstavljali su revolucionarnu novost, dok je popularnost Keynesovih tekstova, koji su promicali razmišljanja o iracionalnom ponašanju na financijskom tržištu, opala (Thaler, 2020). Iako se pojam *efikasno tržište* spominje već 1889. godine u knjizi Georgea Gibsona (*The Stock Markets of London, Paris and New York*), prema kojem dionice postaju javno poznate na otvorenom tržištu, a njihova vrijednost koju steknu može se smatrati prosudbom najboljih inteligencija, taj pojam je postao rasprostranjeno poznat tek u radovima profesora Sveučilišta u Chicagu, Eugenea Fame (Shiller, 2015), te je i do danas predmet debate između ekonomista koji zagovaraju pristup o racionalnom investitoru i bihevioralnog pristupa (Thaler, 2020). Unatoč različitim pogledima na utjecaj ponašanja investitora na tržištu, Eugene Fama je zajedno s Robertom Shillerom dijelio Nobelovu nagradu za ekonomske znanosti 2013. godine, za njihovu empirijsku analizu cijena imovine (Shiller, 2015), ali otpor prihvaćanju bihevioralnih zapažanja se nastavio (Thaler, 2020). Bihevioralna teorija argumentirala je često i sustavno zastranjivanje od racionalnosti. Čak je i Markowitz, inače dobitnik Nobelove nagrade za ekonomiju 1990. godine i tvorac matematičkog modela optimalnog portfelja, svojom izjavom o vlastitom iskustvu investiranja: „umjesto da je izračunao kovarijancu i nacrtao efikasnu granicu, on je vizualizirao svoju tugu, u slučaju kada je tržište raslo, ako je bio izvan njega, ili kada je tržište padalo, ako je bio unutra", zapravo potvrdio da je ulagački mozak daleko od logičnog, dosljednog i učinkovitog uređaja, kada se čak i Nobelovci ne ponašaju kako im njihove ekonomske teorije nalažu (Zweig, 2007). Također, čak je i Fama, zajedno sa suradnikom Kennethom Frenchom, potaknut nalazima bihevioralnih ekonomista, nakon serije radova, službeno proglasio Sharpeov model vrednovanja kapitalne imovine (eng. *Capital Asset Pricing Model*, CAPM) netočnim, ali teorije efikasnog tržišta se nije odrekao (Thaler, 2020). Teorija efikasnog tržišta postaje sastavni

dio sveučilišnih odjela za ekonomiju i financije, sa stasanjem nove generacije ekonomista, a linijom razmišljanja seže do Adama Smitha, promičući dobrobiti slobodnog tržišta, ne samo u kapitalističkim društvima Sjedinjenih Država i Velike Britanije, već i diljem svijeta, čak i u zemljama sa socijalističkim tradicijama, poput Kine, Indije i Rusije (Akerlof i Shiller, 2009).

Ključna riječ klasične ekonomije, *nevidljiva ruka* Adama Smitha, postala je moćno načelo koje je definiralo kapitalizam slobodnog tržišta kao savršen i stabilan sustav, jer su tržišne sile temeljni okvir alokacije resursa. Ipak, ekonomske krize dovode u pitanje neregulirana slobodna tržišta te se javlja potreba za uplitanjem vlada, odnosno zagovaraju se pravci koji su prepoznati kod Keynesa. On smatra da gospodarstvom ne upravljaju samo racionalni akteri, koji će se „kao nevidljivom rukom" uključiti u svaku transakciju koja im je na obostranu ekonomsku korist, već ljude pokreću i neekonomski motivi (*animal spirit*, koji mnogi doslovno prevode kao životinjski poriv, dok Šonje (2014) to interpretira kao *pokretački duh*), koji dovode do nestabilnosti kapitalizma. Keynes je bihevioralne elemente, kao što su oponašanje i strateško predviđanje ukusa većine, kao u natjecanju ljepote, već tada zapažao i tumačio snalaženjem u danim okolnostima, a koje ne znači iracionalno ponašanje (Akerlof i Shiller, 2009; Šonje 2014; Zelić i Lukavac, 2018). Adam Smith, koji se smatra ocem modernog ekonomskog razmišljanja, prije nego je napisao svoje kapitalno djelo *Bogatstvo naroda* (1776) (eng. *The Wealth of Nations*), napisao je knjigu *Teorija moralnih osjećaja* (1759) (eng. *The Theory of Moral Sentiments*). U njoj govori kako su moralnost i osjećaji dio ljudskog ponašanja koje ekonomisti ne bi smjeli zanemariti i naglašava činjenicu o ljudskoj strasti koja uzrokuje problem samokontrole u odlukama koje se tiču odgode vremena konzumiranja užitka (Ariely 2009; Thaler 2020). Ipak, pojam strasti se ne pojavljuje ni u kojim ekonomskim udžbenicima, a model ekonomskog ponašanja, koji se temelji na racionalnom *ekonu*, postao je općeprihvaćen, zbog čega su i brojni kritičari bihevioralnih teorija marginalizirali njihov doprinos razumijevanju poremećaja na tržištu koji, između ostalog, nastaju i zbog iracionalnog ponašanja običnih, *normalnih* ljudi (Thaler, 2020). Bihevioralna ekonomija ne odbacuje teorije koje se temelje na pretpostavci da se ljudi ponašaju kao *ekoni*, već se na njih nadograđuje te poboljšava razumijevanje psihologije koja dovodi do poremećaja, kako bi se moglo unaprijediti i poboljšati funkcioniranje tržišta (Shiller 2015; Thaler 2020). Američki ekonomist prošlog stoljeća, John Maurice Clark, također je naglašavao potrebu preuzimanja koncepcije čovjeka kakvu daju psiholozi te da ekonomist može pokušati zanemariti psihologiju, ali je nemoguće ignorirati ljudsku prirodu. Međutim, ekonomisti su se uspjeli udaljiti od prihvaćanja psihologije, a radije su

fascinirani matematičkim modelima. Bihevioralna ekonomija, za razliku od tradicionalne ekonomije, govori o ljudskoj iracionalnosti, no spoznaja o tome da je ljudska sposobnost promišljanja nesavršena, ali predvidljivo iracionalna, može predstavljati ishodišnu točku za šire proučavanje ekonomije i popravljanje načina donošenja odluka (Ariely, 2009). Dok prva generacija bihevioralnih ekonomista ljude obično opisuje kao iracionalne, koji podliježu kognitivnim i emocionalnim pogreškama do ostvarenja svojih racionalnih želja, druga generacija bihevioralnih ekonomista opisuje ljude kao normalne s normalnim željama, čiji su kognitivni i emocionalni prečaci i pogreške temelj odgovora na važna financijska pitanja, uključujući i učinkovitost tržišta (Statman, 2017).

U teoriji efikasnog tržišta, iracionalno ponašanje se tumači kao sporadično i slučajno, a koje će biti poništeno i ispravljeno djelovanjem tržišta racionalnih investitora kao cjeline, koji donose razumne procjene vrijednosti na temelju svih dostupnih informacija. Dakle, uvijek postoje vremena kada su investitori iracionalni, ali bihevioralne financije smatraju da je to ponašanje stalno, a ne samo epizodno. Prema mišljenju ekonomista koji vjeruju u efikasnost, tržišta mogu biti efikasna i kada cijene iskazuju kolebljivost, pa čak i kada su mnogi sudionici na tržištu iracionalni, jer u najvećem dijelu brzo i točno odražavaju nove informacije, a investitorima ne dopuštaju natprosječne zarade bez prihvaćanja natprosječnih rizika (Malkiel, 2005).

U svom korijenu, teorija efikasnih tržišta smatra da različite sposobnosti investitora ne proizvode različite performanse ulaganja, pa najpametniji ljudi neće biti bolji od najmanje inteligentnih ljudi u smislu ulaganja. Oni ne mogu biti bolji, jer je njihovo vrhunsko razumijevanje već potpuno ugrađeno u cijene dionica, što bi vodilo zaključku da, ako nije prednost *biti pametan*, onda nije ni nedostatak *ne biti pametan* (Shiller, 2015).

Inteligentno upravljanje investicijama, na način kako su Graham i Dodd poučavali, odnosno kupovanje vrijednosnih papira kojima je cijena privremeno ispod intrinzične vrijednosti i prodaja onih kojima je cijena privremeno visoka (Graham, Zweig i Buffet, 2003), je prilično respektabilna logika. Stoga se mnogobrojni tržišni profesionalci bave fundamentalnom analizom koja bi trebala, pomnim proučavanjem sadašnjih uvjeta i budućih mogućnosti, utvrditi intrinzičnu vrijednost. Nasuprot takve analize, druga skupina analitičara svoje strategije temelji na tehničkoj analizi, koja, proučavajući kretanje cijena dionica, pretpostavlja da ponašanje dionica u prošlosti može pomoći u predviđanju njihovih budućih ponašanja. Stajalište analitičara koji koriste tehničku analizu je da

je tržište 10 posto logično, a 90 posto psihološko, dok je obrnuto stajalište analitičara koji koriste fundamentalnu analizu, odnosno da je tržište 90 posto logično, a samo 10 posto psihološko (Malkiel, 2005). Andre Kostolany, u svojoj knjizi *Psihologija burze*, govoreći o svom 70-godišnjem iskustvu na europskim burzama tijekom 20. stoljeća, tvrdi da uloga psihologije u događajima na burzi kratkoročno i srednjoročno čini 90 posto onoga što se na burzi zbiva. Kostolany, koji sebe naziva špekulantom te mu je predviđanje reakcije mase eminentno pitanje, zaključuje o riječima Georgea Katona, profesora ekonomskih znanosti koji je specijalizirao psihologiju gospodarstva, da su psihološke reakcije burzovne publike mjerljive i procjenljive, odnosno, da se doista katkada žestina psihološke reakcije ili približno vrijeme može, ne predvidjeti, nego naslutiti ili pogoditi. Međutim, dugoročno, psihologija nije više tako bitna, već ulogu imaju fundamentalni razlozi (Kostolany, 2008). Analitičare tržišta koji koriste tehničku analizu, nastojeći predvidjeti kako će se grupa investitora ponašati i preduhitriti ih, zapravo se promatra kroz teoriju gradnje „kula u zraku“, za razliku od teorije čvrstih temelja, koja koristi fundamentalnu analizu, nastojeći utvrditi stvarnu vrijednost vrijednosnog papira. Međutim, akademska zajednica izrazila je mišljenje da ni fundamentalna analiza nije ništa bolja od tehničke analize u omogućavanju ostvarivanja natprosječnih povrata, a na kojim argumentima se nastavila učvršćivati teorija efikasnog tržišta (Malkiel, 2005).

Cijene dionica, prema teoriji efikasnog tržišta, približno opisuju slučajan hod (eng. *random walk*) kroz vrijeme, odnosno, promjene cijena su nepredvidljive, budući da se javljaju samo kao odgovor na nove informacije, a samom činjenicom da su informacije nove, time su i nepredvidljive. Argumenti za teoriju efikasnog tržišta dolaze iz zapažanja da je teško zaraditi mnogo novca kupujući jeftino, a prodajući visoko na burzi, i mnogi sposobni ljudi to pokušavaju, ali ne uspijevaju s dosljednim stupnjem uspjeha. Naime, ako netko misli da je imovina podcijenjena ili precijenjena, mora razmisliti zašto ostaje takva unatoč naporima pametnog novca da ostvari isplativ posao (Shiller, 2015). S druge strane, neki smatraju da je tržište toliko efikasno da se cijene pomiču toliko brzo kad se pojavi nova informacija, da nitko ne može dovoljno brzo ostvariti pogodnost od kupnje ili prodaje temeljem te nove informacije. Te novosti razvijaju se slučajno, odnosno nepredvidljivo i ne može se predvidjeti ni iz tehničkih ni iz fundamentalnih informacija. Čak je i Graham, nedugo prije smrti, nevoljko došao do zaključka da se više ne mogu očekivati bolji povrati investicija temeljem opsežnih fundamentalnih analiza u svrhu pronalaženja boljih prilika za ulaganje (Malkiel, 2005).

Bihevioralna ekonomija je prvi put javno saslušana u listopadu 1985. godine na poslovnoj školi Sveučilišta Chicago, gdje su u bihevioralnom timu prisustvovali Herbert Simon, Amos Tversky, Daniel Kahneman, Kenneth Arrow, Robert Shiller, Richard Zeckhauser i Richard Thaler, a Robert Lucas, Merton Miller, Eugene Fama i Sherwin Rosen, profesori Sveučilišta Chicago, koji su imali ulogu moderatora, zauzimali su stranu racionalista. Zaključci debate da se paradigme mijenjaju samo kad su stručnjaci uvjereni da postoji veliki broj anomalija koje se ne mogu objasniti trenutnom paradigmom, a da u ovom slučaju nema razloga za revoluciju i obaranje konvencionalnih uvjerenja, branili su *status quo* (Thaler, 2020). Shefrin i Statman (1984) u svom radu ponudili su bihevioralno objašnjenje nefunkcioniranja Miller-Modiglianijevog teorema, odnosno nelogičan izbor preferiranja isplate dividende, unatoč oporezivanju u odnosu na otkup vlastitih dionica, pa iako to nije bilo po volji Milleru, nije našao odgovor koji bi bio drugačiji od bihevioralnog (Thaler, 2020). Miller je, uz Famu, najgorljivije branio teoriju efikasnog tržišta, pa iako su prepoznali anomalije koje su zagovornici bihevioralne ekonomije otkrili, tvrdili su da su te anomalije beznačajne i da su burze učinkovite u širokom smislu. Mnoge druge anomalije, poput učinka siječnja (tendencija rasta cijena dionica između prosinca i siječnja), učinka malih poduzeća (mala poduzeća imaju tendenciju većeg povrata), učinka dana u tjednu (tržište dionica ima tendenciju lošije raditi ponedjeljkom) i drugi učinci, smanjile su se nakon što su otkrivene, ali činjenica da su te anomalije trajale duže vrijeme ne potvrđuje efikasnost tržišta. Kada dođe do napuhavanja cijena na tržištu, ljudi i dalje vjeruju da će cijene nastaviti rasti, čak i ako su smatrali da su cijene previsoke, pa počinju dovoditi u pitanje svoje ranije presude o tome. S druge strane, kada cijene stagniraju duže vrijeme, raste nezadovoljstvo koje može dovesti do opadanja tržišta, čak i kad se fundamenti poduzeća povećavaju. Očekivanje vraćanja trenda s pada na rast ne mora uslijediti, odnosno cijena može pasti i ostati nisko tijekom dužeg vremenskog razdoblja. Područje psihologije nudi mnoga načela ljudskog ponašanja za koja se pokazalo da su relevantna za vrednovanje teorije efikasnog tržišta. Ključna je kejnezijanska ideja da je vrednovanje dugotrajne imovine u velikoj mjeri stvar dogovora, kao što je to slučaj s procjenom ljepote lica. Koju god cijenu ljudi prihvatili kao konvencionalnu vrijednost, ona dugo ostaje utkana u kolektivnu svijest kao prava vrijednost, čak i ako stvarni prinosi neko vrijeme ne uspijevaju opravdati očekivanja (Shiller, 2015).

Osim ciljeva da empirijski pronađu i dokumentiraju anomalije, bihevioralni ekonomisti imali su cilj i razvoj teorijskog dijela, pa su se mnogi talentirani bihevioralni ekonomisti priključivali

području, a u oba pravca postignut je veliki napredak. Ukoliko bi se razvili formalni matematički modeli koji će uključivati nalaze koji se tiču psihologije, tada bi se ovo područje ozbiljno doživjelo, koje bi i možebitno zaštitilo ljude od donošenja neispravnih odluka (Thaler, 2020).

3.2 Bihevioralni faktori na financijskom tržištu

Bihevioralni faktori koji se najčešće promatraju u istraživanjima na financijskom tržištu su: heuristike, prospektna teorija i ponašanje krda, a ponekad se analiziraju i tržišni faktori, koji mogu uvelike utjecati na odluke investitora (De Bondt i Thaler, 1985; Phuoc Luong i Thi Thu Ha, 2011). Osim toga, na investicijske odluke utječu i emocije i raspoloženja, kao i faktori osobnosti (Jurevičiene i Ivanova, 2013; Charles i Kasilingam, 2014a), a unutar bihevioralnih faktora također postoji i nekoliko komponenti koje se mogu i zasebno analizirati.

3.2.1 Heuristike i predrasude

U situacijama kada ljudi moraju donijeti odluke ili izraziti mišljenje o složenim stvarima o kojima se zadovoljavajući odgovor ne može brzo pronaći, primijenit će jednostavnu proceduru koja pomaže u pronalaženju primjerenog, iako nesavršenog odgovora (Kahneman, 2013), a koju su Tversky i Kahneman nazvali heuristički pristup predrasudama, prema riječi koja ima isti korijen kao *eureka* (grč. *heúrēka*), što znači pronaći, otkriti (Evitiani, 2014). Heuristika (eng. *heuristics*), kao alternativa pozornom promišljanju, ponekad funkcionira dobro, ali ponekad dovodi i do ozbiljnih pogrešaka (Kahneman, 2013). Heurističke metode uključuju provizorno pravilo, tzv. *pravilo palca* (eng. *rule of thumb*), upućeno nagađanje, intuitivni sud ili zdrav razum (Evitiani, 2014). Najpoznatije heuristike i predrasude kojima se ljudi služe za rješavanje problema su: reprezentativnost, dostupnost, sidrenje, pretjerana samouvjerenost i igračeva zabluda (Kahneman i Tversky, 1974; Wang, Shi i Fan, 2006; Waweru, Munyoki i Uliana, 2008; Phuoc Luong i Thi Thu Ha, 2011; Allameh et al., 2015; Khan et al., 2017).

Reprezentativnost (eng. *representativeness*) predstavlja pristranost pri prosudbama, koja se sastoji od sklonosti ljudi da koriste sličnost ili reprezentativnost kao predstavnika ispravnog vjerojatnog razmišljanja (Malkiel, 2005). Ponekad procjenjivanje putem reprezentativnosti može imati važne prednosti, jer postoji određena istinitost u stereotipima i intuitivni dojmovi su često puno točniji od pukog nagađanja. Međutim, problem korištenja heuristike reprezentativnosti je pretjerana spremnost za predviđanje pojavljivanja nevjerojatnih događaja, kao i neosjetljivost na

kvalitetu dokaza, unošenjem nevažne informacije (Kahneman, 2013). Problem heuristike reprezentativnosti jest u tome što se za prosudbe neizvjesne situacije traže poznati obrasci, pretpostavljajući da će u budućnosti uzorci nalikovati prošlim, često bez dovoljnog razmatranja razloga za obrazac ili vjerojatnost ponavljanja uzorka (Shiller, 2015; Raut, Das i Mishra, 2020). Na financijskom tržištu ovo se posebno odnosi na analitičare koji se u tehničkoj analizi tržišta oslanjaju na grafikone kretanja cijena iz prošlosti, smatrajući da posjeduju kontrolu nad situacijama u kojima ona uopće ne postoji (Malkiel, 2005).

Dostupnost (eng. *availability*) predstavlja proces procjenjivanja učestalosti prema lakoći kojom određeni slučajevi dolaze u um. Iako može biti korisna, ipak ova heuristika može uzrokovati pogreške, prvenstveno zbog lakoće kojom se neke situacije mogu prizvati u sjećanje (Kahneman, 2013). Učinak prisutnosti u nekim događajima učinit će dostupnijim informaciju o tome, nego samo temeljem čitanja u novinama. Također, nedavni događaji su relativno dostupniji od starijih. Učestaliji događaji su dostupniji od manje čestih događaja. Predrasude zamislivosti u situacijama u stvarnom životu dovest će do procjenjivanja veće dostupnosti od situacija koje je teško zamisliti (Kahneman i Tversky, 2014). Očekivanja o učestalosti događaja su iskrivljena i emocionalnim intenzitetom događaja kojem su ljudi izloženi, a uzevši u obzir da mediji oblikuju interes javnosti, a i da su sami oblikovani tim interesom, određene teme ili neobični događaji snažnije će se izražavati i češće prikazivati, što može razviti heuristiku afekta u kojoj ljudi donose odluke i prosudbe temeljem svojih osjećaja (Kahneman, 2013; Shiller, 2015). Medije prirodno privlače financijska tržišta koja su uvijek potencijalno zanimljiva vijest, u najmanju ruku pružaju stalne vijesti u obliku dnevnih promjena cijena. Također, financijske vijesti pobuđuju interes javnosti, s obzirom da javnost percipira burzu kao „veliku kockarnicu" (eng. *Big Casino*), namijenjenu za velike igrače, ali i kao barometar statusa nacije. Problem u prekomjernoj količini vijesti, kao i poplavi broja pokazatelja, nastaje kada je ljudima teško prepoznati ili individualno procijeniti kada se nešto veliko zaista događa, pa imaju sklonost dohvaćati podatke kako ih tumače poznati izvori (Shiller, 2015).

Sidrenje (eng. *anchoring*) je pojava koja se događa kada ljudi pretpostave određenu vrijednost neke nepoznate veličine prije nego što procijene tu veličinu. Posebno je iznenađenje snažnost učinka sidra u psihološkim istraživanjima. Naime, putem psihološke pripreme i poticaja, misli i ponašanje postaju pod utjecajem iz okoline, i to znatno više nego što su ljudi tog postavljenog sidra

svjesni (Kahneman, 2013). Inicijalna vrijednost ili početna točka može sugerirati rješenje problema ili biti rezultat djelomičnog izračunavanja, pa različite početne točke dovode do različitih procjena (Kahneman i Tversky, 2014). Psihološka istraživanja dokazuju da postoje obrasci ljudskog ponašanja, koji sugeriraju sidrenje na tržištu, a koji se ne bi očekivali u slučaju da tržišta rade potpuno racionalno. Ovi obrasci ljudskog ponašanja nisu posljedica ekstremnog ljudskog neznanja, već karaktera ljudske inteligencije. Prepoznate su dvije vrste psiholoških sidara: kvantitativna i moralna sidra. S kvantitativnim sidrima ljudi odmjeravaju brojeve, odnosno razinu cijena, kao i pokazatelje precijenjenog ili podcijenjenog tržišta. Kvantitativna sidra objašnjavaju zašto dionice poduzeća različitih industrija sa sjedištem u istoj zemlji obično imaju više slična kretanja od dionica poduzeća iz iste industrije, ali sa sjedištem u različitim zemljama, premda bi bilo očekivano da industrija bolje određuje osnove poduzeća nego mjesto sjedišta. S moralnim sidrima ljudi uspoređuju intuitivnu ili emocionalnu snagu argumenata za ulaganje, pa je najčešći primjer ovakvog ponašanja ulaganje u dionice poduzeća s kojim su na neki način povezani (imaju priču koja stoji iza te odluke, a koja nema kvantitativnu dimenziju), bilo da su zaposleni u tom poduzeću ili da su bliski s proizvodima koje to poduzeće proizvodi (Shiller, 2015).

Jedno od najraširenijih odstupanja od racionalnosti prilikom donošenja prosudbi je tendencija **pretjerane samouvjerenosti** (eng. *overconfidence*) u vlastita uvjerenja i sposobnosti te intuitivni sud i preveliki optimizam vezan uz procjenu budućnosti (Malkiel, 2005; Kahneman, 2013; Shiller, 2015). Pretjerana samouvjerenost u prosudbe na financijskom tržištu može ponekad utjecati na ljude da vjeruju da znaju kada će se dogoditi tržišni pomak, čak i ako općenito vjeruju da se cijene dionica ne mogu predvidjeti (Shiller, 2015). Ova predrasuda objašnjava i svakodnevni visoki broj trgovanja na tržištu vrijednosnica. Naime, u svijetu *ekona*, odnosno u racionalnom svijetu, podrazumijevalo bi se da niti jedan racionalni agent ne bi htio kupiti dionicu koju drugi racionalni agent želi prodati, osim ako se ne pretpostavi da su neki od njih bili pretjerano samouvjereni pa se velik broj trgovanja javljao kao prirodna posljedica (Thaler, 2020). Većina kupaca i prodavača zna da imaju iste informacije, ali zagonetka je zašto vjeruju da bolje od tržišta znaju kakva cijena dotične dionice treba biti, odnosno i jedni i drugi misle da je trenutačna cijena pogrešna. Iz toga proizlazi zaključak da ih ne kupuju i prodaju na temelju informacije, već na temelju drugačijeg mišljenja o njima. Subjektivna pouzdanost mišljenja nije dovoljna za procjenu ispravnosti tog mišljenja. Kognitivni prividi valjanosti i vještine mogu biti uporniji od vizualnih, posebno u profesionalnoj kulturi financijske zajednice, u kojoj veliki broj pojedinaca u svijetu smatra sebe

nekolicinom odabranih koji mogu učiniti nešto za što misle da nitko drugi ne može (Kahneman, 2013). Da su ljudi u potpunosti racionalni, onda bi, okvirno govoreći, polovica ulagača za sebe trebala misliti da je ispod prosjeka svojih trgovačkih sposobnosti u odnosu na drugu polovicu, te ne bi trgovali s onima koji bi dominirali u trgovanju. Stoga, iznadprosječna polovica ne bi imala s kime trgovati te ne bi bilo trgovine iz špekulativnih razloga. Pretjerana samouvjerenost u vlastite prosudbe, dakle, igra veliku ulogu u špekulativnim mjehurićima (Shiller, 2015).

U eksperimentima na polju pretjerane samouvjerenosti, kada su ljudi rekli da su sigurni da su u pravu, zapravo su bili u pravu samo oko 80% vremena, a na polju intuitivnog suda, ljudi su donosili ozbiljne odluke samo temeljem mišljenja, dok bi kasnije nakon preispitivanja utvrdili da su odluke bile nelogične (Shiller, 2015). Model intuitivnog donošenja odluka prezentirao je Herbert Simon, koji intuiciju definira kao prepoznavanje informacija pohranjenih u pamćenju, kako je citirano u Kahnemanu (2013): ”Situacija daje nagovještaj: taj nagovještaj daje stručnjaku pristup informacijama koje su pohranjene u njegovu pamćenju, a te informacije pružaju mu odgovor”. Samouvjerenost ljudi na temelju vjerovanja u svoju intuiciju nije pouzdan vodič u procjeni njene valjanosti. U nepredvidljivoj situaciji, u nedostatku valjanih nagovještaja, intuitivni pogodci su samo puka sreća (Kahneman, 2013). Pristranosti u pogledu pretjerivanja, kada je riječ o vještinama, manifestiraju se tako da su mnogi investitori uvjereni da mogu pobijediti tržište, a rezultat toga je da previše trguju, odnosno više špekuliraju nego što bi trebali. U tom smislu je i istraživanje bihevioralnih ekonomista Barbera i Odeana (2001) pokazalo da, što su više individualni investitori trgovali, to su im bili lošiji rezultati, pri tome su muškarci trgovali više od žena, uz odgovarajuće lošije rezultate (Malkiel, 2005; Raut, Das i Mishra, 2020). Prenaglašavanje sposobnosti predviđanja budućnosti stvara pretjeranu optimističnu samouvjerenost. Optimizam je normalna pojava i obilježje je karaktera, optimisti su veseli i sretni pa zbog toga i popularni, što im dodatno ojačava samopouzdanje zbog divljenja drugih. Iz tog razloga, optimistični ljudi poduzimaju više rizika nego što su ga svjesni, podcjenjujući opasnosti i ne ulažući dovoljno truda u dobivanje informacija koje bi pokazale kakve su šanse za uspjeh (Kahneman, 2013; Raut, Das i Mishra, 2020). Iluzija financijske vještine može proizlaziti iz pristranosti gledanja unatrag, odnosno selektivnog sjećanja vezanog za uspjeh. Gledanjem unatrag lakše se uvjeriti i u efekt „znao sam”, nakon što su se događaji već odigrali, pa se promiče preveliko samopouzdanje da je svijet mnogo predvidljiviji nego što jest (Malkiel, 2005). Ekonomisti Ulrike Malmendier i Geoffrey Tate su zamijetili da tržište dionica zna prepoznati prekomjerno samopouzdane direktore koji ulaze u

velike rizike, ne zato što oni upravljanju tuđim novcem, već zato što je prestiž koji mediji daju direktorima, kada ih uzdiže kao heroje, vrlo skup za dioničare poduzeća kojeg vode (Kahneman, 2013).

Premda statistički obrazovani ljudi izbjegavaju elementarne greške, poput **igračeve zablude** (eng. *Gambler's fallacy*), njihovi su intuitivni sudovi ipak podložni sličnim greškama u složenijim i manje jasnim problemima (Kahneman i Tversky, 2014). Manjak razumijevanja vjerojatnosti može dovesti do neispravnih pretpostavki i predviđanja početaka događaja. Ovu predrasudu obilježava pogrešno vjerovanje u vjerojatnost nastanka određenog niza slučajnih događaja, pa nerazumijevanje slučajnosti dovodi do kajanja. Prošli događaj ne mijenja vjerojatnost nastanka istog događaja u budućnosti (Brajković i Radman Peša, 2015). Pri procjeni vjerojatnosti, ljudi također često zanemaruju veličinu uzorka, a pretjerana vjera u male uzorke (tzv. zakon malih brojeva) je primjer općenitijeg pristupa i brzanja sa zaključcima. Pridavanje uzročnosti slučajnim događajima dovodi do ozbiljnih pogrešaka u procjeni vjerojatnosti nastanka budućeg događaja (Kahneman, 2013).

3.2.2 Prospektna teorija

Za prospektnu teoriju (eng. *prospect theory*) ili teoriju očekivanja, koja opisuje individualno ponašanje u situacijama kada postoje izgledi dobitaka i gubitaka, zaslužni su Amos Tversky i Daniel Kahneman, a prema početnoj ideji ekonomista Harryja Markowitza, prema kojoj je korisnost bogatstva više povezana uz promjene u bogatstvu, nego uz stanje bogatstva. Markowitzeva ideja nije bila primijećena više od četvrt stoljeća, dok Tversky i Kahneman nisu uočili zrcalni odraz objašnjenja kako odbojnost prema riziku prelazi u sklonost preuzimanja rizika kada su izgledi gubitka sigurni (Malkiel, 2005; Kahneman, 2013; Thaler, 2020). Inicijalno se ova teorija temeljila na razmišljanjima Daniela Bernoullija iz 1738. godine, koji je izmislio ideju **odbojnosti prema riziku** (eng. *risk aversion*), tako da je definirao da se razina zadovoljstva ili korisnosti povećava s porastom bogatstva, ali po opadajućoj stopi (Thaler, 2020). Tversky i Kahneman su zaključili da se gubitci smatraju mnogo manje poželjnima nego što su jednakovrijedni dobitci poželjni (Malkiel, 2005). Promatranjem suprotstavljenih stavova prema rizicima u slučaju povoljnog i nepovoljnog izgleda uočena je nedosljednost, odnosno odbojnost prema riziku kada je zajamčen povoljan ishod, a spremnost na preuzimanje rizika ako je nepovoljan ishod siguran (Kahneman, 2013). Kreirajući teoriju donošenja odluka u uvjetima rizika, nazvanu

teorija očekivane koristi (eng. *expected utility theory*), matematičar John von Neumann i ekonomist Oskar Morgenstern krenuli su od aksioma o racionalnim izborima. Nasuprot tome, prospektna teorija trebala je ponuditi točna predviđanja kakve će se odluke u stvarnosti donijeti. U prospektnoj teoriji promijenjen je i fokus s apsolutne razine bogatstva, iz Bernoullijevog modela, na stupanj promjene bogatstva, jer su promjene bile osnovni način na koji ljudi doživljavaju život (Thaler, 2020). Grafikon koji prikazuje prospektnu teoriju sastoji se od dva dijela, desno i lijevo od neutralne referentne točke. Najupadljivije obilježje grafikona je krivulja u obliku slova S, što predstavlja smanjenu osjetljivost i prema dobitcima i prema gubitcima, s tim da krivulje slova S nisu simetrične, već pokazuju snažniju reakciju na gubitke od reakcije na istovrijedne dobitke. Krivulja je konkavna u oblasti dobitaka, a konveksna u oblasti gubitaka i značajno strmija za gubitke nego za dobitke (Kahneman, 2013).

Studija Odeana i Barbera o trgovanju 10000 klijenata velike brokerske tvrtke pokazala je veću spremnost klijenata za prodaju svojih dobitnih dionica i zadržavanje svojih investicija koje bilježe gubitak, što je upravo u skladu s prospektnom teorijom ponašanja. Naime, prodaja dionice koja je zabilježila rast omogućava investitorima dobit i izgrađuje samopoštovanje, dok bi prodajom dionica koje gube na vrijednosti shvatili bolni učinak gubitka, koji se ne može neutralizirati jednakovrijednim dobitkom. Bol zbog gubitka je barem dvostruko snažnija od zadovoljstva prouzročenog dobitkom. Oklijevanje u realizaciji gubitaka nije optimalno s aspekta racionalnog investiranja. Premda je katkad razumno držati dionicu koja je zabilježila pad cijene, posebno ako postoji razlog vjerovanja da je poduzeće još uvijek uspješno, ipak nema smisla držati gubitnu dionicu samo zato da se ne pretrpi gubitak, jer je i gubitak „na papiru" jednako stvaran kao i ostvareni gubitak (Malkiel, 2005; Jabeen et al., 2020).

Richard Thaler (2020) je otkrio da funkcija prospektne teorije koja opisuje **odbojnost prema gubitku** (eng. *loss aversion*) može objasniti brojne primjere koje je prikupio, a koje je nazvao *učinkom posjedovanja* ili *učinkom baštine*, pa je ovo ujedno prva primjena prospektne teorije na neku ekonomsku zagonetku i prekretnica u razvoju bihevioralne ekonomije (Kahneman, 2013). Posjedovanje nekog dobra povećava njegovu vrijednost, na način da će ljudi u transakciji razmjene procjenjivati na viši iznos cijenu vlastite imovine, nego što bi bili spremni platiti za stjecanje iste takve imovine. Iracionalna navika u ljudskoj prirodi jest da se emocionalno veže za ono što posjeduje, pa se ljudi usredotočuju više na ono što bi izgubili odvajajući se od svog dobra, nego na

ono što bi mogli time dobiti. Vlasništvo se ne odnosi samo na materijalne stvari, već i na poglede na svijet ili ideje, kojima se pridaje veća vrijednost nego što je uistinu imaju te ih se teže osloboditi zbog nesklonosti pomisli na gubitak (Ariely, 2009).

Odbojnost prema gubitku utvrđuje se u odnosu na neku referentnu točku. Ostvarenje korisnosti neke transakcije može biti ili pozitivno ili negativno, može biti izvrsna ponuda ili grozna podvala. Upravo zbog takvog razmišljanja trgovci imaju poticaj manipulirati percepcijom predložene referentne cijene koja stvara iluziju „dobre prilike" (Thaler, 2020). Osim toga, odbojnost prema gubitku javlja se i u konceptu nepovratnih troškova. Prema tome, kada je neki novac potrošen, a ne postoji nikakva mogućnost njegova povratka, ljudi će to doživjeti kao gubitak, ukoliko za taj novac nisu osjetili korisnost stjecanja (Thaler, 2020). Osim ekonomskog aspekta razmjene, može se govoriti i o sociološkom aspektu, koji smatra da bi s obje strane razmjene ulazi trebali biti jednaki izlazima, pa će se prema stajalištu je li neka transakcija poštena ili pravična, osloboditi impuls ljutnje na strani koja bude uskraćena. Razmatranje pravičnosti razmjene je glavni motivator u mnogim ekonomskim odlukama koje su povezane s osjećajem povjerenja i sposobnosti djelotvorne suradnje (Akerlof i Shiller, 2009).

Ovakva razmišljanja inspirirala su Thalera da pokrene raspravu o **mentalnom računovodstvu** (eng. *mental accounting*). Naime, slično kao i što se poslovni događaji bilježe u računovodstvu, tako i ljudi pomoću mentalnih računa, tj. računa koji se nalaze u njihovim glavama, organiziraju i vode svoje živote. To ne mora nužno podrazumijevati držanje novca odvojeno na različitim računima. Mentalni računi koriste se za praćenje rezultata i oblik su uskog uokvirivanja (Kahneman, 2013). Upravo zbog činjenice da ljudi koriste mentalno računovodstvo, oni će, na primjer, kupovinu ulaznice za koncert, koju nisu iskoristili, u svojim mentalnim računovodstvenim knjigama zabilježiti kao trošak, a tek bi odlazak na koncert omogućio zatvaranje tog konta bez gubitka (Thaler, 2020). Financijska istraživanja potvrdila su masovnu sklonost prodaji dionica koje su donosile dobitak, a ne dionicama na kojima se ostvarivao gubitak, što je zapravo slučaj uskog uokvirivanja, odnosno korištenja mentalnih računa. Racionalno ponašanje pretpostavlja sveobuhvatan pogled na ukupan portfelj, za razliku od iracionalnog, u kojem se za svaku dionicu pojedinačno „otvara mentalni račun". Rezultat toga je odbijanje stvaranja gubitka u situacijama koje bi značile priznavanje neuspjeha (Kahneman, 2013).

U prospektnoj teoriji opisuje se i način ponašanja u situacijama koje su posljedica nedjelovanja, a psiholozi to stanje nazivaju žaljenjem ili kajanjem zbog propuštene prilike. **Odbojnost prema žaljenju** (eng. *regret aversion*) javlja se i kao žaljenje zbog pogrešnog izbora. Donositelji odluka znaju da mogu požaliti, a upravo očekivanje tog osjećaja kajanja, i bolnog osjećaja kojeg će izazvati, igra značajnu ulogu u mnogim odlukama. Asimetrija u riziku žaljenja jednako je snažna kao i asimetrija koja se odnosi na gubitke, što dovodi do konvencionalnih odabira i izbjegavanja rizika (Kahneman, 2013). Žaljenje zbog pogrešnog izbora je bolno, kao i iščekivanje budućeg žaljenja, ako se izbor koji je donesen pokaže pogrešnim (Statman, 2017).

3.2.3 Ponašanje krda

Proučavanje ponašanja mase privuklo je pozornost bihevioralnih financija, s obzirom na brojne primjere kroz povijest, u kojima je određeno ludilo u ponašanju masa dovodilo do slomova tržišta. Jedan od prvih eksperimenata, koji je proučavao na koji način ponašanje grupe može dovesti do neispravnih odluka, proveo je psiholog Solomon Asch tijekom 1952. godine. Izabrani sudionici u eksperimentu davali su namjerno pogrešne odgovore, koji su utjecali na to da je sudionik koji je imao priliku izraziti svoje mišljenje, pod društvenim pritiskom, također odabirao pogrešan odgovor. Suočeni s grupom ljudi koji su jednoglasno davali očito pogrešne odgovore na pitanja, trećinu vremena ispitanici su popuštali i davali iste takve pogrešne odgovore. Pri tome su pokazivali znakove tjeskobe i uznemirenosti, nakon što je grupa pokolebala njihovo mišljenje (Shiller, 2015). Međutim, nisu samo društveni pritisci prouzrokovali takvo priklanjanje grupi, već su zaključci neuroznanstvenika Gregoryja Bernsa, temeljem skeniranja mozga i reakcijom stražnjeg dijela mozga zaduženog za percepciju prostora, pokazali da su se njihove percepcije zaista promijenile te se čini da pogreške drugih ljudi uistinu utječu na to kako netko percipira vanjski svijet (Malkiel, 2005). Osim toga, pokusi s elektrošokovima, koje je proveo Milgram, tumačili su se kao pokazivanje ogromne moći koju vlast ili autoritet ima nad ljudskim umom, iako postoji i tumačenje da su ljudi naučili da kada im stručnjaci kažu da je nešto u redu, onda vjerojatno i jest, čak i ako se ne čini tako. Milgram je u svom pokusu pokazao i način opiranja mišljenju krda uvođenjem „vršnjačke pobune“ (eng. *peer rebellion*) ili „neslaganjem među autoritetima” (eng. *disagreement between authorities*) (Zweig, 2007; Shiller, 2015).

Temeljno razmišljanje o ljudskom društvu jest da ljudi, koji međusobno redovito komuniciraju, razmišljaju slično. Prosudbe ljudi u sličnim vremenima su slične, jer reagiraju na iste informacije

koje su dostupne u to vrijeme (Shiller, 2015). Investitori iskazuju tendenciju okupljanja oko istih dionica, po modelu epidemije širenja informacija o dionicama usmenom predajom. Studija koju su proveli bihevioristi Hong, Kubik i Stein, pokazala je da menadžeri uzajamnih fondova u istom gradu drže slične portfelje (Malkiel, 2005). Ukoliko bi svi ulagači na financijskom tržištu bili neovisni jedni od drugih, svako pogrešno razmišljanje imalo bi tendenciju uprosječivanja, pa kao takvo, ne bi imalo utjecaja na cijene. Međutim, ako je iracionalno razmišljanje slično kod velikog broja ljudi, onda takvo razmišljanje može dovesti do burzovnih uspona i padova (Shiller, 2015).

Nije neobično da vrlo racionalni ljudi mogu sudjelovati u ponašanju krda, kada uzmu u obzir tuđe prosudbe, čak i ako znaju da se svi drugi ponašaju poput stada (krda). Brojni primjeri iz života pokazuju kako prenošenje i širenje informacija utječu na ljudsko ponašanje, pa iz istog razloga neka mjesta postaju popularna za izlaske, a druga ista takva ne, jer svi žele biti na mjestu na kojem se svi okupljaju. Ista stvar se događa i na financijskom tržištu, kada se u društvu vrlo brzo širi informacija o ljudima koji vode tvrtke, o mogućnostima kupnje dionica koje donose ogromnu zaradu ili, u suprotnom smjeru, priče o neposrednoj prijetnji na osobno bogatstvo. Iako mediji imaju veliku sposobnost širenja ideja, najsnažniji utjecaj na ljudsko ponašanje još uvijek ima usmena komunikacija licem u lice. U anketi koju je proveo Shiller nakon pada burze 1987. godine, 86.1% individualnih investitora saznalo je za taj događaj istog dana, dakle, prije nego što je to objavljeno u medijima. Također, prosječno doba dana u kojem su individualni investitori doznali za događaj je 13:56, a institucionalni investitori u 10:32. Prosječan broj ljudi s kojima se razmjenjuju informacije o stanju tržišta kod individualnih investitora je 7.4 drugih ljudi, a kod institucionalnih investitora 19.7 drugih ljudi (Shiller, 2015).

Općenito se smatra da je ekonomistima neprofesionalno zasnivati svoje mišljenje na pričama. Međutim, ljudski um je izgrađen da razmišlja u obliku narativa u kojem se nizovi događaja s unutarnjom logikom i dinamikom pojavljuju kao cjelina. Upravo su mnoge inspirativne priče o novim poslovnim inicijativama i lakom bogaćenju pratile velike procvate na burzama diljem svijeta (Akerlof i Shiller, 2009).

3.2.4 Emocije i raspoloženje

U financijskoj literaturi obično se zamagljuje razlika između emocija i raspoloženja, ali potrebno je razlikovati emocije kao afektivne reakcije koje se osjećaju intenzivno, ali nakratko, a pokrenute

su nekim unutarnjim ili vanjskim događajem, dok se raspoloženja osjećaju manje intenzivno, ali su dugotrajnija i nastaju često bez nekog vidljivog razloga (Duxbury et al., 2020).

Dok su rani radovi na polju bihevioralnih financija bili više skoncentrirani na spoznaju i kognitivne pogreške, odnedavno se prihvaća i uloga emocija i raspoloženja. Čak i samo trgovanje može se smatrati emocijom, tj. psihologijom mase, pohlepom i strahom. Otpor prihvaćanju važnosti emocija potječe od uvjerenja da kod donošenja financijskih odluka treba koristiti samo razum, a emocije treba ostaviti po strani (Fenton-O'Creevy et al., 2011; Statman, 2017). Međutim, emocije zapravo pojačavaju sposobnost pojedinca da donosi racionalne izbore, nadilaženjem detalja, a određivanjem prioriteta i usredotočenjem na donošenje odluke. Veliki broj istraživanja također podržava teoriju da pozitivno raspoloženje pojedincima omogućuje bolje organiziranje i usvajanje informacija te olakšava kreativno rješavanje problema (Ackert, Church i Deaves, 2003; Zelić i Lukavac, 2018).

Premda ne postoji općeprihvaćen popis emocija, psiholog Paul Ekman je naveo sedam **emocija**, čiji su fiziološki efekti evidentni u izrazima lica, a to su: strah, ljutnja, tuga, gađenje, iznenađenje, sreća i zadovoljstvo. Ostali popisi još uključuju nadu, ponos, žaljenje, sram, krivnju i samokontrolu. Šest kognitivnih dimenzija ocjenjivanja leži u osnovi emocija: ugodnost, očekivani napor, izvjesnost, pažljiva aktivnost, odgovornost (vlastita odgovornost ili odgovornost drugih) te kontrola (vlastita kontrola ili kontrola od strane drugih) (Statman, 2017).

Strah je negativna emocija koja nastaje kao odgovor na opasnost te pojedinac pod strahom smatra da njegov očekivani cilj neće biti ostvaren, dok je **nada** pozitivna emocija u očekivanju nagrade i očekivanog cilja. Pri tome kognitivna procjena napominje da je strah neugodan, a nada je ugodna, a i za jedno i drugo kontrola je u rukama drugih, bilo da se radi o drugim ljudima ili situacijama. Pad burzi izaziva strah, pa je kod takvih događaja primijećen povećan prijem ljudi u bolnicu. Oporavak tržišta otvara nadu, a rast prinosa na tržištu povezan je s boljim mentalnim zdravljem. Strah povećava odbojnost prema riziku te uplašeni investitori prelaze iz rizičnih u sigurnija ulaganja (Statman, 2017; Aren i Nayman Hamamci, 2020). Što je rizik živopisnije opisan, strah je veći, pa će ljudi biti spremni više platiti osiguranje od „bilo koje bolesti", nego „iz bilo kojeg razloga", jer je „svaka bolest" živopisniji opis koji izaziva strah. Stoga, iako to nema ekonomskog smisla, ima savršen emocionalni smisao. Pretjerano reagiranje strahom jedna je od najrizičnijih stvari koje investitor može učiniti, ali amigdala u ljudskom mozgu refleksno djeluje kao alarmni

sustav na rijetke, ali živopisne rizike, u kojima je oklijevanje pitanje života ili smrti. Iz tog razloga, najbolji investitori imaju naviku uvoditi procedure koje će pomoći odmaknuti se od vruće reakcije ovog dijela mozga, poput skretanja pažnje na opuštajuće aktivnosti, zatim suočavanjem činjenica i objašnjenja koje će nadvladati osjećaje te odmicanjem od ponašanja krda (Zweig, 2007).

Sreća se povezuje s dobitcima i uživanjem, a **tuga** s gubitcima i bespomoćnosti (Statman, 2017). Vječita dilema o tome kupuje li se novcem sreća, potiče ljude na nastojanje da troše što više vremena za dobivanje više novca, čime onda ostaje manje vremena za stvari koje mogu dati sreću u životu. Kako raste bogatstvo, tako raste i briga. Neuroznanstvenik Richard Davidson sugerira da ljudi koji imaju manji prioritet biti bogati imaju tendenciju biti sretniji, za što je zaslužno područje u lijevom prefrontalnom korteksu u mozgu, pomažući spriječiti pretjeranu reakciju na uspone i padove svakodnevnog života. Potraga za novcem može uzrokovati depresiju, tjeskobu, stres i obiteljsku napetost, što zauzvrat traži i hitniju potragu za još više novca u nadi olakšanja. Suprotno tome, posvećivanje više vremena uživanju, smanjeni stres i jači imunološki obrambeni sustav organizma, lakše će dovesti i do potrebne količine novca (Zweig, 2007).

Gađenje se povezuje s blizinom neukusnih predmeta ili ideja. **Ljutnja** je negativna emocija koja proizlazi iz negativnog iskustva. Da bi došlo do ljutnje, potrebno je da dođe do određenog događaja, dok se primjerice strah javlja kao negativna emocija pri iščekivanju određenog događaja koji se još nije dogodio (Statman, 2017; Aren i Nayman Hamamci, 2020). Za razliku od straha, kontrola nad emocijom ljutnje je u vlastitim rukama, pa taj osjećaj kontrole potiče na poduzimanje rizika i ponašanje slično kao kod optimista, dok kod straha osjećaj nemogućnosti kontrole potiče ponašanje poput pesimista. Dok je **žaljenje** negativna kognitivna emocija, na suprotnoj strani spektra je **ponos**, a oni utječu na financijske izbore poput kupnje ili prodaje dionica. Investitori obično radije kupuju dionice koje su ranije prodali s dobitkom, nego one koje su prodali s gubitkom. Naime, otkup dionica čija je cijena pala nakon ranije prodaje stvara osjećaj ponosa za prodaju na vrijeme. Investitori koji prodaju dionice s gubitkom, vjerojatno su požalili što su ih ikada i kupili, a ponovni otkup po višim cijenama doprinosi boli žaljenja otvaranjem starih rana (Statman, 2017).

Problemom **samokontrole** ekonomisti su se bavili i prije pojave bihevioralne ekonomije, pa je već i Adam Smith isticao „snagu volje", koja je nužna kako bi se riješio konflikt između „strasti" i „nepristranog promatrača", koji u ljudima utječu na donošenje odluka o vremenu konzumiranja. Irving Fisher je ponudio krivulju indiferencije (eng. *indifference curve*), kako bi objasnio na koji

način racionalna osoba treba donijeti odluke o potrošnji u različitim razdobljima. Paul Samuelson definirao je diskontirani model korisnosti (eng. *discounted utility model*), polazeći od ideje da je potrošnja koja se događa ranije vrjednija od potrošnje koja se događa kasnije. Problemom samokontrole bavili su se u svojim radovima i Keynes, Friedman i Modigliani, a implicitno se pretpostavljalo da su ljudi mogli biti sposobni pokazati volju da bi odgodili potrošnju, u Modiglianijevom slučaju, čak i za desetljeća. Bihevioralni pristup ovom problemu je utvrditi koje mjere se mogu poduzeti da bi se osiguralo neodstupanje od originalnog plana, odnosno što bi trebalo učiniti kako bi se ograničilo svoje odabire u budućnosti (Thaler, 2020). Dovoljan je samo mali pomak od ekonomije slobodnog tržišta, koji vodi do toga da ljudi kupuju i plaćaju i za stvari koje su im nepotrebne, uočavanjem razlike između optimalnosti stvarnog izbora i optimalnosti izbora onoga što ljudi misle da žele (*Monkey-on-the-Shoulder Tastes*), da se postigne velika razlika u ljudskom životu (Akerlof i Shiller, 2015). Zbog ovog sukoba emocija i razuma, samokontrola se smatra jednim od ključnih faktora u ponašanju investitora (Zelić i Lukavac, 2018).

Raspoloženje je prigušena emocija, manje intenzivna, ali dugotrajnija, pa za razliku od emocije straha od nadolazećeg automobila, strah od nezaposlenosti može trajati mjesecima ili godinama i nepovoljno se odražavati na mentalno zdravlje. Godišnja doba i vremenske prilike također utječu na raspoloženje, pa sunčano vrijeme podiže raspoloženje te je čak u istraživanju na burzi u New Yorku i 26 burzi iz drugih zemalja visoki prinos povezan s lijepim vremenom, a oblačni dani s nižim prinosima i lošim raspoloženjem (Statman, 2017).

Optimizam i pesimizam mogu se opisati kao raspoloženja, pa je optimizam povezan s emocijama nade i sreće, a pesimizam s emocijama straha i tuge, ali ni optimizam ni pesimizam nisu tako intenzivni poput nade, sreće, straha ili tuge. U kontekstu ulaganja na burzi, „medvjeđi“ osjećaj odgovara pesimističnom raspoloženju, a „bikovski“ osjećaj optimističnom raspoloženju. Sklonosti optimizmu ili pesimizmu su ukorijenjene u ljudskoj genetici. Iako je optimizam poželjna ljudska karakteristika i potiče se kada to može utjecati na performanse, ipak ponekad pretjerani optimizam može dovesti do podcjenjivanja rizika i nedovoljnog pridavanja važnosti opasnostima koji mogu utjecati na negativne ishode (Statman, 2017).

3.2.5 Faktori osobnosti

Osobnost se može promatrati kao kibernetski sustav koji obuhvaća (DeYoung, 2010):

- skup ciljeva, definiranih kao svjesni i nesvjesni prikazi željenog budućeg stanja,
- skup svjesnih i nesvjesnih evaluacijskih tumačenja sadašnjeg stanja, uokvirenih u odnosu na te ciljeve, i
- skup strategija, planova i automatiziranih rutina, korištenih za pretvaranje sadašnjeg stanja u željeno buduće stanje.

U bihevioralnim istraživanjima, ekonomisti sve više važnosti pridaju faktorima osobnosti te sve više istraživanja dolazi do rezultata da osobnost utječe na aspekte ekonomske situacije ljudi i financijsko odlučivanje. Ljudi koji su ekstrovertniji obično imaju veću sklonost riziku i više preferiraju kratkoročna ulaganja, a ljudi s visokom ocjenom neuroticizma skloniji su dugoročnim ulaganjima, kao i averziji prema riziku. Najrašireniji model koji grupira crte osobnosti poznat je kao **model velikih pet varijabli osobnosti**, a klasificiran je u pet dimenzija (eng. *Big Five Personality*), koje čine: otvorenost prema iskustvima (eng. *openness*), savjesnost (eng. *conscientiousness*), ekstraverzija (eng. *extraversion*), ugodnost (eng. *agreeableness*) i neuroticizam (eng. *neuroticism*) (John i Srivastava, 1999; De Bortoli et al., 2019).

Ekstrovertirani pojedinci uživaju biti okruženi ljudima, društveni su, suosjećajni, energični, samopouzdani i prijateljski raspoloženi. Zbog ovih osobina i sklonosti, ekstroverti više komuniciraju s drugima i razmjenjuju ideje te su više angažirani u vanjskom, nego u svom unutarnjem svijetu. Ova karakteristika osobnosti daje pozitivan pogled na život, a u donošenju financijskih odluka može se povezati s većom samouvjerenosti i preuzimanjem rizika (Lin, 2011a; Nga i Ken Yien, 2013; Aren i Nayman Hamamci, 2020; Yadav i Narayanan, 2021). **Otvorenost** je karakteristika kojom se mogu opisati pojedinci otvorenog uma i stava koji izaziva autoritet. Osim toga, pojedinci s ovom osobinom su vrlo maštoviti, intelektualni, inteligentni, kreativni i otvoreni novim znanjima, idejama i inovacijama. U donošenju odluka, otvoreni ljudi su fleksibilni, često uspješni pri financijskim odlukama i orijentirani na dugoročne investicije, a isto tako mogu biti samouvjereni i češće trgovati zbog svoje znatiželje (Lin, 2011a; Nga i Ken Yien, 2013; Aren i Nayman Hamamci, 2020; Yadav i Narayanan, 2021). **Savjesnost** karakterizira osobe koje su pouzdane, disciplinirane, orijentirane ciljevima, odgovorne, pažljive, sposobne te imaju tendenciju biti temeljite i sklone redu i organiziranosti. Savjesni pojedinci ne žive u svijetu kaosa, već su izrazito produktivni i organizirani te ulažu napore u investiranje u svoju financijsku budućnost. Manje su fleksibilni i vole strukturirano donošenje odluka. Osim toga, disciplinom dolaze do

sigurnijih investicija te akumuliraju više bogatstva u odnosu na manje savjesne ljude (Nga i Ken Yien, 2013; Statman, 2017; Aren i Nayman Hamamci, 2020; Yadav i Narayanan, 2021). **Ugodnost** je karakteristika koja se ogleda u empatiji i nesebičnosti. Ljudi s ovakvim osobinama rado pomažu drugima, poštuju njihova uvjerenja, izbjegavaju konflikte te su pouzdani, srdačni, skromni i suosjećajni. Ovakvi pojedinci povezuju se sa sklonosti ponašanju krda, a manje su skloni samouvjerenosti u svoje vještine (Lin, 2011a; Nga i Ken Yien, 2013; Aren i Nayman Hamamci, 2020; Yadav i Narayanan, 2021). Kao peta karakteristika velikih pet varijabli osobnosti spominje se **neuroticizam**, čija je suprotnost emocionalna stabilnost. Neurotični ljudi povezuju se s negativnim emocijama. Oni su emocionalno nestabilni, anksiozni, krhki, sramežljivi, pesimistični, nesigurni, impulzivni, ćudljivi i pod stresom. Stoga, zbog svoje nesigurnosti, traže savjete od drugih pri donošenju odluka, zbog čega mogu biti podložni efektu ponašanja krda te nisu skloni preuzimanju rizika (Lin, 2011a; Nga i Ken Yien, 2013; Aren i Nayman Hamamci, 2020; Yadav i Narayanan, 2021).

Međutim, postoje dva faktora višeg reda, tzv. alfa i beta faktori osobnosti, koji obuhvaćaju ovih pet varijabli, a to su faktori **stabilnosti** (eng. *stability*) i **prilagodljivosti** (eng. *plasticity*) (DeYoung, 2006; 2010; 2014; Erdle et al., 2010). Stabilnost obuhvaća savjesnost, ugodnost i emocionalnu stabilnost (suprotnost neuroticizmu) te odražava stupanj u kojem se sustav opire zamjeni operativnih ciljeva užim, neposrednim ciljevima koji bi mogli ometati dugoročne ciljeve. Prilagodljivost obuhvaća ekstraverziju i otvorenost te reflektira tendenciju aktivnog uključivanja u stvaranje i doživljaj novih iskustava. Važno je istovremeno održavati stabilnost u svrhu ostvarivanja svojih ciljeva, a ujedno imati sposobnost prilagodbe kompleksnim, promjenjivim i nepredvidljivim okolnostima (Blackburn et al., 2004; DeYoung, 2006; 2010).

3.3 Aktualnost bihevioristička teorije u cikličkom kretanju financijskih tržišta

Ekonomske aktivnosti periodično fluktuiraju i nijedno gospodarstvo ne raste u ravnoteži, već uobičajeno nakon faze rasta i ekspanzije dolazi do zastoja, zatim pada i recesije, te ponovnog oživljavanja i rasta. Kako se gospodarstvo kreće u ciklusima, tako se i na financijskim tržištima odražavaju ta ciklička kretanja. S obzirom da je prema hipotezi efikasnog tržišta cijena dionice u svakom trenutku odraz njene intrinzične vrijednosti, temeljem toga bi promjene cijena, koje se događaju u padu i rastu financijskog tržišta, trebale značiti i promjenu njene intrinzične vrijednosti.

Međutim, najvažniji doprinos bihevioralnih financija je upravo opovrgavanje teorije efikasnog tržišta (Statman, 2017).

Još uvijek je prisutna problematična podjela između entuzijasta, koji vjeruju da tržišne cijene točno uključuju sve javne informacije pa sumnjaju da „mjehurići" (eng. *bubbles*) uopće postoje, i onih koji vjeruju u bihevioralne financije, odnosno vjeruju da se „mjehurići" i druge takve suprotnosti na efikasnom tržištu mogu shvatiti samo uvođenjem psihologije u ekonomiju. Područje psihologije nudi mnoga druga načela ljudskog ponašanja, za koja se pokazalo da su relevantna za vrednovanje teorije efikasnog tržišta (Shiller, 2015). Dvije su osnovne tvrdnje teorije efikasnog tržišta: 1) cijena je točna i 2) tržište se ne može pobijediti. Bihevioralne financije pružaju dokaze po kojima je kontradiktorna tvrdnja teorije efikasnog tržišta o tome da je cijena uvijek točna, a dokazi bihevioralnih financija o nepobjedivosti tržišta su općenito u skladu s teorijom efikasnog tržišta, s tim da bihevioralne financije objašnjavaju zašto toliko investitora vjeruje da je tržište lako pobijediti (Statman, 2017).

Što se tiče tumačenja teorije efikasnog tržišta o fluktuacijama cijena, uvriježeno je mišljenje da se promjena cijena dionica općenito događala s promjenom zarade te da nije posljedica neracionalnog ponašanja ulagača. Promatrajući tri velika *bull* tržišta u posljednjih stotinjak godina, istraživanja na području bihevioralnih financija dolaze do zaključka da se u prvom *bull* tržištu, od 1920. do 1929. godine, rast cijena možda i može povezivati s rastom zarade, ali reakcija na procvat gospodarstva, izražena u cijenama na financijskom tržištu, bila je pretjerana. Na drugom velikom *bull* tržištu 1950-ih, podudarnost cijena sa zaradom nije uopće tako jasna. Većina rasta cijena se dogodila u 1950. godini, a indeks S&P se do kraja 1959. godine gotovo utrostručio, dok je stvarna zarada sastavnica S&P porasla samo 16% za cijelo desetljeće, što je ispod prosjeka po povijesnim standardima. Također, na trećem velikom *bull* tržištu, od 1982. do 2000. godine, cijene dionica su neprestano rasle, dok zarada nije rasla nimalo jednoliko. Isto tako, pojedini ekonomisti smatraju da, ako ne postoji veza s promjenom zarade, onda barem postoji veza s kretanjem dividende. Međutim, povijesne fluktuacije dividendi nisu reprezentativne za potencijalne fluktuacije (Shiller, 2015).

Nakon I. svjetskog rata, proizvodnja i zaposlenost bili su visoki i u porastu. Američki kapitalizam bio je u živoj fazi. Iako su još mnogi ljudi bili siromašni, sve više ljudi je postajalo prilično dobrostojeće ili bogato, bogatije nego ikad. Poslovna zarada je brzo rasla i bilo je to dobro vrijeme

za poslovanje. Kada je došlo do Velike depresije s padom burze 1929. godine, cijela generacija povjesničara okrivljivala je tadašnjeg predsjednika Sjedinjenih Država, Coolidgea, zbog površnog optimizma i propusta da uvidi da se sprema katastrofa. Pojam „željeznog zakona kompenzacije", prema kojem se za deset dobrih godina tijekom dvadesetih moralo platiti s deset loših godina tijekom tridesetih, uspoređivao se s biblijskih sedam debelih i sedam mršavih krava iz faraonovog sna, čime se potvrđivala predrasuda da se događaji mogu predvidjeti. S druge strane, u vrijeme blagostanja i sreće, ljude je najlakše uvjeriti u uspjeh pothvata, jer je povjerenje tada na najvišem stupnju. Političari i ekonomisti tog doba uvjeravali su u nastavak prosperiteta i u zdrave temelje cijena na financijskom tržištu (Galbraith, 2009). One koji su najavljivali slom i prekid „beskonačnog lanca prosperiteta", poput financijskog savjetnika Rogera Babsona, profesionalci s Wall Streeta nisu ozbiljno shvaćali, već su ga podrugljivo nazivali „mudrac iz Wellesleya", sve do prvog pada u rujnu 1929. godine, kada je mogućnost sloma, koji je prije bio potpuno nezamisliv, postala tema o kojoj se raspravljalo, a ovaj snažni pad nazvan „Babson Break" (Malkiel, 2005).

Bihevioralne financije u ovakvim događajima mogu identificirati brojne bihevioristička faktore, u prvom redu emocije i raspoloženje, koji su mogli utjecati na ovakva „špekulativna ludila". Društvo kao cjelina uči, a kumulativni učinak takvog učenja je da je moderno društvo postiglo napredak u usporedbi s prošlim stoljećima, no ostaje pitanje je li društvo naučilo nešto važno o burzi (Shiller, 2015). S obzirom da se „špekulativna ludila" pojavljuju s vremena na vrijeme tijekom povijesti, moglo bi se postaviti pitanje zašto sjećanja kratko traju, zašto je teško izbjeći špekulativne kratkoročne kupovine koje obećavaju brzo bogaćenje i bi li studija ovakvih slučajeva mogla pomoći investitorima da se u sličnim okolnostima oboružaju za preživljavanje (Malkiel, 2005). Neuroznanost također može doprinijeti ekonomiji u smislu komparativne prednosti, kada drugi izvori podataka nisu pouzdani ili su pristrani (Camerer, Loewenstein i Prelec 2004; Zelić, 2017). Cilj neurofinancija je pružiti alternativno objašnjenje neuspjeha klasičnih teorija financija, kombiniranjem eksperimenata s računalnim modelima (Miendlarzewska, Kometer i Preuschoff, 2017; Ardalan, 2018). Proces zaboravljanja, kojeg je Sigmund Freud opisao kao suzbijanje neželjenih sjećanja, sada je barem donekle objašnjen u istraživanju Johna D. E. Gabrielia i suradnika, koji su 2004. godine pomoću fMRI-ja pokazali da su neželjena sjećanja prilikom fronto-hipokampalne koaktivacije kod prisjećanja povezana s povećanim stupnjem aktivacije prefrontalne moždane kore i smanjenom aktivacijom hipokampusa, s posljedičnim sve slabijim prisjećanjem takvih događaja. Čak se iz volumena aktiviranih područja prefrontalne moždane kore i desnog

hipokampusa mogao predvidjeti stupanj zaboravljanja pri svakom sljedećem, prinudnom prisjećanju (Šimić, 2019).

Ljudi uglavnom smatraju da se nakon pada cijena dionica događa preokret i ponovni rast. Međutim, dionice mogu biti precijenjene ili podcijenjene tijekom dužeg vremenskog razdoblja, a u međuvremenu će mnogi investitori pretrpjeti gubitke. Općenito postoji i uvjerenje da rezultat ulaganja u dionice nadmašuje druga ulaganja, poput obveznica, ali su povijesni podaci (prilagođeni za inflaciju) u desetogodišnjim intervalima pokazali da to nije uvijek tako i da nema razloga misliti da će i u budućnosti biti. Promjena mišljenja o dionicama kao najboljem ulaganju, nakon pada 2001. godine, potakla je javnost prema masovnom povećanju cijena nekretnina, potičući uvjerenje da to može biti trajno. Stoga je moralo uslijediti ponovno učenje nakon krize 2008. godine. S time u vezi, potrebno je razmotriti kako se nositi s promjenom mišljenja koja navodi ljude da misle kako su otkrili novo prosvjetljenje, a koje dovodi do lošeg učinka na tržišne cijene (Shiller, 2015).

Shiller (2015) navodi kako su financijska tržišta općenito ranjiva na napade iracionalne bujnosti (eng. *irrational exuberance*), odnosno pretjeranog entuzijazma i euforije. Alan Greenspan, američki ekonomist, tadašnji predsjednik Federalnih rezervi (1987.-2006. godine), u svom govoru 1996. godine, upotrijebio je izraz *„irrational exuberance“* za opis ponašanja investitora na tržištu dionica, nakon čega su, samo nakon izgovorene te dvije riječi, dionički indeksi oštro pali, ne samo Dow Jones u Sjedinjenim Državama, već Nikkei u Japanu, Hang Seng u Hong Kongu, DAX u Njemačkoj, FTSE100 u Londonu, a ovaj izraz, iako nije novi, a ni Greenspanova kovanica, postao je izraz za vrstu društvenog fenomena kada cijene dionica rastu do neuobičajeno visokih i neodrživih razina pod utjecajem tržišne psihologije. Činjenica je da, iako su ljudi osjećali da je u pitanju stvaranje špekulativnih mjehurića, povećanje cijena poticalo je psihološku zarazu pretjeranim entuzijazmom, koji je privlačio sve veći broj investitora, unatoč sumnjama u stvarnu vrijednost ulaganja (Shiller, 2015). Većina varljivih pothvata bila je povezana s nekom novom tehnologijom ili nekim poslovnim prilikama, a pojava interneta je predstavljala oboje. Ludilo za dionicama poduzeća vezanim uz internet utjecalo je na porast cijena tih dionica do vrtoglavih visina, ali i poduzeća koja su, radi povećanja privlačnosti, mijenjala nazive kako bi u njega uključile određenu web orijentaciju, čak i kada osnovno poslovanje nije imalo nikakve veze s internetom. Analitičari dionica također su doprinijeli „varljivom pothvatu interneta“, javno navijajući za *boom*, pa su preporuke „kupiti” prevladavale, a preporuke „prodati” su se izbjegavale, kako se ne bi doveli

u opasnost odnosi s financijašima u korporacijama. Mediji su povećavali broj informacija koje su čitatelje interesirali, a to su uzbudljive priče o jednostavnom putu do bogatstva. Mnogi korporativni menadžeri su spremno prihvatili opravdati visoka očekivanja iz prognoza analitičara, koristeći tzv. kreativno računovodstvo, što je na kraju dovelo do organiziranih prijevara i kolapsa Enrona, sedme najveće korporacije u Sjedinjenim Državama, ali i brojnih drugih internetskih i telekomunikacijskih poduzeća, među kojima se ističu WorldCom i Tyco (Malkiel, 2005).

Rast američkog tržišta dionica za 7,1 puta, od 1982. do 2000. godine, čini ovaj *boom* najvećim, nadmašivši do tada najveći rast od 5,2 puta u razdoblju od 1920. do 1929. godine, kao i *boom* od 1949. do 1968. godine s rastom od 5,1 puta. Nakon ovoga se rast od 2003. do 2007. godine za 1,5 puta i rast od 2009. do 2014. godine za 2,5 puta čine blagima za usporedbu. Rast na drugim svjetskim tržištima se događao prilično istovremeno i u istom intenzitetu te se može govoriti o *boomu* na svjetskom tržištu (Shiller, 2015).

S gledišta biheviorističke ekonomije, nakon kraha *dot.com* dionica i krize „drugorazrednih hipotekarnih kredita" u 2008. godini, bilo je jasno da psihologija i iracionalno ponašanje imaju mnogo veću ulogu u funkcioniranju ekonomije, nego što se do tada priznavalo među ekonomistima (Ariely, 2009). Neprekinuti rast cijena nekretnina tijekom dužeg vremenskog razdoblja doprinio je razmišljanju da je, umjesto u internetske dionice koje su doživjele krah, ulaganje u nekretnine sigurno ulaganje. Tome je pogodovala i politička klima, s obzirom da je George W. Bush, u predizbornoj kampanji 2004. godine, promicao ideju „američkog sna" o društvu vlasništva. U tom kontekstu, i regulatori su dopustili zajmodavcima da preuzmu veliki rizik, omogućujući da što više ljudi posjeduje kuće, odobravanjem hipotekarnih kredita i onima s lošom kreditnom sposobnošću (Shiller, 2015) ili, kako Akerlof i Shiller (2015) takve zajmoprimce nazivaju, NINJA – *No Income, No Job or Assets* (bez prihoda, bez posla, bez imovine). Ono što je započelo upitnim kreditnim poslovanjima, intenziviralo se uvođenjem osiguranih dužničkih obveza (eng. *collateralized debt obligations*), a dovelo je do začaranog kruga smanjivanja vrijednosti i ubrzavanja pada na tržištu nekretnina (Ariely, 2009). Kako bi skrenule pažnju s loših kredita, banke su, umjesto prodaje izvornih hipotekarnih paketa izravno, prodavale pakete u različitim kriškama ili tranšama (eng. *slice*), a što je rejting agencijama davalo izgovor od odustajanja od temeljnog pregledavanja vrijednosnih papira osiguranih tim hipotekama (eng. *mortgage-backed tranches*), s obzirom da ga je ovo činilo složenim. No, to nije spriječilo rejting agencije da velikodušno udovoljavaju

investicijskim bankama, ocjenjujući njihove vrijednosnice visokim ocjenama, a zauzvrat su im banke osiguravale poslove, pa ni jednima ni drugima nije bilo u interesu ulaziti u unutarnju vrijednost ovih tranši (Akerlof i Shiller, 2015).

Rast tržišta dionica, te potom slom ili pad, ne odražava se jednako na ekonomsku situaciju koja uslijedi. Nakon sloma financijskog tržišta 2007./2008. godine, svijet je zahvatila najozbiljnija recesija od Velike depresije iz 1930-ih. Stope gospodarskog rasta su se smanjile, a slabost svjetskog gospodarstva se nastavila godinama poslije toga (Shiller, 2015). Zarada po dionici S&P 500 bila je negativna u četvrtom tromjesečju 2008. godine, što je vrlo rijedak događaj (Shiller, 2019). Pred kraj 2008. godine povjerenje ljudi bilo je na najnižoj razini otkada ga je skupina znanstvenika počela mjeriti, a financijska kriza je mnoge ljude ostavila u uvjerenju da su bankari upleteni u nju i da je ona rezultat njihove pohlepe. Provođenje programa spašavanja financijskog sustava je dodatno narušilo povjerenje građana, „jer su bankari njihov zarađeni novac bacili u vjetar, da bi ih se opet njihovim poreznim novcem spašavalo" (Ariely, 2009).

U 2009. godini vladalo je uvjerenje da se ponavlja Velika depresija, a često spominjane vijesti o pojavi „financijske supernove" pojačavale su strah. Ipak, unatoč slabosti gospodarstva, financijsko tržište pokazuje novi uspon od 2009. godine. Rast se nastavio i dalje punih deset godina, a optimistična prognoza rasta nije potaknuta većim zaradama, već očito znatno višim vrednovanjem zarade. Naime, prosječna desetogodišnja zarada S&P 500 po dionici od 2009. do 2019. godine porasla je samo 71% u odnosu na prethodno desetljeće, dok je za to razdoblje nastalo četverostruko povećanje indeksa cijena S&P 500. Psihologija također ima značajan utjecaj na preokret, u kojem je strah zamijenjen divljenjem poslovnom uspjehu Stevea Jobsa, osnivača Applea, ili Elona Muska s futurističkim tvrtkama, poput proizvođača svemirske opreme SpaceX i Neuralinka, koji razvija implantabilna sučelja mozga i računala (Shiller, 2019).

Početkom 2020. godine dogodio se najavljivani pad tržišta. Međutim, on nije izazvan ekonomskim razlozima, već egzogenim šokom, koji je rezultirao zaključavanjem gospodarstva, a koji se prelio na sve segmente financijskog tržišta. Reakcije centralnih banaka i država pomogle su umiriti tržišta, no neizvjesnost još ostaje na povijesno visokim razinama. I u ovom slučaju, neusklađenost između kretanja gospodarstva i kretanja na financijskom tržištu pokazuje pojavu tzv. *„irrational exuberance"*. Naime, većina investitora smatra da je kriza povisila rizike pogrešnog vrednovanja imovine. Ovi rizici su i prije krize bili na visokim razinama, nakon desetljeća kontinuiranog rasta

(Žigman, 2020). Shiller (2020) primjećuje zagonetnu povezanost kretanja na burzi s vijestima, jer kada bi cijene trebale padati, a ne dosezati rekordne razine, onda se to može objasniti samo psihologijom. Prva faza započela je kada je Svjetska zdravstvena organizacija 30. siječnja proglasila novi koronavirus „hitnim za javno zdravstvo od međunarodnog interesa“. U sljedećih 20 dana S&P 500 porastao je za 3%, dosegnuvši rekord svih vremena, što je neobična reakcija na najavu globalne pandemije, koja od 11. veljače dobiva naziv COVID-19. Nedostatak prethodnog iskustva na pandemiju gripe 1918. godine utjecao je na to da većina investitora nije bila uvjerena da drugi investitori i potrošači obraćaju pažnju na takve vijesti, sve dok nisu vidjeli veću reakciju. Druga faza nastala je kada je S&P 500 pao 34% od 19. veljače do 23. ožujka, što je pad sličan padu burze 1929. godine. Naime, kako se pad burze nastavljao, pojavljivale su se živopisne priče o teškoćama i smetnjama u poslovanju uzrokovanim karantenom, zatim priče o medicinskim radnicima u prenatrpanim bolnicama koji su bili prisiljeni izabrati koji će se pacijenti liječiti. Početak treće faze nastaje kada je tržište S&P 500 započelo ponovno svoj rast, a obilježile su je vijesti o fiskalnoj i monetarnoj politici koja je obećavala poticaje i pomoći. Događaji su se uspoređivali s mjerama protiv velike recesije 2008.-2009. godine, koje su urodile plodom, pa je prevladalo prisjećanje na kolapse, ali nakon kojih slijedi snažan oporavak (Shiller, 2020).

Utjecaj psihologije na ponašanje na financijskom tržištu moglo se uočiti i u događajima na njujorškoj burzi u siječnju 2021. godine. U zadnjem tjednu siječnja, cijena dionica GameStopa, prodavača video igara, narasla je za 323% u tjednu i 1700% u mjesecu. Unutar tvrtke nije se dogodilo ništa što je potaknulo povećanje i fundamentalne osnove nisu se promijenile. Bio je to špekulativni mjehurić. Skupina malih investitora, uglavnom amatera, koji trguju putem platforme Robinhood, popularne i besplatne online aplikacije za trgovanje, smatrala je da veliki trgovci, poput *hedge* fondova na Wall Streetu, špekuliraju na način da destabiliziraju tržište, ostvarujući neprikladnu zaradu na račun malih investitora. Kada su *hedge* fondovi kupili *put* opcije ("prodaja na kratko"), kladeći se da će dionica GameStopa pasti, mali investitori su se „mobilizirali” putem društvene mreže, kupujući dionice GameStopa i time podižući njihovu cijenu, zbog čega su *hedge* fondovi pretrpjeli gubitke. Motiv za nastavak kupnje ili jahanje špekulativnog vala bilo je, baš kao što se u kockarnicama kockaju, radi zabave, ili nanošenje boli *hedge* fondovima, kao svojevrsna populistička politička poruka (Frankel, 2021).

Ekonomisti su dugo ustrajali na tome da investitori znaju što žele, razumiju kompromis između rizika i nagrade i koriste informacije logično za postizanje svojih ciljeva. U praksi se, međutim, često pokazalo da su te pretpostavke pogrešne. Nalazi u neuroznanosti potvrđuju da ljudski mozak često navodi ljude da čine stvari koje nemaju logički, ali imaju savršen emocionalni smisao (Zweig, 2007).

4. MODELIRANJE STRUKTURALNIM JEDNADŽBAMA

4.1 Modeliranje strukturalnim jednadžbama temeljeno na kovarijanci (CB-SEM)

4.1.1 Karakteristike SEM metode

Modeliranje strukturalnim jednadžbama (eng. *structural equation modeling,* SEM) pripada drugoj generaciji metoda multivarijatne analize (Awang, 2012). Dio je skupine statističkih metoda koje imaju za cilj objasniti veze između više varijabli. SEM ispituje strukturu međusobnih veza varijabli, izraženih kao niz jednadžbi sličnih onima kod višestruke regresije (Tabachnick i Fidell, 2007; Hair et al., 2010). Ovim jednadžbama opisuju se sve veze između konstrukata (zavisnih i nezavisnih varijabli) koji su uključeni u analizu. SEM se može smatrati jedinstvenom kombinacijom dvaju tipova multivarijatnih metoda: istraživanja međuovisnosti ili ovisnosti između promatranih varijabli. Naime, temelji ove metode su faktorska analiza i analiza višestruke regresije. U literaturi se pojavljuje i pod drugim nazivima, kao npr. analiza strukture kovarijanci, analiza latentnih varijabli, uzročno modeliranje, uzročna analiza, simultano modeliranje jednadžbama, analiza puta ili konfirmatorna faktorska analiza, gdje su zadnja dva naziva zapravo specifični tipovi SEM-a. Glavne karakteristike SEM-a su (Tabachnick i Fidell, 2007; Hair et al., 2010; Kline, 2011; Civelek, 2018):

- Procjena nekoliko međuovisno povezanih direktnih i indirektnih veza između varijabli,
- Sposobnost prikaza direktno nemjerljivih koncepata i korekcije za komponente pogreške u procesu procjene,
- Definiranje modela koji objašnjava skup odnosa ovisnosti.

Za razliku od višestruke regresije, koja odvojeno testira odnose ovisnosti između varijabli putem pojedinačnih regresijskih jednadžbi, SEM sve te veze testira simultano. Osim toga, SEM može uključiti latentne varijable (konstrukte, faktore), tj. hipotetske koncepte koje nije moguće direktno mjeriti, u analizu, što je jedna od glavnih snaga i prednosti korištenja ove metode. **Latentne varijable** mjere se putem mjerljivih, tj. **manifestnih varijabli** (indikatora) koje se prethodno prikupljaju različitim metodama (ankete, testovi i sl.). Kao primjeri latentnih varijabli navode se različiti stavovi, osobine, inteligencija, motivacija, socio-ekonomski status i slično (Raykov i Marcoulides, 2006; Hair et al., 2010; Kline, 2011; Civelek, 2018). Regresijska analiza također zanemaruje potencijalnu pogrešku mjerenja u eksplanatornim (prediktorskim, nezavisnim) varijablama. Posljedično, rezultati regresijske analize mogu biti netočni i ukazivati na zavaravajuće

zaključke. Komponenta pogreške uvijek je prisutna jer se niti jedan koncept ne može savršeno izmjeriti. Međutim, uključivanjem skupa više varijabli (indikatora) za objašnjenje pojedinog koncepta, može se procijeniti pouzdanost mjerenja te doprinos svakog indikatora u odražavanju tog koncepta (Raykov i Marcoulides, 2006; Tabachnick i Fidell, 2007; Hair et al., 2010).

Latentne varijable, odnosno konstrukti, mogu biti egzogeni i endogeni. **Egzogeni konstrukti** određeni su vanjskim čimbenicima, odnosno nisu objašnjeni niti jednim konstruktom ili varijablom iz modela, pa se mogu smatrati nezavisnim varijablama. Predstavljaju linearne kombinacije indikatora koji čine konstrukt. S druge strane, **endogeni konstrukti** teoretski su određeni faktorima unutar modela, što ih čini zavisnim varijablama (Raykov i Marcoulides, 2006; Hair et al., 2010).

Stoga, SEM se može definirati kao „multivarijatna tehnika koja kombinira aspekte faktorske analize i višestruke regresije, što omogućava simultano ispitivanje niza međusobno povezanih odnosa ovisnosti manifestnih varijabli (indikatora) i latentnih varijabli, kao i između nekoliko latentnih varijabli“ (Hair et al., 2010).

SEM je **konfirmatorna tehnika** i svaki postavljeni model predstavlja nekakvu teoriju. Teorija se može razmatrati kao „skup odnosa koji pruža dosljedno i sveobuhvatno objašnjenje određenih pojava“ (Hair et al., 2010). Cilj SEM-a je testiranje teorije, odnosno procjena u kojoj mjeri je teoretski postavljen model potvrđen empirijskim podacima. Modeli se ne bi trebali graditi bez teoretske podloge, već je potrebno, temeljem empirijskih i teorijskih istraživanja, objasniti postavljene uzročno-posljedične veze unutar modela (Raykov i Marcoulides, 2006; Hair et al., 2010; Schumacker i Lomax, 2010; Kline, 2011). Kako bi se ove veze postavile, potrebno je uspostaviti pretpostavku **uzročnosti** (eng. *causation, causal relation*). Prije nego što se može potvrditi postojanje uzročno-posljedičnih veza, tj. uzročnosti, mora biti zadovoljeno pet preduvjeta (Hair et al., 2010; Kline, 2011; Kline, 2012):

1. Varijabla za koju se pretpostavlja da je uzrok (npr. X) mora se dogoditi prije one za koju se pretpostavlja da je posljedica (npr. Y), odnosno postoji tzv. vremenska prednost (eng. *temporal precedence*).
2. Postoji dovoljan stupanj povezanosti ili kovarijacije između dviju promatranih varijabli.
3. Ne postoje druga vjerodostojna objašnjenja (npr. strane ili zbunjujuće varijable) kovarijacije između pretpostavljenog uzroka i pretpostavljene posljedice.

4. Poznat je oblik distribucije podataka.
5. Smjer uzročne veze točno je specificiran; odnosno X doista uzrokuje Y, a ne obrnuto, ili se X i Y međusobno uzrokuju na recipročan način.

S obzirom na kompleksne veze koje se mogu razmatrati putem SEM-a, uobičajeno je vizualno prikazati model tzv. **dijagramom putanje (eng. *path diagram*)**. Simbolika u dijagramu je sljedeća (Raykov i Marcoulides, 2006; Hair et al., 2010; Kline, 2011; Ho, Stark i Chernyshenko, 2012; Civelek, 2018):

- Manifestne varijable prikazane su kao kvadrati ili pravokutnici,
- Latentne varijable prikazane su kao krugovi ili elipse,
- Pretpostavljeni utjecaj jedne varijable na drugu (direktni efekt) prikazan je ravnom strelicom s jednim vrhom,
- Kovarijance (u nestandardiziranom rješenju) i korelacije (u standardiziranom rješenju) između nezavisnih (egzogenih) varijabli prikazane su zakrivljenom linijom sa strelicama u dva smjera.

Osim navedenog, još se prikazuju i komponente pogreške manifestnih (eng. *measurement error*) i latentnih varijabli (eng. *residual error*). Parametri SEM modela uključuju: izravne učinke na endogene varijable (bilo od egzogenih ili drugih endogenih varijabli), faktorska opterećenja (eng. *factor loadings*) koja povezuju indikatore s pripadajućom latentnom varijablom te varijance i kovarijance egzogenih varijabli (Raykov i Marcoulides, 2006; Kline, 2011). Prikaz simbola koji se koriste u dijagramu putanje nalazi se na slici 4.1.

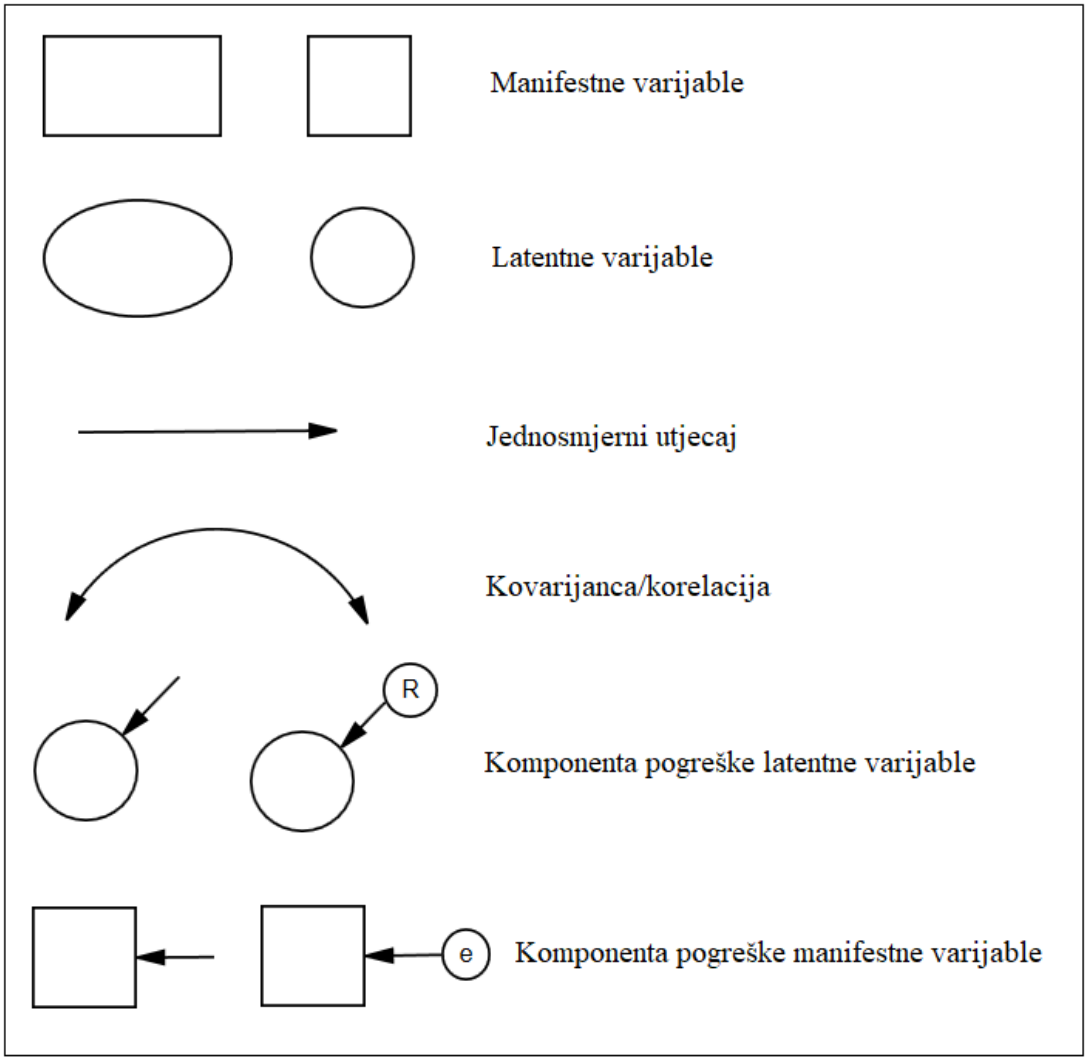

Slika 4.1. Prikaz simbola SEM-a u path dijagramu

Izvor: izrada autorice prema Raykov i Marcoulides (2006), Hair et al. (2010), Kline (2011) i Civelek (2018)

Kako je prethodno spomenuto, veze u modelu mogu biti definirane kao odnosi ovisnosti (eng. *dependence relationship*) ili kao korelacijske veze (eng. *correlational (covariance) relationship*). Kod odnosa ovisnosti, prema samom dijagramu putanje, strelica se kreće u smjeru od nezavisne prema zavisnoj varijabli (Hair et al., 2010; Kline, 2011). Kod mjernog modela, ove veze označavaju strelice koje se kreću iz pojedinog konstrukta prema njegovim indikatorima. U smislu strukturalnog modela, ove se veze promatraju između konstrukata, gdje se grafički strelice kreću od nezavisnih do zavisnih varijabli, što u konačnici određuje hoće li se konstrukt (faktor, latentna varijabla) smatrati endogenim ili egzogenim (Hair et al., 2010). Kod korelacijske veze, pretpostavlja se da postoji određena povezanost između egzogenih konstrukata, ali se ne

pretpostavlja da je jedan konstrukt uzrok promjene drugoga. Egzogeni konstrukti ne mogu dijeliti ovakve veze s endogenim, već s njima mogu dijeliti samo uzročno-posljedične veze. Unutar SEM modela mogu se naći obje vrste veza između manifestnih i latentnih varijabli, ovisno o tome što se analizira na temelju uspostavljene teoretske podloge (Hair et al., 2010).

Primjer SEM modela prikazan je na slici 4.2. Na slici se može uočiti razlika između mjernog (eng. *measurement model*) i strukturalnog modela (eng. *structural model*). **Mjerni model** dio je cjelovitog SEM modela, a odnosi se na veze između manifestnih (indikatora) i latentnih varijabli (konstrukata), dok se **strukturalnim modelom** prikazuju svi odnosi ovisnosti isključivo između latentnih varijabli (Raykov i Marcoulides, 2006; Hair et al., 2010; Awang, 2012; Ho, Stark i Chernyshenko, 2012; De Carvalho i Chima, 2014).

Latentne varijable, odnosno faktori ili konstrukti označeni su kao F1, F2, F3 i F4. Faktori F1 i F2 su egzogeni konstrukti, a između njih je pretpostavljena i korelacijska povezanost. Svaki faktor mjeren je putem tri manifestne varijable (indikatora), koje su za egzogene faktore označene kao $X1,X2,...,X6$, a za endogene kao $Y1,Y2,...,Y6$. Svaki indikator, kao i endogeni faktori (zavisne varijable), imaju i komponentu pogreške, jer nisu savršeno objašnjeni nezavisnim varijablama u modelu (Hair et al., 2010). Dodatno, može se primijetiti kako je faktor F3 s jedne strane zavisna varijabla, na koju utječu F1 i F2, dok je s druge strane prediktor varijable F4. Dakle, putem SEM-a mogu se procijeniti i direktni (izravni) te indirektni (neizravni) utjecaji svih promatranih varijabli (Civelek, 2018).

U SEM terminologiji varijable i parametri često se simbolički označavaju i grčkim slovima (Raykov i Marcoulides, 2006; Hair et al., 2010; Brown i Moore, 2012; Hoyle, 2012). Prema tome, kako je i vidljivo na prikazanoj slici, egzogeni faktori označavaju se grčkim slovom ξ (ksi), a endogeni grčkim slovom η (eta). Putevi koji predstavljaju faktorska opterećenja između faktora i pripadajućih indikatora označavaju se kao λ (lambda), dok se put koji predstavlja uzročno-posljedičnu vezu (ekvivalentno regresijskom koeficijentu) između dva faktora označava kao γ (gama) ako povezuje egzogeni i endogeni konstrukt ili kao β (beta) ako povezuje dva endogena konstrukta. Zakrivljena linija s dvosmjernom strelicom, koja prikazuje kovarijaciju između egzogenih faktora označava se grčkim slovom φ (fi). Osim toga, komponente pogrešaka također se mogu označavati grčkim slovima, i to kao δ (delta) ako se radi o indikatoru egzogenog faktora

ili kao ε (epsilon) ako se radi o indikatoru endogenog faktora, dok se neobjašnjeni dio za same latentne faktore može označiti grčkim slovom ζ (zeta). Pomoću navedenih simbola može se predočiti način na koji se raspisuju jednadžbe koje se odnose na mjerni i na strukturalni model. Primjer jednadžbi za mjerni model koji se odnosi na faktor F1 (ξ_1) izgleda ovako (Raykov i Marcoulides, 2006; Hair et al., 2010; Hoyle, 2012; Civelek 2018):

$$\begin{aligned} X_1 &= \lambda_1\xi_1 + e_1 \\ X_2 &= \lambda_2\xi_1 + e_2 \\ X_3 &= \lambda_3\xi_1 + e_3 \end{aligned} \tag{4.1.}$$

Jednadžbe za strukturalni model, za faktore F3 (η_1) i F4 (η_2) mogu se raspisati ovako:

$$\begin{aligned} \eta_1 &= \gamma_1\xi_1 + \gamma_2\xi_2 + R_1 \\ \eta_2 &= \beta_1\eta_1 + R_2 \end{aligned} \tag{4.2.}$$

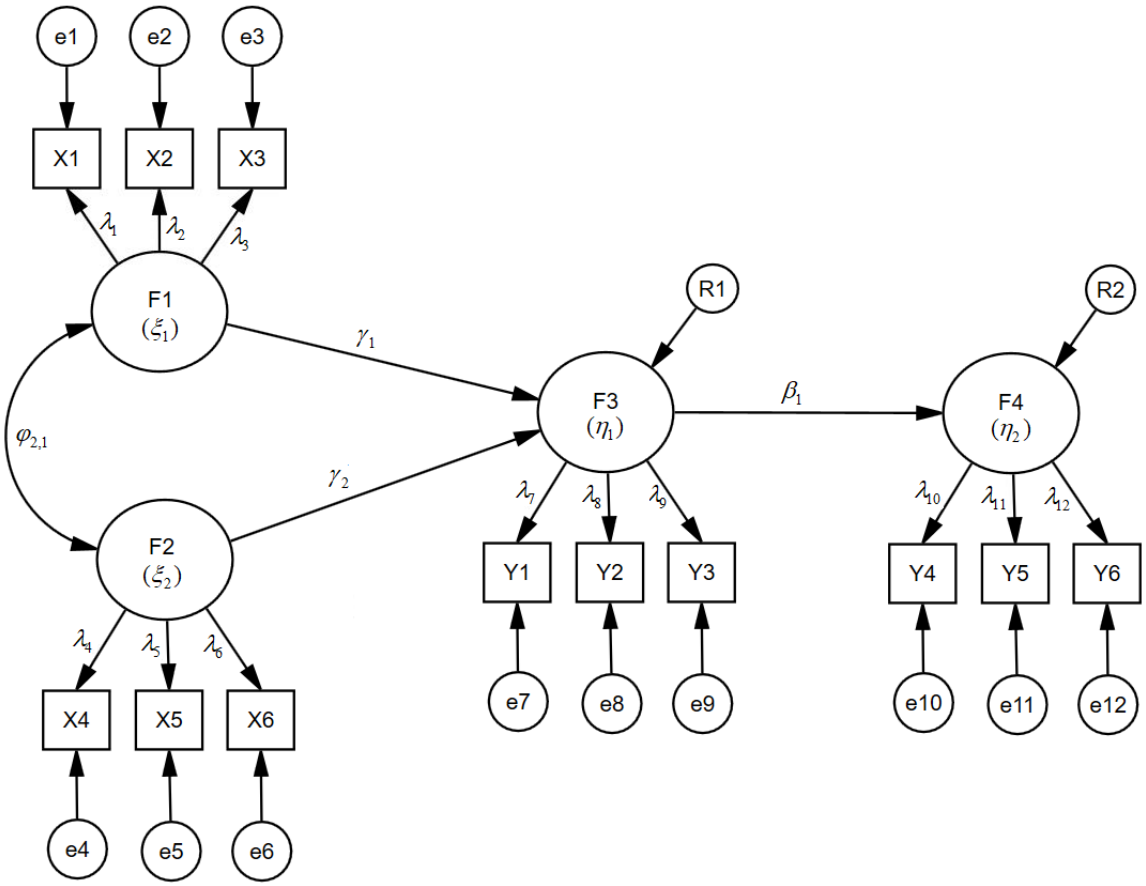

Slika 4.2. Primjer SEM modela

Izvor: izrada autorice

Općenito, tri su glavne jednadžbe za SEM, od kojih se jedna odnosi na strukturalni model, a dvije na mjerni model. To su sljedeće jednadžbe (Tabachnick i Fidell, 2007; Schumacker i Lomax, 2010; Bollen i Noble, 2011; Hoyle, 2012; Bauldry, 2015; Khamis et al., 2017):

$$\eta = \mathrm{B}\eta + \Gamma\xi + \zeta \tag{4.3.}$$

$$X = \Lambda_x \xi + \delta \tag{4.4.}$$

$$Y = \Lambda_y \eta + \varepsilon \tag{4.5.}$$

U jednadžbi 4.3., koja se odnosi na strukturalni model, η predstavlja ($m \times 1$) vektor m endogenih latentnih varijabli, B je ($m \times m$) matrica strukturalnih koeficijenata koji povezuju latentne endogene varijable, Γ je ($m \times n$) matrica strukturalnih koeficijenata koji opisuju vezu egzogenih i endogenih latentnih varijabli, ξ je ($n \times 1$) vektor n egzogenih latentnih varijabli, a ζ je ($m \times 1$) vektor pogreški strukturalnog modela.

Jednadžbe 4.4. i 4.5. odnose se na mjerni model. Oznaka X predstavlja ($q \times 1$) vektor indikatora egzogenog faktora, Λ_x je ($q \times n$) matrica faktorskih opterećenja koja povezuju indikatore x s egzogenim faktorima ξ ($n \times 1$), a δ je ($q \times 1$) vektor pogreški mjernog modela za X. Nadalje, Y je ($p \times 1$) vektor indikatora endogenog faktora, Λ_y je ($p \times m$) matrica faktorskih opterećenja koja povezuju indikatore y s endogenim faktorima η ($m \times 1$), a ε je ($p \times 1$) vektor pogreški mjernog modela za Y.

Prikaz ovih jednadžbi SEM modela u matričnom obliku sa svim prethodno opisanim oznakama prikazan je na slici 4.3. (Schumacker i Lomax, 2010). Osim toga, postoji i nekoliko matrica varijanci i kovarijanci. Matrica Φ sadrži varijance i kovarijance između egzogenih, tj. nezavisnih latentnih varijabli, a Ψ je matrica koja sadrži varijance i kovarijance pogreški endogenih latentnih varijabli. Matrica varijanci i kovarijanci između pogreški mjernog modela za X označava se sa Θ_δ, a matrica varijanci i kovarijanci između pogreški mjernog modela za Y označava se kao Θ_ε.

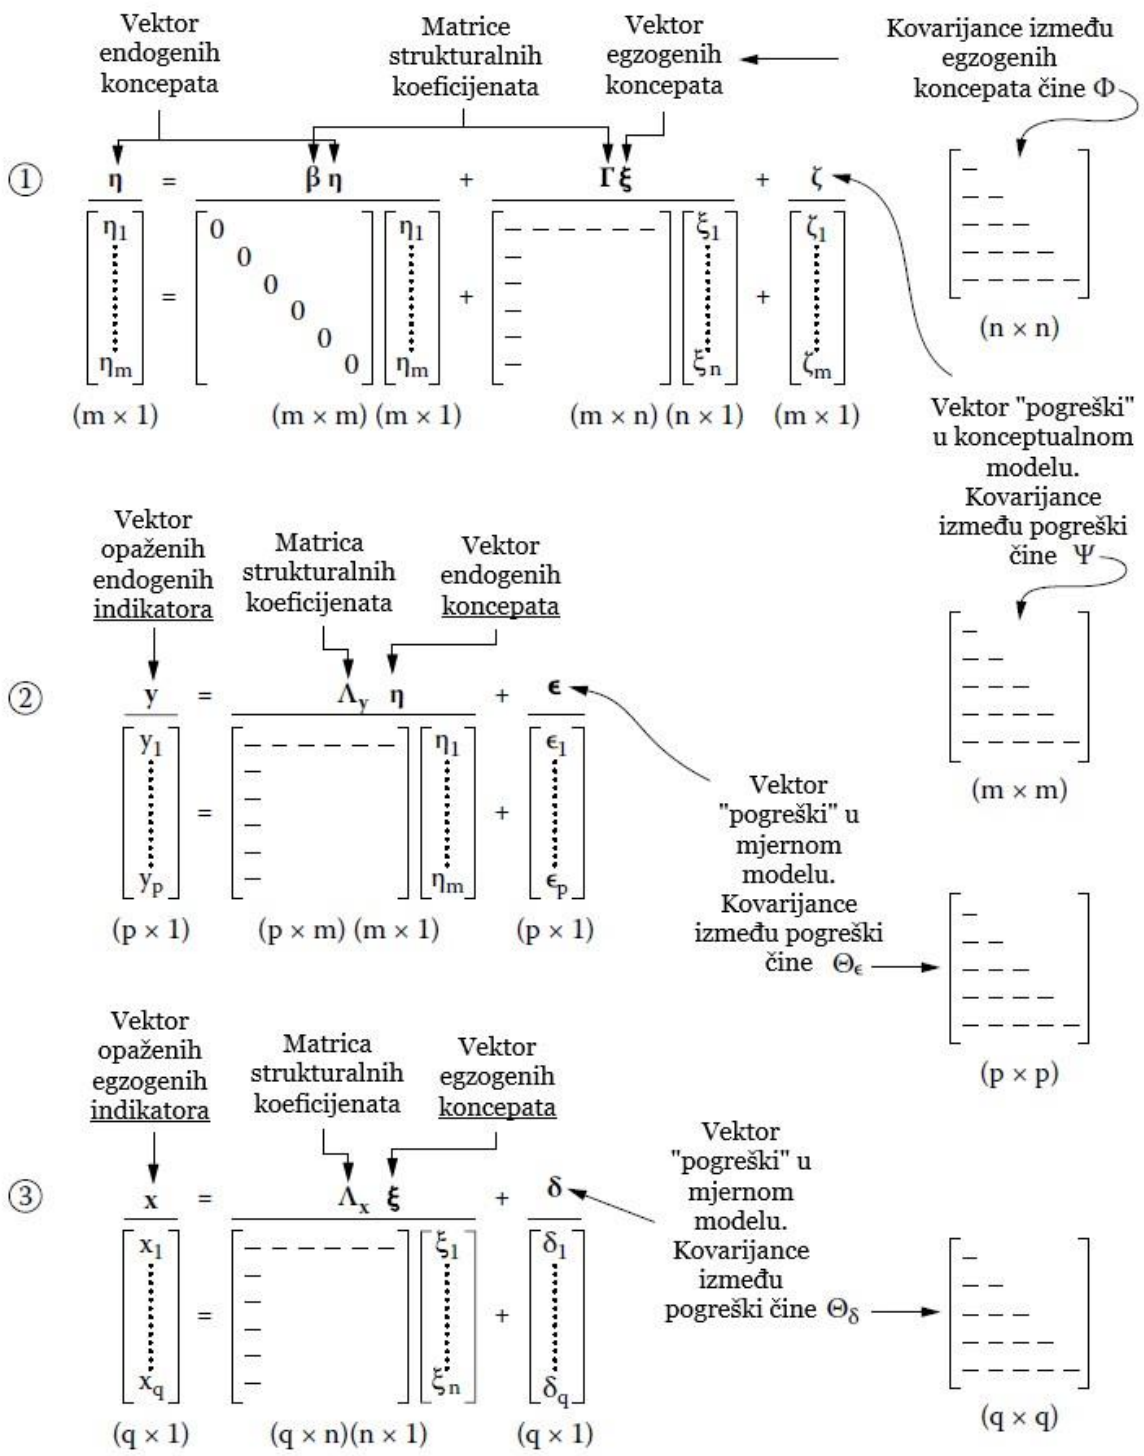

Slika 4.3. Prikaz općih jednadžbi SEM modela u matričnom obliku

Izvor: izrada autorice prema Schumacker i Lomax (2010, str. 374)

Pretpostavke modeliranja strukturalnih jednadžbi (Tabachnick i Fidell, 2007; Hair et al., 2010; Schumacker i Lomax, 2010; Kline, 2011; Civelek, 2018) odnose se na:

- Veličinu uzorka i nedostajuće podatke,
- Multivarijatnu normalnost i netipična opažanja (*outliere*),
- Linearnost,
- Nepostojanje multikolinearnosti i singularnosti i
- Reziduale.

U idealnim uvjetima, istraživači bi uvijek imali potpune baze podataka, bez nedostajućih vrijednosti. Ukoliko **nedostaju** neki **podaci** (eng. ***missing data***), to komplicira testiranje SEM modela (Kline, 2011). Prema Schumacker i Lomax (2010), istraživačima se nude različite mogućnosti glede nedostajućih podataka, a to je prvenstveno jednostavno brisanje ispitanika čije vrijednosti nedostaju, zatim zamjena vrijednosti nedostajućih podataka ili korištenje robusnih statističkih postupaka, koji uvažavaju prisutnost podataka koji nedostaju. Kod ovog problema važno je ispitati mjeru i obrazac nedostajućih podataka (Hair et al., 2010) te se problem mora riješiti ukoliko taj obrazac nije slučajan ili nedostaje više od 10% podataka. Samo nekoliko nedostajućih vrijednosti kod velikih uzoraka ne treba biti zabrinjavajuće, primjerice manje od 5% nedostajućih vrijednosti kod pojedine varijable. To osobito vrijedi ako su podaci izgubljeni slučajno, tj. nesistemski (Kline, 2011). Podaci mogu nedostajati **potpuno slučajno** (eng. ***missing completely at random,*** **MCAR**) ili **slučajno** (eng. ***missing at random,*** **MAR**). Prema Hair et al. (2010), gubitak podataka je MCAR ako „obrazac podataka koji nedostaju za neku varijablu ne ovisi o bilo kojoj drugoj varijabli u bazi podataka ili o vrijednostima same varijable“. S druge strane, gubitak podataka je MAR, „ako je obrazac podataka koji nedostaju za varijablu povezan s drugim varijablama, ali nije povezan s vlastitim vrijednostima“. MCAR je samo jača pretpostavka slučajnosti nedostajućih podataka, iako je u stvarnosti teško donijeti definitivan zaključak o obrascu nedostajućih podataka (Kline, 2011). Postoji nekoliko pristupa koji mogu pomoći u rješavanju problema nedostajućih podataka (McDonald i Ho, 2002; Hair et al., 2010; Schumacker i Lomax, 2010; Kline, 2011; Graham i Coffman, 2012):

- ***Metode dostupnih slučajeva (eng. available case methods)*** – najčešće se spominju tzv. *listwise* metoda, kod koje se brišu sva opažanja s nedostajućim vrijednostima na bilo kojoj varijabli, i *pairwise* metoda, prema kojoj se brišu isključivo opažanja s nedostajućim

vrijednostima za varijable koje su uključene u određenu analizu. *Listwise* metoda je problematična kod manjih uzoraka te manjih faktorskih opterećenja, stoga bi se trebala koristiti kod većih uzoraka (Hair et al., 2010; Kline, 2011). *Pairwise* metoda nije generalno preporučljiva za korištenje, osim ako je broj nedostajućih vrijednosti malen (Kline, 2011; Graham i Coffman, 2012).

- ***Pojedinačno umetanje podataka (eng. single-imputation methods)*** – osnovna metoda je supstitucija aritmetičkom sredinom (eng. *mean substitution*), kojom se svaka nedostajuća vrijednost zamjenjuje aritmetičkom sredinom cijelog uzorka. Varijacija ove metode je supstitucija aritmetičkom sredinom grupe (eng. *group-mean substitution*), što podrazumijeva da se vrijednost koja nedostaje za određenu grupu (npr. grupa muški spol) zamijeni prosječnom vrijednosti te iste grupe. Osim toga, podaci se mogu umetati i temeljem regresije (eng. *regression-based imputation*), pa se tako svaka nedostajuća vrijednost zamjenjuje procijenjenom vrijednošću koristeći višestruku regresiju temeljenu na dostupnim vrijednostima drugih varijabli. Sofisticiranija metoda je metoda podudaranja uzoraka (eng. *pattern matching*), gdje se računalno vrijednost koja nedostaje zamjenjuje vrijednošću koju ima neko drugo opažanje sličnog profila vrijednosti po svim drugim varijablama (Kline, 2011).
- ***Umetanje podataka na temelju modela (eng. model-based imputation)*** – ove metode zamjenjuju nedostajuće podatke skupom procijenjenih vrijednosti, odnosno definira se više skupova podataka: oni potpuni i nepotpuni (McDonald i Ho, 2002; Kline, 2011). Dvije poznate metode umetanja podataka na temelju modela su ML (eng. *maximum likelihood estimation of missing values*) i EM pristup (eng. *expectation-maximization algorithm*) (Hair et al., 2010; Kline, 2011). Ova metoda se preferira kada je uzorak manji i kada nedostaje više podataka (Hair et al., 2010; Schumacker i Lomax, 2010).
- ***Specijalna vrsta ML procjene za nepotpune podatke (eng. special form of ML estimation for incomplete data)*** – kod ove metode podaci se ne brišu, niti se umeću nove vrijednosti na mjesto nedostajućih. Umjesto toga, opažanja iz baze podataka se dijele na podgrupe, od kojih svaka ima isti obrazac nedostajućih podataka. Potom se izvlače relevantne statističke informacije iz svake podgrupe pa su sva opažanja zadržana u analizi te su procjene parametara i njihove standardne pogreške izračunate iz potpunog skupa podataka. Neke

simulacije potvrdile su da ova metoda generalno daje bolje rezultate u odnosu na klasične metode (Kline, 2011).

SEM je općenito tehnika koja zahtijeva **veće uzorke** u usporedbi s ostalim multivarijatnim pristupima. Ako uzorak nije dovoljno velik, standardne pogreške mogu biti netočne, a povećava se i vjerojatnost tehničkih problema u analizi (Tabachnick i Fidell, 2007; Hair et al., 2010; Kline, 2011). Osim toga, procjene parametara i razni testovi prilagodbe modela također su osjetljivi na veličinu uzorka (Hair et al., 2010; Kline, 2011; Civelek, 2018). Iskustvenim pravilom predlaže se da minimalna veličina uzorka bude najmanje 10 puta, a idealno 20, veća od broja parametara koji se mogu procijeniti u modelu ($N:q$ pravilo; gdje je N broj opažanja, a q broj parametara). Sukladno tome, uz željeni omjer veličine uzorka i parametara, 20:1, ako je $q=10$, idealna veličina uzorka bila bi $20 \cdot 10$, odnosno 200. Za isti $q=10$, manje idealan, no često predložen omjer od 10:1 dao bi idealnu veličinu uzorka od $10 \cdot 10$, odnosno 100. Smanjenjem $N:q$ omjera ispod 10:1, smanjuje se i pouzdanost rezultata (Raykov i Marcoulides, 2006; Schreiber et al., 2006; Hair et al., 2010; Schumacker i Lomax, 2010; Kline, 2011; Civelek, 2018). Prema nekim istraživačima, predložene veličine uzorka za SEM uglavnom se kreću u rasponu od 150 do 400, a česta veličina uzorka je 200 (Hair et al., 2010; Schumacker i Lomax, 2010; Kline, 2011; Civelek, 2018). Međutim, na veličinu uzorka utječe nekoliko drugih čimbenika, kao npr. multivarijatna normalnost, kompleksnost modela, nedostajući podaci, prosječna objašnjena količina varijacija među indikatorima, metoda procjene i sl. (Raykov i Marcoulides, 2006; Hair et al., 2010; Kline, 2011) pa se ne može uzeti samo jedna veličina uzorka kao optimalna za sve modele. Naime, ako podaci ne zadovoljavaju pretpostavku **multivarijatne normalnosti distribucije**, potreban je veći uzorak, dok se s manjim uzorcima može raditi ako su podaci normalno distribuirani (Hair et al., 2010; Kline, 2011; Kline, 2012). Dakle, prije analize podataka trebalo bi ispitati pretpostavku normalnosti i postojanje netipičnih opažanja, koja su često uzrok asimetričnih podataka. Normalnost se ispituje putem različitih testova, poput Kolmogorov-Smirnov testa, Shapiro-Wilk testa, Mardia testa, Cox-Small testa, ali kod velikih uzoraka i manje odstupanje od normalnosti može dovesti do signifikantnog rezultata, što je ograničenje ovih testova (McDonald i Ho, 2002; Hair et al., 2010; Kline, 2011; Civelek, 2018). Stoga, može se analizirati i univarijatna normalnost putem pokazatelja asimetrije i zaobljenosti distribucije. Na taj način, ako varijable zadovoljavaju univarijatnu normalnost, to može pomoći, ali ne i garantirati, postizanje multivarijatne normalnosti (Hair et al.,

2010; Kline, 2011). Netipična opažanja mogu se identificirati putem Mahalanobisove udaljenosti (eng. *Mahalanobis distance*), Cookove udaljenosti (eng. *Cook's Distance*) ili putem *leverage* vrijednosti (Hair et al., 2019a; Kline, 2011; Civelek, 2018), a i normalnost i netipična opažanja mogu se dodatno, uz statističke testove, pregledati i grafičkim prikazima, kao što su tzv. *normal probability plot*, *stem-and-leaf plot* ili *box-plot* dijagram (Hair et al., 2010; Kline, 2011). Zaključno, u slučaju kada podaci nisu normalno distribuirani, trebao bi se povećati uzorak, a ako to nije moguće, također se mogu transformirati podaci ili koristiti alternativne metode procjene (Raykov i Marcoulides, 2006; Tabachnick i Fidell, 2007; Hair et al., 2010; Schumacker i Lomax, 2010; Kline, 2011; Kline, 2012). **Kompleksniji modeli** također zahtijevaju veće uzorke. Najjednostavnije rečeno, to su modeli s više indikatora, ali to mogu biti i modeli s više konstrukata, koji zahtijevaju procjenu većeg broja parametara, kao i modeli s manje od tri indikatora po konstruktu (Hair et al., 2010). Kako je prethodno spomenuto, potencijalni nedostajući podaci mogu utjecati na potrebu za većim uzorkom, naročito kada se koriste metode brisanja određenih opažanja. Osim toga, veličina uzorka ovisi i o prosječnoj objašnjenoj varijaciji među indikatorima, koja bi trebala biti što veća, uz veća standardizirana faktorska opterećenja (barem 0.7). U slučaju da je manje varijacija među indikatorima objašnjeno, potrebno je povećati uzorak da bi se postigla stabilnost i konvergencija modela (Hair et al., 2010). Temeljem svega navedenog, Hair et al. (2010) daju sljedeće smjernice vezane uz veličinu uzorka:

- Modeli s pet ili manje konstrukata, od kojih svaki ima više od tri indikatora i visok udio objašnjenih varijacija među indikatorima (0.6 ili više), mogu se adekvatno procijeniti i s manjim uzorcima (100-150).
- Ako je objašnjenost varijacija među indikatorima umjerena (0.45-0.55) ili u modelu postoje konstrukti s manje od tri indikatora, veličina uzorka trebala bi biti barem 200.
- Niža objašnjenost varijacija među indikatorima, uz višestruke konstrukte s manje od tri indikatora, ukazuje da bi uzorak trebao biti najmanje 300, a poželjno i više.
- Ako model ima više od šest konstrukata, od kojih neki imaju manje od tri indikatora, a i prosječna objašnjenost varijacija među indikatorima je niska, potreban je uzorak od preko 500.
- Uzorak treba povećati kada nije zadovoljena pretpostavka multivarijatne normalnosti, kada su korištene alternativne metode procjene i kada nedostaje više od 10% podataka.

SEM testira **linearne** veze među varijablama, bilo između više latentnih varijabli ili između latentnih i manifestnih varijabli. Linearnost povezanosti između manifestnih varijabli može se procijeniti grafički putem dijagrama rasipanja (Tabachnick i Fidell, 2007; Schumacker i Lomax, 2010; Kline, 2011). Ako veza nije linearna, mogu se koristiti kvadratni efekti, odnosno uključuju se manifestne varijable na drugu ili veću potenciju, kao kod višestruke regresije (Tabachnick i Fidell, 2007).

U modelu se može dogoditi i **(multi)kolinearnost**, ako bi se ispostavilo da različite varijable zapravo mjere istu pojavu, odnosno ako su nezavisne varijable međusobno značajno povezane (Kline, 2011; Civelek, 2018). Ovo može narušiti pretpostavku uzročnosti u modelu te nije poželjno. Uzročnost se može potvrditi ako veza varijabli uzroka i posljedica ostaje konstantna kada se drugi prediktori uključe u model te kada je utjecaj pogreške konstrukta neovisan o uzročnom konstruktu (Hair et al., 2010). Multikolinearnost može uzrokovati netočne procjene parametara i standardnih pogrešaka za veze između egzogenih i endogenih latentnih varijabli te povećanje greške tipa II (Bandalos i Gagné, 2012). Isto tako, može doći do problema invertiranja matrice, pa tako singularnost matrice ($det \approx 0$) ukazuje na potencijalni problem multikolinearnosti u modelu (Raykov i Marcoulides, 2006; Tabachnick i Fidell, 2007). Dodatni problem s matricama zbog multikolinearnosti može biti pojava korelacijskih koeficijenata koji su veći od 1, što znači da matrica korelacije nije pozitivno definitna. U tom slučaju ne postoji rješenje, odnosno ne mogu se izračunati procjene parametara (Raykov i Marcoulides, 2006; Tabachnick i Fidell, 2007; Hair et al., 2010; Schumacker i Lomax, 2010; Kline, 2011). Multikolinearnost se može otkriti putem pokazatelja tolerancije (TOL) i faktora inflacije varijance (VIF). Pokazatelj TOL manji od 0.10 i VIF veći od 10 ukazuju na postojanje multikolinearnosti (Hair et al., 2010; Kline, 2011).

Kod SEM-a, **reziduali** predstavljaju razliku između opaženih i procijenjenih kovarijanci (Hair et al., 2010). Oni bi, nakon procjene modela, „trebali biti mali i centrirani oko nule, a distribucija kovarijanci reziduala treba biti simetrična“ (Tabachnick i Fidell, 2007). U protivnom, dolazi se do zaključka o neprikladnom modelu, koji dobro procjenjuje samo dio varijanci. Kod pojave visokih reziduala, može se razmotriti dodavanje novih veza u model (Tabachnick i Fidell, 2007).

Nakon provjere svih preduvjeta za testiranje SEM modela, potrebno je: definirati konstrukte, specificirati mjerni model, procijeniti parametre, testirati validnost mjernog modela, specificirati strukturalni model te procijeniti njegove parametre. Za zadovoljavajući model donose se zaključci

o rezultatima, dok se za model koji nije zadovoljavajući nudi mogućnost dorade ili respecifikacije modela ili testiranje s novim podacima (Hair et al., 2010; Dragan i Topolšek, 2014). Navedene faze SEM modeliranja prikazane su na slici 4.4.

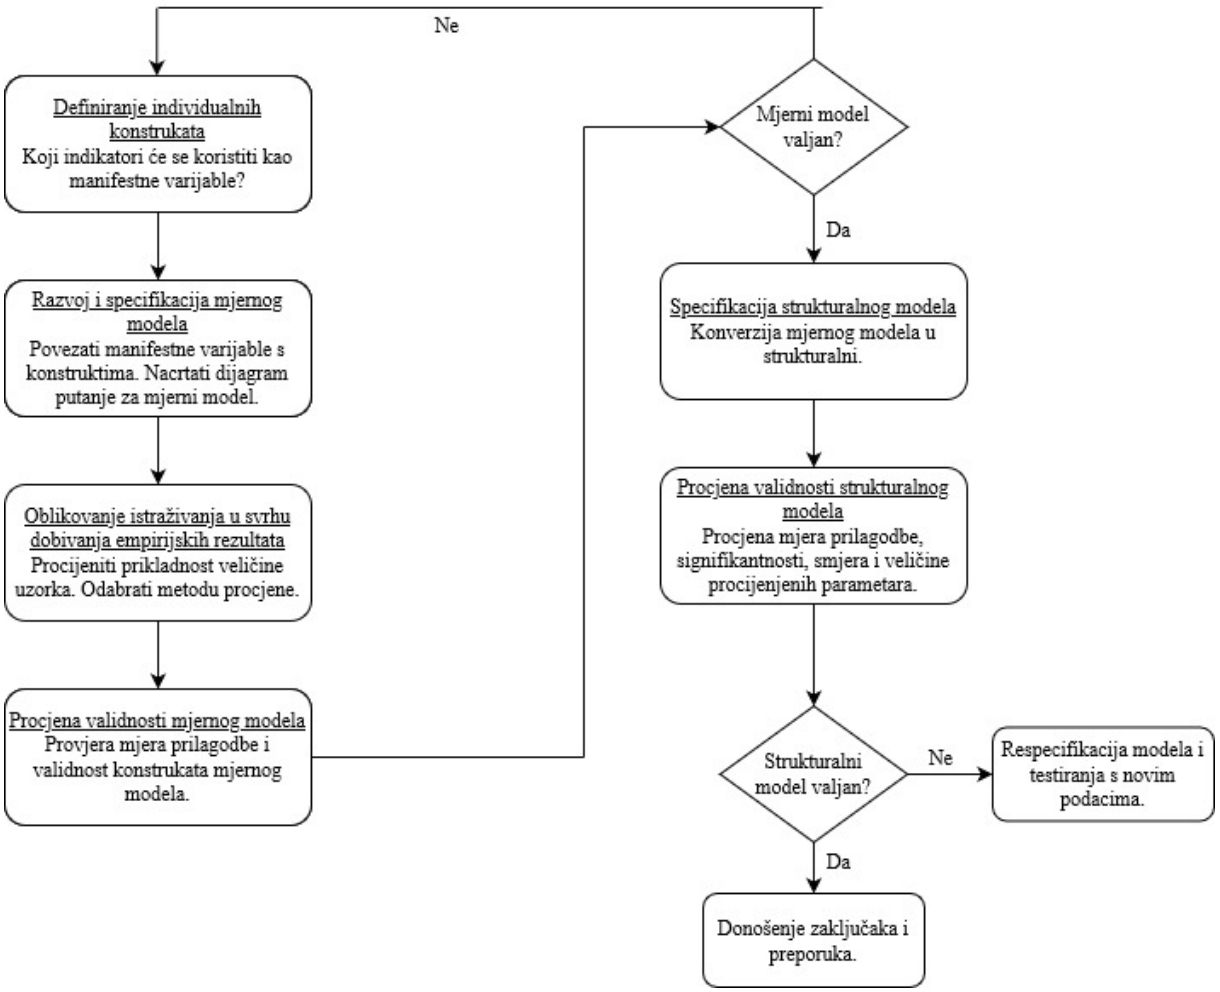

Slika 4.4. Faze SEM modeliranja

Izvor: izrada autorice prema Hair et al. (2010, str. 566)

4.1.2 Specifikacija i identifikacija modela

Specifikacija modela odnosi se na proces formuliranja modela, odnosno korištenje svih relevantnih informacija za razvoj teorijskog modela. Drugim riječima, određuju se svi odnosi i parametri u modelu, čime se zapravo prikazuju sve istraživačke hipoteze u formi SEM modela (Schumacker i Lomax, 2010; Bollen i Noble, 2011; Kline, 2011). Ovo je najvažniji korak u provedbi strukturalnog modeliranja, jer preostali koraci podrazumijevaju da je model u osnovi točan. Često se proces specifikacije modela započinje grafičkim prikazom varijabli i njihovih

međusobnih veza, uz grafičke simbole koji su objašnjeni u prethodnom poglavlju. Alternativno, naknadno se ove veze mogu prikazati i nizom jednadžbi (Kline, 2011).

Kako je prethodno spomenuto i prikazano, SEM modeli sastoje se od mjernog i strukturalnog modela. Mjernim modelom specificira se mjerna teorija, koja pokazuje kako manifestne varijable predstavljaju latentne varijable, odnosno koliko dobro ih indirektno mjere. Stoga se može reći kako je u suštini mjerni model konfirmatorna faktorska analiza (eng. *confirmatory factor analysis*, CFA) (McDonald i Ho, 2002; Schreiber et al., 2006; Hair et al., 2010). Strukturalni model stavlja naglasak na ispitivanje uzročno-posljedičnih veza među konstruktima i, kod modeliranja u dva koraka, izvodi se iz mjernog modela (Schreiber et al., 2006; Hair et al., 2010).

Kod specifikacije modela, bitno je unaprijed, temeljem teoretskih pretpostavki, odrediti broj konstrukata (faktora) i njihovih odgovarajućih indikatora te veze između njih. Osim toga, važno je ustanoviti jednodimenzionalnost, koja osigurava da svaki indikator mjeri samo jedan konstrukt i da su komponente pogreške međusobno nezavisne (Hair et al., 2010; Kline, 2011). Konstrukti se mogu mjeriti i samo jednim indikatorom (eng. *single-indicator measurement*), ali u rijetkim slučajevima, dok se većinom koriste višestruki indikatori (eng. *multiple-indicator measurement*), koji predstavljaju određeni konstrukt (Hair et al., 2010; Kline, 2011). Ovo pitanje broja indikatora po konstruktu usko je vezano s **identifikacijom modela**, koja se odnosi na utvrđivanje postoji li dovoljno podataka za identificiranje rješenja skupa strukturalnih jednadžbi (Hair et al., 2010). Spomenuti podaci dobivaju se iz matrice kovarijanci iz uzorka. Model se smatra identificiranim ako je teoretski moguće dobiti jednu jedinstvenu procjenu za svaki slobodni parametar (Tabachnick i Fidell, 2007; Kline, 2011; Kenny i Milan, 2012). Razinu identifikacije određuje broj parametara koji se procjenjuju i broj opažanja (eng. *observations*) dostupnih za analizu. Ovaj broj opažanja ne odnosi se na veličinu uzorka, već na broj jedinstvenih varijanci/kovarijanci (eng. *unique variance/covariance terms*), tj. to su različite vrijednosti u opaženoj matrici kovarijanci (S) koje uključuju varijance s dijagonale matrice te kovarijance samo u donjem ili gornjem dijagonalnom dijelu matrice. Razlika između broja opažanja (jedinstvenih varijanci/kovarijanci) i broja slobodnih parametara predstavlja stupnjeve slobode (df). Minimalni zahtjev za identificiranost modela jest da broj stupnjeva slobode bude veći ili jednak nuli ($df \geq 0$). Stupnjevi slobode se izračunavaju na sljedeći način (Loehlin, 2004; Raykov i Marcoulides, 2006; Hair et al., 2010; Schumacker i Lomax, 2010; Kline, 2011; Kenny i Milan, 2012):

$$df = p - q \tag{4.6}$$

gdje je:

p – broj opažanja (jedinstvenih varijanci i kovarijanci), a

q – broj slobodnih parametara.

Broj opažanja (jedinstvenih varijanci/kovarijanci) računa se kao:

$$p = v(v+1)/2 \tag{4.7}$$

pri čemu v predstavlja broj manifestnih varijabli.

Poznate su tri razine identifikacije modela (Loehlin, 2004; Raykov i Marcoulides, 2006; Tabachnick i Fidell, 2007; Hair et al., 2010; Schumacker i Lomax, 2010; Kline, 2011):

- ***Neidentificiran model (eng. underidentified)*** – model koji ima više parametara koji se trebaju procijeniti u odnosu na broj jedinstvenih varijanci i kovarijanci. Ovakav model ima negativne stupnjeve slobode, odnosno $df < 0$. Drugim riječima, ne postoji dovoljno informacija za procjenu jednog ili više parametara.
- ***Točno identificiran model (eng. just-identified)*** – model koji ima jednak broj parametara i jedinstvenih varijanci i kovarijanci, odnosno $df = 0$. U ovakvom modelu svaki je parametar jedinstveno procijenjen, jer postoji dovoljno informacija u matrici kovarijanci, tj. iskorištene su sve informacije. Stoga se putem CFA procijenjena matrica kovarijanci savršeno reproducira i dobivaju se savršene mjere prilagodbe modela. Ovakvi modeli nazivaju se i zasićenim (eng. *saturated*) modelima, koji nisu od naročitog interesa istraživačima.
- ***Previše identificiran model (eng. overidentified)*** – model koji ima manje parametara u odnosu na broj jedinstvenih varijanci i kovarijanci, tj. ima pozitivan broj stupnjeva slobode ($df > 0$). Kod ovakvih modela postoji više od jednog načina procjene parametara, jer postoji više nego dovoljno informacija u matrici kovarijanci i upravo ovakvi modeli su najpoželjniji istraživačima. Naime, previše identificirani modeli su uvijek u nekoj mjeri pogrešni i upravo ta razina greške govori koliko je dobra (ili loša) istraživačka hipoteza s

dostupnim podacima. Samo ovi modeli pružaju mjere prilagodbe kao način za procjenu prilagodbe cjelokupnog modela.

Na slici 4.5. prikazani su primjeri triju razina identifikacije modela. Temeljem svakog dijagrama putanje, i bez prikaza matrice kovarijanci, moguće je izračunati broj jedinstvenih varijanci/kovarijanci, kao i broj stupnjeva slobode za svaki model, koristeći formule 4.6. i 4.7. Prema tim formulama, broj jedinstvenih varijanci i kovarijanci za modele je sljedeći:

- Neidentificiran model: $p = v(v+1)/2 = 2(2+1)/2 = 2 \cdot 3/2 = 3$
- Točno identificiran model: $p = v(v+1)/2 = 3(3+1)/2 = 3 \cdot 4/2 = 6$
- Previše identificiran model: $p = v(v+1)/2 = 4(4+1)/2 = 4 \cdot 5/2 = 10$

Stupnjevi slobode za modele su sljedeći:

- Neidentificiran model: $df = p - q = 3 - 4 = -1 < 0$
- Točno identificiran model: $df = p - q = 6 - 6 = 0$
- Previše identificiran model: $df = p - q = 10 - 8 = 2 > 0$

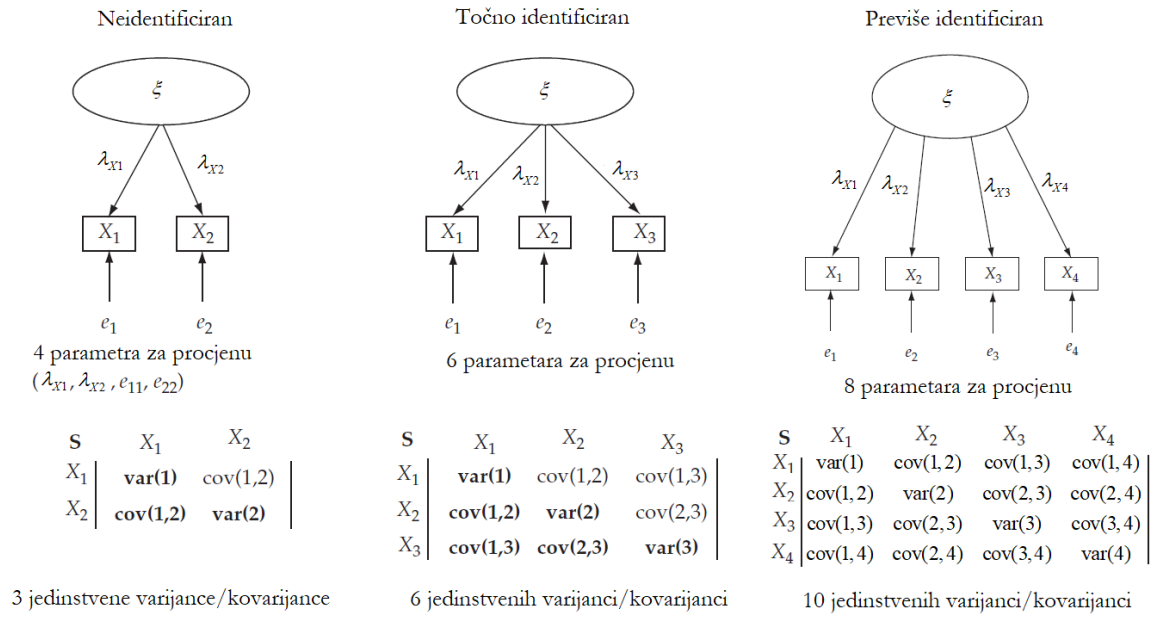

Slika 4.5. Primjeri razina identifikacije modela

Izvor: izrada autorice prema Hair et al. (2010, str. 609-610)

Iako je CFA model s jednim konstruktom mjerenim putem dva indikatora neidentificiran, uključivanjem istoga u veći mjerni ili strukturalni model s više konstrukata može rezultirati i previše identificiranim modelom. Primjenjuju se ista pravila identifikacije i na većim modelima pa bi tako višak stupnjeva slobode od potencijalnih drugih konstrukata iz modela osigurao dodatne stupnjeve slobode za postizanje identifikacije modela (Hair et al., 2010). Ako se radi o standardnom CFA modelu, gdje je uspostavljena jednodimenzionalnost i kod kojega ne postoje korelacije između komponenti pogreške, tada bi model s jednim konstruktom trebao imati barem tri indikatora, kako bi se postigla identifikacija. Ovo se naziva **pravilom tri indikatora** (eng. *three indicator rule*). Ukoliko standardni CFA model ima više od dva konstrukta, s po dva ili više indikatora po konstruktu, tada se također postiže identifikacija modela, što predstavlja pravilo dva indikatora (eng. *two indicator rule*) (Hair et al., 2010; Kline, 2011). Nadalje, poželjno je da se koristi barem četiri indikatora po konstruktu kad god je to moguće, tri indikatora po konstruktu su prihvatljiva, naročito kada ostali konstrukti u modelu imaju veći broj indikatora, a trebalo bi izbjegavati konstrukte s manje od tri indikatora. Konkretno, najviše problema s identifikacijom uzrokuju konstrukti mjereni samo jednim indikatorom, koje bi svakako trebalo izbjegavati (Hair et al., 2010).

Na identifikaciju modela može utjecati i **status parametra**, koji može biti slobodan (eng. *free*), fiksiran (eng. *fixed*) ili ograničen (eng. *constrained*) (Raykov i Marcoulides, 2006; Kline, 2011; Hair et al., 2010; Kenny i Milan, 2012; Civelek, 2018). **Slobodni parametri** su oni koji nemaju unaprijed dodijeljenu vrijednost, već se ona treba procijeniti pomoću podataka pri modeliranju. **Fiksiranim parametrima** vrijednost je određena danom konstantom i oni ne mijenjaju vrijednost tijekom procjene modela. Primjerice, ako promatramo varijable X i Y, pretpostavka da X nema direktan utjecaj na Y odgovarala bi specifikaciji da je koeficijent za jednosmjerni utjecaj X→Y fiksiran na nula. Slično tome, ukoliko bi se pretpostavilo da ne postoji korelacija između dva ili više egzogenih faktora, to bi ukazivalo na specifikaciju koja uključuje fiksiranje vrijednosti parametara koji pokazuju korelaciju na nula. Na grafičkom prikazu tada ne bi postojala dvosmjerna strelica među egzogenim faktorima (Raykov i Marcoulides, 2006). **Ograničeni parametar** procjenjuje se unutar određenog ograničenja, ali nije fiksno jednako nekakvoj konstanti. Ograničenja mogu biti različita, a ovise o vrijednostima drugih parametara. **Ograničenje jednakosti** (eng. *equality constraint*) pretpostavlja da su procjene dvaju ili više parametara jednake. Kod **ograničenja jednakosti među grupama** (eng. *cross-group equality constraint*)

postavlja se uvjet da se izvedu jednake procjene nekog parametra u svim grupama. Ovakva specifikacija odgovara pretpostavci da je parametar jednak u svim populacijama iz kojih su uzeti uzorci. Rjeđi slučajevi ograničenja su ograničenje proporcionalnosti, ograničenje nejednakosti i nelinearno ograničenje. **Ograničenjem proporcionalnosti** (eng. *proportionality constraint*) određuje se da je vrijednost jednog parametra proporcija vrijednosti drugog parametra, dok se **ograničenjem nejednakosti** (eng. *inequality constraint*) prisiljava da vrijednost procjene parametra bude ili veća ili manja od vrijednosti neke konstante. Osim toga, **nelinearno ograničenje** (eng. *nonlinear constraint*) nameće nelinearnu vezu između dvije procjene parametara (Kline, 2011). Na slici 4.6. prikazan je model s različitim vrstama parametara, s naznakama o kojoj se vrsti parametra radi. Osim prikazanih, parametrima fiksiranim na nulu smatraju se i svi oni gdje ne postoji veza među varijablama.

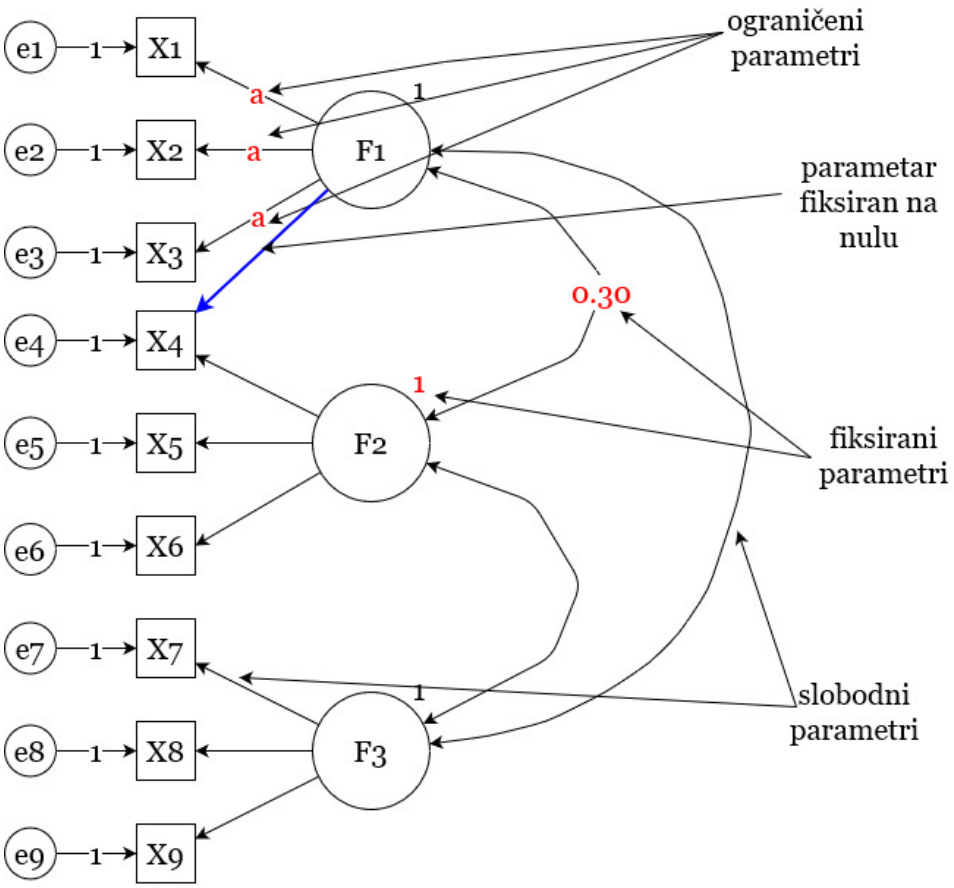

Slika 4.6. Primjeri različitih parametara u modelu

Izvor: izrada autorice

Fiksiranje parametara može pomoći u identifikaciji modela, jer se na taj način postavlja mjerna ljestvica latentnog faktora. Najčešće se vrijednost jednog nestandardiziranog parametra, tj. faktorskog opterećenja (eng. *factor loading*) u mjernom modelu fiksira na 1. To se zove ULI ograničenje (eng. *unit loading identification* (ULI) *constraint*). Alternativno, moguće je fiksirati i varijancu određenog faktora na 1, kroz tzv. UVI ograničenje (eng. *unit variance identification* (UVI) *constraint*), što rezultira standardizacijom toga faktora (Hair et al., 2010; Kline, 2011).

Mjerni modeli mogu biti reflektivni i formativni, ovisno o tome kakva je pretpostavka uzročnosti između faktora i njegovih indikatora. U većini slučajeva, kroz bihevioralna istraživanja, smatra se da latentni faktori uzrokuju manifestne varijable i da se javlja pogreška zbog nemogućnosti njihovog potpunog objašnjavanja. Drugim riječima, pretpostavlja se da određeni broj manifestnih varijabli, tj. indikatora, reflektira odgovarajući faktor. Stoga se takvi modeli nazivaju **reflektivni mjerni modeli** (eng. *reflective measurement models*), a indikatori su reflektivni (eng. *reflective indicators*) ili indikatori posljedice (eng. *effect indicators*). Grafički se to prikazuje na način da strelica koja prikazuje jednosmjerni utjecaj ide od faktora prema indikatoru (Hair et al., 2010; Kline, 2011; Kline, 2012). Za ovakve modele vrijedi pretpostavka da su svi indikatori međusobno visoko korelirani i zamjenjivi. Stoga, bilo koji indikator može biti izostavljen iz analize, bez promjene značenja faktora, dok god taj faktor ima dovoljnu pouzdanost i dok god ostaju barem tri indikatora koji odražavaju taj faktor, kako bi se izbjegli problemi identifikacije modela (Hair et al., 2010; Hanafiah, 2020). U društvenim znanostima često se analiziraju stavovi, osobnost, bihevioralne namjere i slično, što se opisuje reflektivnim mjernim modelom. Primjerice, ako se promatra osobnost kroz određeni broj indikatora koji odražavaju ponašanje pojedinca, tada zapravo osobnost pojedinca uzrokuje njegovo ponašanje u određenim situacijama. Navedena veza odgovara specifikaciji reflektivnog modela. Slično tome, u medicini se mogu promatrati određeni simptomi koji ukazuju na nekakvu bolest. Međutim, ti simptomi ne uzrokuju bolest, već bolest uzrokuje simptome, što također odgovara ispitivanju reflektivnog modela.

S druge strane, **formativni mjerni modeli** (eng. *formative measurement models*) temelje se na pretpostavci da indikatori uzrokuju faktor. Takvi se indikatori nazivaju formativnim (eng. *formative indicators*), odnosno indikatorima uzroka (eng. *cause indicators*). Tada se faktori smatraju objašnjavajućim kombinacijama indikatora. Na grafičkom prikazu formativnog modela, strelica koja pokazuje jednosmjerni utjecaj kreće se od indikatora prema faktoru. Kod formativnih

modela, na faktore utječu indikatori koji ih predstavljaju, kao i broj samih faktora koji utječu na ostale faktore. Stoga, dodavanjem ili uklanjanjem indikatora, konceptualno značenje faktora može se promijeniti (Hair et al., 2010; Kline, 2011; Kline, 2012; Hanafiah, 2020). U tom slučaju, „ako indikatori konceptualno predstavljaju model, oni se i dalje smatraju adekvatnima s gledišta empirijskog predviđanja“ (Hanafiah, 2020). Osim toga, među formativnim indikatorima ne bi smjela postojati visoka kolinearnost, a sami formativni modeli su neidentificirani. Iz tog razloga, potrebno je uključiti dodatne varijable ili faktore, kako bi se postigla identifikacija modela. Zbog tih ograničenja, za procjenu formativnih modela prikladniji je PLS-SEM (eng. *partial least squares structural equation modeling*) (Hair, Ringle i Sarstedt, 2011; Hair et al., 2019), o čemu će biti riječi u nastavku rada. Kao primjer formativnog faktora može se uzeti marketing miks, koji se sastoji od kombinacije četiriju različitih varijabli. Slično tome, indikatori poput ukupne imovine, prodaje, troškova i sl. mogu biti pokazatelji uzroka bankrota, gdje bi se onda bankrot mogao promatrati kao formativni faktor.

Slika 4.7. grafički prikazuje razliku između jednostavnog formativnog i reflektivnog modela, koji se sastoje od po četiri indikatora. Vidljivo je kako se kod formativnog modela strelice utjecaja kreću od indikatora prema faktoru, a u reflektivnom od faktora prema indikatoru. Kako je prethodno i objašnjeno, upravo te strelice opisuju smjer uzročnosti u svakom pojedinom modelu.

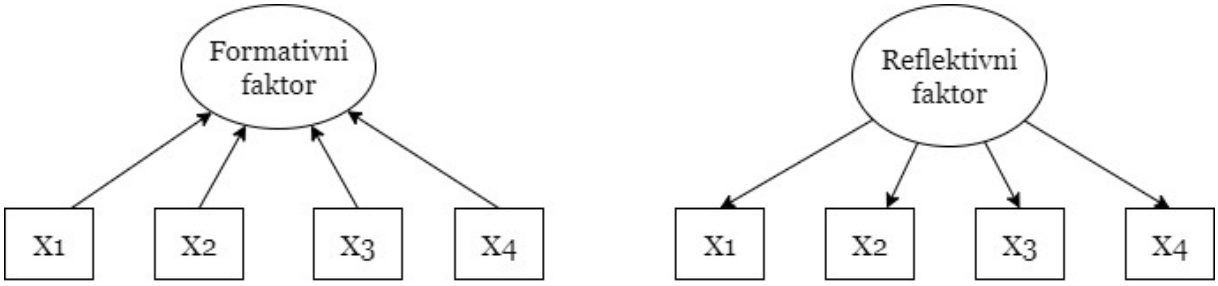

Slika 4.7. Razlika između formativnog i reflektivnog modela

Izvor: izrada autorice

Kada se CFA model modificira, definiranjem uzročno-posljedičnih veza, specificira se strukturalni model. On je štedljiviji (eng. *parsimonious*) od CFA modela, jer sadrži manje parametara za procjenu (Hair et al., 2010). Slika 4.8. prikazuje CFA i strukturalni model. Može se primijetiti kako u CFA modelu postoje četiri faktora, svaki s četiri indikatora. Između svih parova faktora postoji korelacija, odnosno pretpostavlja se da su svi faktori međusobno povezani. Kada se ove korelacije

modificiraju u uzročno-posljedične veze, dobiva se strukturalni model. On sadrži iste faktore i indikatore, ali veze su specificirane na način da su A i B egzogeni faktori, među kojima postoji korelacija. Ovi faktori utječu na faktor C, koji je stoga ishod faktora A i B, a istovremeno i uzrok faktora D, jer utječe na njega. Specifikacijom strukturalnog modela, tj. modifikacijom postojećeg CFA modela, smanjen je i broj parametara koji se trebaju procijeniti, što je također vidljivo na slici.

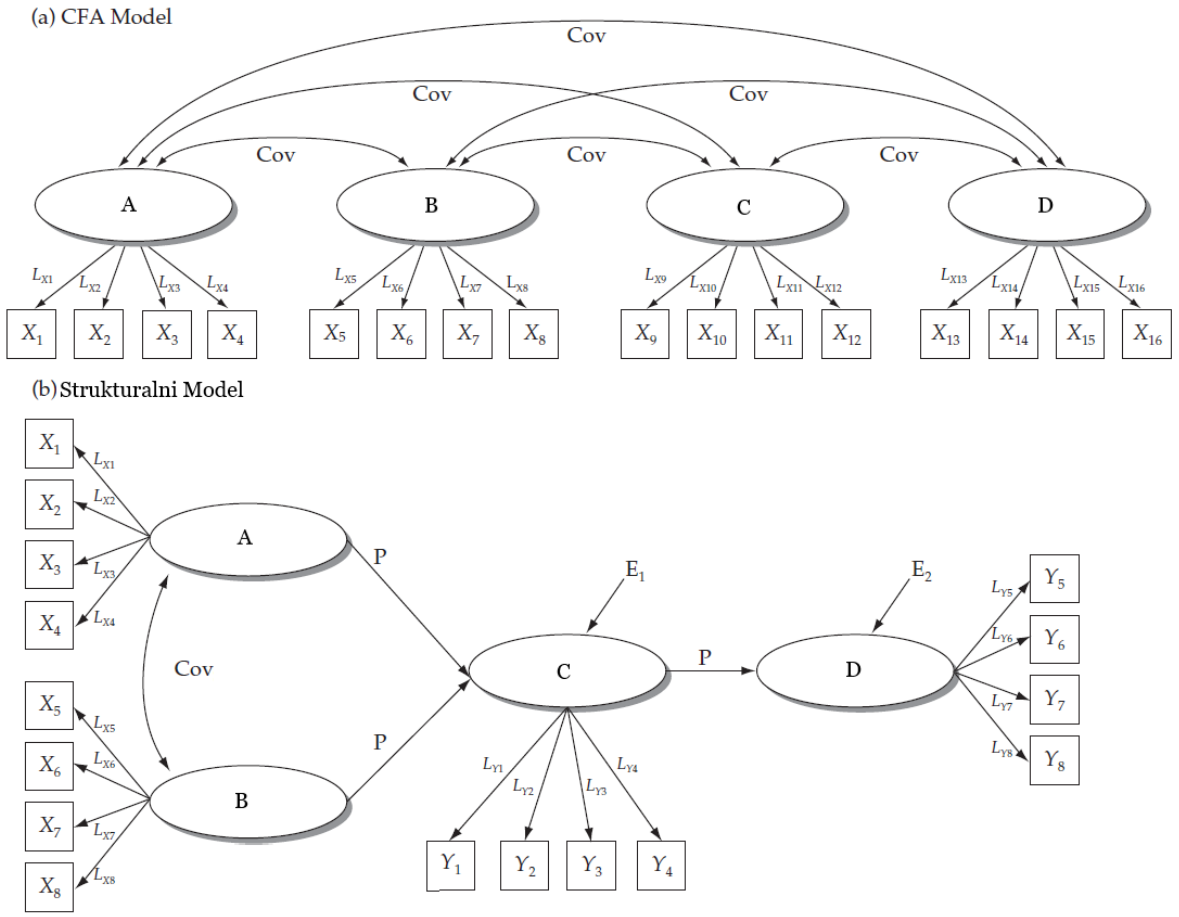

Slika 4.8. Primjer modifikacije CFA modela u strukturalni model

Izvor: izrada autorice prema Hair et al. (2010, str. 645)

Što se tiče strukturalnih modela, oni mogu biti specificirani kao rekurzivni i nerekurzivni. Ako su sve veze u strukturalnom modelu jednosmjerne, tada se radi o **rekurzivnom modelu** (eng. *recursive model*). Suprotno tome, **nerekurzivni modeli** (eng. *nonrecursive model*) sadrže povratnu vezu (eng. *feedback loop*), odnosno jedan faktor istovremeno ima ulogu prediktora i ishoda drugoga faktora. Povratna veza može biti direktna ili indirektna. Direktna povratna veza promatra dva faktora koji su međusobno i uzrok i posljedica jedan drugome, dok indirektna povratna veza

uključuje tri ili više faktora, odnosno manifestira se kroz niz puteva (eng. *paths*) ili kroz korelirane komponente pogreške (McDonald i Ho, 2002; Raykov i Marcoulides, 2006; Hair et al., 2010; Kline, 2011; Kline, 2012). Na slici 4.9. prikazani su primjeri obje vrste modela. Može se uočiti kako u rekurzivnom modelu postoji jednosmjeran utjecaj varijable Y1 na Y2, dok u nerekurzivnom modelu Y1 utječe na Y2, dok istovremeno Y2 također utječe na Y1.

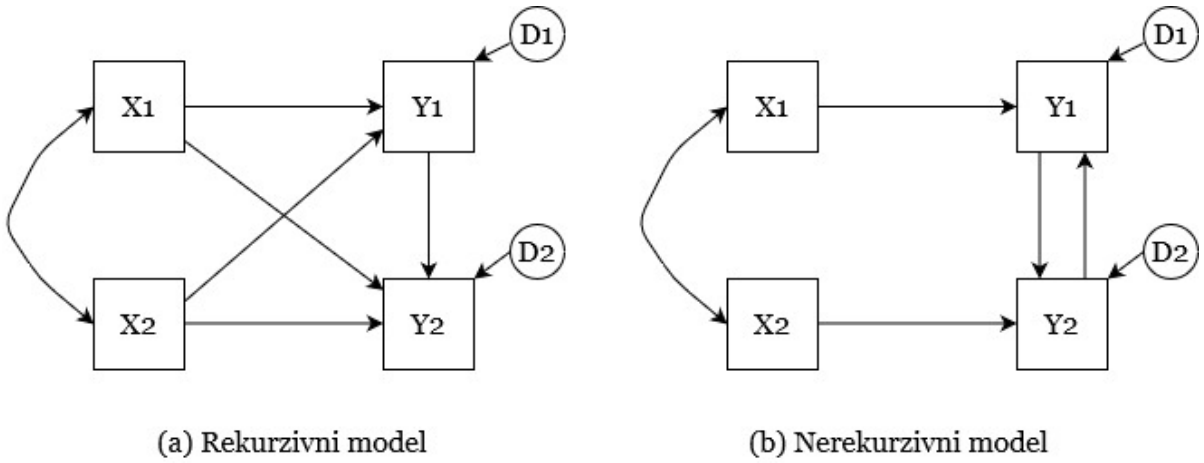

Slika 4.9. Razlika između rekurzivnog i nerekurzivnog modela

Izvor: izrada autorice prema Kline (2011, str. 107; 2012, str. 116)

4.1.3 Metode procjene modela

Procjena modela podrazumijeva dobivanje procjena slobodnih parametara iz modela. Vrijednosti procijenjenih parametara čine procijenjenu matricu kovarijanci. Cilj analize je dobiti što manju razliku između opažene, tj. matrice iz uzorka (S) i procijenjene matrice kovarijanci ($\sum$). Ova razlika ($|S - \sum_k|$) ključna je u ocjeni prilagodbe SEM modela (Hair et al., 2010; Schumacker i Lomax, 2010; Bauldry, 2015).

Kako bi se postigla minimalna razlika između matrica $\sum$ i S, postupak procjene uključuje upotrebu određene funkcije prilagodbe (eng. *fitting function*). Najpoznatija i najučestalija funkcija, odnosno metoda procjene je **metoda najveće vjerodostojnosti (eng. *maximum likelihood,* ML)**, koja se smatra metodom potpunih informacija (eng. *full-information method*) (Schumacker i Lomax, 2010; Bollen i Noble, 2011; Kline, 2011; Lei i Wu, 2012). Sukladno cilju postizanja minimalne razlike između matrice iz uzorka i procijenjene matrice kovarijanci, ML procjenitelj

temelji se na sljedećoj funkciji (Schermelleh-Engel, Moosbrugger i Müller, 2003; Tabachnick i Fidell, 2007; Lei i Wu, 2012; Dragan i Topolšek, 2014):

$$F_{ML} = \ln|\Sigma| - \ln|\mathrm{S}| + tr(\mathrm{S}\Sigma^{-1}) - \mathrm{p} \tag{4.8}$$

gdje je:

Σ – procijenjena matrica kovarijanci,

S – matrica iz uzorka,

$\ln$ – prirodni logaritam,

tr – trag matrice, a

p – broj manifestnih varijabli.

Procjene ovom metodom su asimptotski nepristrane, efikasne i konzistentne, kada su zadovoljeni uvjeti multivarijatne normalnosti i dovoljne veličine uzorka, kada su varijable iskazane omjernom skalom i kada je model točno specificiran (Hair et al., 2010; Mîndrilă, 2010; Kline, 2011), a funkcija ima oblik hi-kvadrat (χ^2) distribucije s $df = p(p+1)/2 - t$ stupnjeva slobode, gdje je t broj procijenjenih parametara u modelu (Lei i Wu, 2012)[1]. Iako je ML procjenitelj izveden pod pretpostavkom multivarijatne normalnosti, pokazalo se kako je ovaj procjenitelj robustan i ako podaci nisu normalno distribuirani, dok god su odstupanja od normalnosti relativno mala (Hair et al., 2010; Mîndrilă, 2010; Bollen i Noble, 2011; Kline, 2011; Bauldry, 2015). U tom slučaju, procjene su relativno nepristrane, ali vrijednost χ^2 testa može biti precijenjena, a vrijednosti standardnih pogreški podcijenjene (Dragan i Topolšek, 2014). ML procjena je iterativna procedura, u kojoj se kreće od inicijalnog rješenja, tj. inicijalnih pretpostavki, koje se potom poboljšavaju nizom kalkulacija (Tabachnick i Fidell, 2007; Kline, 2011). Iterativni postupak nastavlja se sve dok se vrijednosti elemenata u matrici reziduala ne mogu dalje minimizirati, što označava da je postupak procjene konvergirao (Suhr, 2006). Taj postupak može brže konvergirati, odnosno u manje iteracija pronaći rješenje, ukoliko su slične inicijalne pretpostavke i početne vrijednosti (eng.

[1] Prema prethodnim oznakama kod prikaza identifikacije modela, izračun stupnjeva slobode može se zapisati i kao: $df = v(v+1)/2 - q$, gdje je v broj manifestnih varijabli, a q broj slobodnih parametara koji se procjenjuju u modelu.

start values). Računalni softveri za SEM obično automatski generiraju početne vrijednosti, koje su obično poprilično dobre (Tabachnick i Fidell, 2007; Schumacker i Lomax, 2010; Kline, 2011).

Ponekad prilikom procjene može doći do problema, pa se tako može dogoditi da model ne konvergira. Do nekonvergencije dolazi kada iterativni postupak završi tijekom procjene zbog određenih kriterija (npr. dostignut postavljeni maksimalan broj iteracija) ili zbog prekomjernog vremena koje zahtijeva računalo. Tada model nema rješenja. Uzrok je često nedovoljno dobra specifikacija modela ili loše početne vrijednosti (Suhr, 2006). Osim toga, mogu se dobiti i nelogična rješenja. Primjerice, može se dobiti procjena vrijednosti korelacije između faktora ili standardiziranih koeficijenata koje premašuju vrijednost 1 u apsolutnoj vrijednosti. Osim toga, može se dobiti i negativna vrijednost varijance, što je poznato pod nazivom *Heywood case*. Ovakav rezultat implicirao bi manje od 0% pogreške kod indikatora i, sukladno tome, više od 100% objašnjenu varijancu indikatora, što je nemoguće (Hair et al., 2010; Schumacker i Lomax, 2010; Kline, 2011). Uzroci pojave tzv. *Heywood case* problema mogu biti (Kline, 2011):

- Pogreške u specifikaciji,
- Neidentificiranost modela,
- Prisutnost *outliera* koji mogu iskriviti rješenje,
- Loše početne vrijednosti ili
- Ekstremno niske ili visoke korelacije populacije, koje rezultiraju empirijskom neidentifikacijom.

Ovi problemi češći su kod testiranja modela s manjim uzorkom ili s manje od tri indikatora po faktoru. U takvim slučajevima, kako bi se riješio problem *Heywood case*, potrebna je respecifikacija modela. Primjerice, problematične procjene mogu se fiksirati na neke jako niske vrijednosti, što može identificirati model, ali dati i lošije rezultate prilagodbe modela, jer ta fiksna vrijednost ne mora odgovarati pravoj vrijednosti. Osim toga, može se i izbrisati problematična varijabla (indikator), što nije poželjno ako bi tada faktor ostao na manje od tri indikatora. Također se mogu postaviti i druga ograničenja, poput ograničenja jednakosti i sl. (Chen et al., 2001; Hair et al., 2010; Van Kesteren i Oberski, 2019).

U praksi pretpostavka multivarijatne normalnosti često nije zadovoljena, a također se, naročito u društvenim znanostima, jako često analiziraju varijable koje su iskazane redoslijednom skalom.

ML metoda nije prikladna za redoslijedne varijable, jer su procjene osjetljive na vrstu varijable, no taj utjecaj se smanjuje ako je veći broj kategorija redoslijedne varijable (Mîndrilă, 2010; Kline, 2011; Awang, Afthanorhan i Mamat, 2016; Newsom, 2018). Istraživači stoga sugeriraju minimalno 5, a idealnije 7 ili 10 kategorija redoslijedne varijable, kako bi se one mogle tretirati kao omjerne i procjenjivati ML metodom (Carifio i Perla, 2007; Mîndrilă, 2010; Rhemtulla, Brosseau-Liard i Savalei, 2012; Awang, Afthanorhan i Mamat, 2016; Newsom, 2018).

Kako je već spomenuto, ML metoda u uvjetima kada nije zadovoljena normalnost distribucije daje male standardne pogreške, stoga testovi značajnosti parametara rezultiraju većom greškom tipa I, a vrijednosti pokazatelja prilagodbe modela, prvenstveno hi-kvadrat testa, nisu pouzdani (Kline, 2011; Newsom, 2018). Jedan od načina izbjegavanja pristranosti u rezultatima je normalizacija varijabli transformacijama i testiranje takvih varijabli ML metodom. Osim toga, moguće je analizirati originalne podatke ML metodom, ali uz robusne standardne pogreške. Najpoznatiji primjer korigirane testne veličine je Satorra-Bentler testna veličina, koja prilagođava vrijednost dobivenu ML procjenom za količinu koja odražava stupanj zaobljenosti (Tomarken i Waller, 2005; Tabachnick i Fidell, 2007; Schumacker i Lomax, 2010; Kline, 2011; Lei i Wu, 2012; Dragan i Topolšek, 2014; Newsom, 2018).

Osim toga, razvijene su i druge metode procjene modela, od kojih neke zahtijevaju zadovoljen uvjet normalnosti distribucije podataka, a neke ne. **Metoda generaliziranih najmanjih kvadrata (eng. *generalized least squares*, GLS)** i **metoda neponderiranih najmanjih kvadrata (eng. *unweighted least squares*, ULS)** također pretpostavljaju da je zadovoljena multivarijatna normalnost. ULS metoda zapravo je tip metode najmanjih kvadrata, OLS (eng. *ordinary least squares*, OLS), koja minimizira zbroj kvadrata odstupanja između kovarijanci iz uzorka i procijenjenih kovarijanci, ali nije efikasna kao ML metoda. Ograničenje ULS metode je zahtjev da sve manifestne varijable imaju istu skalu, dok je potencijalna prednost to što ova metoda ne zahtijeva pozitivno definitnu kovarijacijsku matricu (Kline, 2011). Ova metoda temelji se na sljedećoj funkciji (Schermelleh-Engel, Moosbrugger i Müller, 2003; Tabachnick i Fidell, 2007):

$$F_{ULS} = \frac{1}{2} tr\left\{(S - \Sigma)^2\right\} \tag{4.9}$$

GLS metoda može biti izražena u kvadratnom obliku, a daje slične rezultate kao ML metoda, osim u slučajevima netočno specificiranog modela. GLS metoda temelji se na sljedećoj funkciji (Olsson

et al., 2000; Schermelleh-Engel, Moosbrugger i Müller, 2003; Tabachnick i Fidell, 2007; Dragan i Topolšek, 2014; Deng, Yang, i Marcoulides, 2018; Newsom, 2020):

$$F_{GLS} = \frac{1}{2} tr\left\{(S - \Sigma)\,\mathrm{W}^{-1}\right\}^2 \tag{4.10}$$

Pri čemu je W težinska matrica, a kod GLS metode najčešće se za težinsku matricu koristi inverzna kovarijacijska matrica iz uzorka S. Ova funkcija asimptotski je ekvivalentna funkciji ML metode, stoga su s povećanjem uzorka približno jednake. GLS metoda temelji se na istim pretpostavkama kao i ML, ali manje je efikasna kod manjih uzoraka. Jednostavnost funkcije ukazuje da se može odabrati drugačija težinska matrica, kako bi se pokušao riješiti problem narušenosti distribucijskih pretpostavki (Tabachnick i Fidell, 2007; Newsom, 2020).

Osim toga, razvijene su i metode koje ne pretpostavljaju nikakve oblike distribucije, a među njih spada **metoda ponderiranih najmanjih kvadrata (eng. *weighted least squares*, WLS)**, poznata i kao **metoda proizvoljne funkcije distribucije (eng. *arbitrary distribution function*, ADF)**. Ova metoda u izračun uključuje i četvrte momente, odnosno elemente zaobljenosti (Olsson et al., 2000; Tomarken i Waller, 2005; Schermelleh-Engel, Moosbrugger i Müller, 2003; Tabachnick i Fidell, 2007; Kline, 2011; Dragan i Topolšek, 2014; Li, 2016; Newsom, 2020), a temelji se na sljedećoj funkciji:

$$F_{WLS} = (s - \sigma(\theta))' W^{-1} (s - \sigma(\theta)) \tag{4.11}$$

pri čemu je:

s – vektor podataka iz uzorka (korelacije),

$\sigma(\theta)$ – modelom procijenjen vektor elemenata populacije u matrici Σ, a

W – pozitivno definitna težinska matrica, koja ima elemente zaobljenosti i kovarijacije ($W_{ijkl} = \sigma_{ijkl} - \sigma_{ij}\sigma_{kl}$, gdje je σ_{ijkl} zaobljenost, a σ_{ij} kovarijacija).

Ova funkcija praktički je funkcija GLS metode, ponderirana zaobljenosti i kovarijacijom kako bi se korigiralo narušavanje distribucijskih pretpostavki. Ukoliko bi podaci bili normalno distribuirani, ADF/WLS procjenitelj bio bi ekvivalentan GLS procjenitelju, jer ne bi bilo

zaobljenosti (Newsom, 2020). Međutim, ova metoda zahtijeva kompleksne kalkulacije, što zahtijeva izrazito velike uzorke, kako bi rezultati bili pouzdani (Schermelleh-Engel, Moosbrugger i Müller, 2003; Tabachnick i Fidell, 2007; Kline, 2011; Dragan i Topolšek, 2014; Newsom, 2020).

Temeljem ove metode, razvijene su i posebne metode za kategorijalne i ordinalne varijable, a to su **robusne WLS metode**, koje koriste nešto jednostavnije kalkulacije u odnosu na klasični WLS procjenitelj (Kline, 2011). Robusne WLS metode su WLSM (*mean-adjusted weighted least squares*) i WLSMV (*mean and variance adjusted weighted least squares*) metode, koje uključuju samo dijagonalne elemente težinske matrice u funkciji (Olsson et al., 2000; Flora i Curran, 2004; Kline, 2011; Li, 2016):

$$F_{WLSMV} = (s - \sigma(\theta))' W_D^{-1} (s - \sigma(\theta)) \tag{4.12}$$

U rezultatima istraživanja, prema Flora i Curran (2004), pokazalo se kako WLSMV metoda daje pouzdanije rezultate u odnosu na WLS kod podataka koji su distribuirani normalno i kod onih koji nisu, iako se može javiti pristranost pri manjim uzorcima, najčešće ako je $N < 200$ (Flora i Curran, 2004; Li, 2016). Također, procjene ovom metodom manje su pristrane u odnosu na procjenu robusnom ML metodom i imaju manje greške tipa I (Kline, 2011; Dragan i Topolšek, 2014; Newsom, 2018).

Ponekad se može koristiti i tzv. ***bootstrapping*** procedura za podatke koji značajno odstupaju od normalne distribucije. Ova procedura je neparametrijska i pretpostavlja samo da su distribucije populacije i uzorka istog oblika, a temelji se na uzimanju velikog broja (najčešće se sugerira minimalno 500 do 1000) ponovljenih slučajnih uzoraka, kao reprezentativne zamjene za populaciju (tzv. pseudo populacija), kako bi se utvrdila empirijska varijacija rezultata (Loehlin, 2004; Schumacker i Lomax, 2010; Kline, 2011; Newsom, 2020). Parametri, standardne pogreške i pokazatelji prilagodbe procjenjuju se temeljem empirijskih sampling distribucija velikog broja uzoraka, a metoda je pogodna i za kategorijalne varijable, dok nije pogodna za analizu s manjim uzorcima (Kline, 2011; Dragan i Topolšek, 2014).

Pored navedenih metoda, postoji i **Bayesov pristup** procjeni parametara SEM modela. Ovaj pristup može se koristiti ukoliko se radi o nelinearnim modelima, npr. modelima koji sadrže interakcije između nekih varijabli, i fundamentalno je drugačiji od ML metode i drugih klasičnih

„frekventističkih“ metoda. Prednost ovog pristupa je korištenje prethodnih (eng. *prior*) informacija o distribuciji, kako bi se pronašla posteriorna (eng. *posterior*) vjerojatnost parametara s obzirom na dostupne podatke. Posteriorna distribucija dobiva se kao kompromis između *prior* i distribucije vjerojatnosti. Metoda je pogodna za analize s manjim uzorcima (Muthén i Asparouhov, 2012; Deng, Yang, i Marcoulides, 2018; Newsom, 2020).

4.1.4 Analiza mjernog modela

Kako bi se odgovorilo na pitanje je li mjerni model valjan (eng. *valid*), potrebno je ispitati prilagodbu modela kao cjeline, kao i validnost svakog pojedinog konstrukta (Hair et al., 2010). Nakon što je model točno specificiran i procijenjen odgovarajućom metodom, pristupa se procjeni **pokazatelja prilagodbe modela (eng. *model fit*)**, kako bi se utvrdilo koliko se dobro model prilagođava podacima. Drugim riječima, ove mjere pokazuju koliko dobro specificirani model reproducira matricu kovarijanci među indikatorima, tj. koliko su kovarijacijska matrica iz uzorka i procijenjena međusobno slične. Može se reći da se model dobro prilagođava podacima kada su elementi rezidualne matrice približno nula, što potvrđuje sličnost dviju promatranih kovarijacijskih matrica (Hair et al., 2010; Kline, 2011; Hoyle, 2012).

Poznate su tri kategorije mjera prilagodbe modela, a to su (Hair et al., 2010; Kline, 2011; Siddiqui, 2015):

- **Apsolutni pokazatelji prilagodbe** (eng. *absolute fit indices*) – predstavljaju izravnu mjeru koliko dobro istraživački model prikazuje podatke iz uzorka. Kod ovih mjera svaki model se ocjenjuje nezavisno od drugih mogućih modela.
- **Inkrementalni pokazatelji prilagodbe** (eng. *incremental fit indices*) – mogu se nazvati i komparativnim mjerama prilagodbe, jer pokazuju koliko dobro se specificirani istraživački model prilagođava podacima u usporedbi s alternativnim osnovnim (eng. *baseline*) modelom. Odnosno, ove mjere označavaju relativno poboljšanje prilagodbe istraživačkog u odnosu na osnovni model.
- **Parsimonijski pokazatelji prilagodbe** (eng. *parsimony fit indices*) – uključuju ugrađenu korekciju (eng. *penalty*) za kompleksnost modela. Prema tome, između dva modela slične prilagodbe podacima, ove mjere favorizirale bi jednostavniji model.

Osnovni pokazatelj prilagodbe modela je **hi-kvadrat (χ^2) test (eng. *chi-square*)**, čiji ključni element je procjena razlike između dviju kovarijacijskih matrica ($\mathrm{S}-\sum_k$) (Schermelleh-Engel, Moosbrugger i Müller, 2003; Hooper, Coughlan i Mullen, 2008; Hair et al., 2010). Kod velikih uzoraka gdje je zadovoljen uvjet multivarijatne normalnosti, produkt $(N-1)F_{\min}$ (N je veličina uzorka, a $F_{\min}$ minimum funkcije korištene metode procjene modela) slijedi hi-kvadrat distribuciju s $df = p - q$ stupnjeva slobode (Hu i Bentler, 1998; Schermelleh-Engel, Moosbrugger i Müller, 2003; Bollen i Noble, 2011; Kline, 2011; West, Taylor i Wu, 2012; Dragan i Topolšek, 2014). Ovo je ujedno i jedini test koji pruža statističku značajnost (signifikantnost) za ispitivanje prilagodbe modela (Hooper, Coughlan i Mullen, 2008; Schumacker i Lomax, 2010). Može se izračunati prema sljedećoj formuli (Schermelleh-Engel, Moosbrugger i Müller, 2003; Hair et al., 2010):

$$\chi^2 = (N-1)(\mathrm{S}-\sum_k) \tag{4.13}$$

gdje je

N – veličina uzorka

S – matrica iz uzorka

$\sum$ – procijenjena matrica kovarijanci, a

k – broj slobodnih parametara za procjenu.

Procijenjena matrica je pod utjecajem broja slobodnih parametara koji se procjenjuju modelom, što implicira da je vrijednost χ^2 testa također pod utjecajem broja stupnjeva slobode, koji se računaju prema formuli 4.6. (Raykov i Marcoulides, 2006; Hair et al., 2010; Siddiqui, 2015). Vrijednost hi-kvadrata nalazi su u rasponu od nule (što se postiže za zasićeni (eng. *saturated*) model, koji uključuje sve moguće veze u modelu) do maksimalne vrijednosti, koja se postiže za model neovisnosti (eng. *independence model*) koji ne uključuje niti jednu vezu u model, odnosno pretpostavlja da su sve veze između manifestnih varijabli, kao i između latentnih varijabli jednake nuli. Hi-kvadrat vrijednost dobivena temeljem procijenjenog modela nalazi se između ove dvije krajnosti (Schumacker i Lomax, 2010). Ako bi hi-kvadrat test poprimio vrijednost nula, to bi ukazivalo na savršenu prilagodbu modela, odnosno jednakost kovarijacijskih matrica. Ovo se

odnosi na točno identificirane zasićene modele, koji nisu od naročitog interesa istraživača (Schumacker i Lomax, 2010; Kline, 2011; Civelek, 2018). Naime, cilj SEM-a je približno dobro, a ne savršeno, procijeniti određeni fenomen. Sukladno tome, potrebno je postići što manju **nesignifikantnu** vrijednost hi-kvadrata kroz parsimonijski model sa značajnim parametrima. To ukazuje na relativno malu razliku između dviju promatranih kovarijacijskih matrica, odnosno zaključak da ne postoji statistički značajna razlika između njih. Drugim riječima, nesignifikantan rezultat s *p*-vrijednosti većom od 0.05 ukazuje da je procijenjeni model u skladu s podacima iz uzorka (Gefen, Straub i Boudreau, 2000; Schermelleh-Engel, Moosbrugger i Müller, 2003; Raykov i Marcoulides, 2006; Hair et al., 2010; Schumacker i Lomax, 2010; Kline, 2011; Dragan i Topolšek, 2014).

Međutim, ovaj pokazatelj ima i svoje nedostatke. Naime, velika je osjetljivost hi-kvadrata na veličinu uzorka, s obzirom da se njegova vrijednost povećava zajedno s povećanjem uzorka (Schermelleh-Engel, Moosbrugger i Müller, 2003; Tabachnick i Fidell, 2007; Hooper, Coughlan i Mullen, 2008; Hair et al., 2010; Kline, 2011; Awang, 2012; West, Taylor i Wu, 2012; Siddiqui, 2015). Veće χ^2 vrijednosti povezane su s nižim *p*-vrijednostima, koje ukazuju na statistički značajan rezultat, odnosno lošu prilagodbu modela (Schermelleh-Engel, Moosbrugger i Müller, 2003; Schumacker i Lomax, 2010). To može potaknuti korištenje manjih uzoraka, što može biti kontraproduktivno, jer oni mogu samo prividno prikriti lošije pokazatelje prilagodbe i dati manje precizne procjene parametara. Također, kada varijable ne zadovoljavaju multivarijatnu normalnost i/ili kada je uzorak manji, tada testna veličina vjerojatno neće slijediti hi-kvadrat distribuciju. Kod ovakvih modela, ovisno o načinu i mjeri odstupanja od normalnosti, češći su pogrešni zaključci, pa χ^2 može biti precijenjen i tako prikazati model lošijim nego što je on u stvarnosti, ili pak χ^2 može biti podcijenjen te prikazati model boljim nego što on jest (Hooper, Coughlan i Mullen, 2008; Schumacker i Lomax, 2010; Kline, 2011; West, Taylor i Wu, 2012).

Osim toga, hi-kvadrat se povećava i s povećanjem broja manifestnih varijabli (indikatora), tj. ovisi i o kompleksnosti modela. Prema tome, kompleksniji modeli s više parametara pokazat će manju χ^2 vrijednost, zbog smanjenja broja stupnjeva slobode. Stoga, prihvatljiva vrijednost ovog pokazatelja može biti i rezultat dodavanja slobodnih parametara u model, a ne isključivo rezultat točno specificiranog modela (Schermelleh-Engel, Moosbrugger i Müller, 2003; Hair et al., 2010; Kline, 2011).

Zbog ograničenja hi-kvadrat testa preporučuje se koristiti i dodatne pokazatelje prilagodbe modela prilikom analize, umjesto da se oslanja samo na jedan pokazatelj (Hooper, Coughlan i Mullen, 2008; Hair et al., 2010; Siddiqui, 2015).

Jedan od alternativnih pokazatelja prilagodbe modela je **normirani hi-kvadrat (eng. *normed chi-square*, NC)**, koji zapravo prikazuje omjer hi-kvadrat veličine i broja stupnjeva slobode procijenjenog modela (Gefen, Straub i Boudreau, 2000; Schermelleh-Engel, Moosbrugger i Müller, 2003; Hooper, Coughlan i Mullen, 2008; Hair et al., 2010; Kline, 2011; Dragan i Topolšek, 2014; Goodboy i Kline, 2017; Civelek, 2018), odnosno:

$$NC = \chi^2 / df \tag{4.14}$$

NC je razvijen kako bi se pokušao otkloniti nedostatak osjetljivosti hi-kvadrata na veličinu uzorka. Postoji nekoliko prijedloga za granične vrijednosti prihvatljivosti ovog pokazatelja, a najčešće se uzimaju vrijednosti omjera od 2 ili 3. Ukoliko je NC manji od 2 ili 3, smatra se da se model dobro prilagođava podacima, a ako je NC manji od 5, model se smatra prihvatljivim (Gefen, Straub i Boudreau, 2000; Schermelleh-Engel, Moosbrugger i Müller, 2003; Schreiber et al., 2006; Hooper, Coughlan i Mullen, 2008; Hair et al., 2010; Kline, 2011; Awang, 2012; Dragan i Topolšek, 2014; Cangur i Ercan, 2015; Civelek, 2018). S obzirom da nisu jasno ustanovljene granice prihvaćanja modela temeljem NC-a, Kline (2011) sugerira da se ovaj pokazatelj i ne upotrebljava redovito u izvještavanju prilagodbe modela. West, Taylor i Wu (2012) smatraju da je i NC osjetljiv na veličinu uzorka, s obzirom da se dodavanjem parametara u model gube stupnjevi slobode, što kao posljedicu daje veći NC omjer, tj. lošiji pokazatelj.

Još jedan važan pokazatelj prilagodbe modela je **korijen prosječne kvadratne pogreške procjene (eng. *root mean square error of approximation*, RMSEA)**, kojim se pokušava korigirati utjecaj veličine uzorka te stupnjeva slobode, uzimajući ih zajedno u izračun prema sljedećoj formuli (Rigdon, 1996; Schermelleh-Engel, Moosbrugger i Müller, 2003; Hair et al., 2010; Schumacker i Lomax, 2010; Kline, 2011):

$$RMSEA = \sqrt{\frac{\chi^2 - df}{df\,(N-1)}} \tag{4.15}$$

Kod ovog pokazatelja manja vrijednost, tj. vrijednost bliža nuli označava bolju prilagodbu modela. Stoga se može smatrati tzv. *badness-of-fit* mjerom, kod koje veća vrijednost označava lošiju prilagodbu (Hair et al., 2010). Može se primijetiti da se povećanjem broja stupnjeva slobode i uz veći uzorak vrijednost RMSEA smanjuje. Stoga, RMSEA pokazatelj je sklon boljim vrijednostima pri modelima s manjim brojem parametara, odnosno više stupnjeva slobode. Međutim, to ne mora nužno biti pravilo, s obzirom da se korekcija za parsimoniju smanjuje s povećanjem uzorka (Rigdon, 1996; Schermelleh-Engel, Moosbrugger i Müller, 2003; Hair et al., 2010; Kline, 2011). Granična vrijednost prihvatljivosti RMSEA pokazatelja još uvijek nije usklađena među različitim autorima, pa se tako temeljem različitih istraživanja može uzeti u obzir nekoliko vrijednosti (Hooper, Coughlan i Mullen, 2008). Generalno se smatra da RMSEA vrijednosti manje od 0.05 ukazuju na dobru prilagodbu modela, vrijednosti između 0.05 i 0.08 ukazuju na prihvatljivu prilagodbu, vrijednosti između 0.08 i 0.10 pokazuju osrednju prilagodbu modela, dok se modeli s RMSEA većim od 0.10 smatraju neprihvatljivim (Rigdon, 1996; Schermelleh-Engel, Moosbrugger i Müller, 2003; Schreiber et al., 2006; Chen et al., 2008; Hooper, Coughlan i Mullen, 2008; Hair et al., 2010; Schumacker i Lomax, 2010; Kline, 2011; Awang, 2012; Dragan i Topolšek, 2014; Cangur i Ercan, 2015; Civelek, 2018). RMSEA je jedna od mjera koja je pod najmanjim utjecajem veličine uzorka (Schermelleh-Engel, Moosbrugger i Müller, 2003; Cangur i Ercan, 2015), a još jedna prednost ovog pokazatelja je mogućnost izračuna intervala pouzdanosti za njegovu procijenjenu vrijednost. Na taj način moguće je uz određenu razinu pouzdanosti zaključiti da dobiveni interval sadrži istinsku vrijednost RMSEA za model u populaciji (Schermelleh-Engel, Moosbrugger i Müller, 2003; Chen et al., 2008; Hair et al., 2010; Kline, 2011; West, Taylor i Wu, 2012).

Indeks prikladnosti modela (eng. *goodness-of-fit index*, GFI) još je jedan pokušaj razvoja mjere koja će biti manje osjetljiva na veličinu uzorka, a procjenjuje stupanj modelom objašnjene varijance i kovarijance iz uzorka (Raykov i Marcoulides, 2006; Hooper, Coughlan i Mullen, 2008; Hair et al., 2010; Kline, 2011; Civelek, 2018). Pokazatelj je na neki način sličan koeficijentu determinacije koji se koristi u regresijskoj analizi (Tabachnick i Fidell, 2007; West, Taylor i Wu, 2012). Pojednostavljeno, računa se prema sljedećem izrazu (Schermelleh-Engel, Moosbrugger i Müller, 2003; Hair et al., 2010; Schumacker i Lomax, 2010):

$$GFI = 1 - \frac{F_t}{F_n} = 1 - \frac{\chi_t^2}{\chi_n^2} \tag{4.16}$$

pri čemu je

χ_t^2 – hi-kvadrat istraživačkog modela

χ_n^2 – hi-kvadrat osnovnog (eng. *baseline*) ili *null* modela (model koji pretpostavlja da su svi parametri jednaki 0, odnosno da ne postoje nikakve veze u modelu), a

F – odgovarajući minimum funkcije prilagodbe.

GFI se kreće u rasponu od 0 do 1, gdje više vrijednosti pokazuju bolju prilagodbu modela. S druge strane, ako se model ne prilagođava dobro podacima, tada je omjer dvaju hi-kvadrata relativno visok, iz razloga što se oni značajno ne razlikuju, što posljedično daje manji GFI (Schermelleh-Engel, Moosbrugger i Müller, 2003; Hooper, Coughlan i Mullen, 2008; Hair et al., 2010; Schumacker i Lomax, 2010). GFI ponekad može biti i van uobičajenog raspona, pa je tako manji od 0 u slučaju manjih uzoraka i kada je prilagodba jako loša, a može biti veći od 1 kod točno identificiranih modela ili kod previše identificiranih modela s hi-kvadrat vrijednosti blizu 0 (Kline, 2011). Uobičajeno se vrijednosti veće od 0.90 smatraju prihvatljivim kao donja granica prihvaćanja modela, dok se u uvjetima kada su faktorska opterećenja niska i veličina uzorka manja, preporučuje koristiti vrijednost od 0.95 kao granična vrijednost prihvaćanja modela (Schermelleh-Engel, Moosbrugger i Müller, 2003; Raykov i Marcoulides, 2006; Schreiber et al., 2006; Hooper, Coughlan i Mullen, 2008; Hair et al., 2010; Schumacker i Lomax, 2010; Awang, 2012; Dragan i Topolšek, 2014). Ipak, i kod ovog pokazatelja postoji utjecaj veličine uzorka, pa se GFI također povećava zajedno s uzrokom (Hooper, Coughlan i Mullen, 2008; Hair et al., 2010; Kline, 2011).

Osim toga, razvijen je i **prilagođeni indeks prikladnosti modela (eng. *adjusted goodness-of-fit index*, AGFI)**, koji pokušava uzeti u obzir kompleksnost modela putem stupnjeva slobode. Prema Schermelleh-Engel, Moosbrugger i Müller (2003) može se izračunati kao:

$$AGFI = 1 - \frac{df_n}{df_t}(1 - GFI) = 1 - \frac{\chi_t^2 / df_t}{\chi_n^2 / df} \tag{4.17}$$

pri čemu je

χ_t^2 – hi-kvadrat istraživačkog modela

χ_n^2 – hi-kvadrat osnovnog (eng. *baseline*) ili *null* modela

df_t – broj stupnjeva slobode ciljanog modela, a

df_n – broj stupnjeva slobode *null* modela.

Ovaj pokazatelj također se kreće u rasponu od 0 do 1 i ide u prilog modelima s minimalnim brojem slobodnih parametara. Njegove su vrijednosti obično niže u odnosu na GFI. Ako je broj stupnjeva slobode ciljanog i null modela približno jednak, AGFI se približava GFI vrijednosti (Schermelleh-Engel, Moosbrugger i Müller, 2003; Hair et al., 2010). Granice prihvaćanja dobrog modela jednake su kao i kod GFI, odnosno iznose 0.90 ili 0.95 (Schermelleh-Engel, Moosbrugger i Müller, 2003; Schreiber et al., 2006; Hair et al., 2010; Schumacker i Lomax, 2010; Awang, 2012; Civelek, 2018).

Nadalje, **korijen prosječnog kvadratnog odstupanja (eng. *root mean square residual*, RMR)** te **standardizirani korijen prosječnog kvadratnog odstupanja (eng. *standardized root mean square residual*, SRMR)** indeksi su temeljeni na rezidualima, odnosno razlikama između kovarijanci iz uzorka i procijenjenih kovarijanci (Schermelleh-Engel, Moosbrugger i Müller, 2003; Tabachnick i Fidell, 2007; Hair et al., 2010; Kline, 2011). Mogu se izračunati prema sljedećim formulama (Schermelleh-Engel, Moosbrugger i Müller, 2003; Tabachnick i Fidell, 2007; Cangur i Ercan, 2015):

$$RMR = \sqrt{\frac{\sum_{i=1}^{p}\sum_{j=1}^{i}(s_{ij} - \hat{\sigma}_{ij})^2}{p(p+1)/2}} \tag{4.18}$$

$$SRMR = \sqrt{\frac{\sum_{i=1}^{p}\sum_{j=1}^{i}\left[(s_{ij} - \hat{\sigma}_{ij})/(s_{ii} - s_{jj})\right]^2}{p(p+1)/2}} \tag{4.19}$$

gdje je:

s_{ij} – element empirijske matrice kovarijanci S

$\hat{\sigma}_{ij}$ – element modelom procijenjene matrice kovarijanci $\sum$

p – broj manifestnih varijabli.

S obzirom da se RMR računa temeljem nestandardiziranih varijabli, njegov raspon ovisi o mjernoj ljestvici manifestnih varijabli. Ukoliko se mjerne ljestvice razlikuju, teško je uspoređivati različite modele temeljem RMR. Stoga je uveden SRMR, odnosno standardizirana verzija ovog pokazatelja (Schermelleh-Engel, Moosbrugger i Müller, 2003; Tabachnick i Fidell, 2007; Hooper, Coughlan i Mullen, 2008; Hair et al., 2010; Kline, 2011). SRMR je korisniji kod usporedbe različitih modela. Za oba pokazatelja vrijedi da je niža vrijednost bolja, tj. pokazuje bolju prilagodbu modela, a 0 pokazuje savršenu prilagodbu. Dakle, i ovi pokazatelji također spadaju u tzv. *badness-of-fit* mjere. SRMR kao standardizirani pokazatelj kreće se u rasponu od 0 do 1. Kao gornja granica pokazatelja za dobar model uzima se vrijednost 0.05, dok se fleksibilnije za prihvatljiv model može uzeti i granica 0.10, dok se u praksi često koristi 0.08 kao gornja granica prihvatljive vrijednosti (Schermelleh-Engel, Moosbrugger i Müller, 2003; Tabachnick i Fidell, 2007; Hooper, Coughlan i Mullen, 2008; Hair et al., 2010; Schumacker i Lomax, 2010; Kline, 2011; Cangur i Ercan, 2015).

Normirani indeks prikladnosti (eng. *normed fit index*, NFI) jedna je od originalnih inkrementalnih mjera prilagodbe modela, a računa se kao odnos razlike hi-kvadrata istraživačkog modela i *null* modela i samog hi-kvadrata *null* modela (Hu i Bentler, 1998; Schermelleh-Engel, Moosbrugger i Müller, 2003; Tabachnick i Fidell, 2007; Hair et al., 2010; Schumacker i Lomax, 2010):

$$NFI = \frac{\chi_n^2 - \chi_t^2}{\chi_n^2} \tag{4.20}$$

pri čemu je

χ_t^2 – hi-kvadrat istraživačkog modela

χ_n^2 – hi-kvadrat *null* modela.

Raspon NFI također se kreće od 0 do 1, a više vrijednosti označavaju bolju prilagodbu modela. Slično kao kod GFI i AGFI, donja granica prikladnosti modela je 0.90 ili 0.95 (Schermelleh-Engel, Moosbrugger i Müller, 2003; Schreiber et al., 2006; Schumacker i Lomax, 2010; Awang, 2012;

West, Taylor i Wu, 2012; Dragan i Topolšek, 2014; Civelek, 2018). Međutim, i ovaj je pokazatelj pod utjecajem veličine uzorka, podcjenjujući prikladnost modela s veličinom uzorka manjom od 200 (Schermelleh-Engel, Moosbrugger i Müller, 2003; Tabachnick i Fidell, 2007; Hooper, Coughlan i Mullen, 2008; Cangur i Ercan, 2015). Kako bi se riješio ovaj problem, uspostavljen je **nenormirani indeks prikladnosti (eng. *non-normed fit index*, NFI)**, poznat i kao **Tucker Lewis indeks (TLI)**, koji preferira jednostavnije modele. S obzirom da nije normiran, njegove vrijednosti mogu poprimiti i vrijednosti manje od 0 ili veće od 1, što može biti problem kod interpretacije te može poprimiti nerealno niske vrijednosti kod manjih uzoraka (Tabachnick i Fidell, 2007; Hooper, Coughlan i Mullen, 2008; Hair et al., 2010). Može se izračunati prema izrazu (Schermelleh-Engel, Moosbrugger i Müller, 2003; West, Taylor i Wu, 2012; Cangur i Ercan, 2015):

$$TLI = NNFI = \frac{(\chi_n^2 / df_n) - (\chi_t^2 / df_t)}{(\chi_n^2 / df_n) - 1} \tag{4.21}$$

pri čemu su oznake hi-kvadrata kao i prethodno u izrazu 4.20., a df su stupnjevi slobode svakog pojedinog modela. Kao i kod ostalih indeksa, gdje veća vrijednost označava bolju prikladnost modela, granične vrijednosti za TLI su također 0.90 ili, još poželjnije, 0.95, a neki autori navode i vrijednost 0.97. Prednost ovog indeksa je činjenica što nije pod značajnim utjecajem veličine uzorka (Schermelleh-Engel, Moosbrugger i Müller, 2003; Schreiber et al., 2006; Hooper, Coughlan i Mullen, 2008; West, Taylor i Wu, 2012; Cangur i Ercan, 2015; Siddiqui, 2015).

Još jedan važan pokazatelj je **indeks komparativne prilagodbe (eng. *comparative fit index*, CFI)**, koji mjeri relativno poboljšanje istraživačkog modela u usporedbi s osnovnim, najčešće *null* modelom (Hair et al., 2010; Kline, 2011). Smatra se poboljšanom verzijom NFI-ja, koji izbjegava podcjenjivanje prilagodbe modela u manjim uzorcima (Schermelleh-Engel, Moosbrugger i Müller, 2003; Hooper, Coughlan i Mullen, 2008), a može se izračunati na sljedeći način (Tabachnick i Fidell, 2007; Hair et al., 2010; Schumacker i Lomax, 2010; Kline, 2011):

$$CFI = 1 - \frac{\chi_t^2 - df_t}{\chi_n^2 - df_n} \tag{4.22}$$

gdje su oznake jednake kao u izrazima 4.20. i 4.21., a odnose se na hi-kvadrate i stupnjeve slobode istraživačkog i *null* modela. CFI je među najčešće korištenim pokazateljima prikladnosti u SEM-u te je relativno neosjetljiv na kompleksnost modela i veličinu uzorka (Schermelleh-Engel,

Moosbrugger i Müller, 2003; Hair et al., 2010). Vrijednosti CFI kreću se u rasponu od 0 do 1, a veća vrijednost pokazuje bolju prikladnost modela. U literaturi su također postavljene vrijednosti donje granice prihvatljivog i dobrog modela na 0.90 i 0.95 (Schermelleh-Engel, Moosbrugger i Müller, 2003; Schreiber et al., 2006; Tabachnick i Fidell, 2007; Hooper, Coughlan i Mullen, 2008; Hair et al., 2010; Schumacker i Lomax, 2010; Kline, 2011; Awang, 2012; West, Taylor i Wu, 2012; Cangur i Ercan, 2015; Siddiqui, 2015).

Prilikom evaluacije prikladnosti modela, potrebno je uvijek prikazati vrijednost hi-kvadrata s pripadajućom *p*-vrijednosti. Međutim, kako su razvijene brojne mjere koje na različite načine ocjenjuju model, uz hi-kvadrat je potrebno prikazati i dodatne pokazatelje, naročito ako hi-kvadrat ne daje zadovoljavajući rezultat, što se može dogoditi zbog veličine uzroka (Kline, 2011). Svakako se nije dobro osloniti samo na jedan pokazatelj, već uz hi-kvadrat treba dati i vrijednosti još nekih od prethodno opisanih pokazatelja, a korisno je kombinirati tzv. *goodness-of-fit* i *badness-of-fit* mjere, gdje kod prvih veće vrijednosti označavaju bolju prilagodbu, a kod drugih lošiju (Hooper, Coughlan i Mullen, 2008; Hair et al., 2010; Kline, 2011). U sljedećoj tablici sumirani su prethodno opisani najčešće korišteni pokazatelji prikladnosti modela te njihove granične vrijednosti temeljem kojih se ocjenjuje model (Schermelleh-Engel, Moosbrugger i Müller, 2003; Schreiber et al., 2006; Hooper, Coughlan i Mullen, 2008; Hair et al., 2010; Schumacker i Lomax, 2010; Kline, 2011; Awang, 2012; West, Taylor i Wu, 2012; Dragan i Topolšek, 2014).

Tablica 4.1. Pokazatelji prilagodbe modela s granicama prihvaćanja

Pokazatelj	**Granica prihvaćanja**	**Komentar**
Hi-kvadrat (χ^2)	Vrijednost hi-kvadrata s pripadajućom p-vrijednosti koja ukazuje na nesignifikantan rezultat (p>0.05)	Osjetljiv na veličinu uzorka i kompleksnost modela.
Normirani hi-kvadrat (NC)	< 2 poželjno < 3 dobro < 5 prihvatljivo	Omjer vrijednosti hi-kvadrata i pripadajućih stupnjeva slobode.
RMSEA	<0.05 poželjno 0.05-0.08 prihvatljivo 0.08-0.10 osrednje >0.10 loše	
GFI	>0.90 dobro	

	>0.95 poželjno	
AGFI	>0.90 dobro >0.95 poželjno	
RMR	Poželjna manja vrijednost	Prikazuje razlike između kovarijanci iz uzorka i procijenjenih kovarijanci.
SRMR	<0.05 poželjno 0.05-0.10 prihvatljivo	Standardizirani RMR, kreće se u rasponu od 0 do 1.
NFI	>0.90 dobro >0.95 poželjno	
TLI (NNFI)	>0.90 dobro >0.95 poželjno	Nije normiran, može poprimiti i vrijednost manju od 0 i veću od 1.
CFI	>0.90 dobro >0.95 poželjno	

Izvor: izrada autorice

Prema Hair et al. (2010), pod različitim uvjetima veličine uzorka i broja manifestnih varijabli, mogu se prilagoditi vrijednosti granica prihvaćanja za određene pokazatelje. U sljedećoj tablici prikazane su karakteristike, očekivanja i sugestije vezane za dio pokazatelja prilagodbe, ovisno o veličini uzorka i broju manifestnih varijabli. Vidljivo je kako se smatra da bi se jednostavnije modele s manjim uzorcima trebalo strože evaluirati u odnosu na kompleksnije modele s većim uzorcima. Osim toga, kompleksnije modele s manjim uzorcima ne bi trebalo previše strogo evaluirati (Hair et al., 2010).

Tablica 4.2. Karakteristike različitih pokazatelja prilagodbe modela pri različitim uvjetima modeliranja

	$N < 250$			$N > 250$		
	$m \leq 12$	$12 < m < 30$	$m \geq 30$	$m \leq 12$	$12 < m < 30$	$m \geq 30$
Hi-kvadrat (χ^2)	Očekivane nesignifikantne p-vrijednosti	Signifikantne p-vrijednosti, čak i uz dobru prilagodbu	Očekuju se signifikantne p-vrijednosti	Nesignifikantne p-vrijednosti ukazuju na dobru prilagodbu	Očekuju se signifikantne p-vrijednosti	Očekuju se signifikantne p-vrijednosti
CFI ili TLI	≥ 0.97	≥ 0.95	> 0.92	≥ 0.95	> 0.92	> 0.90

SRMR	Može biti pristran, preporučuje se koristiti druge pokazatelje	≤ 0.08 (uz CFI ≥ 0.95)	< 0.09 (uz CFI > 0.92)	Može biti pristran, preporučuje se koristiti druge pokazatelje	≤ 0.08 (uz CFI > 0.92)	≤ 0.08 (uz CFI > 0.92)
RMSEA	< 0.08 (uz CFI ≥ 0.97)	< 0.08 (uz CFI ≥ 0.95)	< 0.08 (uz CFI > 0.92)	< 0.07 (uz CFI ≥ 0.97)	< 0.07 (uz CFI ≥ 0.92)	< 0.07 (uz CFI ≥ 0.90)
N=veličina uzorka, m=broj manifestnih varijabli						

Izvor: izrada autorice prema Hair et al. (2010, str. 584)

Osim ocjene prilagodbe modela kao cjeline, potrebno je pristupiti analizi validnosti svakog pojedinačnog konstrukta. **Validnost konstrukta (eng. *construct validity*)** pokazuje u kojoj mjeri skup indikatora uistinu reflektira, odnosno predstavlja latentni konstrukt koji mjeri. Drugim riječima, zadovoljavajuća validnost konstrukta pokazuje da indikatori ne mjere nijednu latentnu varijablu osim one s kojom su povezani u konceptualnom modelu. Obično se testira kroz konvergentnu (eng. *convergent validity*) i diskriminantnu (eng. *discriminant validity*) validnost, a još se mogu spomenuti i nomološka (eng. *nomological validity*) i sadržajna (eng. *face validity*) validnost. Na ovaj način testira se i jednodimenzionalnost konstrukta (Hair et al., 2010; Awang, 2012; Civelek, 2018).

Konvergentna validnost (eng. *convergent validity*) pokazuje koliki udio varijance dijele indikatori određenog konstrukta, odnosno pronalazi se stupanj usklađenosti indikatora koji mjere isti konstrukt (Hair et al., 2010; Dragan i Topolšek, 2014). Također, ako je zadovoljena, konvergentna validnost pokazuje i visoku koreliranost među indikatorima jednog konstrukta, što je poželjno kod reflektivnih modela (Brown, 2006; Kline, 2011; Brown i Moore, 2012; Civelek, 2018). Ona se može ustanoviti na nekoliko načina. Najprije se mogu pregledati **faktorska opterećenja (eng. *factor loadings*)**, čije bi vrijednosti u slučaju zadovoljavajuće validnosti trebale biti relativno visoke, a također bi sva faktorska opterećenja trebala biti statistički značajna. Jakost faktorskog opterećenja ne mora nužno biti povezana sa značajnosti, pa tako i faktorska opterećenja slabijeg intenziteta mogu biti statistički značajna. Stoga, visine standardiziranih faktorskih opterećenja koje se predlažu za uspostavljanje konvergentne validnosti su između 0.5 i 0.7, a idealno bi bilo i kada bi vrijednosti bile veće od 0.7 (Hair et al., 2010; Awang, 2012; Civelek, 2018). Zahtjevi za ovim vrijednostima povezani su s najčešće korištenom mjerom konvergentne

validnosti, a to je **prosječna izlučena varijanca (eng. *average variance extracted,* AVE)**. AVE pokazuje prosječan postotak objašnjenih varijacija među indikatorima, a računa se prema sljedećem izrazu (Fornell i Larcker, 1981; Hair et al., 2010; Awang, 2012; Dragan i Topolšek, 2014):

$$AVE = \frac{\sum_{i=1}^{n} \lambda_i^2}{n} \tag{4.23}$$

gdje je:

λ – standardizirano faktorsko opterećenje (eng. *standardized factor loading*),

i – broj elemenata (eng. *items*), a

n – broj manifestnih varijabli.

Može se zaključiti da je AVE zapravo prosjek kvadratnih faktorskih opterećenja svih indikatora, koji predstavljaju **kvadratnu višestruku korelaciju (eng. *squared multiple correlation,* SMC; R^2)**, mjeru razine u kojoj je varijanca indikatora objašnjena latentnim konstruktom, odnosno koliko dobro indikator mjeri konstrukt (Raykov i Marcoulides, 2006; Hair et al., 2010). Kako bi se utvrdilo postojanje konvergentne validnosti, sugerira se da bi vrijednosti AVE trebale biti minimalno 0.5, a poželjno što više. To bi značilo da je latentnim konstruktom objašnjeno barem 50% varijance u svojim indikatorima (Fornell i Larcker, 1981; Hair et al., 2010; MacKenzie, Podsakoff i Podsakoff, 2011; Awang, 2012; Civelek, 2018).

Pouzdanost je također bitan pokazatelj konvergentne validnosti. Ona se često ispituje **Cronbach's alpha** koeficijentom, koji pokazuje u kojoj mjeri su varijable konzistentne u svojim vrijednostima. Međutim, pokazalo se kako je ovaj pokazatelj dosljedan samo kada svi analizirani indikatori predstavljaju jedan konstrukt, i to podjednako dobro, te može podcijeniti pouzdanost. Osim toga, ovaj pokazatelj može biti osjetljiv na broj promatranih varijabli (Hair et al., 2017a). Ipak, ovo ostaje jedan od glavnih pokazatelja pouzdanosti, odnosno interne konzistentnosti, jer ne daje drastično različite rezultate u odnosu na alternativne mjere pouzdanosti (Hair et al., 2010; Kline, 2011; MacKenzie, Podsakoff i Podsakoff, 2011; Geldhof, Preacher i Zyphur, 2014). Prema Kline (2011), pokazatelj se računa prema sljedećoj formuli:

$$\alpha_c = \frac{n\overline{r}_{ij}}{1+(n-1)\overline{r}_{ij}} \tag{4.24}$$

Gdje je n broj varijabli (eng. *items*), a $\overline{r}_{ij}$ prosječna Pearsonova korelacija između svih parova varijabli. Njegova vrijednost kreće se u rasponu od 0 do 1, gdje vrijednosti bliže 1 označavaju da varijable dobro objašnjavaju latentnu varijablu koju predstavljaju. Kao donje granice prihvatljivih vrijednosti najčešće se uzimaju 0.7 ili fleksibilnije 0.6, gdje se fleksibilnija granica obično koristi za eksplorativna istraživanja (Gefen, Straub i Boudreau, 2000; Tavakol i Dennick, 2011; Awang, 2012; Dragan i Topolšek, 2014; Civelek, 2018).

S obzirom na ograničenja Cronbach's alpha pokazatelja, koristi se i pokazatelj **pouzdanosti konstrukta (eng. *construct reliability*, CR)**, za koji se smatra da može dati preciznije procjene u odnosu na alpha pokazatelj (Geldhof, Preacher i Zyphur, 2014). Ovaj pokazatelj uzima u obzir faktorska opterećenja i računa se prema izrazu (Hair et al., 2010; Awang, 2012; Dragan i Topolšek, 2014; Geldhof, Preacher i Zyphur, 2014):

$$CR = \frac{\left(\sum_{i=1}^{n}\lambda_i\right)^2}{\left(\sum_{i=1}^{n}\lambda_i\right)^2 + \left(\sum_{i=1}^{n}\delta_i\right)^2} \tag{4.25}$$

Pri čemu je:

λ – faktorsko opterećenje,

i – broj elemenata, a

δ_i – pogreška.

Kako bi se ustanovila dobra pouzdanost konstrukta, potrebno je postići veće vrijednosti CR pokazatelja. Donjom granicom dobre pouzdanosti smatra se vrijednost od 0.7, što bi pokazivalo da svi indikatori dosljedno predstavljaju isti latentni konstrukt. Vrijednosti od 0.6 do 0.7 također se smatraju prihvatljivim, ako je validnost ostalih konstrukata u modelu zadovoljavajuća (Hair et al., 2010; MacKenzie, Podsakoff i Podsakoff, 2011; Hair et al., 2017a; Civelek, 2018).

Nadalje, potrebno je ispitati i **diskriminantnu validnost (eng. *discriminant validity*)** konstrukata u modelu, kako bi se utvrdila mjera u kojoj je svaki konstrukt uistinu različit od ostalih. Drugim riječima, potrebno je utvrditi mjeri li svaki konstrukt samo jedan određeni koncept i postoje li u modelu suvišni konstrukti koji mjere isti koncept (Brown, 2006; Hair et al., 2010; Awang, 2012; Brown i Moore, 2012; Dragan i Topolšek, 2014). Kada korelacije manifestnih varijabli nisu visoke, tada se smatra da one mjere različite konstrukte i da je potvrđena diskriminantna validnost (Kline, 2011). Prema Awang (2012), korelacija između egzogenih konstrukata trebala bi biti manja od 0.85, kako bi se utvrdila diskriminantna validnost. Najčešći način provjere postojanja diskriminantne validnosti je tzv. **Fornell-Larcker kriterij**, koji se temelji na usporedbi korijena AVE vrijednosti svakog konstrukta s koeficijentima korelacije između parova latentnih konstrukata. S obzirom da je svaki konstrukt mjera određenog teoretskog koncepta, trebao bi bolje objašnjavati varijancu svojih indikatora, nego indikatora ostalih konstrukata. Iz toga proizlazi da bi korijen AVE pokazatelja nekog konstrukta trebao biti veći od bilo koje korelacije s drugim konstruktima iz modela (Zaiţ i Bertea, 2011; Ab Hamid, Sami i Sidek, 2017; Civelek, 2018). Osim toga, diskriminantna validnost može se ispitati i kroz **test razlike hi-kvadrata (eng. *chi-square difference test*)**, kojim se uspoređuje model u kojem su konstrukti međusobno korelirani i model u kojem nisu. Ako je razlika između dvaju navedenih modela statistički značajna, tada se može potvrditi postojanje diskriminantne validnosti. Međutim, test nije uvijek pouzdan, jer ponekad i visoke korelacije među konstruktima mogu dati statistički značajan rezultat testa razlike hi-kvadrata, što bi upućivalo na pogrešne zaključke (Hair et al., 2010; MacKenzie, Podsakoff i Podsakoff, 2011; Zaiţ i Bertea, 2011).

Konstrukti bi trebali također zadovoljavati nomološku i sadržajnu validnost. **Nomološka validnost (eng. *nomological validity*)** ispituje se na način da se provjerava imaju li smisla korelacije konstrukata mjernog modela, s obzirom na ispitivanu teoriju (Hair et al., 2010). Dodatno, **sadržajna validnost (eng. *face validity; content validity*)** trebala bi biti uspostavljena i prije testiranja teorijskog modela. Naime, od iznimne je važnosti razumjeti sadržaj i značenje svakog indikatora i njegovu reprezentativnost u mjerenju konstrukta. Za uspostavljanje sadržajne validnosti nisu potrebni statistički testovi, već procjena stručnjaka i istraživača (Hair et al., 2010; Kline, 2011).

Nakon provjere validnosti pojedinačnih konstrukata i prilagodbe cjelokupnog modela, može se pristupiti pretraživanju specifikacija (eng. *specification search*), čija je svrha modifikacija modela, kako bi se dobio model s boljim pokazateljima prilagodbe, validnosti te parametrima s većom značajnosti (Tabachnick i Fidell, 2007; Hair et al., 2010; Schumacker i Lomax, 2010; Civelek, 2018). Međutim, treba voditi računa kako se modifikacija modela ne bi smjela provoditi samo na temelju statističkih pokazatelja, već temeljem teoretskih pretpostavki (Hair et al., 2010; Kline, 2011). Ukoliko postoji problem s konvergentnom validnosti, pregledavaju se standardizirana faktorska opterećenja. Kako je već spomenuto, njihove vrijednosti bi trebale biti barem 0.5 ili 0.7, stoga se indikatori s nižim vrijednostima faktorskih opterećenja mogu izbaciti iz modela. Međutim, to nije nužno pravilo, naročito ako je prilagodba modela kao cjeline zadovoljavajuća (Hair et al., 2010; Awang, 2012). Osim toga, za SEM modele računaju se i **modifikacijski indeksi (eng. *modification indices*, MI)**, koji pokazuju za koliko bi se smanjila vrijednost hi-kvadrata procijenjenog modela kad bi se oslobodio parametar koji je u originalnom modelu bio fiksiran na nulu (Hair et al., 2010; Kline, 2011). Smatra se da bi se prikladnost modela poboljšala ukoliko bi se oslobodio parametar s MI vrijednosti 4 ili više, dok jako visoke vrijednosti MI (iznad 15) ukazuju na suvišne indikatore u modelu (Hair et al., 2010; Awang, 2012).

4.1.5 Analiza strukturalnog modela

Pod analizom strukturalnog modela podrazumijeva se testiranje cjelokupne prilagodbe modela te smjera, intenziteta i značajnosti parametara koji prikazuju veze između latentnih konstrukata, odnosno testiraju se teoretske pretpostavke o povezanosti latentnih konstrukata (Raykov i Marcoulides, 2006; Schreiber et al., 2006; Hair et al., 2010).

Dakle, nakon procjene svih parametara, odnosno uzročno-posljedičnih veza u strukturalnom modelu, bitno je pregledati prilagodbu cjelokupnog modela. Ona se analizira na isti način kao kod mjernog modela, putem različitih pokazatelja prilagodbe. Naime, modeliranje se može provesti u jednom (eng. *one-step modeling*) ili u dva koraka (eng. *two-step modeling*) (Hair et al., 2010; Kline, 2011). Kad se provodi modeliranje u jednom koraku, tada se mjerna i strukturalna komponenta SEM modela analiziraju simultano, dok se modeliranjem u dva koraka procjenjuju zasebno. Prvi korak obuhvaća analizu mjernog modela, odnosno CFA, gdje je cilj dobiti adekvatan model dobre prikladnosti. Ukoliko pokazatelji nisu zadovoljavajući, moguće je postojanje greške u specifikaciji modela, što je potrebno korigirati prije pristupanja analizi strukturalnog modela (Hair et al., 2010;

Kline, 2011). Uz postignut adekvatan mjerni model, u drugom koraku se analizira strukturalni model putem istih pokazatelja prilagodbe. Testom razlike hi-kvadrata može se pokazati postoji li značajna razlika u prikladnosti mjernog i strukturalnog modela. Ako bi mjere strukturalnog modela bile značajno lošije u odnosu na CFA model, zaključilo bi se da postoji problem s validnosti strukturalne teorije (Tabachnick i Fidell, 2007; Hair et al., 2010; Kline, 2011). Ukoliko mjere prilagodbe nisu značajno drugačije, tada se detaljnije pregledavaju procjene parametara u svrhu donošenja istraživačkih zaključaka.

Kao što je prethodno naglašeno, strukturalni model promatra isključivo uzročno-posljedične veze između latentnih konstrukata. Te veze, odnosno utjecaji, mogu se i rastaviti na direktne i indirektne utjecaje (Kline, 2011; Hair et al., 2019a). **Direktni utjecaji (eng. *direct effects*)** povezuju dva konstrukta direktno od konstrukta uzroka (nezavisne varijable) do konstrukta posljedice (zavisna varijabla), a grafički se prikazuju jednosmjernom strelicom koja se kreće od uzroka prema posljedici. **Indirektni utjecaji (eng. *indirect effects*)** prikazuju niz uzročno-posljedičnih veza, koje uključuju barem jedan posrednički konstrukt, odnosno prikazuju utjecaj nezavisne varijable na zavisnu putem posredničke varijable. Indirektni utjecaj računa se kao umnožak svih direktnih utjecaja koji ga sačinjavaju. S obzirom da može postojati i više posredničkih varijabli u modelu, mogu se promatrati i ukupni indirektni utjecaji, kao zbroj svih pojedinačnih indirektnih utjecaja. U konačnici, zbroj svih direktnih i indirektnih utjecaja predstavlja **ukupan utjecaj (eng. *total effect*)** jedne varijable na drugu (Schreiber et al., 2006; Schumacker i Lomax, 2010; Kline, 2011; Awang, 2012; Hair et al., 2019a). Indirektni utjecaji povezani su s medijacijom, o kojoj će biti riječi u nastavku rada. Na slici 4.10. prikazan je primjer SEM modela s direktnim i indirektnim utjecajima. Može se vidjeti da konstrukti A i B direktno utječu na konstrukt C, koji direktno utječe na konstrukt D. Osim toga, na konstrukt D direktno utječe konstrukt B, a indirektno konstrukti A i B putem konstrukta C. U nastavku je prikazan primjer izračuna indirektnih i ukupnih utjecaja temeljem slike 4.10. i danih visina procijenjenih parametara.

Navedeni su sljedeći direktni utjecaji:

$$A \rightarrow C = 0.50$$
$$B \rightarrow C = 0.50$$
$$B \rightarrow D = 0.30$$
$$C \rightarrow D = 0.40$$

Temeljem danih vrijednosti, na sljedeći način se mogu izračunati indirektni utjecaji konstrukata A i B na konstrukt D:

$$A \rightarrow C \rightarrow D = 0.50 \cdot 0.40 = 0.20$$
$$B \rightarrow C \rightarrow D = 0.50 \cdot 0.40 = 0.20$$

Konstrukt A ima samo indirektan utjecaj na konstrukt D, stoga je to i njegov ukupan utjecaj na konstrukt D. S druge strane, konstrukt B i direktno i indirektno utječe na konstrukt D, stoga se njegov ukupan utjecaj može izračunati kao zbroj dvaju navedenih utjecaja. Izračun ukupnog utjecaja konstrukta B na D je kako slijedi:

ukupan utjecaj = 0.30 (direktni) + 0.20 (indirektni) = 0.50

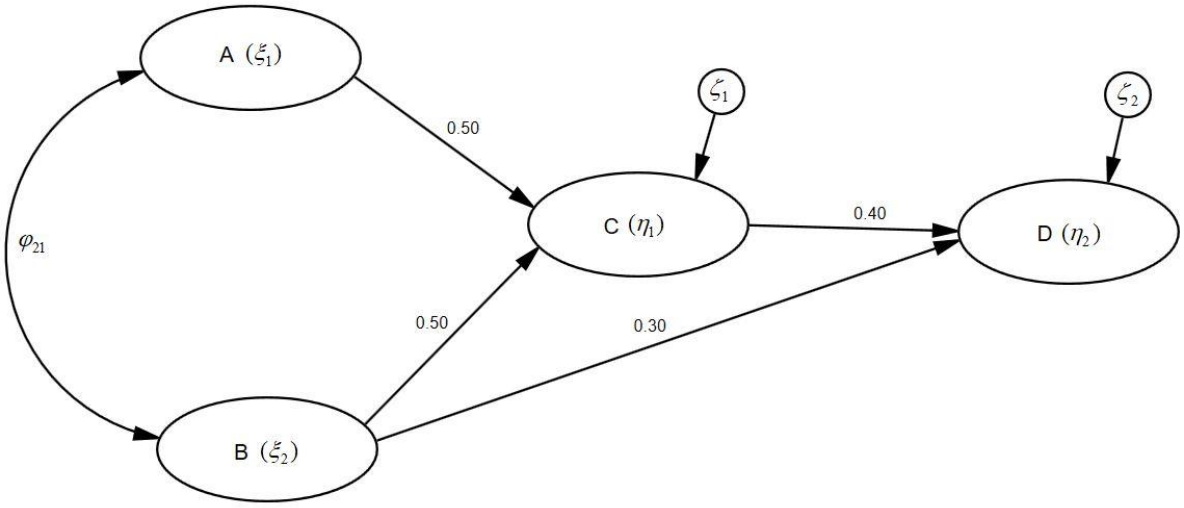

Slika 4.10. SEM model s prikazom direktnih i indirektnih utjecaja

Izvor: izrada autorice

Nadalje, promatra se značajnost procijenjenih parametara, odnosno testira se hipoteza je li parametar značajno različit od nule. Zajedno s procjenama parametara dobivaju se i njihove standardne pogreške, a omjer procjene parametra i njegove standardne pogreške daje testnu veličinu (eng. *critical value*). Pod pretpostavkom normalne distribucije, ove testne veličine mogu se uspoređivati s tabličnim vrijednostima površine ispod normalne krivulje, a temeljem toga mogu se izračunati i odgovarajuće *p*-vrijednosti (Schumacker i Lomax, 2010). Osim toga, ispituju se i predznaci parametara, odnosno smjer utjecaja jedne varijable na drugu, te njihovo podudaranje s

teoretskom pretpostavkom. Nakon toga, parametri i veze koje predstavljaju mogu se smisleno objasniti (Hair et al., 2010; Schumacker i Lomax, 2010). Prilikom interpretacije parametara vodi se logikom kao kod regresijske analize i CFA, što vrijedi i za nestandardizirane i standardizirane procjene parametara. Stoga, ovi se parametri tumače kao regresijski koeficijenti (Kline, 2011). Također se može promatrati i koeficijent determinacije (R^2) endogenih konstrukata, koji predstavlja količinu varijance u zavisnoj varijabli (konstruktu) koja je objašnjena, predviđena ili uzeta u obzir skupom nezavisnih varijabli (konstrukata) koji služe kao prediktori u modelu (Schumacker i Lomax, 2010).

U slučaju da strukturalni model kao cjelina ne daje zadovoljavajuće rezultate, pristupa se modifikaciji modela. Kao kod CFA, to se može postići putem analize modifikacijskih indeksa, gdje je bitno voditi se i teoretskom podlogom, umjesto isključivog oslanjanja na ono što sugeriraju modifikacijski indeksi (Hair et al., 2010; Schumacker i Lomax, 2010; Kline, 2011; Goodboy i Kline, 2017). Model se može respecificirati na različite načine. Primjerice, moguće je „srezati“ model (eng. *model trimming*), odnosno pojednostaviti ga, putem eliminacije slobodnih parametara. Tada se barem jedan parametar, koji je u početnom modelu bio slobodan, fiksira na vrijednost 0. Drugi način respecifikacije modela je izgradnja modela (eng. *model building*), gdje se dodaju novi parametri u model. Tada se barem jedan parametar, prethodno fiksiran na nulu, oslobađa za procjenu. Obično se hi-kvadrat vrijednost smanjuje pojednostavljenjem, a povećava izgradnjom modela. Međutim, svakako se i u ovom slučaju potrebno osloniti na teoriju koja se testira, jer sami empirijski dokazi mogu sugerirati izbacivanje i/ili dodavanje parametara koji teoretski nisu opravdani (Tabachnick i Fidell, 2007; Hair et al., 2010; Kline, 2011; Dragan i Topolšek, 2014).

4.1.6 Medijacija, moderacija i analiza više grupa

Pod **medijacijom (eng. *mediation*)** se podrazumijeva intervencija, odnosno posredovanje treće varijable/konstrukta između dvaju povezanih konstrukata (Cheong i MacKinnon, 2012; Civelek, 2018; Hair et al., 2019a). Upravo ta treća varijabla naziva se medijatorom ili posredničkom varijablom, koja se može opisati kao varijabla koja objašnjava cijeli odnos ili dio odnosa između prediktora i zavisne varijable, odnosno prenosi utjecaj nezavisne varijable na zavisnu (Baron i Kenny, 1986; Cheong i MacKinnon, 2012). Slika 4.11. prikazuje primjer efekta medijacije, gdje se moguće osvrnuti na direktne i indirektne utjecaje, koji su opisani u prethodnom poglavlju. Naime, na slici se može uočiti kako nezavisna varijabla X direktno (veza c) i indirektno (umnožak

veza a i b, tj. $a \cdot b$) utječe na zavisnu varijablu Y, dok medijatorska varijabla M posreduje između njih. Medijator zapravo objašnjava zašto postoji veza između prediktorske varijable i zavisne varijable. Zahtijeva značajne korelacije među svim promatranim konstruktima, a testira se putem indirektnih utjecaja (Stride, 2018; Hair et al., 2019a).

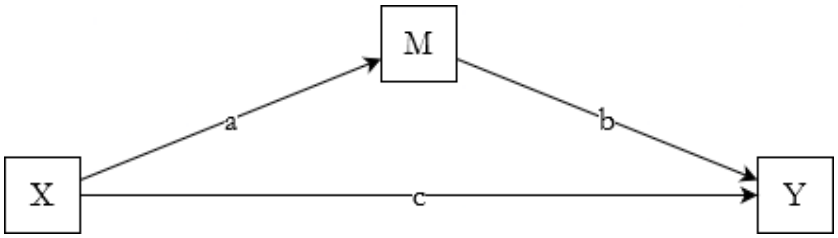

Slika 4.11. Prikaz efekta medijacije

Izvor: izrada autorice

Najpoznatija metoda testiranja medijacije je Baron i Kenny metoda, koja se sastoji od četiri koraka (Baron i Kenny, 1986; Kline, 2015; Civelek, 2018; Stride, 2018):

1. Nezavisna varijabla X utječe na zavisnu varijablu Y, zanemarujući medijator M.
2. Nezavisna varijabla X utječe na medijator M, tj. koeficijent a različit je od 0.
3. Medijator M utječe na zavisnu varijablu Y, neutralizirajući utjecaj varijable X, tj. koeficijent b različit je od 0.
4. Da bi se utvrdilo da je medijator M potpuno odgovoran za povezanost nezavisne i zavisne varijable, koeficijent c trebao bi biti 0.

Za evaluaciju medijacije, tj. utvrđivanje njezinog postojanja, potrebno je slijediti niz koraka, koji će biti opisani na primjeru oznaka varijabli sa slike 4.11. Ti koraci su sljedeći (Tabachnick i Fidell, 2007; Stride, 2018; Hair et al., 2019a):

1. Provjeriti postojanje statistički značajnih korelacija između varijabli X i Y, X i M te M i Y.
2. Ako veza između varijabli X i Y (c) ostaje značajna i nepromijenjena kada se uključi medijator M, kao dodatni prediktor varijable Y, tada se zaključuje da medijacija ne postoji.
3. Ako se koeficijent c smanji, ali ostane statistički značajan uključivanjem varijable M u model, tada se utvrđuje postojanje **parcijalne medijacije (eng. *partial mediation*)**.
4. Ako se koeficijent c smanji na razinu pri kojoj nije statistički značajan nakon uključivanja medijatora M u model, utvrđuje se postojanje **potpune medijacije (eng. *full mediation*)**.

Ova metoda utvrđivanja medijacije zahtijeva procjenu modela bez uključenog medijatora te s uključenim medijatorom. Hair et al. (2019a) također sugeriraju i usporedbu pokazatelja prilagodbe modela s medijatorom i bez njega. Ako bi model s medijatorom bez direktne veze imao dobre pokazatelje prilagodbe, utvrdilo bi se postojanje medijacije, a ako bi se ti pokazatelji pogoršali dodavanjem direktne veze u model, zaključilo bi se da medijacija ne postoji. U slučaju da dva procijenjena modela imaju slične pokazatelje prilagodbe, donio bi se zaključak o postojanju medijacije.

Kako bi se medijacija utvrdila u jednom koraku, može se koristiti i statistički Sobel test za indirektne utjecaje s jednim medijatorom. Sobelova procjena standardne pogreške za indirektni utjecaj $a \cdot b$ može se izračunati putem formule (Baron i Kenny, 1986; Kline, 2011; Stride, 2018):

$$s_{ab} = \sqrt{b^2 s_a^2 + a^2 s_b^2} \tag{4.26}$$

Pri čemu je:

a – nestandardizirani koeficijent koji prikazuje uzročno-posljedičnu vezu između nezavisne varijable i medijatora,

s_a – standardna pogreška koeficijenta a,

b – nestandardizirani koeficijent koji prikazuje uzročno-posljedičnu vezu između medijatora i zavisne varijable,

s_b – standardna pogreška koeficijenta b.

U velikim uzorcima omjer indirektnog utjecaja i njegove standardne pogreške može se interpretirati kao z-test nestandardiziranog indirektnog utjecaja. Ovaj omjer naziva se **Sobel test** i računa se kao (Kline, 2011; Stride, 2018; Hair et al., 2019a):

$$z = ab / s_{ab} \tag{4.27}$$

Statistički značajan rezultat za indirektni utjecaj ukazuje na postojanje medijacije u modelu. Međutim, Sobel test pretpostavlja multivarijatnu normalnost indirektnih utjecaja, koja često nije zadovoljena, pa je i sam test nepouzdan. Stoga se mogu izračunati intervali pouzdanosti za

indirektni utjecaj. Ako interval za izabrani indirektni utjecaj ne sadrži vrijednost 0, smatra se da postoji medijacija (Cheong i MacKinnon, 2012; Stride, 2018).

Kad se ustanovi postojanje medijacije u modelu, može se izračunati i **veličina efekta (eng. *effect size*)** na način da se podijeli vrijednost indirektnog utjecaja s vrijednosti ukupnog utjecaja. Tada se dobiva udio ukupnog utjecaja nezavisne na zavisnu varijablu koji djeluje putem medijatora (MacKinnon, Fairchild i Fritz, 2007; Stride, 2018).

Kod medijacijskih modela može doći do efekta suzbijanja (eng. *suppression effect*) u slučaju kada postoji nedosljedna medijacija (eng. *inconsistent mediation*), odnosno kada direktni i indirektni utjecaj imaju suprotne predznake (MacKinnon, Fairchild i Fritz, 2007; Kline, 2011; Kline, 2015; Stride, 2018). Takav slučaj je problematičan, jer se može doći do pogrešnih zaključaka o medijaciji. Naime, ako su predznaci direktnog i indirektnog utjecaja suprotni, tada ukupan utjecaj može biti blizu 0, iako indirektni utjecaj može biti primjetan. Iz tog razloga, istraživači često preskaču prvi korak Baron i Kenny metode te kreću od drugog koraka nadalje za procjenu postojanja medijacije (Kline, 2015).

Osim testiranja jednostavne medijacije s jednim medijatorom, može se testirati i višestruka medijacija. Ona može biti paralelna medijacija (eng. *parallel mediation*) ili serijska medijacija (eng. *serial mediation*). Ovi tipovi medijacije prikazani su na slici 4.12. i 4.13. Kod paralelne medijacije X utječe na više medijatora, a oni utječu na Y, dok kod serijske medijacije postoji lanac indirektnih utjecaja putem više medijatora. Princip testiranja jednostavne medijacije primjenjuje se i za višestruku medijaciju (Stride, 2018).

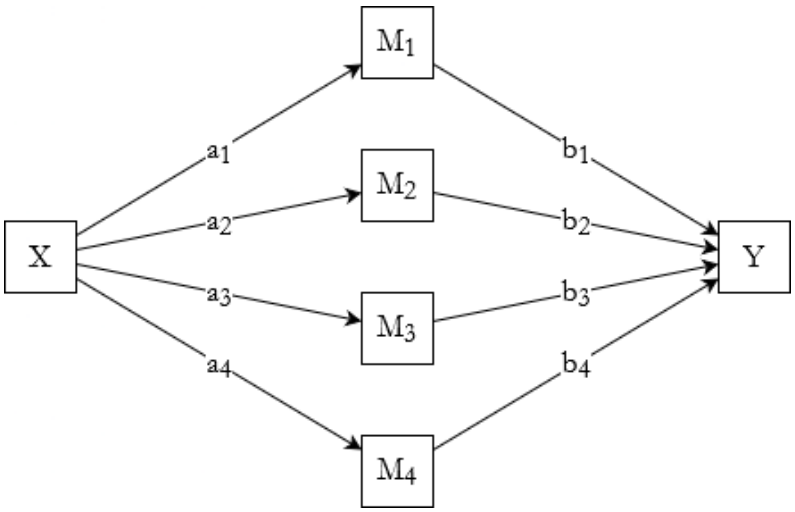

Slika 4.12. Prikaz paralelne medijacije

Izvor: izrada autorice prema Stride (2018, str. 10)

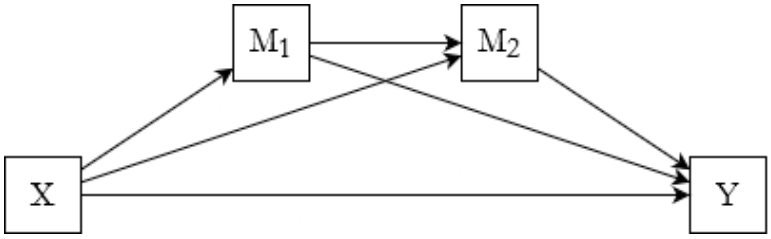

Slika 4.13. Prikaz serijske medijacije

Izvor: izrada autorice prema Stride (2018, str. 11)

Moderacija (eng. *moderation*) se javlja kada treća varijabla ili konstrukt mijenja vezu između dvije povezane varijable ili konstrukta (Awang, 2012; Hair et al., 2019a). Kod SEM modela s moderatorom, odnos između nezavisne i zavisne varijable mijenja se s obzirom na razinu moderatorske varijable. Za razliku od medijacije, koja objašnjava zašto postoje veze između prediktora i zavisne varijable, moderacija identificira kada ili za koga te veze postoje (Stride, 2018; Hair et al., 2019a). Primjerice, testiranjem moderacije moglo bi se odgovoriti na pitanja postoje li razlike u vezi financijskog ponašanja i financijske sigurnosti između muškaraca i žena ili između različitih dobnih skupina i sl. Na slici 4.14. grafički je prikazan utjecaj moderatora W na vezu između varijabli X i Y. Može se primijetiti da, za razliku od medijatora, moderator nije dio modela, već istraživač određuje za koju će vezu u modelu testirati potencijalnu moderaciju.

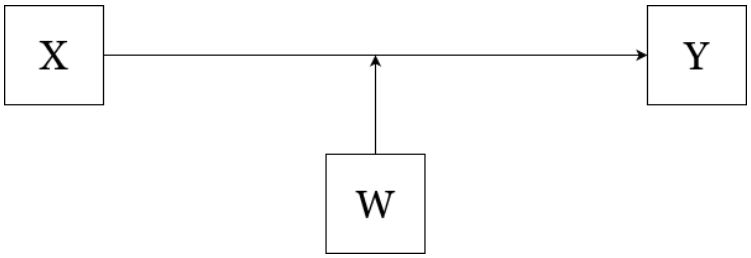

Slika 4.14. Grafički prikaz moderacije

Izvor: izrada autorice prema Stride (2018, str. 29)

Moderatori su najčešće kategorijalne varijable, kao npr. spol, iako se kao moderatori također mogu koristiti i omjerne varijable, ako bi se mogle smisleno kategorizirati. Vrlo je bitno moderator birati na temelju teoretske podloge, odnosno mora postojati razlog da istraživač pretpostavi da moderator

utječe na vezu između dviju varijabli (Hair et al., 2019a). Analiza moderacije najlakše se provodi ako moderator nije značajno povezan s niti jednom varijablom iz modela. Moderacija se najčešće testira putem kreiranja efekta interakcije, gdje se množe vrijednosti indikatora nezavisne varijable i moderatora (Awang, 2012; Kline, 2011; Hair et al., 2019a). Model s efektom interakcije prikazan je na slici 4.15. u obliku statističkog modela, gdje su nezavisna varijabla X, moderator W i efekt interakcije XW specificirani na način da direktno utječu na zavisnu varijablu Y.

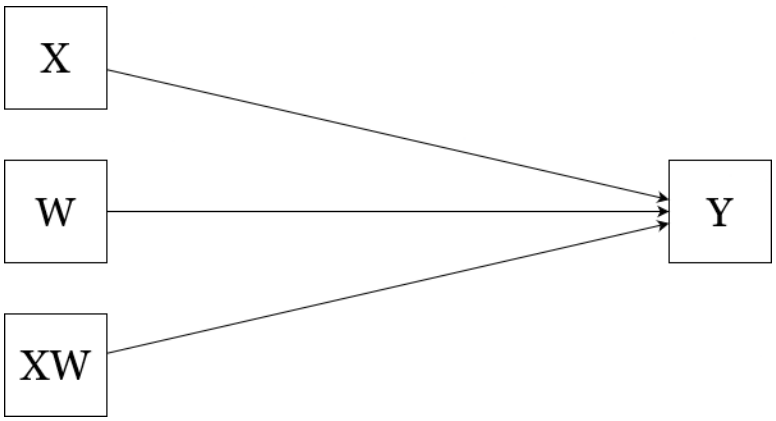

Slika 4.15. Model s efektom interakcije

Izvor: izrada autorice prema Kline (2011, str. 332), Awang (2012, str. 132) i Stride (2018, str. 32)

Postojanje moderacijskog efekta može se utvrditi ako je statistički značajan koeficijent koji predstavlja vezu između efekta interakcije i zavisne varijable, a koeficijent koji predstavlja vezu između moderatora i zavisne varijable je beznačajan. Osim toga, može se promatrati i potencijalno poboljšanje prilagodbe, odnosno objašnjenosti modela putem promjene R^2 nakon dodavanja interakcijskog efekta (Stride, 2018; Awang, 2012). Nakon zaključka o postojanju moderacije u modelu, može se testirati i pojedinačne koeficijente (eng. *simple slopes tests*). Na taj način može se utvrditi značajnost utjecaja specifične vrijednosti moderatora na zavisnu varijablu (Schumacker i Lomax, 2010; Kline, 2011; Stride, 2018).

Kod kategorijalnih varijabli, može se koristiti **analiza više grupa (eng. *multigroup analysis*)** u smislu testiranja efekta moderacije. Tada bi se najprije procijenio model za svaku grupu pojedinačno, a potom bi se procijenio model u kojem bi se parametar koji prikazuje relevantnu uzročno-posljedičnu vezu ograničio, tj. postavio kao jednak za sve grupe. Testom razlike hi-kvadrata između modela sa svim slobodnim parametrima te modela s ograničenim parametrom, utvrdilo bi se postoji li značajno smanjenje ili povećanje hi-kvadrat vrijednosti. Ako postoji

značajna razlika u hi-kvadratima između procijenjenih modela, tada se donosi zaključak o postojanju moderacije, jer ta razlika upućuje na činjenicu da relevantna veza nije ista među promatranim grupama (Hair et al., 2019a). Analiza više grupa inače se može primijeniti i na CFA model, a istraživačima je zanimljivija u smislu uzročno-posljedičnih veza između latentnih konstrukata, odnosno u analizi strukturalnog modela. Razlika analize više grupa u odnosu na testiranje moderacije očituje se u tome što se kod moderacije promatra samo razlika u procijenjenim modelima za jedan specifičan parametar, za koji se pretpostavlja da je pod utjecajem moderacije neke treće varijable, dok se kod analize više grupa gleda razlika u svim parametrima između različitih grupa (Raykov i Marcoulides, 2006; Stride, 2018; Hair et al., 2019a).

4.1.7 Napredne tehnike

Osim osnovnog SEM modeliranja, ponekad se mogu koristiti i neke naprednije tehnike modeliranja. Među naprednije tehnike SEM analize spada prethodno opisana **analiza više grupa (eng. *multigroup analysis*)**, kojom se utvrđuju razlike u procijenjenim parametrima cjelokupnog modela između dviju ili više grupa, a najčešće se grupe temelje na kategorijalnoj varijabli (npr. spol, obrazovanje i sl.).

Osim toga, SEM se može primijeniti i na **longitudinalne podatke (eng. *longitudinal data*)**, kod kojih se u model uključuju dodatni izvori kovarijacija kod istih jedinica promatranja tijekom vremena (Hair et al., 2019a). Najčešće korišten model za analizu longitudinalnih podataka je **model latentnog rasta (eng. *latent growth model*, LGM)** (Raykov i Marcoulides, 2006; Schumacker i Lomax, 2010; Kline, 2011; Hair et al., 2019a). Uz varijance i kovarijance, LGM modeli nužno analiziraju i aritmetičke sredine i njihove promjene kroz vrijeme. Bitno je da se vremenski podaci promatraju u jednakim intervalima (Schumacker i Lomax, 2010; Kline, 2011). Kako bi se modelirale promjene tijekom vremena, LGM modeli ilustriraju upotrebu konstantnog člana (eng. *intercept*) i koeficijenta smjera (eng. *slope*) kao latentne faktore u modelu, čiji su indikatori vremenske komponente (npr. godine). Latentni faktor koji predstavlja konstantni član ima sva faktorska opterećenja fiksirana na vrijednost 1. S druge strane, latentni faktor koji predstavlja koeficijent smjera također ima fiksirane vrijednosti faktorskih opterećenja, a one odgovaraju vremenskim jedinicama u linearnom trendu. Te vrijednosti započinju s nulom za inicijalno razdoblje i dalje se označavaju kao $1, 2, 3, ..., T-1$, gdje T označava broj promatranih vremenskih razdoblja (Raykov i Marcoulides, 2006; Schumacker i Lomax, 2010; Kline, 2011). Procjena

aritmetičke sredine faktora konstantnog člana predstavlja prosječnu inicijalnu razinu promatrane pojave za cijeli uzorak, dok varijanca predstavlja raspon individualnih razlika oko prosjeka. Aritmetička sredina faktora koji predstavlja koeficijent smjera odražava prosječnu razinu promjene promatrane pojave kroz jedinice vremena, a njegova varijanca prikazuje raspon individualnih razlika u stopi promjene tijekom vremena. Ukoliko su ove razlike neznatne i blizu nuli, tada pojedinci ne pokazuju značajnu promjenu u razini pojave u odnosu na inicijalno razdoblje. Pojedinci se razlikuju u mjeri u kojoj varijanca odstupa od nule (Kline, 2011; Boomsma, Hoyle i Panter, 2012). Slika 4.16. prikazuje primjer LGM modela.

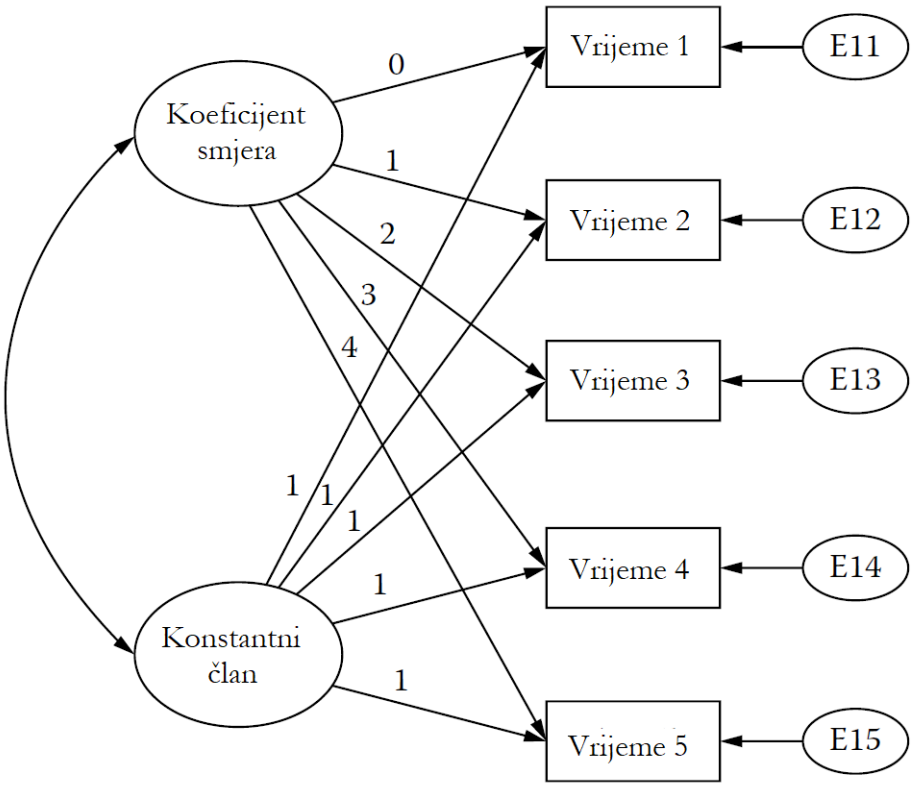

Slika 4.16. Primjer LGM modela

Izvor: izrada autorice prema Schumacker i Lomax (2010, str. 342)

Nadalje, moguće je i **modeliranje na više razina (eng. *multilevel modeling,* MLM)**, čija je svrha analiza hijerarhijskih podataka, gdje su jedinice promatranja svrstane u klastere (npr. učenici u različitim školama, zaposlenici u poduzećima), koji također mogu biti svrstani u klastere više razine (npr. školske četvrti ili države). Dakle, višerazinski podaci odnose se na podatke koji su grupirani unutar jedne ili niza jedinica više razine (Rabe-Hesketh, Skrondal i Zheng, 2012; Stride,

2017). Glavni interes u MLM modeliranju je pronaći učinke na različitim razinama: unutar grupa (eng. *within groups*) i između grupa (eng. *between groups*). Na taj način varijanca koja objašnjava promjene u zavisnoj varijabli razdvaja se sukladno višerazinskoj strukturi i objašnjava se na svakoj pojedinačnoj razini (Stride, 2017). Stoga se može izračunati i mjera u kojoj je ukupna varijanca pripisana razlikama između grupa putem ICC (eng. *intra-class correlation*) pokazatelja. ICC se računa kao omjer varijance između grupa i zbroja varijance unutar i između grupa (Schumacker i Lomax, 2010; Stride, 2017). MLM modeliranje obično se radi putem izgradnje modela u nekoliko koraka (Aguinis, Gottfredson i Culpepper, 2013; Stride, 2017). Prvenstveno se procjenjuje *null* model, kako bi se procijenila objašnjena varijanca prije uključivanja ikakvih prediktora u model te služi kao osnova za evaluaciju nadograđenih modela. Potom se uključuje ispitivanje varijacije prosječnih vrijednosti između grupa putem modela slučajnog konstantnog člana i fiksnog koeficijenta smjera (eng. *Random Intercept and Fixed Slope Model*, RIFSM). Uključivanje trećeg izvora varijacije podrazumijeva procjenu modela slučajnog konstantnog člana i slučajnog koeficijenta smjera (eng. *Random Intercept and Random Slope Model*, RIRSM). Takav model dopušta varijacije koeficijenata smjera između grupa, odnosno ispituje se razlikuju li se utjecaji prediktora na zavisnu varijablu između različitih grupa (Aguinis, Gottfredson i Culpepper, 2013). Ovi modeli uspoređuju se u pokazateljima prikladnosti i promjeni u objašnjenoj varijanci između grupa (Stride, 2017).

Modeli koji su dosad opisani mogu se nazvati i modelima prvog reda (eng. *first-order model*), kod kojih je konstrukt objašnjen kroz određeni broj indikatora. Međutim, postoje i **modeli višeg reda (eng. *higher-order models*)**, koji sadrže više slojeva, odnosno razina latentnih konstrukata (Awang, 2012; Hair et al., 2019a). Najčešće se upotrebljavaju modeli drugog reda (eng. *second-order model*), koji imaju dvije razine latentnih konstrukata. To znači da se uvodi konstrukt drugog (višeg) reda (tzv. glavni konstrukt), koji je uzrok određenom broju konstrukata prvog (nižeg) reda. Konstrukti prvog reda klasično su uzrok određenog broja indikatora. Drugim riječima, faktori prvog reda su komponente faktora drugog reda (Schumacker i Lomax, 2010; Awang, 2012; Hair et al., 2019a). Stoga, kao što faktori prvog reda uzimaju u obzir kovarijacije između indikatora, tako faktori višeg reda uzimaju u obzir kovarijaciju između faktora nižeg reda (Hair et al., 2019a). Modeli višeg reda također mogu imati i formativne faktore. Međutim, s obzirom da SEM temeljen na kovarijanci (eng. *covariance-based SEM*, CB-SEM) nije uvijek prikladan za analizu formativnih

faktora, za ovakve procjene koristi se PLS-SEM (eng. *partial least squares structural equation modeling*) procedura, koja će biti opisana u sljedećem poglavlju (Hair et al., 2019a).

Na slici 4.17. prikazan je kontrast između modela prvog i drugog reda. Prvi dio odnosi se na prikaz modela prvog reda. Vidljivo je da postoje četiri međusobno korelirana faktora, od kojih je svaki mjeren putem četiri reflektivna indikatora. U drugom dijelu slike prikazan je model drugog (višeg) reda. Uvođenjem faktora višeg reda (označen kao F0), faktori koji su originalno bili egzogeni postaju endogeni, jer predstavljaju posljedicu faktora F0, što je vidljivo i grafički. Faktor višeg reda (F0) je egzogeni faktor, dok se u ovakvoj strukturi modela faktori prvog reda ponašaju kao njegovi indikatori.

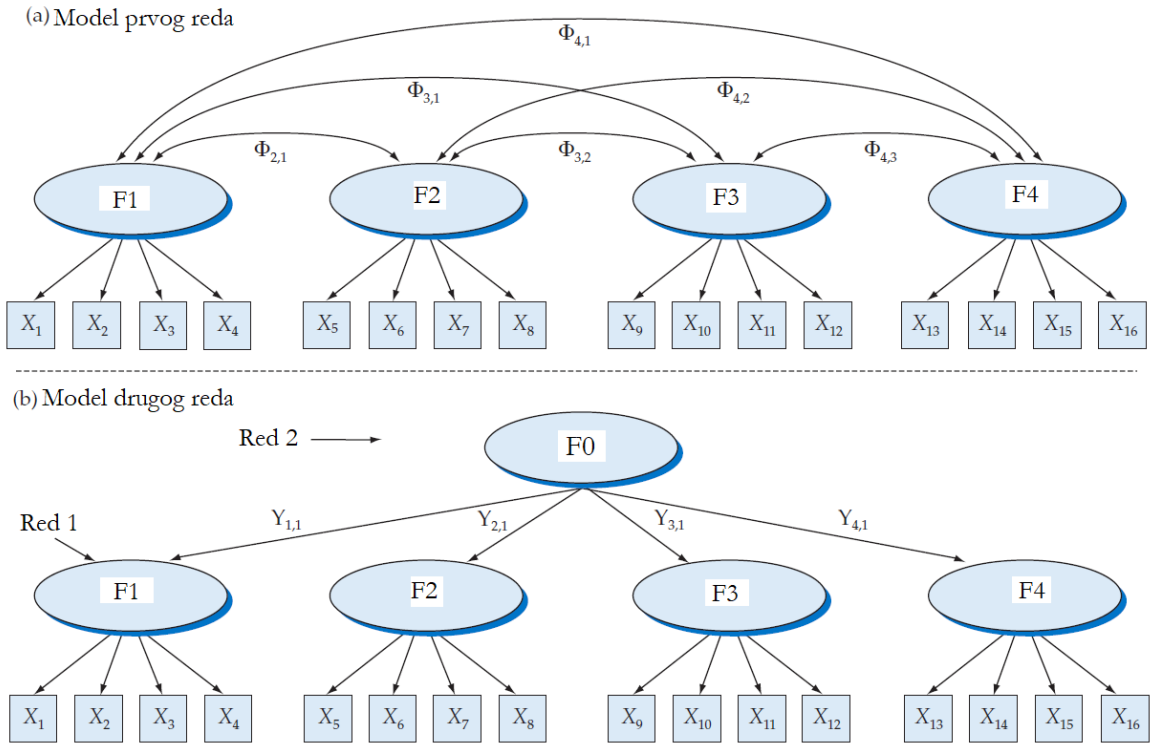

Slika 4.17. Kontrast modela prvog i drugog reda

Izvor: izrada autorice prema Hair et al. (2019a, str. 734)

Kod specifikacije modela kao modela višeg reda, glavni kriterij je teorija. Teoretski, različiti koncepti, naročito u bihevioralnim istraživanjima, mogu se mjeriti na različitim razinama apstrakcije, a upravo to je razlog za korištenje modela višeg reda (Schumacker i Lomax, 2010;

Awang, 2012; Hair et al., 2019a). U određivanju je li model višeg reda prikladan, mogu pomoći odgovori na određena pitanja (Hair et al., 2019a):

- Postoji li teoretska osnova za očekivanje da postoji više konceptualnih razina konstrukta;
- Očekuje li se da će svi faktori prvog reda utjecati na ostale povezane faktore na isti način;
- Hoće li faktori višeg reda predviđati druge faktore na istoj razini apstrakcije;
- Jesu li minimalni uvjeti za identifikaciju i dobra mjerna praksa prisutni u prvom i u drugom redu mjerne teorije.

Ukoliko je pozitivan odgovor na bilo koje od navedenih pitanja, tada je prikladna upotreba modela višeg reda. Nakon testiranja takvog modela, potrebno je ispitati pruža li model zadovoljavajuće pokazatelje prilagodbe. Osim toga, ispituje se predviđaju li faktori višeg reda druge konceptualno povezane faktore na adekvatan način i prema očekivanjima. Isto tako, uspoređuju se modeli nižeg i višeg reda, kako bi se utvrdilo pruža li model višeg reda jednaku ili bolju prediktivnu validnost u odnosu na model nižeg reda (Hair et al., 2019a).

S obzirom da se navedene napredne tehnike SEM modeliranja neće koristiti u obradi podataka u ovom radu, neće se detaljnije opisivati.

4.2 Modeliranje strukturalnim jednadžbama metodom parcijalnih najmanjih kvadrata (PLS-SEM)

4.2.1 Razlike između CB-SEM i PLS-SEM metode

U prethodnom poglavlju opisano je modeliranje strukturalnim jednadžbama temeljeno na kovarijanci (eng. *covariance-based structural equation modeling*, CB-SEM), kao jedna od metoda multivarijatne analize druge generacije. Još jedna metoda druge generacije multivarijatne analize, koja se može smatrati komplementarnim pristupom SEM-u, a koji je orijentiran na predviđanje, je **modeliranje strukturalnim jednadžbama metodom parcijalnih najmanjih kvadrata (eng. *partial least squares structural equation modeling*, PLS-SEM)** (Hair et al., 2017a; Hair et al., 2017b; Hanafiah, 2020). PLS-SEM metoda široko je rasprostranjena u istraživanjima u području društvenih znanosti, a interes za korištenjem ove metode ubrzano raste, zahvaljujući njezinim brojnim prednostima i mogućnostima (Garson, 2016; Hair et al., 2019b; Hanafiah, 2020).

Za razliku od CB-SEM metode, koja je prvenstveno namijenjena korištenju u konfirmatorne svrhe, odnosno testiranje teorije, PLS-SEM je orijentiran na predviđanje te je prikladan za korištenje i

kod eksplanatornih i konfirmatornih istraživanja (Hair et al., 2017b; Henseler, 2018; Hair et al., 2019b). Kad se radi o eksplanatornim istraživanjima, PLS-SEM se može smatrati alatom za izgradnju, umjesto testiranja teorije. S obzirom na njegovo korištenje i u prediktivne svrhe, kroz PLS-SEM nastoji se zadržati interpretabilnost, istovremeno se uključujući u prediktivno modeliranje (Henseler, 2018). Kako je već i spomenuto, CB-SEM ima za cilj procijeniti parametre na način da se minimiziraju razlike između matrice kovarijanci iz uzorka i procijenjene matrice kovarijanci. Suprotno tome, PLS-SEM usmjeren je na maksimiziranje objašnjene varijance zavisnih latentnih konstrukata (Hair, Ringle i Sarstedt, 2011; Hair et al., 2017a; Henseler, 2018; Hair et al., 2019b). Stoga, iako ove dvije metode na prvi pogled djeluju gotovo jednake, one imaju drugačije ciljeve i algoritme. Ipak, ove dvije metode su komplementarne i nedostaci jedne metode predstavljaju prednosti druge i obrnuto. Osim toga, procjene istih modela putem obje metode pri dobrim mjernim svojstvima modela daju slične rezultate te se mogu usporedno koristiti (Hair, Ringle i Sarstedt, 2011; Hair et al., 2012).

Kao i kod CB-SEM modela, i PLS-SEM model sastoji se od dva dijela: mjerni ili vanjski model (eng. *measurement/outer model*) te strukturalni ili unutarnji model (eng. *structural/inner model*). Unutarnji model prikazuje povezanost između latentnih konstrukata, dok vanjski model prikazuje veze latentnih konstrukata i njihovih pripadajućih indikatora (Hair, Ringle i Sarstedt, 2011; Wong, 2013; Hair et al., 2017a; Hair et al., 2017b; Hair et al., 2019b). Oznake za latentne konstrukte i indikatore na grafičkom prikazu jednaki su kao u CB-SEM modelima. Odnosno, latentni konstrukti označavaju se kao krugovi ili ovali, dok se indikatori označavaju kao pravokutnici. Sve veze na dijagramu putanje također su jednake kao u CB-SEM modelima. Dakle, jednosmjerne strelice upućuju na uzročno-posljedičnu vezu u modelu. Međutim, kod PLS-SEM-a nisu moguće višestruke veze, odnosno indikatori mogu biti povezani samo s jednim latentnim konstruktom, ne promatra se međusobna korelacija konstrukata, a kod strukturalnog modela dopušteni su isključivo rekurzivni modeli, bez povratne veze (Hair, Ringle i Sarstedt, 2011; Hair et al., 2017a; Avkiran, 2018). Na slici 4.18. prikazan je PLS-SEM model, s vidljivo označenim dijelovima koji se odnose na vanjski i unutarnji dio modela. Osim toga, Y1 i Y2 prikazani su kao formativni, a Y3 kao reflektivni faktor. Y4 prikazan je kao konstrukt s jednim indikatorom (eng. *single-item construct*). Slika također navodi na zaključak da PLS-SEM može uvrstiti formativne konstrukte, kao i konstrukte s jednim indikatorom, što je za CB-SEM problematično, naročito zbog zahtjeva identifikacije modela.

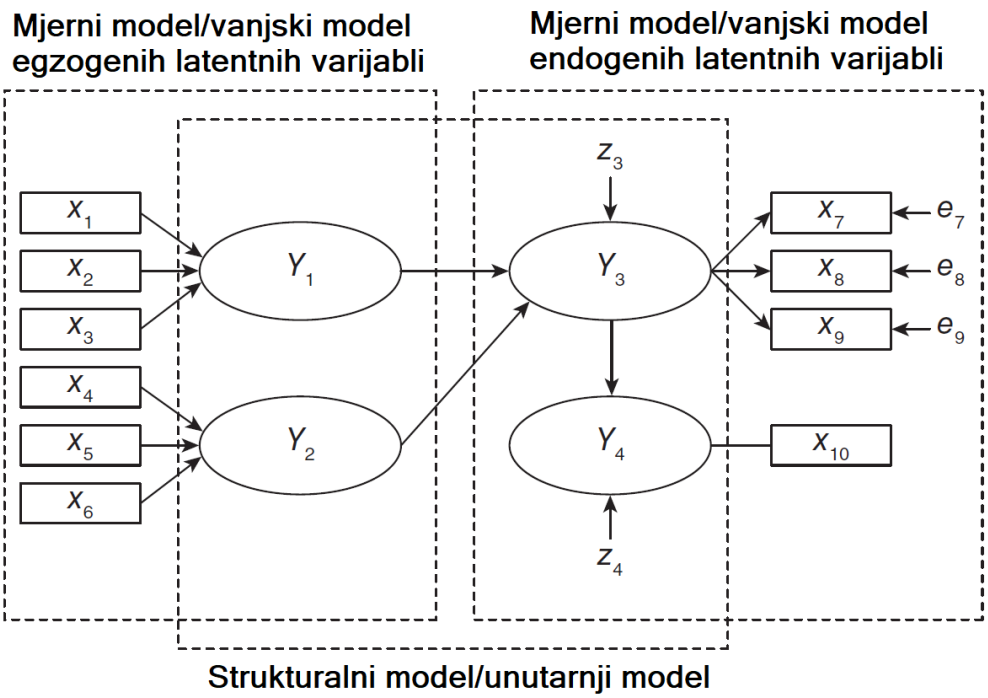

Slika 4.18. Prikaz jednostavnog PLS-SEM modela

Izvor: izrada autorice prema Hair et al. (2017a, str. 12)

PLS-SEM algoritam slijedi pristup modeliranja u dvije faze. Prva faza odnosi se na procjenu skorova latentnih konstrukata (eng. *latent constructs' score*) kroz četiri koraka, dok druga faza obuhvaća izračun konačnih procjena vanjskih težina (eng. *outer weights*) i opterećenja (eng. *loadings*) (Lohmöller, 1989; Hair, Ringle i Sarstedt, 2011; Hair et al., 2017a). Ovo modeliranje naziva se parcijalnim, jer iterativni PLS-SEM algoritam procjenjuje koeficijente za regresijske modele parcijalnih najmanjih kvadrata i kod mjernog i kod strukturalnog modela. Ukoliko se u modelu specificira formativni mjerni model, tada se procjenjuju koeficijenti (težine) višestrukom regresijom, gdje je latentna varijabla u ulozi zavisne, a pripadajući indikatori u ulozi nezavisnih varijabli. S druge strane, u reflektivnim mjernim modelima uzima se jedna regresija za svaki indikator, koji pojedinačno predstavljaju zavisne varijable, dok je latentna varijabla uvijek u ulozi nezavisne varijable (Lohmöller, 1989; Hair, Ringle i Sarstedt, 2011; Hair et al., 2017a). U nastavku su opisane faze PLS-SEM algoritma (Lohmöller, 1989; Hair, Ringle i Sarstedt, 2011; Henseler, Ringle i Sarstedt, 2012; Garson, 2016; Hair et al., 2017a; Sarstedt, Ringle i Hair, 2017a):

- ***Prva faza***: Iterativna procedura procjene skorova latentnih konstrukata:

1. Vanjska aproksimacija skorova latentnih konstrukata – skorovi latentnih varijabli izračunavaju se temeljem inicijalnih skorova indikatora i vanjskih koeficijenata i/ili temeljem skorova iz četvrtog koraka ove procedure.
2. Procjena tzv. unutarnjih težina (eng. *inner weights*), koje mjere snagu veza između latentnih varijabli.
3. Izračun skorova latentnih konstrukata temeljem skorova iz prvog koraka te određenih unutarnjih težina iz drugog koraka.
4. Procjena vanjskih težina (eng. *outer weights*), odnosno veza između indikatora i latentnih konstrukata sa skorovima iz trećeg koraka procedure.

Ova procedura se ponavlja dok zbroj vanjskih težina ne padne ispod prethodno određene granice. Ta granica najčešće se postavlja na vrijednost 10^{-5}, kako bi se osigurala konvergencija algoritma pri beznačajnim razlikama u promjenama težina kroz iterativni postupak (Lohmöller, 1989; Hair, Ringle i Sarstedt, 2011; Henseler, Ringle i Sarstedt, 2012; Garson, 2016).

- ***Druga faza***: Konačna procjena koeficijenata koristeći metodu najmanjih kvadrata za svaku parcijalnu regresiju u PLS-SEM modelu.

Kao što je vidljivo, PLS-SEM više je regresijski orijentiran pristup, koji minimizira rezidualni dio varijance, tj. maksimizira objašnjenu varijancu endogenih konstrukata. Još jedna razlika u odnosu na CB-SEM očituje se u tome što je CB-SEM orijentiran na model zajedničkog faktora (eng. *common factor model*), dok je PLS-SEM temeljen na kompozitnom modelu (eng. *composite model*). Dok se kod zajedničkog faktora za procjenu parametara koristi samo zajednička varijanca, kod kompozitnog pristupa u obzir se uzima ukupna varijanca za procjenu parametara modela. Drugim riječima, ne izostavljaju se specifične i varijance pogreške, što pomaže u učinkovitosti maksimiziranja objašnjene varijance zavisne varijable (Hair et al., 2017a; Hair et al., 2017b; Sarstedt, Ringle i Hair, 2017a; Avkiran, 2018; Rasoolimanesh i Ali, 2018; Hair et al., 2019b). U izboru između ove dvije metode treba obratiti pažnju na ciljeve istraživanja, karakteristike podataka (veličina uzorka, pretpostavke distribucije podataka, nedostajuće vrijednosti, mjerna ljestvica), karakteristike modela (broj indikatora po konstruktu, formativni ili reflektivni modeli, kompleksnost modela, postavke modela) i evaluaciju modela (Hair, Ringle i Sarstedt, 2011; Hair et al., 2017b).

Po pitanju **ciljeva istraživanja**, poželjno je koristiti PLS-SEM u slučaju kad je cilj predviđanje i objašnjavanje ključnih ciljnih konstrukata ili identificiranje ključnih prediktora konstrukta. Također, PLS-SEM koristan je pri eksplorativnim istraživanjima i kod proširivanja postojeće teorije (Hair, Ringle i Sarstedt, 2011; Hair et al., 2012; Peng i Lai, 2012; Hair et al., 2017b; Mohamad et al., 2019). Ova metoda ne zahtijeva ispunjavanje nikakvih **distribucijskih pretpostavki**, stoga se može smatrati neparametrijskom metodom. Kod podataka koji nisu normalno distribuirani, PLS-SEM pokazuje veću robusnost, a ako su podaci normalno distribuirani, CB-SEM i PLS-SEM daju izrazito slične rezultate procjene modela (Hair, Ringle i Sarstedt, 2011; Peng i Lai, 2012; Hair et al., 2017a; Hair et al., 2017b; Sarstedt, Ringle i Hair, 2017a; Hair et al., 2019b). PLS-SEM robustan je na nedostajuće vrijednosti podataka dok god su ispod prihvatljive razine, a radi sa svim vrstama varijabli: omjernim, intervalnim, redoslijednim, dok za binarne i kategorijalne varijable postoje određena ograničenja. U analizu je moguće uključiti i sekundarne podatke, s obzirom da se razmatraju sve moguće veze u modelu, koji je orijentiran na predviđanje (Hair et al., 2017a; Hair et al., 2019b).

Nadalje, prilikom izbora prikladne metode, potrebno je obratiti pažnju i na **veličinu uzorka**. Naime, PLS-SEM učinkovito radi s malim uzorcima kada su modeli kompleksni. Ovo je moguće zato što se odvojeno računaju veze u strukturalnom i u mjernom modelu putem parcijalnih regresija. Također, PLS-SEM u ovakvim situacijama ima veću snagu testa (eng. *statistical power*), odnosno korištenje ove metode dovodi do veće vjerojatnosti pronalaska statistički značajnog rezultata kada je on uistinu prisutan u populaciji (Hair, Ringle i Sarstedt, 2011; Peng i Lai, 2012; Hair et al., 2017a; Hair et al., 2017b; Sarstedt, Ringle i Hair, 2017a; Hair et al., 2019b). Međutim, važno je imati na umu da nijedan statistički test ne može pretvoriti loš uzorak, koji nije reprezentativan, u prikladan uzorak. Stoga, manji uzorci svakako ne bi smjeli biti previše heterogeni, već bi trebali dobro odražavati promatranu populaciju (Henseler, Ringle i Sarstedt, 2012; Hair et al., 2014; Hair et al., 2017a; Sarstedt, Ringle i Hair, 2017a; Hair et al., 2019b). Iako je preporuka poželjne veličine uzorka 10 puta veći broj od strukturalnih veza usmjerenih na određeni konstrukt u strukturalnom modelu ili, ako postoje formativni konstrukti, 10 puta veći broj od formativnih indikatora koji mjere jedan konstrukt, Hair et al. (2017a) sugeriraju odabir veličine uzorka i temeljem snage testa (najčešće je to 80%) koja se želi postići. Prema tablici 4.3., može se reći npr. da kada je maksimalan broj nezavisnih varijabli u mjernim i strukturalnim modelima 5,

potrebno je 45 opažanja kako bi se postigla snaga testa od 80% za otkrivanje vrijednosti koeficijenta determinacije (R^2) od barem 0.25 (uz 5% vjerojatnosti pogreške).

Tablica 4.3. Preporuke veličine uzorka za PLS-SEM pri snazi testa od 80%

Maksimalan broj nezavisnih varijabli konstrukta	Razina signifikantnosti											
	10%				5%				1%			
	Minimalni R^2				Minimalni R^2				Minimalni R^2			
	0.10	0.25	0.50	0.75	0.10	0.25	0.50	0.75	0.10	0.25	0.50	0.75
2	72	26	11	7	90	33	14	8	130	47	19	10
3	83	30	13	8	103	37	16	9	145	53	22	12
4	92	34	15	9	113	41	18	11	158	58	24	14
5	99	37	17	10	122	45	20	12	169	62	26	15
6	106	40	18	12	130	48	21	13	179	66	28	16
7	112	42	20	13	137	51	23	14	188	69	30	18
8	118	45	21	14	144	54	24	15	196	73	32	19
9	124	47	22	15	150	56	26	16	204	76	34	20
10	129	49	24	16	156	59	27	18	212	79	35	21

Izvor: izrada autorice prema Hair et al. (2017a, str. 26)

PLS-SEM prikladan je i za analizu **kompleksnih modela** s brojnim konstruktima, indikatorima i vezama u strukturalnom modelu. Naime, kod CB-SEM metode postupak procjene modela često ne može postići rješenje ili daje neprikladne rezultate, naročito pri manjim uzorcima ili podacima koji nisu normalno distribuirani. Nasuprot tome, PLS-SEM uvijek konvergira, odnosno uvijek postiže rješenje. Stoga, dok god su ispunjeni uvjeti za minimalnu veličinu uzorka, kompleksnost modela je neograničena (Hair et al., 2012; Peng i Lai, 2012; Hair et al., 2017a; Sarstedt, Ringle i Hair, 2017a; Hair et al., 2019b). Također, ovom metodom mogu se procijeniti modeli koji sadrže konstrukte mjerene samo jednim indikatorom (eng. *single-item construct*), što je kod CB-SEM metode neprikladno zbog problema s identifikacijom modela (Hair et al., 2010; Garson, 2016; Hair et al., 2017a). Osim toga, PLS-SEM je fleksibilan što se tiče vrste mjernog modela, odnosno načina mjerenja konstrukata, pa tako može bez problema analizirati **reflektivne i formativne konstrukte** unutar cjelokupnog modela. Model može sadržavati sve reflektivne ili sve formativne konstrukte, a oni se mogu analizirati i zajedno u jedinstvenom modelu, što je velika prednost PLS-SEM metode (Hair, Ringle i Sarstedt, 2011; Hair et al., 2012; Peng i Lai, 2012; Henseler, Ringle i Sarstedt, 2012; Hair et al., 2014; Sarstedt, Ringle i Hair, 2017a; Hair et al., 2017a; Rasoolimanesh i Ali, 2018).

Prilikom **evaluacije modela**, CB-SEM usmjeren je na koncept prilagodbe modela kroz različite mjere, što nije slučaj kod PLS-SEM-a. Naime, za PLS-SEM još uvijek ne postoje jasno ustanovljene mjere prilagodbe modela, iako se one u novije vrijeme sve više razvijaju i predlažu. Međutim, PLS-SEM metodom razmatra se uzajamno djelovanje predviđanja i testiranja teorije, odnosno metoda se može nazvati uzročno-prediktivnom (eng. *causal-predictive*). To znači da se, uz jaku strukturalnu teoriju, strukturalne veze mogu tumačiti kao uzročne veze, što potvrđuje relevantnost korištenja mjera prilagodbe modela. Ipak, ova stavka u analizi manje je važna u odnosu na CB-SEM, stoga je naglasak kod PLS-SEM modela evaluacija pokazatelja prediktivnih sposobnosti modela (Henseler, Ringle i Sarstedt, 2012; Hair et al., 2017a; Sarstedt, Ringle i Hair, 2017a; Avkiran, 2018; Hair et al., 2019b).

Temeljem svega navedenog, mogu se sistematizirati glavne smjernice pri odabiru između CB-SEM i PLS-SEM metode (Hair, Ringle i Sarstedt, 2011; Henseler, Ringle i Sarstedt, 2012; Hair et al., 2017a; Hair et al., 2017b; Hanafiah, 2020). Smjernice su prikazane u tablici 4.4.

Tablica 4.4. Smjernice za odabir između CB-SEM i PLS-SEM metode

Kriteriji	**Metoda**
Ciljevi istraživanja	
Predviđanje	PLS-SEM
Testiranje teorije/konfirmatorna analiza	CB-SEM
Eksplorativno istraživanje, proširivanje postojeće teorije	PLS-SEM
Testiranje teorije i predviđanje	PLS-SEM
Specifikacija mjernog modela	
Reflektivni konstrukti su dio modela	CB-SEM i PLS-SEM
Formativni konstrukti su dio modela	PLS-SEM
Konstrukti mjereni jednim indikatorom su dio modela	PLS-SEM
Komponente pogreške zahtijevaju dodatnu specifikaciju (npr. kovarijacija)	CB-SEM
Strukturalni model	
Kompleksan model (mnogo konstrukata i indikatora)	PLS-SEM
Rekurzivan model	CB-SEM i PLS-SEM
Nerekurzivan model	CB-SEM
Karakteristike podataka	
Omjerna skala podataka	CB-SEM i PLS-SEM
Kvazi-omjerna skala (intervalna, redoslijedna), nominalna skala	PLS-SEM
Normalno distribuirani podaci	CB-SEM i PLS-SEM
Podaci nisu normalno distribuirani	PLS-SEM
Sekundarni podaci	PLS-SEM
Veličina uzorka	

Manji uzorci	PLS-SEM
Veliki uzorci	CB-SEM i PLS-SEM
Evaluacija modela	
Potrebno je koristiti skorove latentnih varijabli u naknadnim analizama	PLS-SEM
Potrebno je ustanoviti kriterije prilagodbe modela	CB-SEM

Izvor: izrada autorice

4.2.2 Specifikacija modela

Prilikom specifikacije modela potrebno je prvenstveno odrediti konstrukte od interesa te ih definirati, tj. odrediti način njihovog mjerenja putem određenih indikatora. Potom je potrebno odrediti veze između konstrukata u modelu temeljem teoretskih i logičkih saznanja o predmetu istraživanja. Samim postavkama tih veza određuje se i koji su konstrukti egzogeni, a koji endogeni, odnosno specificira se **strukturalni (unutarnji) model** (Hair et al., 2014; Hair et al., 2017a; Sarstedt, Ringle i Hair, 2017a). Najjednostavnije je kreirati dijagram putanje (eng. *path diagram*) kojim se povezuju varijable u modelu, radi jasnijeg pregleda postojećih veza. Potrebno je voditi računa da u modelu ne smije biti povratnih veza između konstrukata. Kako je i bilo prikazano na slici 4.18., kod grafičkog prikaza egzogeni konstrukti nemaju nikakve strelice koje upućuju na njih, odnosno oni uzimaju ulogu nezavisnih varijabli. Endogeni konstrukti uzimaju ulogu zavisnih varijabli, a grafičkim prikazom to se vidi kada je prema njima usmjerena jednosmjerna strelica iz nekog egzogenog konstrukta. Međutim, endogeni konstrukti mogu se ponašati i kao nezavisne varijable, ukoliko se nalaze između dva konstrukta (primjerice Y3 na slici 4.18.). Stoga, kao i u CB-SEM analizi, i kod PLS-SEM-a u modelu se mogu javiti i direktni i indirektni utjecaji jedne varijable na drugu (Hair et al., 2014; Garson, 2016; Hair et al., 2017a; Sarstedt, Ringle i Hair, 2017a).

Nakon postavljanja unutarnjeg modela, specificiraju se vanjski (mjerni) modeli. Potrebno je definirati način na koji će se mjeriti konstrukti. Naime, kako je već poznato, konstrukti su latentne varijable koje se ne mogu direktno mjeriti. Iz tog razloga potrebno je identificirati skup indikatora (ili samo jedan indikator) koji će odražavati latentni konstrukt. Osim toga, potrebno je specificirati hoće li konstrukti biti mjereni kao reflektivni ili kao formativni (Hair et al., 2014; Garson, 2016; Hair et al., 2017a; Sarstedt, Ringle i Hair, 2017a).

Reflektivni mjerni modeli dugo su korišteni u istraživanjima društvenih znanosti, gdje direktne veze idu od konstrukta prema indikatorima. Mjere, tj. indikatori u ovim modelima predstavljaju

efekte pripadajućeg konstrukta (Sarstedt et al., 2016; Hair et al., 2017a; Sarstedt, Ringle i Hair, 2017a; Hanafiah, 2020). Jednako kao i kod CB-SEM-a, indikatori pojedinog konstrukta trebaju biti međusobno visoko korelirani i izmjenjivi, jer se smatra da su uzrok istog konstrukta. Izostavljanje jednog od indikatora ne mijenja značenje konstrukta, dok god je njegova razina pouzdanosti zadovoljavajuća (Hair et al., 2014; Garson, 2016; Hair et al., 2017a; Sarstedt, Ringle i Hair, 2017a; Rasoolimanesh i Ali, 2018). Reflektivni model može se opisati sljedećom jednadžbom (Sarstedt et al., 2016; Sarstedt, Ringle i Hair, 2017a; Avkiran, 2018):

$$x = lY + e \tag{4.28}$$

Pri čemu je:

x – indikator varijabla,

Y – latentna varijabla,

l – regresijski koeficijent koji mjeri snagu veze između indikatora i latentne varijable,

e – slučajna pogreška.

Suprotno tome, **formativni mjerni modeli** temelje se na pretpostavci uzročnih indikatora, odnosno kod ovakvih modela smatra se da indikatori kao linearna kombinacija određuju latentni konstrukt. Na grafičkom prikazu jednosmjerne strelice idu od indikatora prema konstruktu i, za razliku od reflektivnih modela, indikatori nisu međusobno zamjenjivi niti su nužno korelirani. Izostavljanje indikatora formativnog konstrukta može promijeniti njegovo značenje, stoga bi se takva praksa trebala izbjegavati (Hair et al., 2014; Garson, 2016; Sarstedt et al., 2016; Hair et al., 2017a; Sarstedt, Ringle i Hair, 2017a; Rasoolimanesh i Ali, 2018; Hanafiah, 2020). U kontekstu formativnih modela razlikuju se dva tipa indikatora: uzročni (eng. *causal indicators*) i kompozitni (eng. *composite indicators*) (Hair et al., 2017a; Sarstedt, Ringle i Hair, 2017a). Kompozitni indikatori odgovaraju definiciji formativnog mjernog modela u smislu da predstavljaju linearnu kombinaciju koja u potpunosti formira latentnu varijablu, čiji je koeficijent determinacije tada jednak 1. U ovom slučaju pretpostavlja se da nema slučajne pogreške (Garson, 2016; Hair et al., 2017a; Sarstedt, Ringle i Hair, 2017a). Stoga se ovakav model može opisati sljedećom jednadžbom (Sarstedt et al., 2016; Sarstedt, Ringle i Hair, 2017a):

$$Y = \sum_{k=1}^{K} w_k \cdot x_k \tag{4.29}$$

Gdje je Y linearna kombinacija indikatora x_k ($k = 1,...,K$), ponderiranih težinama w_k.

Nasuprot tome, uzročni indikatori ne formiraju latentnu varijablu, već se smatra da je uzrokuju. Stoga, konstrukt nije savršeno mjeren svojim indikatorima te postoji slučajna pogreška, koja obuhvaća sve druge slučajne nepoznate uzroke latentne varijable. Može se prikazati jednadžbom (Sarstedt et al., 2016; Sarstedt, Ringle i Hair, 2017a; Avkiran, 2018):

$$Y = \sum_{k=1}^{K} w_k \cdot x_k + z \tag{4.30}$$

Gdje w_k prikazuje doprinos svakog indikatora x_k ($k = 1,...,K$) latentnoj varijabli Y, a z predstavlja slučajnu pogrešku latentne varijable.

Glavna razlika reflektivnih i formativnih modela može se pronaći u načinu na koji se mjeri domena sadržaja konstrukta. Kod reflektivnih modela cilj je maksimizirati preklapanje između međusobno izmjenjivih indikatora konstrukta, a kod formativnih modela cilj je minimizirati preklapanje između komplementarnih indikatora konstrukta (Hair et al., 2017a). Ova razlika prikazana je na slici 4.19.

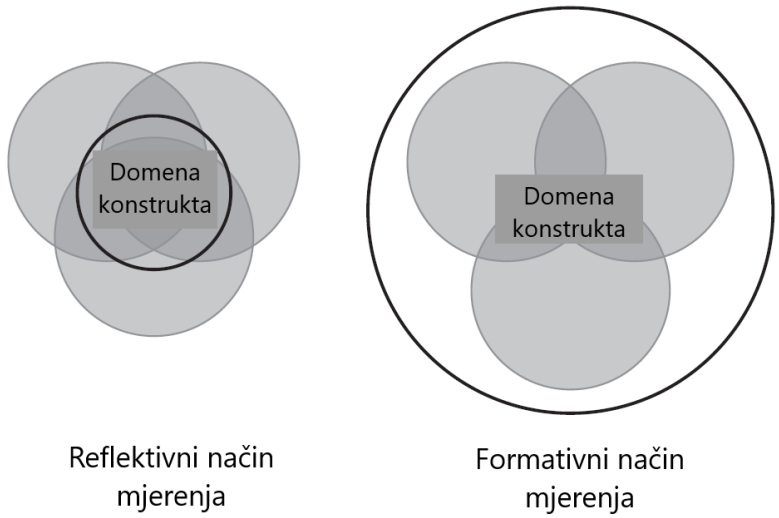

Slika 4.19. Razlika reflektivnog i formativnog načina mjerenja modela

Izvor: izrada autorice prema Hair et al. (2017a, str. 49)

Ipak, ne postoji konačan odgovor kada se konstrukt mjeri reflektivno, a kada formativno. Naime, neki se konstrukti mogu mjeriti na oba načina pa je važno dobro postaviti koncept konstrukta i ciljeve istraživanja da bi se utvrdilo na koji način je primjereno mjeriti konstrukt. Osim toga, konfirmatornom analizom tetrada (eng. *confirmatory tetrad analysis*, CTA) može se testirati nulta hipoteza da je mjera konstrukta reflektivna. Ovom analizom može se utvrditi na koji način bi se trebao specificirati mjerni model. Međutim, svaka promjena načina mjerenja treba biti temeljena na teoretskim razmatranjima i ciljevima istraživanja (Gudergan et al., 2008; Garson, 2016; Hair et al., 2017a; Hair et al., 2017c).

U nastavku su dane temeljne smjernice za odabir između reflektivne i formativne specifikacije modela.

Tablica 4.5. Smjernice za odabir između reflektivne i formativne specifikacije modela

Kriteriji	**Odluka**
Uzročna veza između indikatora i konstrukta	• Od konstrukta prema indikatorima: reflektivni • Od indikatora prema konstruktu: formativni
Objašnjava li konstrukt indikatore ili je konstrukt kombinacija indikatora?	• Objašnjava indikatore: reflektivni • Kombinacija indikatora: formativni
Predstavljaju li indikatori posljedice ili uzroke konstrukta?	• Posljedice: reflektivni • Uzroci: formativni
Hoće li se svi indikatori nužno promijeniti na sličan način (uz pretpostavku da su jednako kodirani), ako se procjena konstrukta promijeni?	• Da: reflektivni • Ne: formativni
Jesu li indikatori međusobno zamjenjivi?	• Da: reflektivni • Ne: formativni

Izvor: izrada autorice prema Hair et al. (2017a, str. 52)

Kako je već spomenuto, PLS-SEM može analizirati i konstrukte s jednim indikatorom. Takav konstrukt u modelu može se specificirati pod uvjetima manjeg uzorka (N<50), uz očekivanje slabijeg utjecaja tog konstrukta u modelu. Osim toga, ako su korelacije među indikatorima i Cronbach's alpha pokazatelj previsoki (>0.80 i >0.90), to može ukazivati na činjenicu da su indikatori izrazito homogeni i semantički suvišni. Primjerice, u anketi se može postavljati pitanje istog značenja na više različitih načina, zbog čega je moguće umjesto putem više pitanja (indikatora) određeni konstrukt mjeriti putem samo jednog pitanja (indikatora) (Diamantopoulos, 2012; Hair et al., 2017a).

4.2.3 Analiza reflektivnog mjernog modela

Prilikom evaluacije reflektivnog mjernog modela, potrebno se voditi sličnim smjernicama kao kod analize konstrukata u CB-SEM mjernom modelu. Naime, potrebno je za konstrukte vanjskog (mjernog) modela ustanoviti razinu njihove interne konzistentnosti, pouzdanosti te konvergentne i diskriminantne validnosti (Hair, Ringle i Sarstedt, 2011; Peng i Lai, 2012; Hair et al., 2017a; Hair et al., 2019b; Hanafiah, 2020).

Prilikom procjene **interne konzistentnosti** koristi se tradicionalni kriterij **Cronbach's alpha** koeficijent, koji daje procjene pouzdanosti temeljem međusobnih korelacija između indikatora. Prema Hair et al. (2017a), može se izračunati prema formuli:

$$Cronbach's\ \alpha = \left(\frac{M}{M-1}\right) \cdot \left(1 - \frac{\sum_{i=1}^{M} s_i^2}{s_t^2}\right) \tag{4.31}$$

Pri čemu s_i^2 predstavlja varijancu indikatora i određenog konstrukta, mjerenog putem M indikatora ($i = 1, ..., M$), a s_t^2 je varijanca zbroja svih M indikatora tog konstrukta.

Kako je spomenuto i pri CB-SEM analizi, ovaj pokazatelj osjetljiv je na broj indikatora (povećava se zajedno s povećanjem broja indikatora) i često podcjenjuje internu konzistentnost, stoga se smatra tradicionalnim konzervativnijim pokazateljem. Kao vrijednost donje granice prihvatljivosti ovog pokazatelja može se uzeti 0.60 za istraživanja u ranoj fazi, dok su vrijednosti od barem 0.70 inače poželjne. Ipak, nije poželjno da vrijednost Cronbach's alpha koeficijenta bude previsoka, tj. veća od 0.90 ili 0.95, jer to ukazuje na činjenicu da svi indikatori mjere isti fenomen i ne mogu biti valjana mjera konstrukta (Hair et al., 2014; Garson, 2016; Ab Hamid, Sami i Sidek, 2017; Hair et al., 2017a; Sarstedt, Ringle i Hair, 2017a).

Zbog ovih ograničenja, predlaže se računati i pokazatelj **kompozitne pouzdanosti (eng. *composite reliability*)** kao dodatnu mjeru interne konzistentnosti. Za razliku od Cronbach's alpha koeficijenta, pokazatelj kompozitne pouzdanosti uzima u obzir vanjska opterećenja (eng. *outer loadings*) indikatora te ne pretpostavlja da su oni jednaki u populaciji, odnosno da su svi indikatori jednako pouzdani. Zato se ovaj pokazatelj preferira u PLS-SEM analizi (Hair, Ringle i Sarstedt, 2011; Hair et al., 2014; Garson, 2016; Hair et al., 2017a; Hair et al., 2017b; Sarstedt, Ringle i Hair, 2017a;

Mohamad et al., 2019). Izračun je sličan kao kod CR-a u CB-SEM analizi, a izraz prema kojem se računa je sljedeći (Hair et al., 2017a; Sarstedt, Ringle i Hair, 2017a):

$$\rho_c = \frac{\left(\sum_{i=1}^{M} l_i\right)^2}{\left(\sum_{i=1}^{M} l_i\right)^2 + \sum_{i=1}^{M} var(e_i)} \tag{4.32}$$

U navedenoj formuli l_i predstavlja standardizirano vanjsko opterećenje indikatora varijable i određenog konstrukta mjerenog putem M indikatora, dok je e_i pogreška mjerenja indikatora varijable i, a $var(e_i)$ označava varijancu mjerne pogreške, definirane kao $1 - l_i^2$.

Vrijednosti ovog pokazatelja nalaze se u rasponu od 0 do 1, gdje veće vrijednosti ukazuju na višu razinu pouzdanosti. Što se tiče donje granice prihvatljive pouzdanosti, uzimaju se vrijednosti kao kod Cronbach's alpha. Dakle, vrijednost donje granice prihvatljivosti pokazatelja za eksplorativna istraživanja kreće se u rasponu od 0.60 do 0.70, dok su vrijednosti od 0.70 do 0.90 zadovoljavajuće za naprednije faze istraživanja. Vrijednosti više od 0.90 ili 0.95 su problematične, jer sugeriraju da su indikatori gotovo identični i suvišni, primjerice kod pitanja u anketi koja su gotovo ista (Hair, Ringle i Sarstedt, 2011; Garson, 2016; Hair et al., 2017a; Sarstedt, Ringle i Hair, 2017a; Avkiran, 2018; Hair et al., 2019b).

U praksi se sugerira prilikom istraživanja u svrhu ispitivanja pouzdanosti konstrukta prikazati vrijednosti oba pokazatelja: i Cronbach's alpha koeficijenta i kompozitne pouzdanosti. Naime, Cronbach's alpha je manje precizan i konzervativan pokazatelj, dok je pokazatelj kompozitne pouzdanosti liberalniji. Prava vrijednost pouzdanosti obično se zato promatra između vrijednosti ovih dvaju pokazatelja, gdje se Cronbach's alpha može smatrati donjom granicom, a kompozitna pouzdanost ρ_c gornjom granicom (Hair et al., 2017a).

Konvergentna validnost ocjenjuje razinu u kojoj jedna mjera pozitivno korelira s alternativnim mjerama istog konstrukta. Drugim riječima, navedene mjere, tj. indikatori smatraju se različitim (alternativnim) pristupima za mjerenje istog konstrukta. Kod reflektivnog konstrukta poželjno je da ovi indikatori dijele visok udio varijance (Hair et al., 2017a). Kod PLS-SEM modela konvergentna validnost također se ocjenjuje putem **AVE** pokazatelja, koji predstavlja prosječnu

vrijednost kvadrata svih opterećenja indikatora povezanih s konstruktom (Hair et al., 2014; Hair et al., 2017a; Hair et al., 2017b; Sarstedt, Ringle i Hair, 2017a; Hair et al., 2019b). Računa se kao kod CB-SEM modela prema formuli (Hair et al., 2017a; Sarstedt, Ringle i Hair, 2017a):

$$AVE = \frac{\sum_{i=1}^{M} l_i^2}{M} \tag{4.33}$$

Gdje su l_i^2 kvadrirana vanjska opterećenja indikatora, a M je broj indikatora.

AVE od barem 0.50 smatra se prihvatljivim, odnosno tada se potvrđuje konvergentna validnost konstrukta. Naime, to znači da je barem 50% varijance indikatora objašnjeno konstruktom. Dakle, logika je jednaka kao kod CB-SEM modela (Hair et al., 2014; Garson, 2016; Ab Hamid, Sami i Sidek, 2017; Hair et al., 2017a; Hair et al., 2017b; Sarstedt, Ringle i Hair, 2017a; Avkiran, 2018; Hair et al., 2019b; Mohamad et al., 2019; Hanafiah, 2020). S obzirom da je AVE povezan s visinom vanjskih opterećenja indikatora, koja i ulaze u formulu za njegov izračun, proizlazi zaključak da bi njihove vrijednosti trebale biti 0.708 ili više, jer ova vrijednost kvadrirana daje traženih 0.50. Vrijednost opterećenja indikatora od 0.7 smatra se dovoljno približnom i prihvatljivom za uspostavljanje **pouzdanosti indikatora (eng. *indicator reliability*)** (Hair, Ringle i Sarstedt, 2011; Hair et al., 2014; Hair et al., 2017a; Hair et al., 2017b; Sarstedt, Ringle i Hair, 2017a; Mohamad et al., 2019; Hanafiah, 2020).

Obično se u modelima zadržavaju i indikatori s nižim vrijednostima vanjskih opterećenja, naročito u društvenim znanostima i pri razvoju novih skala. Takvi indikatori i ne bi se smjeli automatski izbrisati iz modela, već bi se trebalo pažljivo razmotriti kako bi njihova eliminacija utjecala na kompozitnu pouzdanost te validnost konstrukta. Sugerira se da se indikatori s opterećenjima od 0.40 do 0.70 razmatraju za eliminaciju, samo u slučaju kada bi to rezultiralo povećanjem kompozitne pouzdanosti ili validnosti (AVE) konstrukta. Indikatori s jako niskim vrijednostima opterećenja (<0.40) trebali bi svakako biti izbrisani (Hair, Ringle i Sarstedt, 2011; Ab Hamid, Sami i Sidek, 2017; Hair et al., 2017a; Mohamad et al., 2019). Slika 4.20. prikazuje postupak ispitivanja relevantnosti vanjskog opterećenja indikatora.

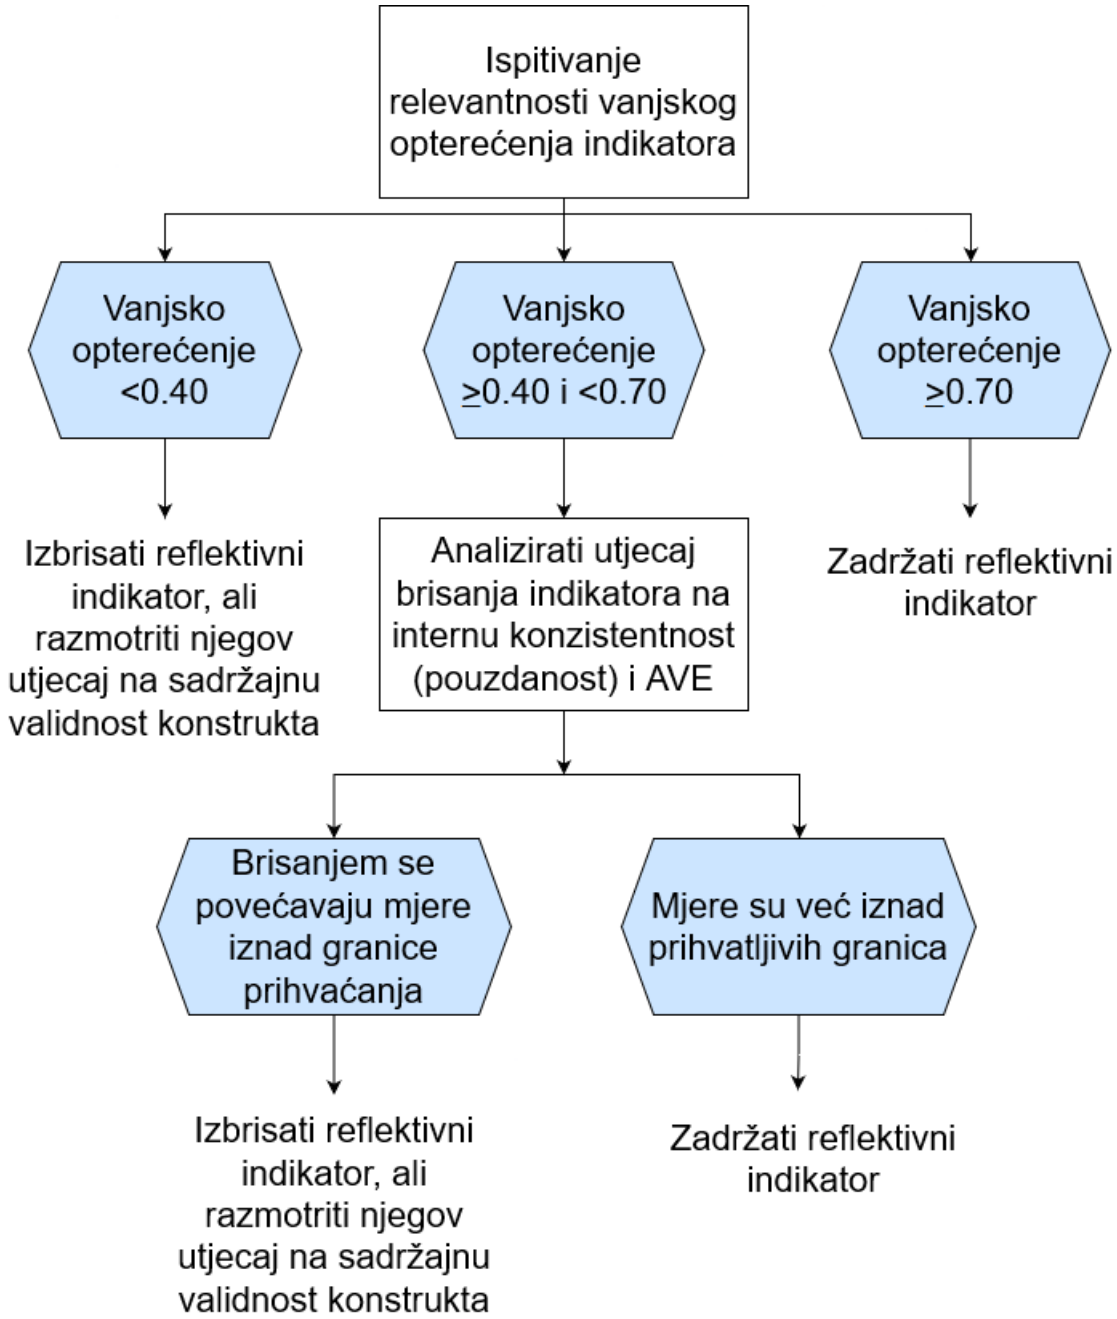

Slika 4.20. Postupak ispitivanja relevantnosti vanjskog opterećenja indikatora

Izvor: izrada autorice prema Hair et al. (2017a, str. 114)

Dodatno se ispituje **diskriminantna validnost** konstrukta, kako bi se utvrdilo koliko je svaki konstrukt uistinu različit od ostalih konstrukata u modelu. Zadovoljavajuća diskriminantna validnost podrazumijeva da je konstrukt jedinstven i da mjeri fenomen koji nije predstavljen niti jednim drugim konstruktom u modelu (Hair et al., 2014; Henseler, Ringle i Sarstedt, 2015; Ab

Hamid, Sami i Sidek, 2017; Hair et al., 2017a; Sarstedt, Ringle i Hair, 2017a; Hair et al., 2019b; Mohamad et al., 2019).

Prvi način za ispitivanje diskriminantne validnosti je provjera **poprečnih opterećenja (eng. *cross-loadings*)**. Konkretno, opterećenje indikatora povezano s pripadajućim konstruktom treba biti veće od bilo kojeg poprečnog opterećenja, odnosno korelacije s drugim konstruktima (Hair, Ringle i Sarstedt, 2011; Hair et al., 2014; Henseler, Ringle i Sarstedt, 2015; Ab Hamid, Sami i Sidek, 2017; Hair et al., 2017a; Avkiran, 2018). Iako Garson (2016) sugerira da opterećenje indikatora na odgovarajući konstrukt treba imati vrijednost veću od 0.7 ili 0.6, a poprečna opterećenja vrijednosti manje od 0.3 ili 0.4, najvažniji uvjet je upravo taj da indikator ne korelira jače s latentnim konstruktom kojeg ne reflektira.

Nadalje, kao i CB-SEM, PLS-SEM metoda također omogućava testiranje diskriminantne validnosti prema **Fornell-Larcker kriteriju**. Kao što je već spomenuto, prema ovom kriteriju uspoređuje se korijen vrijednosti AVE pojedinačnog konstrukta s vrijednostima korelacije između konstrukata. Stoga, korijen AVE pokazatelja određenog konstrukta treba biti veći od visine njegove korelacije s ostalim konstruktima, što je prethodno objašnjeno kod CB-SEM metode. Alternativno, može se promatrati je li AVE nekog konstrukta veći od kvadratne korelacije s ostalim konstruktima u modelu, bazirajući se na ideji da bi konstrukt trebao dijeliti veći dio varijance s pripadajućim konstruktima, nego s drugim latentnim konstruktima (Peng i Lai, 2012; Hair et al., 2014; Henseler, Ringle i Sarstedt, 2015; Garson, 2016; Ab Hamid, Sami i Sidek, 2017; Hair et al., 2017a; Hair et al., 2017b; Mohamad et al., 2019). Ovaj kriterij nije primjenjiv na formativne konstrukte i konstrukte s jednim indikatorom (Hair et al., 2017a).

Međutim, ova dva pristupa ispitivanja diskriminantne validnosti imaju svoja ograničenja. Naime, poprečna opterećenja ne uspijevaju ukazati na problem diskriminantne validnosti ukoliko su dva konstrukta savršeno korelirana. Osim toga, Fornell-Larcker kriterij može dati nepouzdane rezultate diskriminantne validnosti, naročito ako se opterećenja indikatora konstrukata koji se promatraju samo neznatno razlikuju (primjerice, opterećenja svih indikatora konstrukta nalaze se u rasponu od 0.60 do 0.80) (Henseler, Ringle i Sarstedt, 2015; Hair et al., 2017a; Hair et al., 2019b; Mohamad et al., 2019). U simulacijskoj studiji koji su proveli Henseler, Ringle i Sarstedt (2015), pokazalo se da ova dva tradicionalna kriterija utvrđivanja diskriminantne validnosti nisu efikasna u pronalasku problema diskriminantne validnosti kada ona zaista postoji. Fornell-Larcker kriterij uspješno je

detektirao problem u samo približno 15% slučajeva, dok je pristup poprečnih opterećenja bio u potpunosti neuspješan. Iz tog razloga, predložena je nova mjera, nazvana ***heterotrait-monotrait* omjer (eng. *heterotrait-monotrait ratio*, HTMT)**. HTMT predstavlja omjer između prosječnih korelacija među indikatorima koji mjere različite konstrukte (*heterotrait-heteromethod* korelacije) i geometrijske sredine prosječnih korelacija među indikatorima koji mjere isti konstrukt (*monotrait-heteromethod* korelacije) (Henseler, Ringle i Sarstedt, 2015; Garson, 2016; Ab Hamid, Sami i Sidek, 2017; Hair et al., 2017a; Sarstedt, Ringle i Hair, 2017a; Hair et al., 2019b). Izračun HTMT omjera slijedi formulu (Henseler, Ringle i Sarstedt, 2015; Sarstedt, Ringle i Hair, 2017a):

$$HTMT_{ij} = \underbrace{\frac{1}{K_i K_j}\sum_{g=1}^{K_i}\sum_{h=1}^{K_j} r_{ig,jh}}_{\substack{\text{prosječna korelacija među}\\ \text{indikatorima koji mjere}\\ \text{različite konstrukte}}} \div \underbrace{\left(\frac{2}{K_i(K_i-1)}\cdot\sum_{g=1}^{K_i-1}\sum_{h=g+1}^{K_i} r_{ig,ih}\cdot\frac{2}{K_j(K_j-1)}\cdot\sum_{g=1}^{K_j-1}\sum_{h=g+1}^{K_j} r_{jg,jh}\right)^{\frac{1}{2}}}_{\substack{\text{geometrijska sredina prosječnih korelacija među indikatorima}\\ \text{koji mjere iste konstrukte (konstrukt } \xi_i \text{ i konstrukt } \xi_j\text{)}}} \qquad (4.34)$$

Gdje su K_i reflektivni indikatori konstrukta ξ_i, a K_j reflektivni indikatori konstrukta ξ_j, dok su r koeficijenti korelacije između indikatora.

HTMT procjenjuje kolika bi bila istinska korelacija između dvaju konstrukata ako bi oni bili savršeno mjereni, odnosno pouzdani. Stoga, ukoliko je ova korelacija, tj. visina HTMT omjera, blizu vrijednosti 1, to ukazuje na nedostatak diskriminantne validnosti. Naime, korelacije između indikatora koji mjere različite konstrukte trebale bi biti manje u odnosu na korelacije između indikatora koji mjere isti konstrukt. Upravo zato ovaj pokazatelj trebao bi biti što manji. Kao vrijednosti granica HTMT-a do kojih se smatra da je potvrđena diskriminantna validnost, uzimaju se vrijednost 0.90, ukoliko model sadrži konstrukte koji su konceptualno jako slični, te 0.85, ako su konstrukti konceptualno više različiti (Henseler, Ringle i Sarstedt, 2015; Garson, 2016; Ab Hamid, Sami i Sidek, 2017; Hair et al., 2017a; Sarstedt, Ringle i Hair, 2017a; Avkiran, 2018; Hair et al., 2019b). Ako HTMT poprimi vrijednosti iznad 0.90 ili 0.85, smatra se da postoji problem diskriminantne validnosti. Uz to, moguće je putem *bootstrapping* procedure testirati je li HTMT značajno različit od 1 te procijeniti interval pouzdanosti za HTMT ($HTMT_{\text{inference}}$). Ukoliko bi se unutar intervala pouzdanosti nalazila vrijednost 1, tada diskriminantna validnost ne bi bila potvrđena. Ako vrijednost 1 ne bi bila sadržana u intervalu, tada bi se potvrdila diskriminantna

validnost konstrukata (Henseler, Ringle i Sarstedt, 2015; Hair et al., 2017a; Sarstedt, Ringle i Hair, 2017a; Avkiran, 2018; Hair et al., 2019b).

Na slici 4.21. prikazan je postupak procjene diskriminantne validnosti putem HTMT kriterija kroz korake što učiniti ako se pojavi problem (Henseler, Ringle i Sarstedt, 2015; Hair et al., 2017a). Jedna od opcija je zadržati problematične konstrukte u modelu, povećavajući korelacije indikatora koji mjere isti konstrukt. To se može učiniti na način da se eliminiraju indikatori koji nisko koreliraju s ostalim indikatorima istog konstrukta. Također se može jedan konstrukt podijeliti na homogene podkonstrukte, ako je to podržano teorijskim postavkama. Osim toga, mogu se i smanjiti korelacije indikatora koji mjere različite konstrukte, tako da se eliminiraju indikatori koji snažno koreliraju s indikatorima drugog konstrukta ili dodjeljivanjem takvih indikatora drugom konstruktu, ako je to teoretski opravdano. Ukoliko niti jedan od ova dva načina ne riješi problem nedostatne diskriminantne validnosti, moguće je spojiti problematične konstrukte u neki općenitiji zajednički konstrukt, također ako teorija podržava taj pristup. Ako se ni nakon ovog koraka ne uspostavi diskriminantna validnost, model se može odbaciti (Henseler, Ringle i Sarstedt, 2015; Hair et al., 2017a).

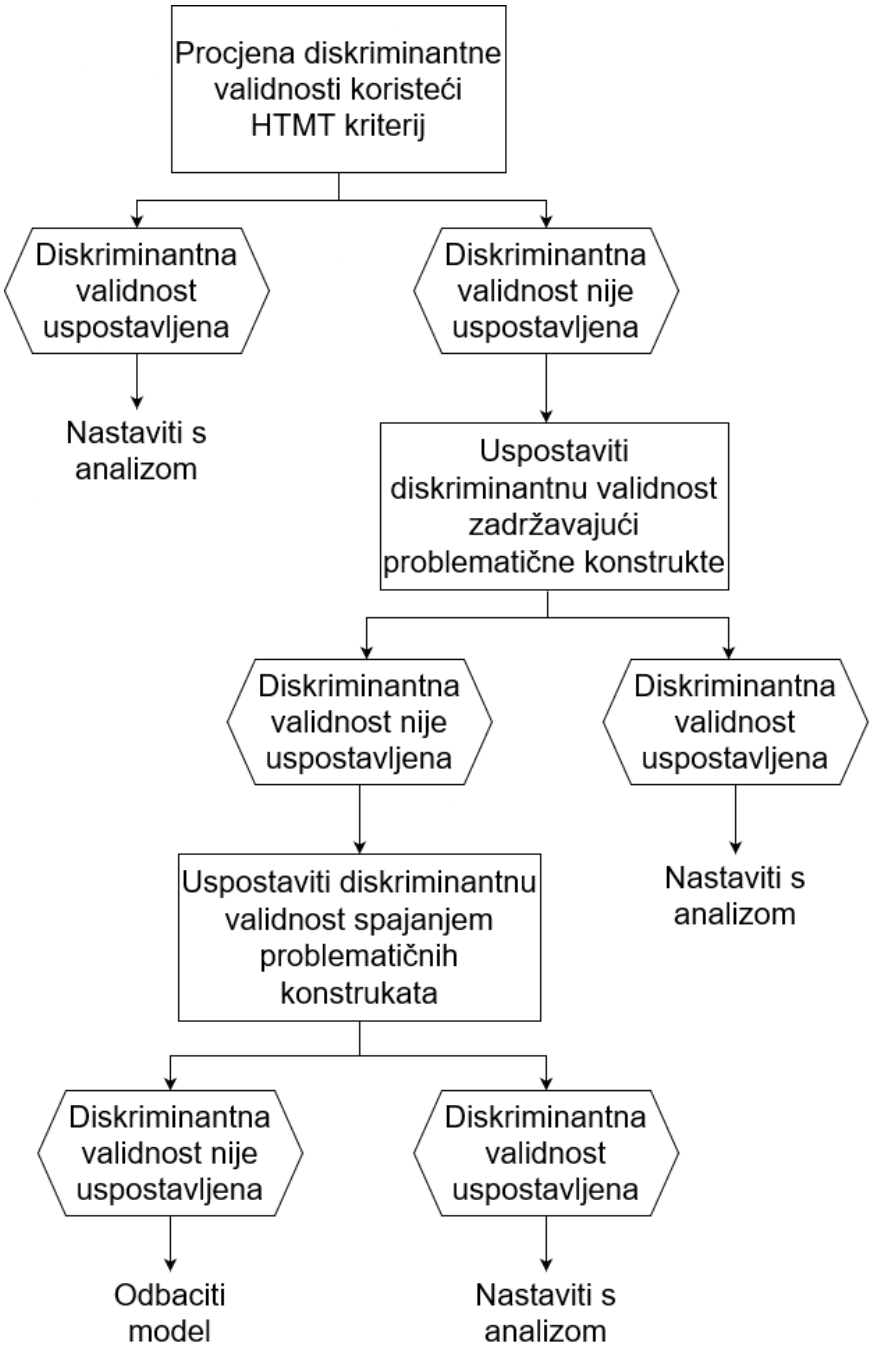

Slika 4.21. Postupak procjene diskriminantne validnosti putem HTMT kriterija

Izvor: izrada autorice prema Hair et al. (2017a, str. 121)

4.2.4 Analiza formativnog mjernog modela

Analiza formativnog mjernog modela razlikuje se u odnosu na reflektivni model, jer se ovi modeli razlikuju i po svojoj definiciji. Naime, utvrđivanje interne konzistentnosti nema smisla kod formativnih konstrukata, jer njihovi indikatori ne moraju biti međusobno povezani, s obzirom da

predstavljaju različite dimenzije kompozitne varijable. Također, ni ispitivanje validnosti na isti način kao u reflektivnim modelima nije smisleno (Hair, Ringle i Sarstedt, 2011; Garson, 2016; Hair et al., 2017a; Rabaa'i, 2017; Sarstedt, Ringle i Hair, 2017a; Cheah et al., 2018; Hair et al., 2019b; Hanafiah, 2020). Procjena validnosti formativnog modela uključuje procjenu konvergentne validnosti kroz analizu suvišnosti (eng. *redundancy analysis*), ispitivanje kolinearnosti među indikatorima te procjenu signifikantnosti i relevantnosti formativnih indikatora (Hair et al., 2014; Hair et al., 2017a; Sarstedt, Ringle i Hair, 2017a; Avkiran, 2018; Cheah et al., 2018; Rasoolimanesh i Ali, 2018; Hair et al., 2019b).

Prilikom evaluacije **konvergentne validnosti** formativnog modela, potrebno je testirati u kojoj mjeri formativni konstrukt korelira s reflektivno mjerenim konstruktom ili konstruktom mjerenim jednim globalnim indikatorom, koji obuhvaćaju isti koncept. Ovo se naziva i **analiza suvišnosti (eng. *redundancy analysis*)** (Hair et al., 2014; Garson, 2016; Hair et al., 2017a; Hair et al., 2017b; Sarstedt, Ringle i Hair, 2017a; Avkiran, 2018; Cheah et al., 2018; Rasoolimanesh i Ali, 2018; Hair et al., 2019b). Ovaj pojam proizlazi iz činjenice što su informacije u modelu suvišne ako su uključene u formativni konstrukt, a onda i u reflektivni. Analiza se provodi na način da se formativno mjereni konstrukt koristi kao egzogena latentna varijabla koja predviđa endogenu latentnu varijablu, koja je mjerena kroz jedan ili više reflektivnih indikatora. Koeficijent koji povezuje ova dva konstrukta trebao bi biti barem 0.70, što ukazuje na koeficijent determinacije reflektivnog endogenog konstrukta od barem 50%. Ako to nije zadovoljeno, formativni indikatori ne doprinose u dovoljnoj mjeri sadržaju formativnog konstrukta te ih je potrebno ponovo definirati razmjenom i/ili dodavanjem indikatora. Umjesto reflektivnog konstrukta, kao endogena latentna varijabla može biti korišten konstrukt mjeren jednim indikatorom, koji predstavlja globalnu mjeru konstrukta. Međutim, ovakvi indikatori daju nižu validnost, stoga se mogu promatrati niže granične vrijednosti visine koeficijenta koji povezuje formativni i reflektivni konstrukt za veće uzorke ili više apstraktne konstrukte (Hair et al., 2017a; Sarstedt, Ringle i Hair, 2017a; Avkiran, 2018; Cheah et al., 2018; Rasoolimanesh i Ali, 2018).

Nadalje, s obzirom da formativni indikatori nisu međusobno zamjenjivi, njihova snažna povezanost može biti problematična. Dakle, kada su dva ili više indikatora visoko korelirana, pojavljuje se problem **(multi)kolinearnosti (eng. *multicollinearity*)**, koji može utjecati na povećanje standardnih pogreški te pristranosti težina indikatora (eng. *indicator weights*), pa čak i promjenu

predznaka (Hair et al., 2014; Garson, 2016; Hair et al., 2017a; Hanafiah, 2020). Ovo se može dogoditi ako je isti indikator dva puta unesen u model ili ako je jedan indikator linearna kombinacija drugoga. Kako bi se uvrdilo postoji li u modelu problem kolinearnosti, može se izračunati pokazatelj **tolerancije (eng. *tolerance*, TOL)** te njegova recipročna vrijednost, tj. pokazatelj **faktor inflacije varijance (eng. *variance inflation factor*, VIF)** (Hair, Ringle i Sarstedt, 2011; Peng i Lai, 2012; Hair et al., 2014; Garson, 2016; Hair et al., 2017a; Rabaa'i, 2017; Sarstedt, Ringle i Hair, 2017a; Avkiran, 2018; Cheah et al., 2018; Hair et al., 2019b; Hanafiah, 2020). Ove vrijednosti računaju se na način da se svaki indikator u formativnom mjernom modelu regresira na ostale indikatore konstrukta. Potom se računa udio varijance „zavisnog“ indikatora povezanog s ostalim indikatorima, tj. koeficijent determinacije. Pokazatelj TOL za svaki indikator računa se tako da se od vrijednosti 1 oduzme pripadajući koeficijent determinacije (Hair et al., 2017a; Rabaa'i, 2017; Sarstedt, Ringle i Hair, 2017a):

$$TOL_k = 1 - R_k^2 \tag{4.35}$$

Recipročna vrijednost ovog pokazatelja je VIF, koji se računa kao (Hair et al., 2017a; Sarstedt, Ringle i Hair, 2017a; Avkiran, 2018):

$$VIF_k = \frac{1}{1 - R_k^2} = \frac{1}{TOL_k} \tag{4.36}$$

Potencijalni problem kolinearnosti postoji ako je vrijednost pokazatelja TOL manja ili jednaka 0.20, a VIF vrijednost veća ili jednaka 5. Tada se može razmotriti uklanjanje jednog od problematičnih indikatora. Ovaj pristup zahtijeva da preostali indikatori dovoljno dobro obuhvaćaju sadržaj konstrukta. Također je moguće od kolinearnih indikatora formirati novi kompozitni indikator (npr. indeks), a ako je teoretski opravdano, može se kreirati i formativni model višeg reda. Svakako, vanjske težine indikatora dalje se analiziraju po relevantnosti i značajnosti jedino ako nema problema kolinearnosti (Hair, Ringle i Sarstedt, 2011; Henseler, Ringle i Sarstedt, 2012; Wong, 2013; Garson, 2016; Hair et al., 2017a; Sarstedt, Ringle i Hair, 2017a; Avkiran, 2018; Hair et al., 2019b; Hanafiah, 2020). Postupak procjene kolinearnosti u formativnim mjernim modelima koristeći pokazatelj VIF prikazan je na slici 4.22.

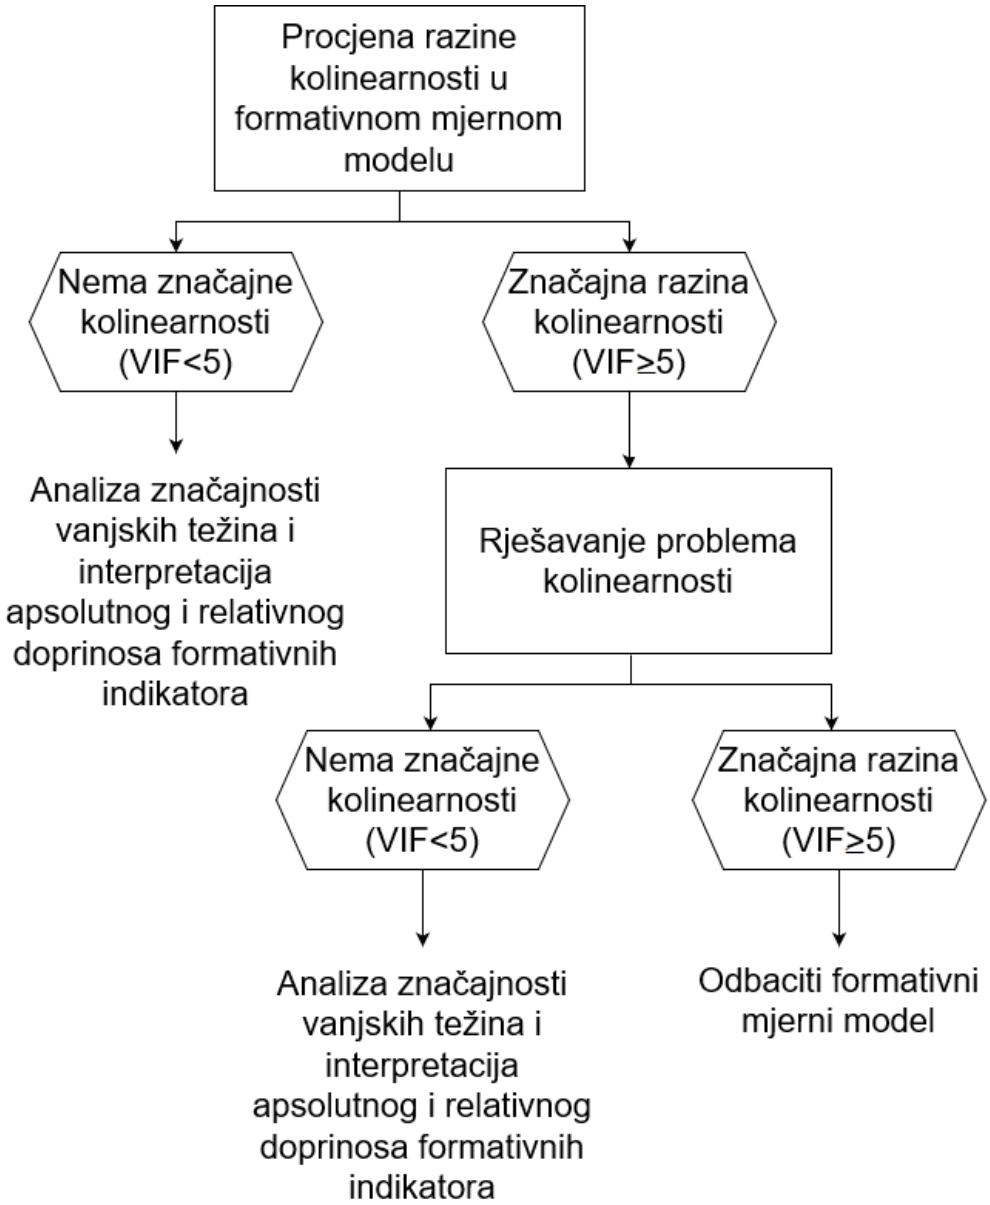

Slika 4.22. Postupak procjene kolinearnosti u formativnim mjernim modelima koristeći pokazatelj VIF

Izvor: izrada autorice prema Hair et al. (2017a, str. 145)

Nakon što se ustanovi da ne postoji problem kolinearnosti u modelu, pristupa se **analizi značajnosti i relevantnosti formativnih indikatora**. Polazi se od **vanjskih težina (eng. *outer weights*)**, koje su zapravo rezultat višestruke regresije, u kojoj skor latentne varijable predstavlja zavisnu, a formativni indikatori nezavisne varijable (Hair et al., 2017a). Ove težine su standardizirane, a samim time i usporedive te odražavaju **relativni doprinos indikatora**, tj. njihovu relativnu važnost u formiranju konstrukta. S obzirom da PLS-SEM ne pretpostavlja

nikakav oblik distribucije, u svrhu utvrđivanja značajnosti ovih vanjskih težina koristi se ***bootstrapping*** procedura (Hair, Ringle i Sarstedt, 2011; Hair et al., 2014; Garson, 2016; Hair et al., 2017a; Rabaa'i, 2017; Sarstedt, Ringle i Hair, 2017a; Avkiran, 2018; Rasoolimanesh i Ali, 2018; Hair et al., 2019b). U ovoj proceduri velik broj slučajnih uzoraka (eng. *bootstrap samples*) izvlači se iz originalnog uzorka sa zamjenom. Ta zamjena znači da svaki put prilikom uzimanja nekog slučajnog opažanja, ono se vraća nazad u sampling populaciju prije nego što se uzima sljedeće opažanje. Populacija iz koje se opažanja uzimaju uvijek ima iste elemente, stoga ta opažanja mogu biti izabrana u slučajni uzorak više nego jednom, a mogu uopće i ne biti izabrana. Najčešće se uzima 5000 slučajnih uzoraka ili više, a svaki od njih ima jednak broj opažanja (eng. *bootstrap cases*) kao i originalni uzorak (Hair, Ringle i Sarstedt, 2011; Hair et al., 2014; Garson, 2016; Hair et al., 2017a; Sarstedt, Ringle i Hair, 2017a; Avkiran, 2018). *Bootstrapping* procedura skicirana je prema Hair et al. (2017a) na slici 4.23.

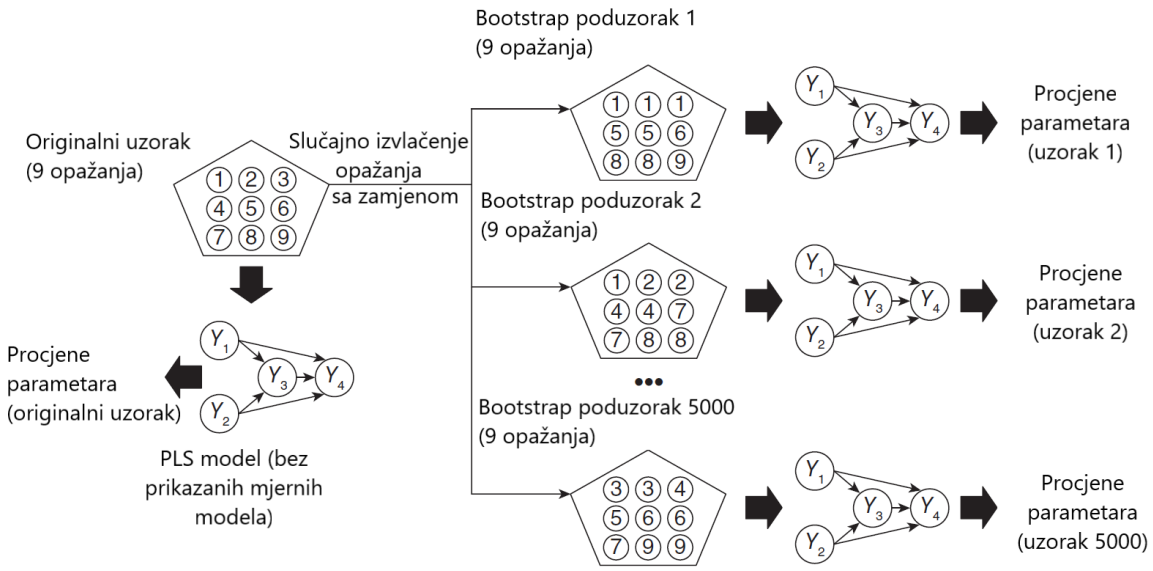

Slika 4.23. *Bootstrapping* procedura

Izvor: izrada autorice prema Hair et al. (2017a, str. 152)

Nadalje, nakon ove procedure, računaju se procjene sampling distribucije, temeljem koje je moguće izračunati standardne pogreške za svaki parametar u modelu. Uz ove standardne pogreške računaju se i *t*-vrijednosti (s pripadajućim *p*-vrijednostima), putem kojih se donosi zaključak o značajnosti parametara. Nultom hipotezom pretpostavlja se da je vanjska težina indikatora jednaka nuli, odnosno da nije statistički značajna, a alternativna hipoteza pretpostavlja da je vanjska težina

različita od nule, tj. statistički značajna (Hair, Ringle i Sarstedt, 2011; Hair et al., 2014; Garson, 2016; Hair et al., 2017a; Sarstedt, Ringle i Hair, 2017a; Avkiran, 2018). Empirijska *t*-vrijednost računa se po sljedećoj formuli (Hair et al., 2017a):

$$t = \frac{w}{se_w^*} \tag{4.37}$$

Pri čemu je w određena vanjska težina, a se_w^* njezina standardna pogreška dobivena *bootstrapping* procedurom.

Ova testna veličina slijedi *t* distribuciju, koja je dobro aproksimirana normalnom distribucijom za veće uzorke, tj. uzorke veće od 30. S obzirom da uzorci uglavnom premašuju ovu veličinu, mogu se koristiti kritične vrijednosti normalne distribucije za testiranje signifikantnosti. Najčešće granične *t*-vrijednosti dvosmjernih testova za donošenje zaključaka su 1.96 (uz razinu signifikantnosti od 5%) i 2.57 (za razinu signifikantnosti od 1%) te 1.65 (za razinu signifikantnosti od 10%) (Garson, 2016; Hair et al., 2017a). Dodatno je moguće prikazati i interval pouzdanosti za procijenjene parametre. Ako interval ne uključuje vrijednost nula, tada se može zaključiti da je parametar značajan (Hair et al., 2017a).

Poželjno je da se putem *bootstrapping* procedure dobiju statistički značajne vanjske težine formativnog konstrukta. Stoga, ako rezultat nije statistički značajan, moglo bi se zaključiti da određeni indikator ne doprinosi formiranju konstrukta i da se može ukloniti iz modela. Međutim, uklanjanje indikatora iz modela ovisi i o **apsolutnom doprinosu indikatora** konstruktu. Ovaj se doprinos ogleda u **vanjskim opterećenjima (eng. *outer loadings*)**, koji proizlaze iz korelacija između indikatora i konstrukta. Ovisno o njihovim veličinama, donosi se odluka o uklanjanju ili zadržavanju indikatora (Hair, Ringle i Sarstedt, 2011; Henseler, Ringle i Sarstedt, 2012; Hair et al., 2014; Hair et al., 2017a; Rabaa'i, 2017; Sarstedt, Ringle i Hair, 2017a; Avkiran, 2018; Rasoolimanesh i Ali, 2018; Hair et al., 2019b; Hanafiah, 2020). Postupak procesa donošenja odluke o zadržavanju ili uklanjanju formativnih indikatora prikazan je na slici 4.24.

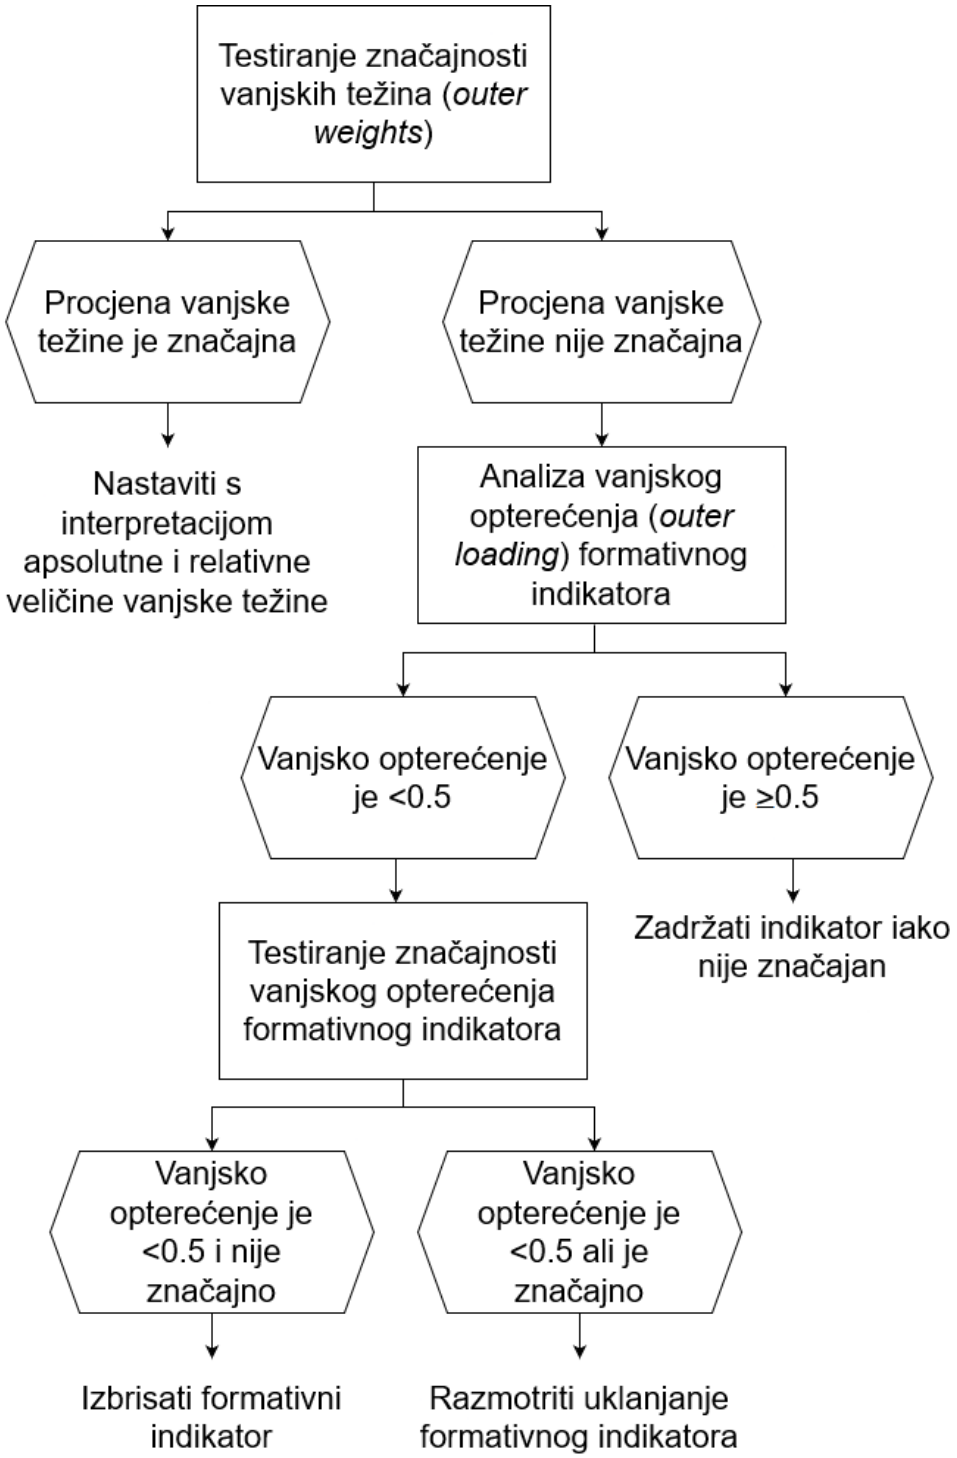

Slika 4.24. Proces donošenja odluke o zadržavanju ili uklanjanju formativnih indikatora

Izvor: izrada autorice prema Hair et al. (2017a, str. 150)

4.2.5 Analiza strukturalnog modela

Nakon potvrđene validnosti i pouzdanosti konstrukata kroz mjerni model, pristupa se analizi rezultata strukturalnog (unutarnjeg) modela. Ova analiza uključuje evaluaciju prediktivnih sposobnosti modela te veza između konstrukata, no prije toga je potrebno provjeriti potencijalnu **kolinearnost**, kako bi se osiguralo da regresijski rezultati ne budu pristrani. Kao i pri ocjeni kolinearnosti u formativnim mjernim modelima, promatraju se VIF vrijednosti. Poželjno je da one budu manje od 5, kako bi se ustanovilo da ne postoji problem kolinearnosti u modelu. Ako problem postoji, moguće je kreirati modele višeg reda (eng. *higher-order models*), ako su teoretski opravdani (Hair et al., 2014; Garson, 2016; Hair et al., 2017a; Sarstedt, Ringle i Hair, 2017a; Avkiran, 2018; Hair et al., 2019a; Hair et al., 2019b).

Nakon toga, **procjenjuju se veze u strukturalnom modelu prema svojoj značajnosti i relevantnosti**. Navedene veze su koeficijenti koji predstavljaju utjecaj jednog konstrukta na drugi (eng. *path coefficients*). Oni se dobiju već putem PLS-SEM algoritma i imaju standardizirane vrijednosti koje se nalaze u rasponu od -1 do +1, iako rijetko mogu biti i van ovih granica. Tumače se kao standardizirani regresijski koeficijenti. Koeficijenti snage približno +1 i -1 prikazuju snažnu pozitivnu ili negativnu povezanost konstrukata i obično su statistički značajni. Što je vrijednost procijenjenog koeficijenta niža i bliža nuli, slabije su veze i takvi koeficijenti obično nisu statistički značajni. Kako bi se utvrdila statistička značajnost svakog pojedinog koeficijenta, tj. parametra, koristi se *bootstrapping* procedura, koja je opisana u prethodnom poglavlju. Ipak, istraživači bi trebali voditi računa i o relevantnosti značajnih parametara. Naime, neki parametar može biti statistički značajan, no njegov utjecaj može biti iznimno slab da bi mu se pridala važnost u praksi (Hair, Ringle i Sarstedt, 2011; Henseler, Ringle i Sarstedt, 2012; Peng i Lai, 2012; Hair et al., 2014; Garson, 2016; Hair et al., 2017a; Sarstedt, Ringle i Hair, 2017a; Avkiran, 2018; Rasoolimanesh i Ali, 2018; Hair et al., 2019b). I kod PLS-SEM modela moguće je analizirati odvojeno direktne, indirektne i ukupne utjecaje među konstruktima u modelu, o čemu će biti riječi u nastavku rada vezano za medijaciju (Hair et al., 2017a).

Sljedeći korak u analizi strukturalnog modela je procjena njegove **prediktivne relevantnosti (eng. *predictive relevance*)**. Promatra se **eksplanatorna snaga (eng. *explanatory power*)**, tj. **predviđanje unutar uzorka (eng. *in-sample prediction*)** i **prediktivna snaga (eng. *predictive power*)**, tj. **predviđanje izvan uzorka (eng. *out-of-sample prediction*)**. Eksplanatorna snaga mjeri

se koeficijentom determinacije (eng. *coefficient of determination*) R^2 i veličinom efekta f^2 (eng. *effect size*). Ove mjere koriste cijeli podatkovni set za procjenu modela i predviđanje opservacija iz tog podatkovnog seta. S druge strane, prediktivna snaga modela utvrđuje se korištenjem procjena iz modela, u svrhu predviđanja novih budućih opservacija, putem prediktivne relevantnosti (Stone-Geisser Q^2 pokazatelj) i PLSpredict procedure (Hair, Ringle i Sarstedt, 2011; Henseler, Ringle i Sarstedt, 2012; Hair et al., 2014; Hair et al., 2017a; Hair et al., 2017b; Sarstedt, Ringle i Hair, 2017a; Avkiran, 2018; Rasoolimanesh i Ali, 2018; Hair et al., 2019b).

Koeficijent determinacije (R^2) predstavlja količinu varijance u endogenim konstruktima objašnjenu svim egzogenim konstruktima koji su s njima povezani. Drugim riječima, koeficijent determinacije predstavlja kombinirane efekte egzogenih latentnih varijabli na endogenu latentnu varijablu. S obzirom da je ovaj koeficijent kvadrat korelacije stvarnih i predviđenih vrijednosti, a samim time uključuje sve podatke koji su bili potrebni za procjenu modela kako bi se zaključilo o prediktivnoj snazi, on pripada u mjere „*in-sample*“ predviđanja. Vrijednosti R^2 nalaze se u rasponu od 0 do 1, gdje su veće vrijednosti pokazatelj bolje eksplanatorne snage modela. Ove vrijednosti variraju ovisno o kompleksnosti modela te znanstvenoj disciplini u kojoj se promatra R^2. Kao „grubo pravilo“ može se reći da R^2 vrijednosti 0.25-0.50 označavaju slabu, 0.50-0.75 umjerenu, a iznad 0.75 visoku eksplanatornu snagu modela (Hair, Ringle i Sarstedt, 2011; Henseler, Ringle i Sarstedt, 2012; Hair et al., 2014; Hair et al., 2017a; Sarstedt, Ringle i Hair, 2017a; Avkiran, 2018; Hair et al., 2019a; Hair et al., 2019b). Međutim, primjerice za bihevioralne i društvene znanosti, predložene su i niže granične vrijednosti koeficijenta determinacije (0.02, 0.13 i 0.26). Stoga, prilikom tumačenja R^2 uvijek treba voditi računa o kontekstu istraživanja, tj. znanstvenoj disciplini u kojoj se promatra model (Ringle, Silva i Bido, 2014; Sarstedt, Ringle i Hair, 2017a). Ponekad može nastati problem ako se pomoću koeficijenta determinacije uspoređuju različito specificirani modeli. Naime, vrijednost R^2 povećava se dodavanjem konstrukata u model, pa nije dobro oslanjati se samo na ovaj pokazatelj prilikom odabira modela. Kako bi se izbjegla pristranost prema kompleksnim modelima, može se izračunati korigirani koeficijent determinacije R^2_{adj} (eng. *adjusted coefficient of determination*) (Hair et al., 2014; Garson, 2016; Hair et al., 2017a), koji se računa sljedećom formulom (Garson, 2016; Hair et al., 2017a):

$$R^2_{adj} = 1-(1-R^2)\cdot\frac{n-1}{n-k-1} \tag{4.38}$$

Pri čemu je n veličina uzorka, a k je broj egzogenih latentnih varijabli, tj. prediktora endogene latentne varijable. Uz pomoć R^2_{adj} mogu se uspoređivati PLS-SEM modeli koji uključuju različit broj egzogenih latentnih varijabli te modeli s različitim veličinama uzroka (Hair et al., 2017a).

Dodatno, promjena u vrijednosti R^2 kada se određeni egzogeni konstrukt izostavi iz modela može se koristiti u svrhu procjene visine njegovog utjecaja na endogeni konstrukt. Ta mjera naziva se **veličina efekta (eng. *effect size,*** f^2) te procjenjuje koliko snažno neki egzogeni konstrukt doprinosi objašnjavanju određenog endogenog konstrukta u pogledu R^2 (Peng i Lai, 2012; Wong, 2013; Hair et al., 2014; Garson, 2016; Hair et al., 2017a; Sarstedt, Ringle i Hair, 2017a; Avkiran, 2018; Hair et al., 2019b). Računa se prema formuli (Hair et al., 2014; Hair et al., 2017a; Sarstedt, Ringle i Hair, 2017a; Avkiran, 2018):

$$f^2 = \frac{R^2_{uključen} - R^2_{isključen}}{1-R^2_{uključen}} \tag{4.39}$$

Gdje vrijednosti $R^2_{uključen}$ i $R^2_{isključen}$ prikazuju vrijednosti koeficijenta determinacije endogenog konstrukta kada je odabrani egzogeni konstrukt uključen (puni model) ili isključen iz modela. Promjena u vrijednostima R^2 računa se na način da se PLS-SEM model procijeni dva puta: jednom s uključenim odabranim egzogenim konstruktom (dobivajući $R^2_{uključen}$), a drugi put bez njega (dobivajući $R^2_{isključen}$). Smjernice za tumačenje veličine efekta su sljedeće (Henseler, Ringle i Sarstedt, 2012; Peng i Lai, 2012; Wong, 2013; Hair et al., 2014; Garson, 2016; Hair et al., 2017a; Sarstedt, Ringle i Hair, 2017a; Avkiran, 2018; Hair et al., 2019a; Hair et al., 2019b):

$0.02 \leq f^2 < 0.15$: slab efekt,

$0.15 \leq f^2 < 0.35$: srednje jak (umjeren) efekt,

$f^2 \geq 0.35$: jak efekt.

U nastavku analize strukturalnog modela, potrebno je ispitati pokazatelj **prediktivne relevantnosti (eng. *predictive relevance*)**, odnosno tzv. **Stone-Geisser Q^2 pokazatelj**. Ovaj pokazatelj pripada u mjere „*out-of-sample*“ predviđanja. Zadovoljavajući Q^2 pokazatelj ukazuje na sposobnost modela da adekvatno predvidi podatke koji nisu korišteni u procjeni modela. Njegova vrijednost dobiva se putem tzv. ***blindfolding*** procedure: tehnike ponovne upotrebe uzorka, koja izostavlja svaki d-ti podatak (eng. *data point*) kod indikatora endogenog konstrukta i koristi rezultirajuće procjene za predviđanje izostavljenog dijela. Ovo je iterativni postupak koji se ponavlja dok god se svaki podatak ne izostavi i model se ponovo procijeni. Koristi se samo kod endogenih konstrukata s reflektivnim indikatorima. Kod *blindfolding* procedure prvenstveno je potrebno postaviti udaljenost izostavljanja (eng. *omission distance*, D), najčešće na vrijednost između 5 i 10, tako da broj opažanja podijeljen s D ne bude cijeli broj. Primjerice, udaljenost 7 značila bi da se svaki sedmi podatak indikatora endogenog konstrukta izostavlja iz svake pojedinačne *blindfolding* „runde“. Ovi izostavljeni podaci tretiraju se kao nedostajući i zamjenjuju se aritmetičkom sredinom. Procijenjeni parametri pomažu u predviđanju izostavljenih podataka, a razlika između njihovih originalnih i predviđenih vrijednosti postaje input za izračun Q^2 (Hair, Ringle i Sarstedt, 2011; Henseler, Ringle i Sarstedt, 2012; Wong, 2013; Hair et al., 2014; Garson, 2016; Hair et al., 2017a; Sarstedt, Ringle i Hair, 2017a; Avkiran, 2018; Hair et al., 2019a; Hair et al., 2019b; Shmueli et al., 2019). Ova vrijednost može se računati kroz dva različita pristupa: „*cross-validated redundancy*“ ili „*cross-validated communality*“. „*Cross-validated redundancy*“ pristup nadovezuje se na procjene predviđanja podataka i strukturalnog modela (skorovi prethodnih konstrukata) i mjernog modela (ciljni endogeni konstrukt). Suprotno tome, „*cross-validated communality*“ pristup koristi samo skorove procijenjene za ciljni endogeni konstrukt, bez uključivanja informacija strukturalnog modela. Sugerira se upotreba prvog pristupa, jer za predviđanje podataka koristi i strukturalni model, koji čini glavni element cjelokupnog modela (Hair, Ringle i Sarstedt, 2011; Garson, 2016; Hair et al., 2017a; Sarstedt, Ringle i Hair, 2017a; Hair et al., 2019a). Izračun Q^2 slijedi formulu (Garson, 2016; Avkiran, 2018):

$$Q^2 = 1 - \frac{\sum_D SSE_D}{\sum_D SSO_D} \tag{4.40}$$

Gdje je SSE_D zbroj kvadrata pogreške predviđanja, a SSO_D zbroj kvadrata pogrešaka koristeći aritmetičku sredinu za predviđanje. Q^2 vrijednosti veće od 0 za određeni konstrukt upućuju na postojanje prediktivne relevantnosti strukturalnog modela za taj konstrukt. Smjernice za tumačenje rezultata Q^2 temeljenih na „*cross-validated redundancy*“ pristupu su sljedeće (Sarstedt, Ringle i Hair, 2017a):

$0.02 \leq Q^2 < 0.15$: slaba prediktivna snaga,

$0.15 \leq Q^2 < 0.35$: srednje jaka (umjerena) prediktivna snaga,

$Q^2 \geq 0.35$: jaka prediktivna snaga.

Na temelju Q^2 može se izračunati i interpretirati i **relativni utjecaj prediktivne relevantnosti**, tzv. q^2 veličina efekta. Njome se procjenjuje prediktivna relevantnost svakog egzogenog konstrukta za određeni endogeni konstrukt, a računa se po formuli (Hair et al., 2017a; Avkiran, 2018):

$$q^2 = \frac{Q^2_{uključen} - Q^2_{isključen}}{1 - Q^2_{uključen}} \tag{4.41}$$

Izračun je sličan kao kod veličine efekta f^2 koja se bazirala na razlici u koeficijentu determinacije. Shodno tome, slično se i interpretira prema već navedenim granicama: 0.02, 0.15 i 0.35, koje predstavljaju slabu, srednje jaku (umjerenu) te jaku prediktivnu relevantnost za određeni konstrukt (Hair et al., 2017a; Sarstedt, Ringle i Hair, 2017a; Avkiran, 2018).

Međutim, Q^2 ipak nije istinski mjera „*out-of-sample*“ predviđanja, jer *blindfolding* ne izostavlja cijele opservacije, već samo pojedinačne podatke. Stoga se ova mjera može smatrati kombinacijom „*in-sample*“ i „*out-of-sample*“ predviđanja, jer struktura uzorka ostaje uglavnom netaknuta prilikom izračuna. U tom smislu, nema ni potpuno jasnog ukazivanja na eksplanatornu ili prediktivnu snagu modela. Osnova za predviđanje je sposobnost modela da predvidi mjerljive informacije o novim opservacijama. Iz tog razloga, razvijena je nova tzv. **PLSpredict** procedura, koja omogućava predviđanje podataka na razini indikatora ili konstrukta temeljem generiranih testnih uzoraka (eng. *holdout sample/testing sample*) (Hair et al., 2014; Shmueli et al., 2016; Hair

et al., 2017a; Sarstedt, Ringle i Hair, 2017a; Rasoolimanesh i Ali, 2018; Shmueli et al., 2019). Ovaj proces temelji se na odvojenim uzorcima za treniranje (eng. *training sample*) i testnim uzorcima (eng. *holdout sample/testing sample*) za procjenu parametara modela i evaluaciju njegove prediktivne snage. *Training* uzorak je udio ukupnog skupa podataka koji je korišten za procjenu parametara modela, dok se preostali dio skupa podataka, koji nije korišten za procjenu modela, naziva *holdout* uzorkom. Kada se računaju predviđene vrijednosti za *training* uzorak, to su „*in-sample*“ predviđanja. Suprotno tome, izračun predviđenih vrijednosti u *holdout* uzorku daje „*out-of-sample*“ predviđanja. Mala razlika između stvarnih i predviđenih „*out-of-sample*“ vrijednosti ukazuje na visoku prediktivnu snagu modela (Shmueli et al., 2016; Shmueli et al., 2019).

Proces PLSpredict započinje podjelom podataka u k jednakih podgrupa (eng. *fold*), a zatim se procjenjuje model k puta na $k-1$ skupova podataka. Primjerice, ako je $k=5$, tada se uzorak dijeli na 5 podgrupa jednake veličine. Zatim PLSpredict kombinira 4 ($k-1=5-1=4$) podgrupe u jedan *training* uzorak koji se koristi za predviđanje preostale pete podgrupe. Ta podgrupa je *holdout* uzorak za prvu fazu procesa, koji se ponavlja 5 puta u ovom slučaju, a svaka podgrupa jednom je iskorištena kao *holdout* uzorak. Posljedično, svako opažanje u svakom *holdout* uzorku ima predviđenu vrijednost temeljenu na modelu u kojem nije bilo korišteno u procjeni parametara modela. Pri određivanju broja podgrupa za PLSpredict proceduru, potrebno je osigurati da *training* uzorak i dalje zadovoljava zahtjeve za minimalnu veličinu uzorka. Preporučuje se koristiti 10 podgrupa ($k=10$), što je praksa u istraživanjima. Osim toga, poželjno je ponoviti PLSpredict proceduru više puta, kako bi se postigle stabilnije procjene. Broj ponavljanja (eng. *repetitions*) r obično se postavlja na 10, što je dobar kompromis između preciznosti procjene i vremena izračuna (Shmueli et al., 2016; Hair et al., 2019b; Shmueli et al., 2019). Koncept PLSpredict procedure s pet podgrupa prikazan je na slici 4.25.

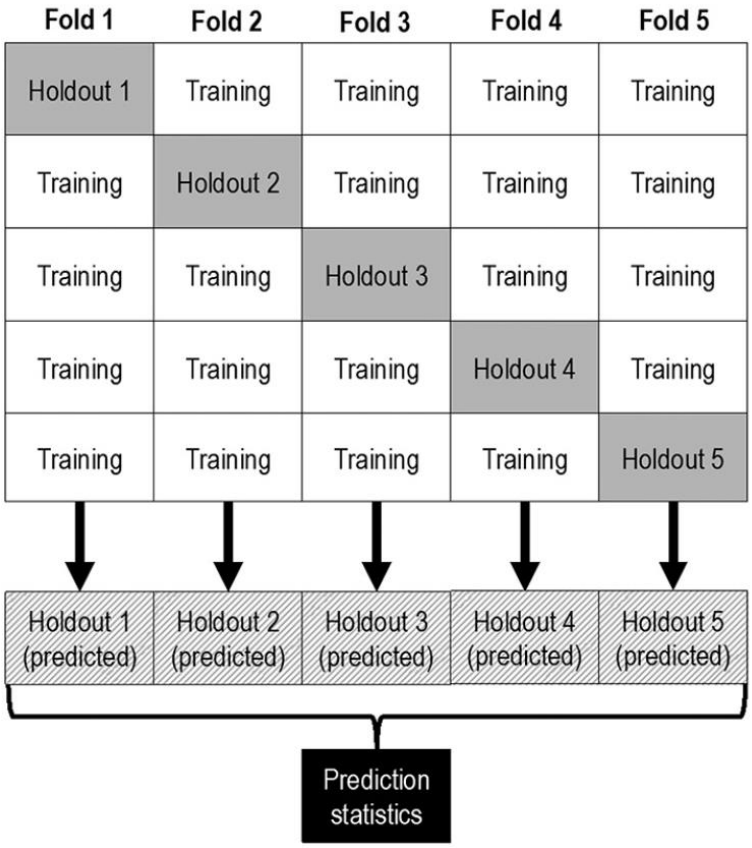

Slika 4.25. Primjer PLSpredict procedure s 5 podgrupa

Izvor: Shmueli et al. (2019, str. 2326)

Točnost ovih procjena ogleda se kroz statističke pokazatelje predviđanja (eng. *prediction statistics*), koji kvantificiraju vrijednost **pogreške predviđanja (eng. *prediction error*)**. Nekoliko je pokazatelja koji se koriste, a to su: **prosječna apsolutna pogreška (eng. *mean absolute error*, MAE), prosječna apsolutna postotna pogreška (eng. *mean absolute percentage error*, MAPE) i korijen prosječne kvadratne pogreške (eng. *root mean squared error*, RMSE)**. Njihovi izračuni temelje se na razlikama stvarnih i procijenjenih vrijednosti opažanja i slijede formule (Shmueli et al., 2016; Hair et al., 2019b; Shmueli et al., 2019):

$$MAE = \frac{1}{n}\sum_{i=1}^{n}\left|y_i - \hat{y}_i\right| \tag{4.42}$$

$$MAPE = \frac{1}{n}\sum_{i=1}^{n}\left|\frac{y_i - \hat{y}_i}{y_i}\right| \tag{4.43}$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^{n}(y_i - \hat{y}_i)^2}{n}} \tag{4.44}$$

Pri čemu y_i predstavlja originalnu vrijednost za opažanje i ($i = 1,...,n$), dok je $\hat{y}_i$ predviđena, tj. procijenjena vrijednost za to opažanje.

MAE mjeri prosječnu veličinu pogrešaka u skupu predviđanja, ne uzimajući u obzir njihov smjer. Kao takva, MAE pokazuje prosječne apsolutne razlike stvarnih i očekivanih vrijednosti, gdje sve razlike imaju jednaku težinu, stoga njezine vrijednosti ovise o skali indikatora. S druge strane, MAPE izražava pogrešku u pogledu postotka pa nije ovisna o skaliranju indikatora. Ipak, MAPE ima ograničenje u pogledu nedefiniranosti za manifestnu varijablu vrijednosti 0, što bi pri izračunu rezultiralo dijeljenjem s nulom. Dakle, MAPE je nedefinirana na kompozitnoj razini. Osim toga, pri jednakoj apsolutnoj razlici stvarne i procijenjene vrijednosti, ukoliko je stvarna vrijednost veća od procijenjene, pogreška će biti manja, a ako je stvarna vrijednost manja, pogreška će biti veća. Zbog ovih ograničenja, ne sugerira se upotreba MAPE. Nadalje, RMSE je definiran kao korijen prosječnih kvadrata razlika stvarnih i predviđenih vrijednosti. Također ovisi o skaliranju manifestne varijable. S obzirom da u izračunu kvadrira pogreške prije njihovog uprosječivanja, ovaj pokazatelj dodjeljuje veću težinu većim pogreškama, zbog čega je koristan kad su velike pogreške nepoželjne. Iz tog razloga, često se preferira pored ostalih pokazatelja. Međutim, kada je distribucija pogrešaka predviđanja znatno asimetrična, RMSE može prikazati previše pesimističnu procjenu prediktivne snage modela. U tom slučaju može se koristiti MAE, jer daje jednake težine svim pogreškama te je manje osjetljiva na ekstremne vrijednosti. Svi ovi pokazatelji trebali bi biti što manjih vrijednosti kako bi ukazali na visoku prediktivnu snagu modela (Hair et al., 2019b; Shmueli et al., 2019).

Kod interpretacije PLSpredict rezultata, fokus je na ključnom endogenom konstruktu. Radi lakše interpretacije prethodno navedenih pokazatelja pogreške predviđanja, preporučuje se njihova usporedba s pokazateljem $Q^2_{predict}$, definiranim kao prosjek indikatora iz *training* uzorka. Pozitivna $Q^2_{predict}$ vrijednost ukazuje da PLS model ima manje pogreške predviđanja u odnosu na najjednostavnije mjerilo (eng. *naïve benchmark*), odnosno da prediktivna snaga PLS-SEM modela nadmašuje najjednostavnije mjerilo. U tom slučaju, dalje je potrebno usporediti RMSE ili MAE

vrijednosti PLS-SEM modela s njihovim vrijednostima kod modela linearne regresije (eng. *linear regression model*, LM), kao najjednostavnijim mjerilom. Naime, LM model uključuje samo informacije o posljedici (endogeni indikatori), ali ne i za prediktore. S druge strane, predviđanje za indikator PLS modela jednostavan je prosjek na razini indikatora u *training* uzorku. Postoji nekoliko mogućih ishoda i zaključaka pri usporedbi navedenih pokazatelja između ova dva modela (Shmueli et al., 2016; Hair et al., 2019b; Shmueli et al., 2019):

- Ako niti jedan indikator PLS-SEM modela u usporedbi s LM modelom ne daje niže pogreške predviđanja u pogledu RMSE ili MAE, modelu nedostaje prediktivna snaga.
- Ako manjina indikatora zavisnog konstrukta ima niže pogreške predviđanja za PLS-SEM model u usporedbi s LM modelom, model ima nisku prediktivnu snagu.
- Ako većina (ili jednak broj) indikatora PLS-SEM analize daje manje pogreške predviđanja u usporedbi s LM modelom, model ima srednje jaku (umjerenu) prediktivnu snagu.
- Ako svi indikatori PLS-SEM analize imaju niže RMSE ili MAE vrijednosti u odnosu na LM model, model ima visoku prediktivnu snagu.

Dakle, nakon ispitivanja vrijednosti $Q^2_{predict}$, ako je pozitivna, cilj je dobiti što niže vrijednosti RMSE ili MAE za PLS-SEM model u odnosu na njihove vrijednosti u LM modelu, kako bi se ustanovila što viša prediktivna snaga modela (Hair et al., 2019b; Shmueli et al., 2019).

Postupak procjene prediktivne snage PLS-SEM modela putem PLSpredict procedure te smjernice za interpretaciju rezultata prikazani su na slici 4.26.

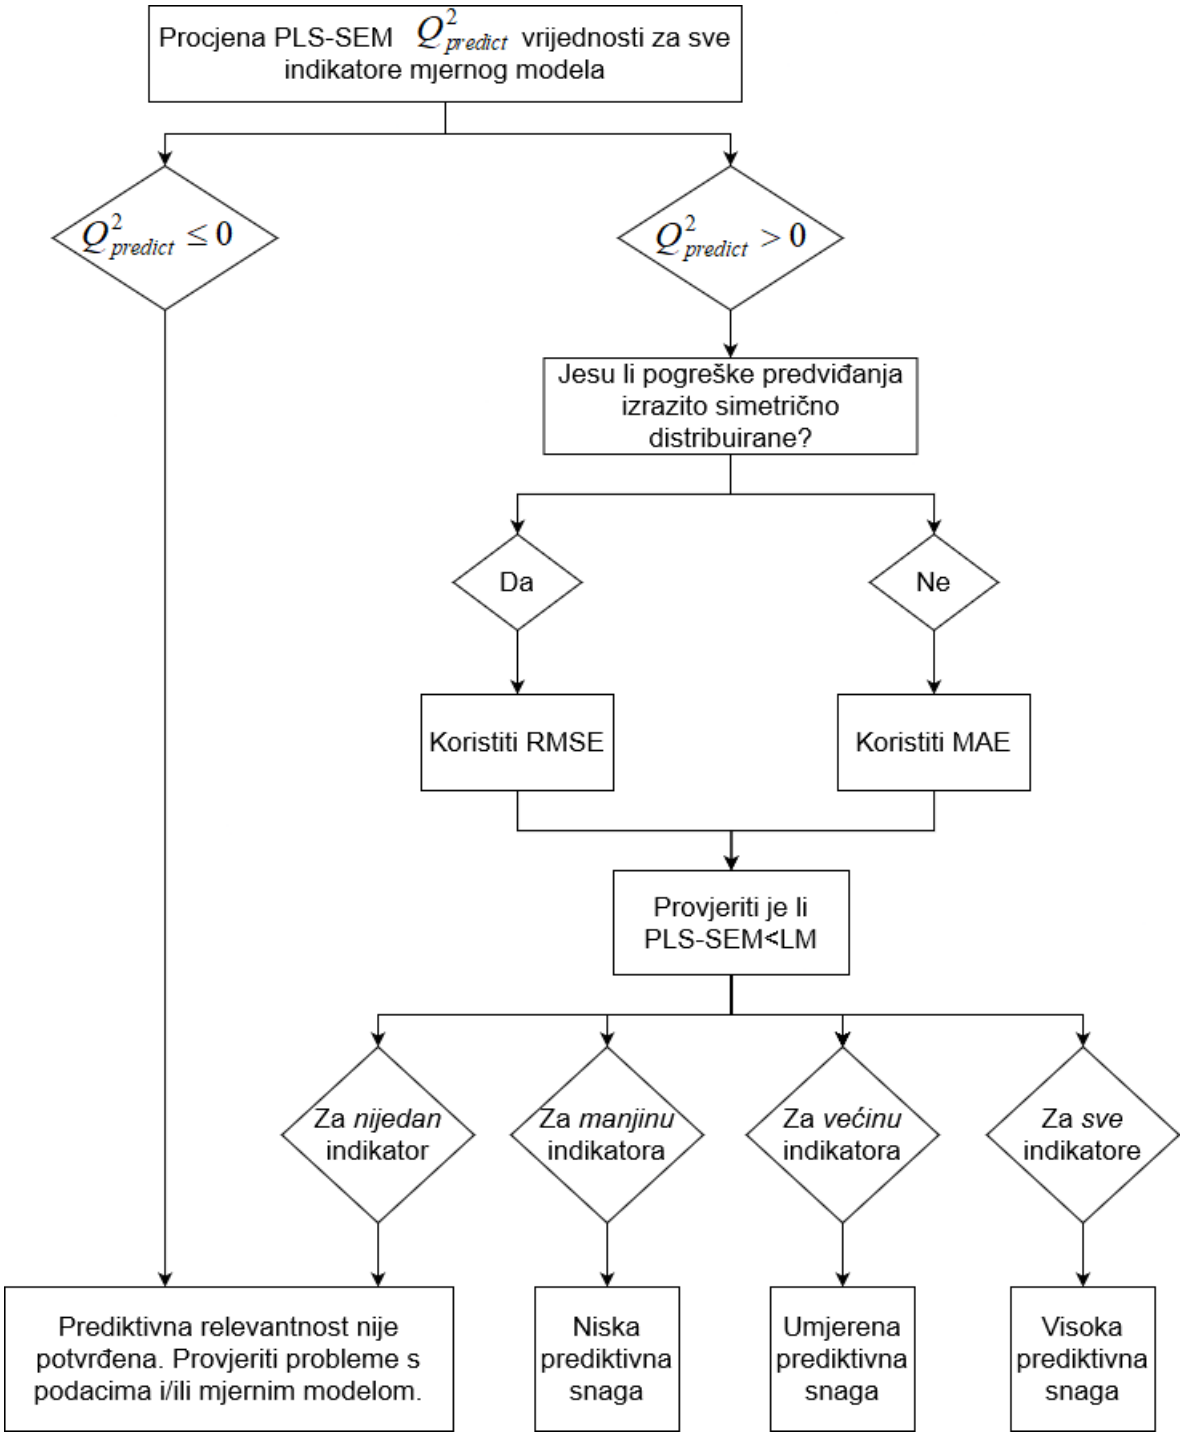

Slika 4.26. Smjernice za interpretaciju PLSpredict rezultata

Izvor: izrada autorice prema Shmueli et al. (2019, str. 2329)

Iako je PLS-SEM originalno namijenjen za prediktivne svrhe, njegove mogućnosti su proširene i na testiranje teorije razvojem **mjera prilagodbe modela**. Na ovaj način širi se i primjenjivost

metode. Primjeri mjera prilagodbe PLS-SEM modela su (Hair et al., 2017a; Sarstedt, Ringle i Hair, 2017a):

- **Standardizirani korijen prosječnog kvadratnog odstupanja (eng. *standardized root mean square residual,* SRMR)**, već spomenut kod CB-SEM metode. Prikazuje razlike između stvarnih i modelom procijenjenih korelacija. Vrijednost bliža nuli označava bolju prilagodbu modela, a prihvatljive vrijednosti su one vrijednosti do granica od 0.08 ili 0.10. Granica prihvatljivosti trebala bi biti viša za PLS-SEM, jer korelacije imaju različitu ulogu u odnosu na CB-SEM model (Hair et al., 2017a).
- **Korijen prosječnog kvadratnog odstupanja kovarijance (eng. *root mean square residual covariance,* RMS_{theta})**, koji mjeri stupanj korelacije reziduala vanjskog modela. Prikladan je samo za reflektivne modele, jer kod formativnih vanjski reziduali nisu značajni. Također bi za dobru prilagodbu vrijednost pokazatelja trebala biti što bliža nuli, a kao granične vrijednosti prihvatljive prilagodbe uzimaju se 0.12 ili 0.14 (Hair et al., 2017a).
- **Egzaktni test prilagodbe (eng. *exact fit test*)**, koji *bootstrapping* procedurom daje rezultate *p*-vrijednosti razlike stvarnih i modelom procijenjenih korelacija. Za razliku od SRMR, razlika nije iskazana u obliku reziduala, već u obliku udaljenosti, koje se mogu izračunati na dva načina: Euklidska (d_ULS) i geodetska (d_G) udaljenost. Da bi se zaključilo da je prilagodba modela dobra, originalne vrijednosti d_ULS i d_G trebale bi biti unutar 95% (ili 99%) intervala pouzdanosti (Hair et al., 2017a).

Postoje još neki pokazatelji prilagodbe, no njihova upotreba se ne sugerira, jer niti jedna mjera nije još uvijek u potpunosti razvijena. Osim toga, postavlja se pitanje kolika je uopće korist oslanjati se na ove pokazatelje, jer glavni cilj PLS-SEM metode nije samo objašnjavanje teorije. U budućnosti je potrebno još istraživanja na temu pokazatelja prilagodbe, kako bi se oni unaprijedili (Hair et al., 2017a; Sarstedt, Ringle i Hair, 2017a).

Konačno, istraživači mogu biti zainteresirani za usporedbu različitih modela. Osim analize svih prethodno opisanih pokazatelja eksplanatorne i prediktivne snage pri usporedbi strukturalnih modela, mogu se koristiti i informacijski kriteriji u tu svrhu. Naime, oni optimiziraju točnost predviđanja uspostavljanjem ravnoteže između prilagodbe i kompleksnosti modela (Sharma et al.,

2019; 2021). Prilikom odabira modela bira se onaj model koji minimizira vrijednost informacijskog kriterija, s tim da te vrijednosti mogu biti i negativne. U simulacijskoj studiji koju su proveli Sharma et al. (2021), zaključeno je kako Bayesov informacijski kriterij (eng. *Bayesian Information Criterion*, BIC) i Geweke-Meese kriterij (eng. *Geweke-Meese Criterion*, GM) postižu najbolji kompromis između prilagodbe modela (objašnjavanje modela) i prediktivne snage modela („*out-of-sample*“ predviđanja) (Hair et al., 2019b; Sharma et al., 2019; 2021).

4.2.6 Analiza medijacije i moderacije

Medijacija i moderacija u PLS-SEM modelu obuhvaćaju isti koncept kao i u CB-SEM modelu. Dakle, **medijacija** je prisutna kada treća varijabla posreduje između dva povezana konstrukta. Ako postoji medijacija, može se reći da promjena u egzogenom konstruktu uzrokuje promjenu u medijatoru, što u konačnici uzrokuje promjenu u endogenom konstruktu PLS-SEM modela. Kako je već spomenuto kod medijacije u CB-SEM modelu, medijator je varijabla koja objašnjava cijeli odnos ili dio odnosa između prediktora i zavisne varijable (Baron i Kenny, 1986; Hair et al., 2014; Garson, 2016; Wong, 2016; Carrión, Nitzl i Roldán, 2017; Hair et al., 2017a). Prilikom analize medijacije promatraju se direktni i indirektni utjecaji među varijablama. Shema općeg medijacijskog modela prikazana je na slici 4.27. Glavni endogeni konstrukt na slici označen je kao Y_3. Y_1 direktno utječe na Y_3, kao i indirektno putem medijatora Y_2. Direktni utjecaj označen je kao p_3, a indirektni utjecaj računa se kao umnožak $p_1 \cdot p_2$. Ukupan utjecaj računa se kao zbroj direktnog i indirektnog utjecaja, što je u ovom primjeru $p_3 + (p_1 \cdot p_2)$.

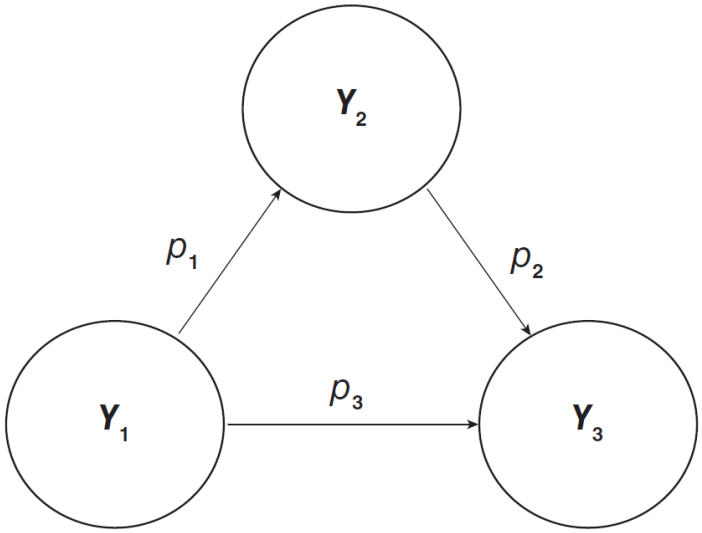

Slika 4.27. Shema općeg medijacijskog modela

Izvor: Hair et al. (2017a, str. 229)

Medijacija se testira putem analize indirektnih utjecaja i njihove značajnosti, koja se u PLS-SEM modelima utvrđuje kroz *bootstrapping* proceduru. Postoje dva ishoda kada medijacija nije prisutna u modelu (Zhao, Lynch i Chen, 2010; Carrión, Nitzl i Roldán, 2017; Hair et al., 2017a):

- **Samo direktni utjecaj (nema medijacije) (eng. *direct-only nonmediation*)** – direktni utjecaj je statistički značajan, a indirektni nije. Moguće je da se radi o testiranju pogrešnog medijatora i da medijacija možda i postoji, ali kroz drugu posredničku varijablu.
- **Nema utjecaja (nema medijacije) (eng. *no effect nonmediation*)** – ni direktni ni indirektni utjecaj nije statistički značajan. Može se raditi o manjkavom teoretskom modelu.

Ako medijacija u modelu postoji, mogu se identificirati tri vrste (Zhao, Lynch i Chen, 2010; Carrión, Nitzl i Roldán, 2017; Hair et al., 2017a):

- **Komplementarna parcijalna medijacija (eng. *complementary partial mediation*)** – indirektni i direktni utjecaji su statistički značajni i kreću se u istom smjeru, tj. smjerovi njihovih utjecaja su istog predznaka. U ovom slučaju dio utjecaja nezavisne varijable prenesen je na zavisnu varijablu putem medijatora, dok nezavisna varijabla i dalje objašnjava dio zavisne varijable, neovisno o medijatoru. Ovo može ukazivati na postojanje dodatnog potencijalnog medijatora, koji je izostavljen, a njegov bi indirektni utjecaj imao jednak predznak kao i direktni utjecaj (Zhao, Lynch i Chen, 2010; Carrión, Nitzl i Roldán, 2017; Hair et al., 2017a).
- **Kompetitivna parcijalna medijacija (eng. *competitive partial mediation*)** – indirektni i direktni utjecaji su statistički značajni, ali kreću se u suprotnom smjeru, tj. smjerovi njihovih utjecaja imaju suprotan predznak. S obzirom da se također radi o parcijalnoj medijaciji, samo dio zavisne varijable objašnjen je putem medijatora, dok je drugi dio zavisne varijable objašnjen putem nezavisne varijable, neovisno o medijatoru. U ovom slučaju medijator se ponaša kao varijabla suzbijanja (eng. *suppressor*), smanjujući veličinu ukupnog utjecaja nezavisne na zavisnu varijablu. Ako se ovakva medijacija pojavi u modelu, potrebno je pažljivo analizirati teoretsku potkrijepljenost svih uključenih utjecaja. Osim toga, i u ovom slučaju postoji mogućnost postojanja dodatnog izostavljenog

medijatora, čiji bi indirektni utjecaj imao suprotan predznak od direktnog (Zhao, Lynch i Chen, 2010; Carrión, Nitzl i Roldán, 2017; Hair et al., 2017a).

- **Samo indirektni utjecaj (potpuna medijacija) (eng. *indirect-only mediation, full mediation*)** – samo indirektni utjecaj je statistički značajan, a direktni nije. Tada je utjecaj nezavisne varijable u potpunosti prenesen na zavisnu uz pomoć medijatora (Zhao, Lynch i Chen, 2010; Carrión, Nitzl i Roldán, 2017; Hair et al., 2017a).

Kod utvrđivanja medijacije može se ispitati i snaga, tj. udio parcijalne medijacije. Pristup koji se koristi pri izračunu temelji se na odnosu između indirektnog i direktnog utjecaja (eng. *ratio of the indirect-to-total effect*). Ovaj omjer poznat je pod nazivom **uračunata varijanca (eng. *variance accounted for,* VAF)**, a definira mjeru u kojoj proces medijacije objašnjava varijancu zavisne varijable. Izračun VAF slijedi formulu (Wong, 2016; Carrión, Nitzl i Roldán, 2017):

$$\mathrm{VAF} = \frac{a \cdot b}{(a \cdot b) + c'} \tag{4.45}$$

Pri tome a označava utjecaj nezavisne varijable na medijator, b označava utjecaj medijatora na zavisnu varijablu, a c' označava utjecaj nezavisne varijable na zavisnu.

Slika 4.28. prikazuje proceduru i zaključke analize medijacije, uz oznake utjecajnih veza sa slike 4.27.

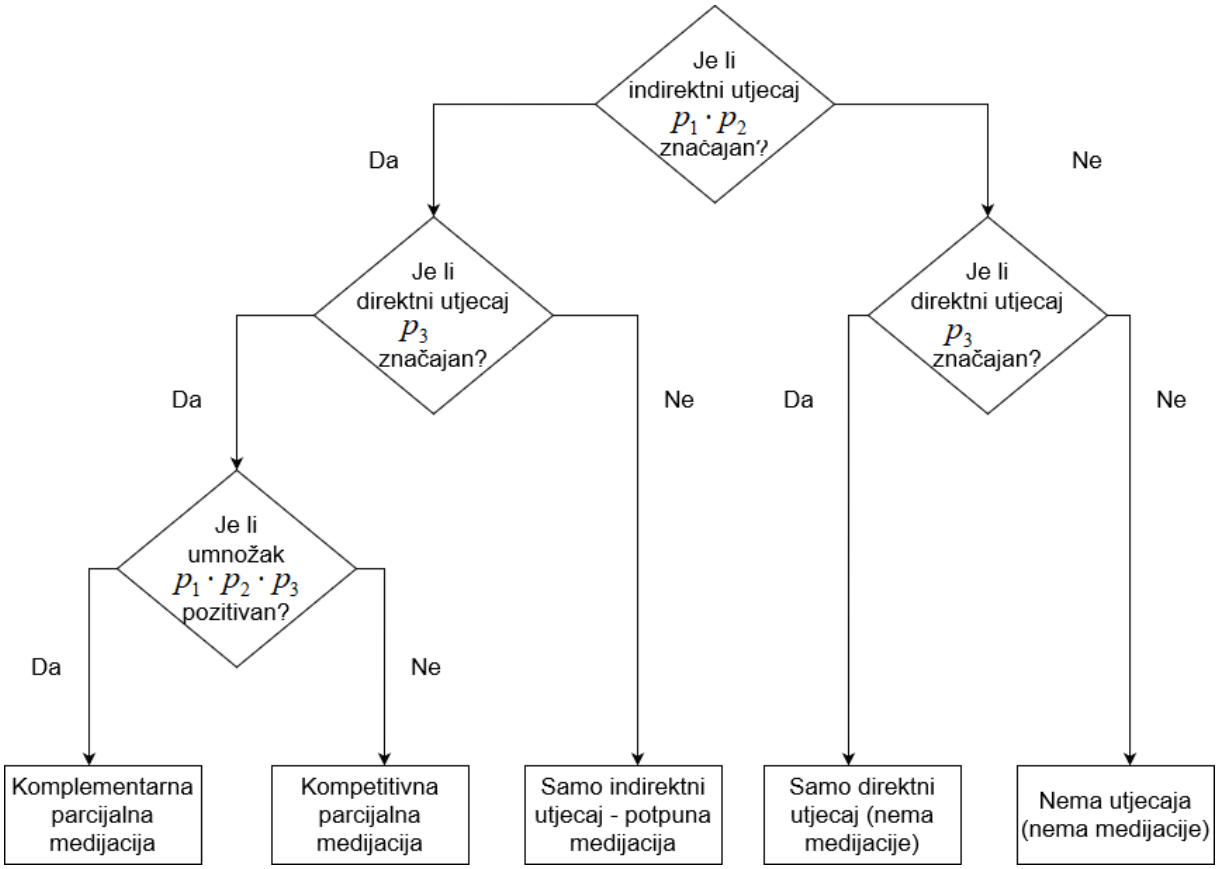

Slika 4.28. Proces analize medijacije

Izvor: izrada autorice prema Zhao, Lynch i Chen (2010, str. 201) i Hair et al. (2017a, str. 233)

Osim jednostavne, može se testirati i višestruka medijacija (eng. *multiple mediation*), i to paralelna (eng. *parallel mediation*) i serijska (eng. *serial mediation*). Ovi modeli uključuju više medijatora istovremeno, a mogu se testirati usporedbom specifičnih indirektnih utjecaja s direktnim utjecajem ili usporedbom ukupnog indirektnog utjecaja s direktnim utjecajem (Hair et al., 2017a). Prikaz primjera paralelne i serijske medijacije prikazan je na slici 4.29.

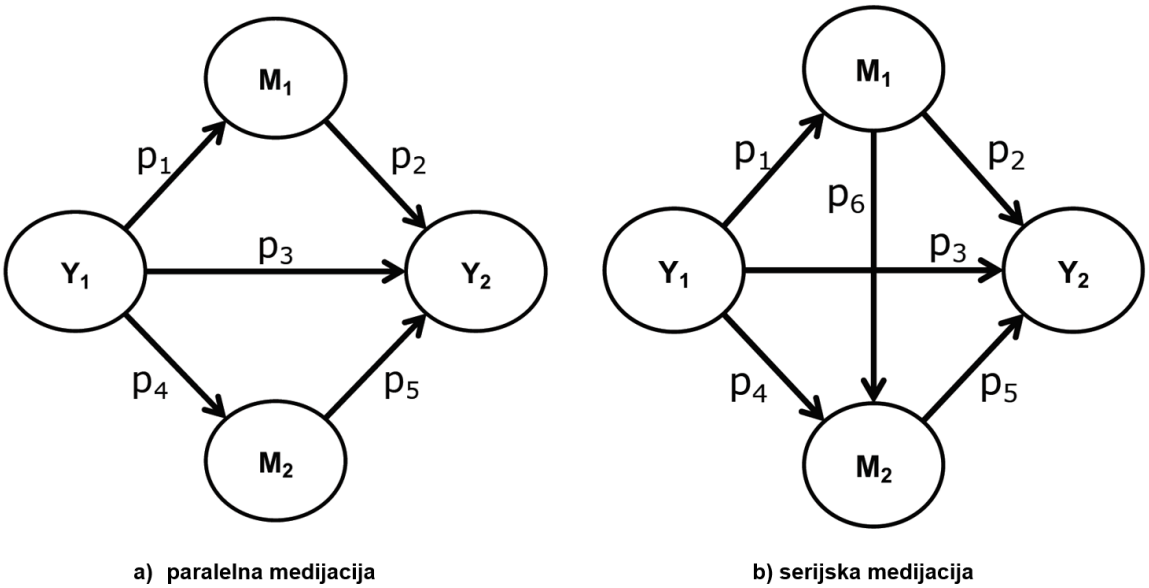

Slika 4.29. Primjer paralelne i serijske medijacije

Izvor: izrada autorice prema Hair et al. (2017a, str. 237)

Moderacija opisuje situaciju u kojoj utjecaj egzogenog konstrukta na endogeni nije konstantan, već ovisi o vrijednostima treće varijable, koja se naziva moderator. Ova varijabla mijenja snagu i/ili smjer utjecaja između promatranih konstrukata. Ideja moderacije je da nagib nezavisne varijable više nije konstantan, već linearno ovisi o razini moderatora (Henseler i Fassott, 2010; Hair et al., 2014; Fassott, Henseler i Coelho, 2016; Hair et al., 2017a; Becker, Ringle, i Sarstedt, 2018; Ramayah et al., 2018). Moderatorske varijable unaprijed su pretpostavljene, a testiranje moderacije ovisi o tome pretpostavlja li se da samo jedna specifična veza u modelu ili sve veze u modelu ovise o vrijednostima moderatora. Ako se istražuju sve veze u modelu i pretpostavka je da se razlikuju s obzirom na određene grupe (primjerice po spolu), tada se često provodi analiza više grupa (eng. *multigroup analysis*), koja procjenjuje isti model za svaku grupu moderatorske varijable (Hair et al., 2017a). U nastavku se promatra moderacija gdje je fokus na utjecaju moderatora na samo jednu vezu u modelu. Moderatori mogu biti mjereni jednim ili više indikatora, bilo reflektivnim ili formativnim. Najvažnija razlika odnosi se na vrstu moderatorske varijable, koja može biti kategorijalna (obično dihotomna) ili omjerna. Upravo kod kategorijalnih moderatora najčešće se provodi analiza više grupa umjesto klasične moderacije. Međutim, i moderatori omjerne skale mogu se rekodirati u kategorijalne i kao takvi se koristiti u grupnoj analizi (Henseler i Fassott, 2010; Fassott, Henseler i Coelho, 2016; Hair et al., 2017a).

Prilikom testiranja moderacije, potrebno je pretvoriti konceptualni model u statistički, što je prikazano na slici 4.30. Model se može raspisati na sljedeći način (Hair et al., 2017a; Ramayah et al., 2018):

$$\begin{aligned} Y &= (p_1 + p_3 \cdot M) \cdot X + p_2 \cdot M \\ Y &= p_1 \cdot X + p_2 \cdot M + p_3 \cdot (X \cdot M) \end{aligned} \tag{4.46}$$

Parametar p_1 predstavlja glavni efekt (eng. *main effect*) kada moderator nije uključen u model. Kada postoji moderator u modelu, tada p_1 predstavlja jednostavan efekt (eng. *simple effect*). Veza između zavisne i nezavisne varijable ne ovisi samo o jednostavnom efektu, već i o produktu p_3 i M, koji se naziva i efektom interakcije (eng. *interaction term*). Stoga, parametar p_3 pokazuje kako se utjecaj p_1 mijenja kada se moderator M promijeni za jednu standardnu devijaciju (Hair et al., 2017a; Ramayah et al., 2018). Osim toga, moguće su i tzv. kaskadne analize moderacije (eng. *cascaded moderator analysis*), gdje moderacijski efekt neke varijable nije konstantan, već je i on sam pod utjecajem neke druge moderatorske varijable (Henseler i Fassott, 2010; Hair et al., 2017a).

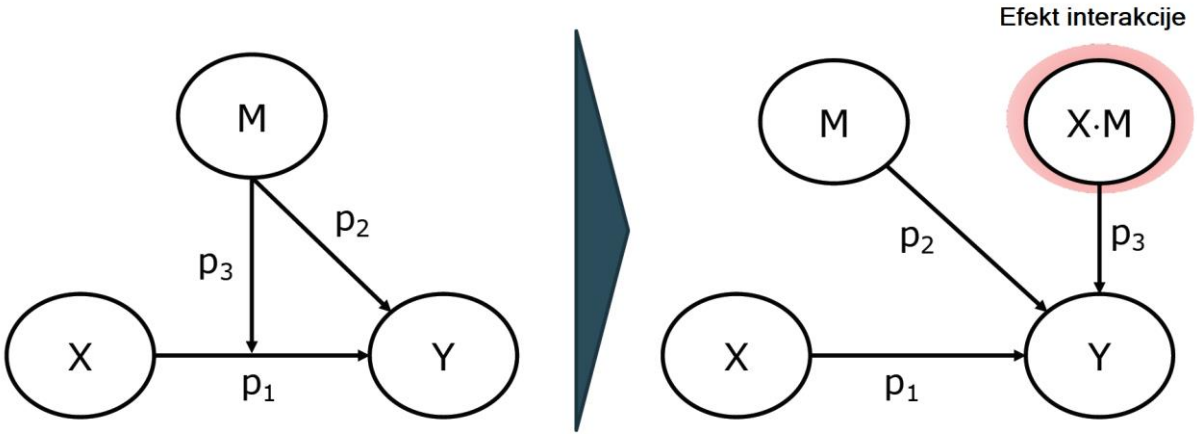

Slika 4.30. Pretvorba konceptualnog modela s moderatorom u statistički model

Izvor: izrada autorice prema Hair et al. (2017a, str. 247-248)

Postoji nekoliko pristupa kreiranja efekta interakcije, a to su: pristup produkta indikatora (eng. *product indicator approach*), ortogonalizacijski pristup (eng. *orthogonalizing approach*) i dvoetapni pristup (eng. *two-stage approach*) (Henseler i Fassott, 2010; Fassott, Henseler i Coelho, 2016; Hair et al., 2017a; Ramayah et al., 2018).

Pristup produkta indikatora (eng. *product indicator approach*) uključuje množenje svakog indikatora egzogene latentne varijable sa svakim indikatorom moderatorske varijable. Upravo ovi tzv. produkti indikatora postaju indikatori konstrukta koji predstavlja efekt interakcije. Množenje indikatora zahtijeva da su indikatori egzogenog konstrukta i moderatora međusobno zamjenjivi i da potječu iz iste domene konstrukta. Stoga, ovaj pristup je prikladan isključivo ako su egzogeni konstrukt i moderator reflektivno mjereni, a nije prikladan za formativne modele (Henseler i Fassott, 2010; Fassott, Henseler i Coelho, 2016; Garson, 2016; Hair et al., 2017a; Ramayah et al., 2018). S obzirom da se indikatori međusobno množe, to znači da se oni ponavljaju u mjernom modelu efekta interakcije, što povećava kolinearnost u modelu. Kako bi se izbjegao ovaj problem, indikatori moderatora obično se standardiziraju prije kreiranja samog efekta interakcije (Hair et al., 2017a). Slika 4.31. prikazuje primjer pristupa produkta indikatora.

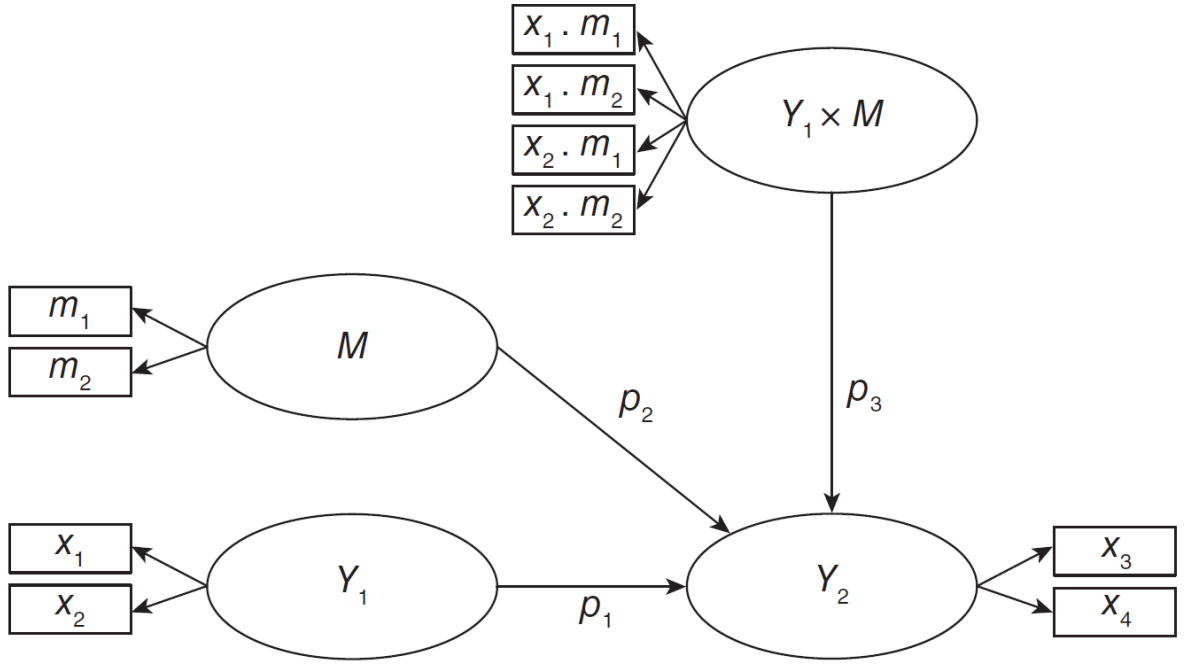

Slika 4.31. Pristup produkta indikatora

Izvor: Hair et al. (2017a, str. 250)

Ortogonalizacijski pristup (eng. *orthogonalizing approach*) može se razumjeti kao proširenje pristupa produkta indikatora. Cilj ovog pristupa je osigurati da indikatori efekta interakcije nisu u korelaciji s niti jednim indikatorom egzogenog konstrukta (prediktora) i moderatora. Na taj način izbjegava se problem kolinearnosti u modelu (Fassott, Henseler i Coelho, 2016; Hair et al., 2017a;

Becker, Ringle, i Sarstedt, 2018; Ramayah et al., 2018). Procedura ovog pristupa uključuje kreiranje svih mogućih produkata indikatora, a zatim njihovo regresiranje na sve indikatore nezavisne i moderatorske varijable. Prema modelu prikazanom na slici 4.31., uz četiri produkta indikatora potrebna su četiri regresijska modela (Fassott, Henseler i Coelho, 2016; Hair et al., 2017a; Ramayah et al., 2018):

$$\begin{aligned}
x_1 \cdot m_1 &= b_{1,11} \cdot x_1 + b_{2,11} \cdot x_2 + b_{3,11} \cdot m_1 + b_{4,11} \cdot m_2 + e_{11} \\
x_1 \cdot m_2 &= b_{1,12} \cdot x_1 + b_{2,12} \cdot x_2 + b_{3,12} \cdot m_1 + b_{4,12} \cdot m_2 + e_{12} \\
x_2 \cdot m_1 &= b_{1,21} \cdot x_1 + b_{2,21} \cdot x_2 + b_{3,21} \cdot m_1 + b_{4,21} \cdot m_2 + e_{21} \\
x_2 \cdot m_2 &= b_{1,22} \cdot x_1 + b_{2,22} \cdot x_2 + b_{3,22} \cdot m_1 + b_{4,22} \cdot m_2 + e_{22}
\end{aligned} \tag{4.47}$$

Unutar ovih raspisanih modela, za ortogonalizacijski pristup razmatraju se reziduali e, koji se u standardiziranom obliku uzimaju za indikatore efekta interakcije. Prednost ovog pristupa je u osiguravanju ortogonalnosti, tj. nekoreliranosti indikatora efekta interakcije s indikatorima nezavisne i moderatorske varijable. Još jedna posljedica ortogonalnosti su jednake procjene strukturalnih koeficijenata u modelu sa i bez interakcijskog efekta, što olakšava interpretaciju snage efekta moderacije. Međutim, i ovaj pristup je ograničen isključivo na reflektivne modele (Hair et al., 2017a; Ramayah et al., 2018). Vizualizacija ortogonalizacijskog pristupa prikazana je na slici 4.32.

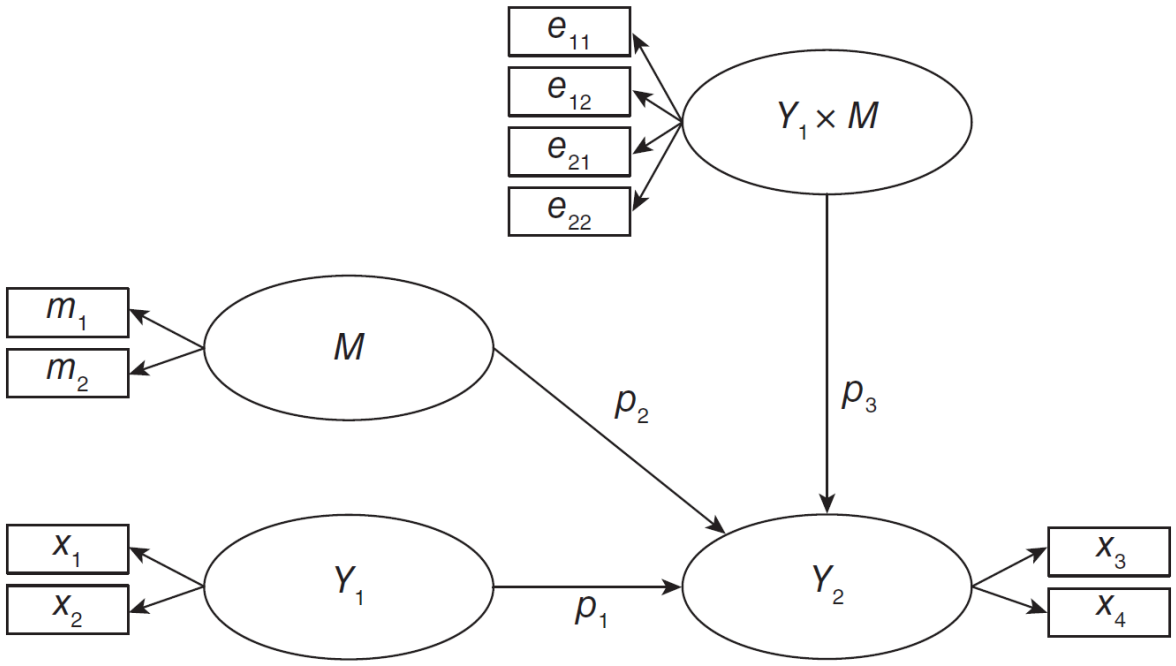

Slika 4.32. Ortogonalizacijski pristup

Izvor: Hair et al. (2017a, str. 252)

Dvoetapni pristup (eng. *two-stage approach*) razvijen je kako bi se mogla analizirati moderacija i u slučaju formativno mjerenih egzogenih konstrukata i/ili moderatora. Općenito primjenjivost ovog pristupa proizlazi iz iskorištavanja prednosti PLS-SEM-a za procjenu skorova latentnih varijabli. Stoga, efekt interakcije uopće ne treba produkte indikatora kao u prethodno opisanim pristupima. Sam naziv ovog pristupa analizi moderacije upućuje na činjenicu da se provodi u dva koraka, tj. dvije faze, a to su (Henseler i Fassott, 2010; Fassott, Henseler i Coelho, 2016; Garson, 2016; Hair et al., 2017a; Ramayah et al., 2018):

- **Faza 1:** Model glavnih efekata (eng. *the main effects model*), tj. bez efekta interakcije, procjenjuje se kako bi se dobili skorovi latentnih varijabli. Oni se spremaju za daljnju analizu u drugoj fazi procesa.
- **Faza 2:** Skorovi latentnih varijabli (eng. *latent variable scores*, LVS) egzogenog konstrukta i moderatora iz faze 1 množe se kako bi se kreirale mjere koje će kao jedan indikator (eng. *single-item measure*) predstavljati efekt interakcije. Preostale latentne varijable također su prikazane jednim indikatorom koji obuhvaća njihove skorove dobivene u prvoj fazi procesa.

Primjenu ovog pristupa analize moderacije ne treba ograničavati na formativne modele, već se može koristiti i kod potpuno reflektivno mjerenih modela. Izbor ove metode kreiranja efekta interakcije ovisi o cilju istraživanja (Hair et al., 2017a; Ramayah et al., 2018). Dvoetapni pristup grafički je prikazan je slici 4.33.

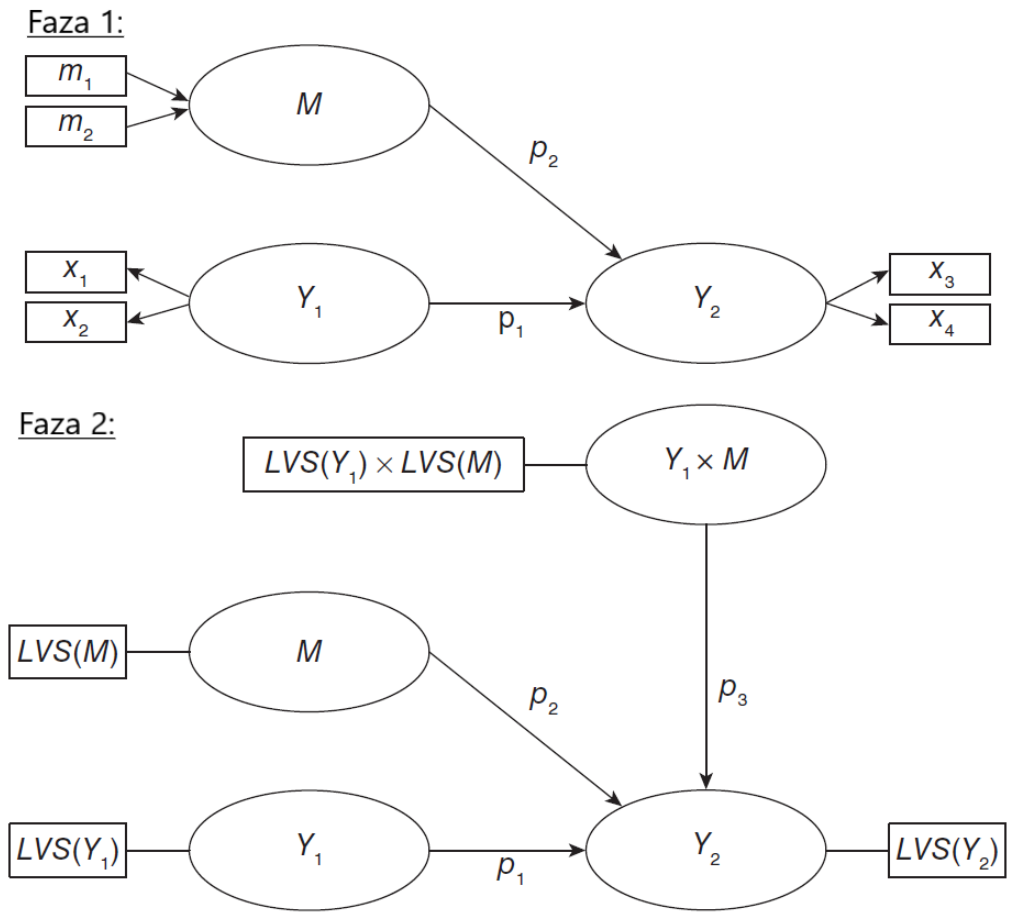

Slika 4.33. Dvoetapni pristup

Izvor: izrada autorice prema Hair et al. (2017a, str. 253)

Pri izboru pristupa za kreiranje efekta interakcije, prvenstveno je potrebno sagledati mjerni model egzogenog konstrukta i moderatora. Za formativno mjerene varijable moguće je koristiti isključivo dvoetapni pristup. Ako se radi o reflektivnim konstruktima, potrebno je utvrditi cilj analize kako bi se izabrao pravi pristup. Ako je cilj utvrditi postoji li značajan efekt moderatora na promatranu vezu, prikladno je koristiti dvoetapni pristup. Ako je glavni cilj minimizirati pristranost procjene efekta moderacije, tada je najprikladniji ortogonalizacijski pristup. Ovaj pristup najprikladniji je i kada je cilj maksimizirati točnost predviđanja u modelu. Pristup produkta indikatora ne savjetuje se koristiti (Garson, 2016; Hair et al., 2017a; Becker, Ringle, i Sarstedt, 2018; Ramayah et al., 2018). Slika 4.34. prikazuje smjernice za izbor pristupa za kreiranje interakcijskog efekta.

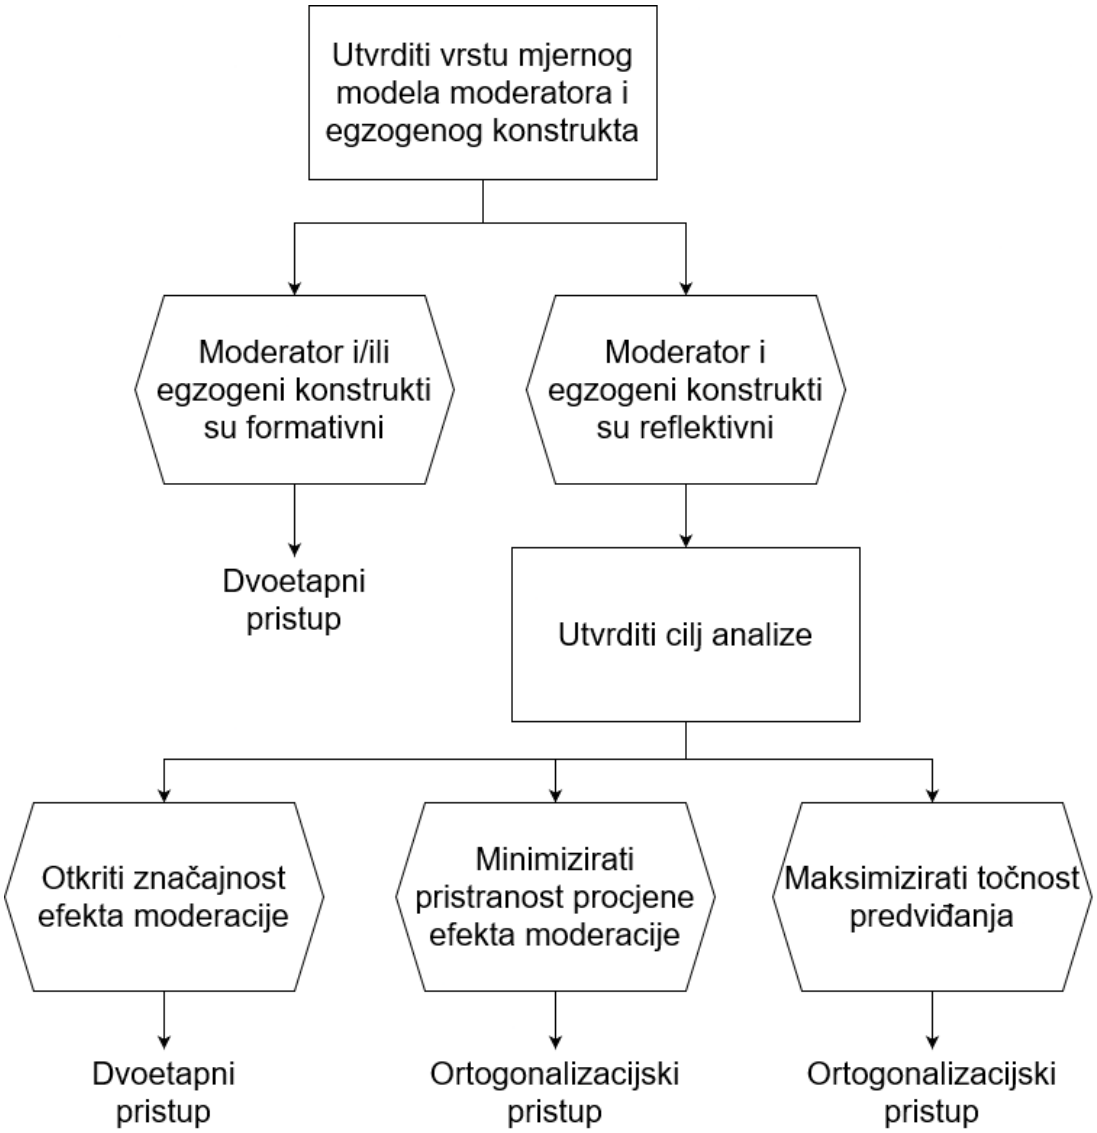

Slika 4.34. Smjernice za izbor pristupa za kreiranje interakcijskog efekta

Izvor: izrada autorice prema Hair et al. (2017a, str. 254)

Prema nedavnoj simulacijskoj studiji (Becker, Ringle, i Sarstedt, 2018), pokazalo se da je dvoetapni pristup najprikladniji pri različitim uvjetima i kao takav se savjetuje za generalno korištenje.

Evaluacija modela s moderatorom provodi se na klasičan način. Standardni evaluacijski kriteriji vrijede za varijablu moderatora, no ne i za interakcijski efekt. Naime, putem pristupa produkta indikatora i ortogonalizacijskog pristupa, zbog množenja indikatora iz dvije različite konceptualne domene, mjerni model interakcijskog efekta je samo pomoćna mjera. Također, ponovnom

upotrebom indikatora egzogenog i moderatorskog konstrukta, kolinearnost je uvedena, narušavajući tako diskriminantnu validnost. U dvoetapnom pristupu interakcijski efekt mjeren je samo jednim konstruktom, stoga u svakom slučaju ne treba biti ocijenjen pri analizi mjernog modela (Hair et al., 2017a; Ramayah et al., 2018). Strukturalni model ocjenjuje se prema standardnim smjernicama. Od glavnog interesa je značajnost efekta interakcije, koja se dobiva putem *bootstrapping* procedure, a zatim se određuje snaga efekta moderacije. U kontekstu moderacije važno je obratiti pažnju na veličinu efekta f^2 interakcijskog efekta. Kod moderacije, ovim pokazateljem procjenjuje se koliko moderacija doprinosi objašnjavanju endogene latentne varijable. Standardne vrijednosti opisane kod analize strukturalnog modela uzimaju se za slab, umjeren i jak utjecaj moderatora (0.02, 0.15 i 0.35). Međutim, pokazalo se kako je kod moderacije veličina efekta uglavnom mala (u prosjeku 0.009), stoga se predlažu niže granice za slab, umjeren i jak utjecaj moderatora, i to: 0.005, 0.01 i 0.025 (Fassott, Henseler i Coelho, 2016; Hair et al., 2017a; Kenny, 2018). Dodatno, jednako kao pri analizi moderacije kod CB-SEM modela, moguće je provesti i analizu jednostavnih nagiba (eng. *simple slope analysis*). Analiziraju se uvjetni (jednostavni) efekti egzogenog konstrukta pri različitim razinama moderatora, i to: pri aritmetičkoj sredini moderatora, pri jednoj standardnoj devijaciji iznad aritmetičke sredine i pri jednoj standardnoj devijaciji ispod aritmetičke sredine. Odnosno, ovi rezultati pokazuju koliko se mijenja utjecaj egzogenog na endogeni konstrukt ukoliko se moderator poveća za jednu standardnu devijaciju (Hair et al., 2017a; Ramayah et al., 2018).

4.2.7 Pregled naprednih tehnika

Napredne tehnike u PLS-SEM modeliranju većinom se odnose na slične analize kao i u CB-SEM modeliranju, dok su neke tehnike specifične za PLS-SEM.

Modeli višeg reda (eng. *higher-order models*) ili **modeli hijerarhijskih komponenata (eng. *hierarchical component models*, HCM)** uključuju konstrukte operacionalizirane na višim razinama apstrakcije, a obično su u upotrebi modeli drugog reda (eng. *second-order models*). Apstraktniji konstrukti modeliraju se na višim razinama i nazivaju se **komponentama višeg reda (eng. *higher-order components*, HOC)**, a njihove konkretnije poddimenzije modeliraju se na nižoj razini i nazivaju se **komponentama nižeg reda (eng. *lower-order components*, LOC)**. Prednosti uključivanja konstrukata višeg reda uključuju smanjivanje broja veza u strukturalnom modelu, čime se postiže parsimonija modela. Osim toga, smatra se da su širi konstrukti bolji prediktori

kriterija koji obuhvaćaju više domena i vremenskih perioda, odnosno ako je cilj objašnjavanje šire definiranog ponašanja, modeli višeg reda mogu biti korisni. Nadalje, ovakvi modeli se mogu pokazati korisnima i u situacijama kada su konstrukti prvog reda visoko korelirani, čime se može riješiti problem kolinearnosti i diskriminantne validnosti. Kod PLS-SEM metode, modeli višeg reda koriste se i kada postoje formativni indikatori u modelu, gdje također mogu pomoći u rješavanju problema multikolinearnosti. Stoga, ukoliko je teoretski podržano, konstrukt višeg reda može poslužiti kao egzogeni konstrukt u modelu, koji je mjeren putem nekoliko konstrukata nižeg reda (Hair et al., 2014; Hair et al., 2017a; Hair et al., 2017c; Sarstedt et al., 2019).

Pri specifikaciji modela višeg reda, potrebno je obratiti pažnju na veze između HOC i LOC te veze između konstrukata i njihovih indikatora, a te veze ne moraju biti iste na obje razine. Uzimajući ovo u obzir, može se zaključiti kako postoje četiri vrste modela: **reflektivno-reflektivni, reflektivno-formativni, formativno-reflektivni i formativno-formativni**. U ovim nazivima prvi dio odnosi se na način mjernih modela LOC, a drugi dio se odnosi na veze između HOC i LOC. Reflektivna specifikacija veze HOC i LOC znači da određeni apstraktniji konstrukt objašnjava korelacije između više LOC koji su njegova posljedica (npr. dopadljivost i kompetentnost manifestiraju korporativnu reputaciju). Suprotno tome, ako konkretniji LOC formiraju apstraktniji HOC, prikladna je formativna specifikacija veze (npr. različite konkretne razine zadovoljstva određenim stavkama, kao što su cijena, usluga i sl., formiraju apstraktniji konstrukt koji predstavlja generalno zadovoljstvo). Dakle, LOC se ponaša kao reflektivni ili formativni indikator HOC-a (Hair et al., 2017a; Hair et al., 2017c; Sarstedt et al., 2019). Na slici 4.35. prikazane su vrste modela višeg reda, tj. modela hijerarhijskih komponenata.

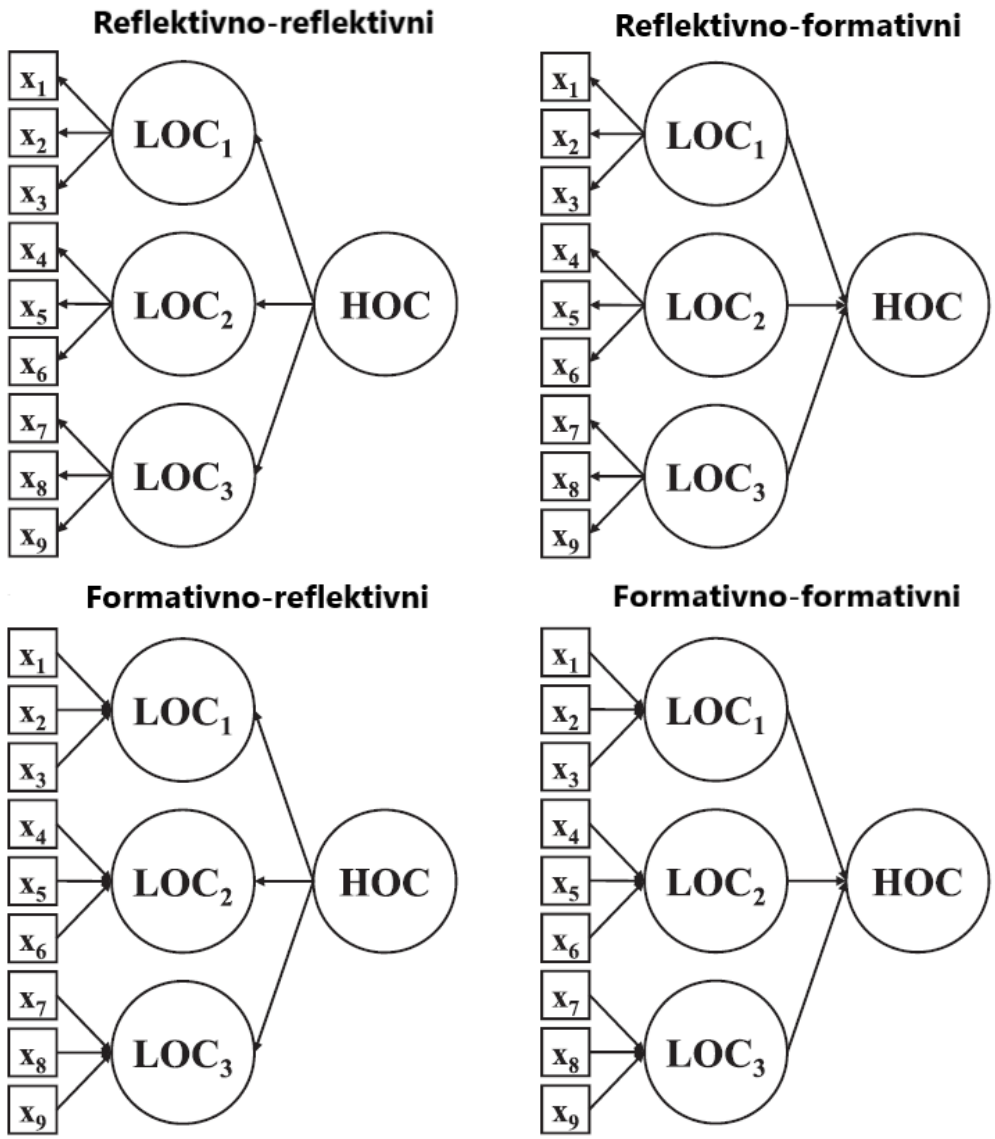

Slika 4.35. Vrste modela hijerarhijskih komponenata

Izvor: izrada autorice prema Hair et al. (2017c, str. 45) i Sarstedt et al. (2019, str. 198)

Nadalje, potrebno je odrediti na koji način će se specificirati indikatori za mjerni model konstrukta višeg reda. Postoje dva pristupa ovoj specifikaciji. Prvi je **pristup ponovljenih indikatora (eng. *repeated indicators approach*)**, gdje su svi indikatori konstrukata nižeg reda dodijeljeni mjernom modelu konstrukta višeg reda. Vrlo je jednostavno na ovaj način specificirati i procijeniti model. Međutim, problem se javlja kod modeliranja formativno-formativnih ili reflektivno-formativnih endogenih konstrukata višeg reda. Naime, kako su svi indikatori konstrukta nižeg reda ponovljeni u konstruktu višeg reda, njegova varijanca bit će u potpunosti objašnjena komponentama nižeg

reda ($R^2 \approx 1$). U tom slučaju, bilo koji drugi konstrukt u modelu koji utječe na taj HOC pokazat će jako slab ili nikakav te beznačajan utjecaj. Da bi se riješio ovaj problem, sugerira se upotreba **proširenog pristupa ponovljenih indikatora (eng. *extended repeated indicators approach*)**, kod kojeg se dodatno specificira i veza između nekog egzogenog konstrukta u modelu i konstrukata nižeg reda. Na ovaj se način ne procjenjuje samo direktni efekt nezavisnog konstrukta na HOC, već njegov ukupan efekt. Treći poznati pristup i alternativa proširenog pristupa ponovljenih indikatora je **dvoetapni pristup (eng. *two-stage approach*)**. U prvoj fazi ovog pristupa, koristi se pristup ponovljenih indikatora u svrhu dobivanja skorova latentnih varijabli, koji se zatim u drugoj fazi koriste kao indikatori mjernog modela konstrukta višeg reda (Hair et al., 2017a; Hair et al., 2017c; Sarstedt et al., 2019). Sva tri navedena pristupa grafički su prikazana na sljedećim slikama.

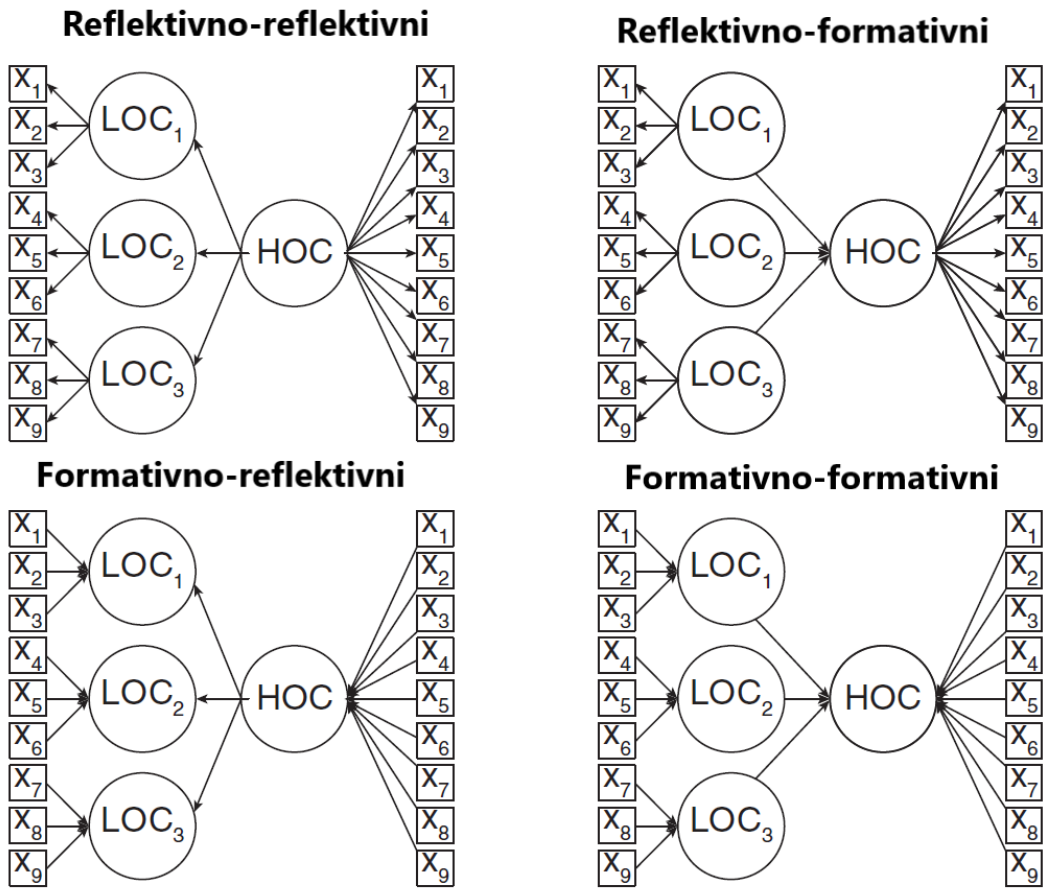

Slika 4.36. Pristup ponovljenih indikatora

Izvor: izrada autorice prema Hair et al. (2017a, str. 282) i Hair et al. (2017c, str. 49)

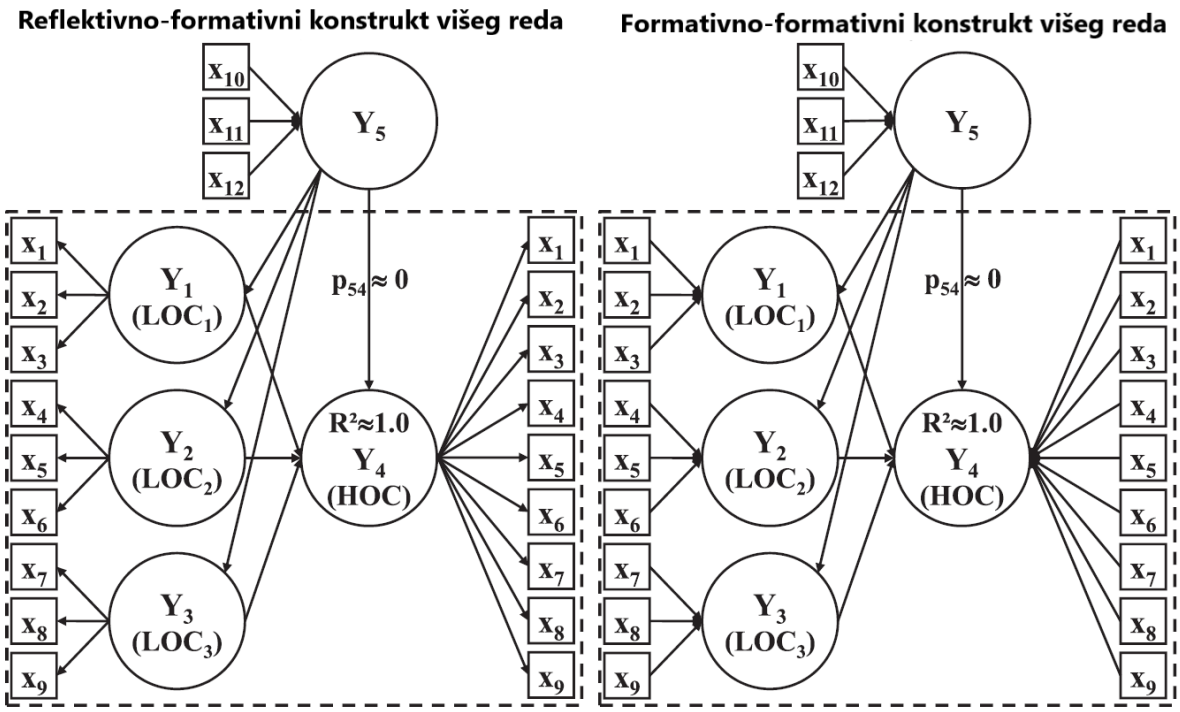

Slika 4.37. Prošireni pristup ponovljenih indikatora

Izvor: izrada autorice prema Hair et al. (2017c, str. 53) i Sarstedt et al. (2019, str. 199)

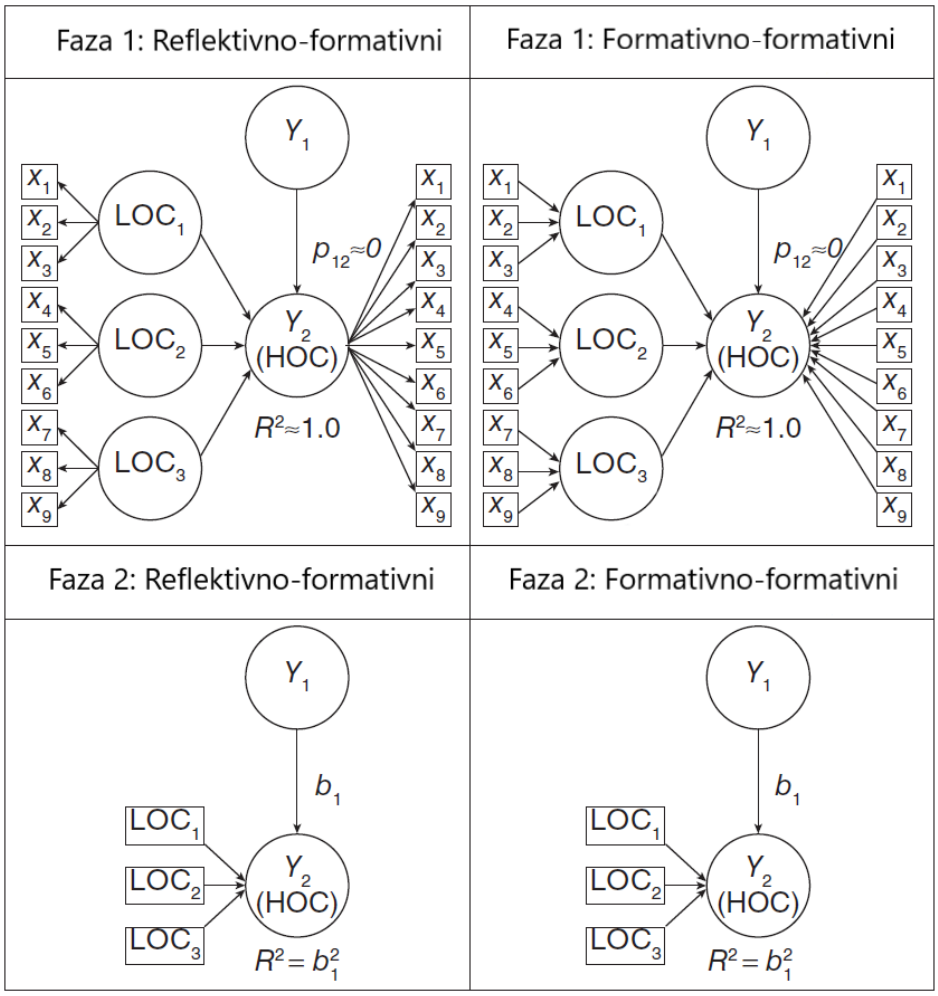

Slika 4.38. Dvoetapni pristup HOC

Izvor: izrada autorice prema Hair et al. (2017a, str. 284)

Ako je konstrukt višeg reda egzogeni konstrukt u modelu, savjetuje se korištenje pristupa ponovljenih indikatora kada je fokus na minimiziranju pristranosti parametra u vezama mjernog modela konstrukta višeg reda. Ako je fokus na minimiziranju pristranosti parametara u strukturalnim vezama, tada se preporučuje korištenje dvoetapnog pristupa. S druge strane, ako je konstrukt višeg reda endogeni konstrukt u modelu, tada se također vodi prethodno navedenim smjernicama, uz određene izuzetke. Naime, ako se radi o reflektivno-formativnim ili formativno-formativnim konstruktima višeg reda, svakako bi trebalo koristiti prošireni pristup ponovljenih indikatora ili dvoetapni pristup (Hair et al., 2017a; Hair et al., 2017c; Sarstedt et al., 2019). Nakon procjene modela višeg reda, mjerni modeli ocjenjuju se standardnom analizom za konstrukte nižeg reda. Veze između konstrukata višeg i nižeg reda, kod reflektivno-reflektivnih te formativno-reflektivnih modela, interpretiraju se kao vanjska opterećenja, a kod reflektivno-formativnih te

formativno-formativnih kao vanjske težine. Također se za konstrukte višeg reda procjenjuju pokazatelji validnosti, pouzdanosti, kolinearnosti, značajnosti težina, ovisno o tome o kakvom se modelu radi. Što se tiče strukturalnog modela, procjenjuje se na klasičan način, uz izuzetak što se konstrukti nižeg reda ne koriste kao elementi strukturalnog modela (Hair et al., 2017c; Sarstedt et al., 2019).

Analiza važnosti i učinka (eng. *importance-performance map analysis*, IPMA) proširuje standardno izvještavanje o rezultatima PLS-SEM modela. Ova metoda, uz prikaz procjena svih parametara u modelu, dodaje i novu dimenziju, koja razmatra prosječne vrijednosti skorova latentnih varijabli. IPMA uspoređuje ukupan utjecaj prediktora na ciljni konstrukt, koji predstavlja njihovu važnost u predviđanju ciljnog konstrukta, s njihovim prosječnim skorovima, koji ukazuju na njihov učinak. Cilj je identificirati prediktorske konstrukte koji imaju relativno visoku važnost u predviđanju ciljnog konstrukta (imaju jak ukupan utjecaj), ali relativno nizak učinak (niske skorove latentne varijable), kako bi se mogla predložiti poboljšanja (Garson, 2016; Ringle i Sarstedt, 2016; Hair et al., 2017a; Hair et al., 2017c). Kako bi se IPMA mogla provesti, potrebno je osigurati da svi indikatori u modelu budu na omjernoj ili kvazi-omjernoj skali. Za primjer kvazi-omjerne skale uzimaju se ordinalne skale gdje su intervali jednako udaljeni i kod kojih postoji i neutralna opcija (npr. Likertova skala 1-5 ili 1-7). Ova vrsta varijabli potrebna je zbog ponovnog skaliranja skorova latentnih varijabli u raspon od 0 do 100. Kodiranje indikatora trebalo bi imati pozitivan smjer skale, tj. najmanja vrijednost treba odražavati najlošiji, a najveća najbolji ishod indikatora. Vanjske težine moraju biti pozitivne kako bi se osiguralo da njihovi LVS budu u rasponu od 0 do 100. Zatim se računaju indeksi učinka (eng. *performance index values*), tako da se najprije za vrijednost indikatora svakog pojedinačnog opažanja razlika između stvarne i minimalne vrijednosti stavi u odnos s razlikom maksimalne i minimalne vrijednosti te pomnoži sa 100. U konačnici se računa prosječna vrijednost svakog indikatora za sva opažanja i dobije se indeks učinka. Važnost se računa jednostavnim izračunom ukupnih utjecaja prediktorskih konstrukata na ciljni konstrukt. Važnost i učinak prikazuju se grafički u koordinatnom sustavu, gdje je važnost na osi x, a učinak na osi y. Prema grafičkom prikazu, može se uočiti gdje je najbolje uložiti trud za poboljšanje na razini konstrukata ili indikatora. Ovi zaključci mogu poslužiti u praksi (Garson, 2016; Ringle i Sarstedt, 2016; Hair et al., 2017a; Hair et al., 2017c). Grafički prikaz IPMA nalazi se na slici 4.39. Vidljivo je da konstrukt Y_1 ima iznadprosječnu i najveću

važnost, ali ispodprosječan učinak, stoga je prioritet za poboljšanje. Drugi prioritet je Y_2 s iznadprosječnom važnosti i iznadprosječnim učinkom, dok poboljšanje konstrukta Y_3 ne bi previše doprinijelo objašnjavanju ciljnog konstrukta.

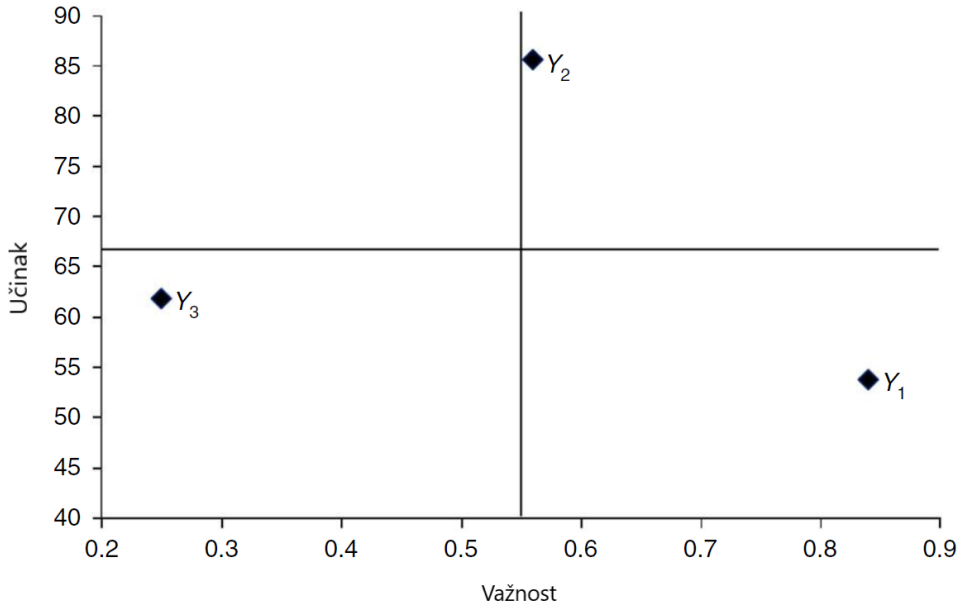

Slika 4.39. Grafički prikaz IPMA

Izvor: izrada autorice prema Ringle i Sarstedt (2016, str. 1874) i Hair et al. (2017c, str. 121)

Iako se uglavnom analizira cijeli skup podataka kako bi se donijeli zaključci na temelju PLS-SEM modela, naprednije tehnike daju mogućnost testiranja postoji li **opažena i neopažena heterogenost (eng. *observed and unobserved heterogeneity*)** u modelu. Naime, analizom svih podataka smatra se da oni potječu iz homogene populacije, što ne mora biti istina. Ako postoje razlike u procijenjenim vezama strukturalnog modela između određenih grupa temeljem jasnih karakteristika (npr. spol, dob i sl.), tada se radi o opaženoj heterogenosti. U tom slučaju, grupe se mogu razdvojiti i model se može odvojeno procijeniti za svaku grupu, tražeći značajne razlike u parametrima. Ako pak razlike ne proizlaze iz jasnih karakteristika, već postaju očite temeljem strukturalnih koeficijenata, tada se radi o neopaženoj heterogenosti, tj. uzrok razlika među grupama nije jasan (Hair et al., 2014; Sarstedt, Henseler i Ringle, 2011; Garson, 2016; Henseler, Ringle i Sarstedt, 2016; Hair et al., 2017a; Hair et al., 2017c; Matthews, 2017; Hair et al., 2019a; Hair et al., 2019b).

Kada se radi o otkrivanju opažene heterogenosti, koristi se **analiza više grupa (eng. *multigroup analysis*, MGA)**. Kao i u CB-SEM modelima, ova vrsta analize je svojevrsna analiza moderacije, kada je moderator kategorijalna varijabla koja utječe na sve veze u modelu. Upravo ovom analizom utvrđuje se postoje li statistički značajne razlike u strukturalnim koeficijentima između promatranih grupa. Postoji nekoliko pristupa testiranja MGA u PLS-SEM modelima (Sarstedt, Henseler i Ringle, 2011; Hair et al., 2014; Hair et al., 2017a; Hair et al., 2017c; Matthews, 2017), koji su prikazani grafički na slici 4.40. i opisani u nastavku.

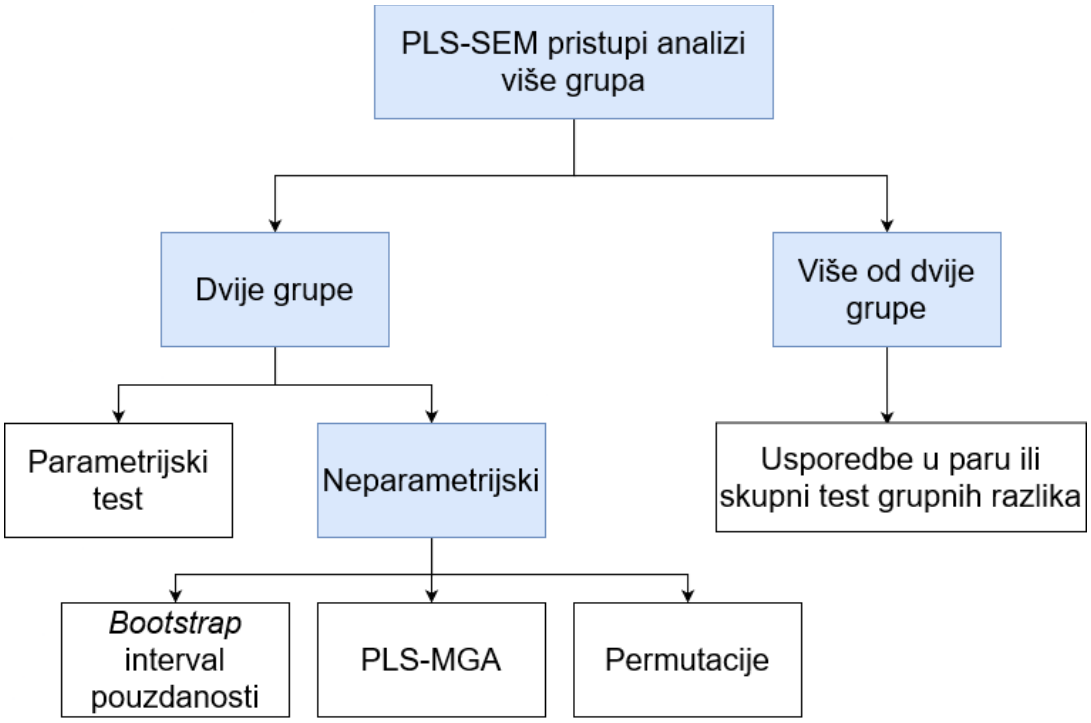

Slika 4.40. Pristupi testiranju MGA u PLS-SEM modelima

Izvor: izrada autorice prema Hair et al. (2017a, str. 293) i Hair et al. (2017c, str. 153)

- **Parametrijski test (eng. *parametric t-test*)** – modificirana verzija standardnog *t*-testa za razlike kod dvaju nezavisnih uzoraka. Potrebno je izračunati parametre modela za svaku grupu i standardne pogreške, koje proizlaze iz *bootstrapping* procedure. S obzirom da ovaj test pretpostavlja jednake varijance među grupama, potrebna je korekcija ukoliko to nije ispunjeno. Tada se koristi modificirana verzija Welch-Satterthwaite *t*-testa. Obje testne veličine slijede *t*-distribuciju s $n_1 + n_2 - 2$ stupnjeva slobode (gdje su n_1 i n_2 veličine dvaju uzoraka). Ovaj je test jednostavan za upotrebu, no sklon je greškama tipa I i upitno je

njegovo korištenje unutar neparametrijske PLS-SEM metode (Sarstedt, Henseler i Ringle, 2011; Hair et al., 2017a; Hair et al., 2017c; Matthews, 2017).

- **Neparametrijski PLS-MGA pristup (eng. *nonparametric PLS-MGA approach*)** – daje *p*-vrijednost jednosmjernog testa uspoređivanjem svake *bootstrapping* procjene jedne grupe sa svim *bootstrapping* procjenama istog parametra u drugoj grupi. Dakle, prvi korak je procjena parametara za svaku grupu, a zatim provedba *bootstrapping* procedure s mnogo uzoraka, također za svaku grupu. Nakon toga, broji se koliko puta je procijenjeni koeficijent za prvu grupu bio veći u odnosu na drugu grupu ($p_1 \geq p_2$), a taj broj se dijeli s brojem *bootstrap* uzoraka. Rezultat je *p*-vrijednost jednosmjernog testa, koja se potom uspoređuje s graničnom razinom signifikantnosti, da bi se utvrdilo je li razlika statistički značajna. S obzirom da PLS-MGA daje samo rezultate jednosmjernog testa, osim niskih, zanimljive su i visoke *p*-vrijednosti, jer bi one ukazivale na suprotan rezultat, odnosno primjerice da je procijenjeni koeficijent druge grupe značajno veći u odnosu na prvu grupu (Sarstedt, Henseler i Ringle, 2011; Hair et al., 2017a; Hair et al., 2017c; Matthews, 2017).
- **Test permutacija (eng. *permutation test*)** – još jedan neparametrijski test, koji se temelji na slučajnim razmjenama (permutacijama) opažanja između grupa i procjenama modela za svaku permutaciju. Test se provodi u šest koraka. Prvo je potrebno procijeniti koeficijente u modelu kako bi se dobile njihove procjene za svaku promatranu grupu posebno. Zatim se računa razlika između procijenjenih strukturalnih koeficijenata između dviju grupa. Treći korak je provedba nasumičnih permutacija podataka, gdje su opservacije dodijeljene grupama na slučajan način. Vodi se računa o tome da pri svakoj permutaciji svakoj grupi mora biti dodijeljeno onoliko slučajno izabranih opservacija koliko ih grupa originalno ima. Sugerira se upotreba barem 1000 permutacija. U četvrtom koraku provode se grupne procjene PLS modela za svaki postupak permutacije, pa se tako npr. za 1000 permutacija dobiva 1000 procjena za grupu 1 i grupu 2. Peti korak obuhvaća izračun razlika u strukturalnim koeficijentima dobivenim kroz svaku permutaciju, na temelju kojih se u zadnjem koraku kreira interval pouzdanosti. Ako se originalna razlika u koeficijentima nalazi izvan granica intervala, može se zaključiti da je razlika statistički značajna. Ograničenje ovog testa je činjenica da je pod utjecajem značajno različitih veličina grupa, tj. grupe bi trebale biti približno jednake veličine (Sarstedt, Henseler i Ringle, 2011; Hair et al., 2017a; Hair et al., 2017c; Matthews, 2017).

- Ako bi se ispitivale razlike između više od dviju grupa, mogu se koristiti **usporedbe u paru (eng. *pairwise comparisons*)**, gdje se više puta provodi test dok se ne dobiju sve moguće usporedbe. Međutim, kod ovog pristupa pojavljuje se problem povećanja greške tipa I, zbog velikog broja ponavljanja testa. Stoga je potrebno korigirati testnu veličinu pomoću Bonferroni ili Šidák korekcije. Drugi pristup analizi razlike između više od dviju grupa je **skupni test grupnih razlika (eng. *omnibus test of group differences*, OTG)**, koji se temelji na kombinaciji *bootstrapping* procedure i permutacija (Sarstedt, Henseler i Ringle, 2011; Hair et al., 2017a; Hair et al., 2017c).

Preduvjet za samu provedbu MGA je **mjerna nepromjenjivost (eng. *measurement invariance*)**, koja se odnosi na ispitivanje daju li mjerni modeli provedeni među različitim populacijama ekvivalentne prikaze istog konstrukta. U analizi MGA, zaključci o razlikama strukturalnih veza u modelu mogu biti upitni, ako nije uspostavljena mjerna nepromjenjivost (Henseler, Ringle, i Sarstedt, 2016; Hair et al., 2017a; Hair et al., 2017c; Matthews, 2017; Hair et al., 2019a). Te razlike mogu postojati jer ispitanici interpretiraju koncepte na različite načine (primjerice kod prevedenih anketa), zbog individualnih razlika (spol, dob, nacionalnost i sl.) ili zbog specifičnih stilova odgovora (npr. tendencija da se odaberu ili ne odaberu ekstremi na skali odgovora). Iako postoje određene metode analize mjerne nepromjenjivosti kod CB-SEM modela, one nisu u potpunosti primjenjive na PLS-SEM modele. Stoga je razvijena **procedura za procjenu mjerne nepromjenjivosti kompozitnih modela (eng. *measurement invariance of composite models*, MICOM)** u tri koraka (Henseler, Ringle i Sarstedt, 2016; Hair et al., 2017a; Hair et al., 2017c; Matthews, 2017):

1. **Nepromjenjivost u specifikaciji (eng. *configural invariance*)** – zahtijeva da među grupama budu svi jednaki indikatori i da ih bude jednak broj. Osim toga, mjerni modeli trebaju biti specificirani jednako (ili reflektivno ili formativno) za sve grupe, na jednak način treba kodirati i rekodirati indikatore, kao i tretirati nedostajuće podatke. Konačno, postavke algoritma moraju biti identične za sve grupe. Ako je ovaj uvjet zadovoljen, kreće se na sljedeći korak (Henseler, Ringle i Sarstedt, 2016; Hair et al., 2017a; Hair et al., 2017c; Matthews, 2017).
2. **Kompozitna nepromjenjivost (eng. *compositional invariance)*** – postoji kada su konstrukti, tj. njihovi skorovi, isti među svim grupama, a to je slučaj kada su visoko

korelirani. Stoga je prvo potrebno izračunati korelaciju između ovih skorova, čija visina bi trebala biti približno 1. Kako bi se testirala nulta hipoteza da je koeficijent korelacije manji od 1, koristi se neparametrijski test permutacija, slično kao u MGA. Ako je uspostavljena i kompozitna nepromjenjivost, znači da postoji parcijalna mjerna nepromjenjivost, a dalje se može testirati postoji li i potpuna mjerna nepromjenjivost (Henseler, Ringle i Sarstedt, 2016; Hair et al., 2017a; Hair et al., 2017c; Matthews, 2017).

3. **Jednakost aritmetičkih sredina i varijanci (eng. *equality of composite mean values and variances*)** – opet se koristi test permutacija, kako bi se utvrdilo imaju li skorovi latentnih varijabli jednake varijance i aritmetičke sredine u svim grupama. Ako su varijance među grupama jednake, a aritmetičke sredine nisu, tada postoji parcijalna mjerna nepromjenjivost (eng. *partial measurement invariance*). U slučaju da su među grupama jednake i varijance i aritmetičke sredine, postoji potpuna mjerna nepromjenjivost (eng. *full measurement invariance*) (Henseler, Ringle i Sarstedt, 2016; Hair et al., 2017a; Hair et al., 2017c; Matthews, 2017).

MICOM procedura prikazana je grafički na slici 4.41.

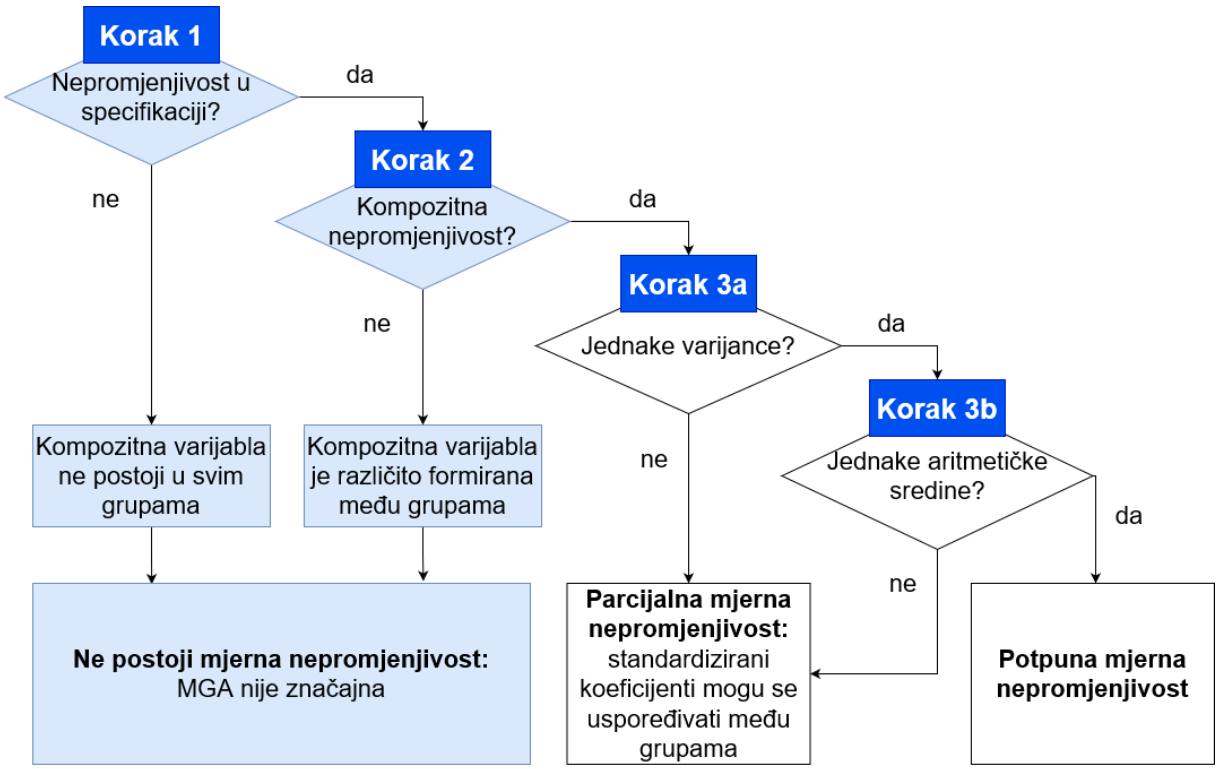

Slika 4.41. MICOM procedura

Izvor: izrada autorice prema Henseler, Ringle i Sarstedt (2016), Hair et al. (2017a, str. 299) i Hair et al. (2017c, str. 146)

Nadalje, kako je već spomenuto, mogu postojati razlike u podgrupama podataka i kada njihovi izvori nisu uvijek unaprijed poznati. Razlike su povezane s **neopaženom heterogenosti (eng. *unobserved heterogeneity*)**. U tom slučaju, zaključci koji se donose na temelju cijelog uzorka mogu biti zavaravajući. Zato je potrebno otkriti postoji li neopažena heterogenost u modelu, kako bi se rezultati modela mogli točno interpretirati (Hair et al., 2014; Garson, 2016; Hair et al., 2017a; Hair et al., 2017c; Matthews, 2017; Sarstedt, Ringle i Hair, 2017b; Hair et al., 2019a; Hair et al., 2019b). Uobičajeno se heterogena struktura podataka pronalazi putem standardnog klasteriranja podataka. Međutim, ovaj pristup nije se pokazao učinkovitim u identificiranju grupnih razlika kod strukturalnih koeficijenata. Iz tog razloga, kroz metodološka PLS-SEM istraživanja, predložile su se drugačije metode za identificiranje i rješavanje problema neopažene heterogenosti. Ove metode obično se nazivaju tehnike latentnih klasa (eng. *latent class techniques*), a najpoznatije takve metode su *finite mixture PLS* (FIMIX-PLS) i segmentacija orijentirana na predviđanje (eng. *prediction-oriented segmentation in PLS-SEM*, PLS-POS) (Hair et al., 2014; Garson, 2016; Hair et al., 2017a; Hair et al., 2017c; Matthews, 2017; Sarstedt, Ringle i Hair, 2017b; Hair et al., 2019b). FIMIX-PLS na temelju različitih informacijskih kriterija definira broj segmenata, tj. grupa koje se formiraju za naknadnu analizu putem PLS-POS metode, ili se ipak zaključuje da heterogenost nije značajna pa se za interpretaciju rezultata ipak koristi cijeli skup podataka[2] (Garson, 2016; Hair et al., 2017a; Hair et al., 2017c; Sarstedt, Ringle i Hair, 2017b; Hair et al., 2019b).

PLS-SEM može analizirati i **nelinearne veze (eng. *nonlinear relationships*)**, s obzirom da je poznato da neke veze mogu biti krivolinijske (eng. *curvilinear*), i to primjerice U-oblika (npr. troškovna krivulja) ili S-oblika (dobitci i gubitci u prospektnoj teoriji). Sugerira se prvenstveno pregledati podatke vizualno na grafičkom prikazu, kako bi se utvrdilo postoji li osnova za pretpostavku o nekoj nelinearnoj povezanosti među varijablama. Ako ne postoji, model se može procijeniti s linearnim vezama (Hair et al., 2017c). Jedan pristup modeliranju nelinearnih veza su logaritamske transformacije, dok se drugi oslanja na funkcije polinoma, od kojih se najčešće promatra kvadratni efekt (eng. *quadratic effect*), tj. polinom drugog stupnja. Ideja njegovog

[2] Detaljne smjernice za identificiranje i rješavanje problema heterogenosti po fazama vidjeti u Sarstedt, Ringle i Hair (2017b, str. 200)

modeliranja jednaka je modeliranju efekta moderacije, koji je prethodno opisan te se svodi na tzv. samo-moderaciju (eng. *self-moderation*) (Hair et al., 2017c; Becker, Ringle, i Sarstedt, 2018).

Osim navedenih naprednijih tehnika modeliranja, može se još spomenuti i **konzistentni PLS algoritam (eng. *consistent PLS*, PLSc)**, dizajniran za situacije kada je cilj oponašati rezultate CB-SEM metode. Putem ovog algoritma cilj je korigirati korelacije između latentnih varijabli, kako bi se dobile konzistentne procjene strukturalnih koeficijenata (Garson, 2016; Sarstedt et al., 2016; Hair et al., 2017a). Proces PLSc započinje klasičnom procjenom modela PLS-SEM algoritmom, nakon čega se ti rezultati koriste za izračun konzistentne pouzdanosti svih reflektivnih konstrukata u modelu. Za formativne i konstrukte s jednim indikatorom konzistentna pouzdanost fiksira se na 1. Ovi rezultati koriste se u svrhu korekcije prvotno dobivene korelacijske matrice. Nakon korekcije, konzistentna korelacijska matrica omogućava ponovnu procjenu modela (Sarstedt et al., 2016; Hair et al., 2017a). U konačnici, usporedbom CB-SEM, PLS-SEM i PLSc metode, PLS-SEM pokazuje najmanje pristranosti u većini situacija i sugerira se za upotrebu, naročito kada je cilj predviđanje, a ne samo analiza uzročnosti (Garson, 2016; Sarstedt et al., 2016; Hair et al., 2017a).

5. EMPIRIJSKO ISTRAŽIVANJE

5.1 Instrument istraživanja i prikupljanje podataka

U svrhu prikupljanja podataka za empirijsko istraživanje, korišten je anketni upitnik (Prilog 1). Osnovni skup iz kojeg proizlazi uzorak čine investitori, odnosno mali ulagatelji koji trguju vrijednosnim papirima na uređenom tržištu. Prema podacima Statističkog biltena za II. tromjesečje 2021. godine SKDD-a, broj aktivnih klijenata u tom razdoblju iznosio je 7481, s tim da je to kumulativan podatak dobiven od svih članova Fonda za zaštitu ulagatelja, zbog čega ulagatelj, ako je klijent više članova, u statističkom podatku može biti prikazan više puta (Središnje klirinško depozitarno društvo, 2021). Predviđena veličina uzorka, uz signifikantnost testa od 0.05, je 360 ispitanika. U ovom istraživanju fokus je na malim investitorima, tj. pojedincima koji ulažu u vlasničke vrijednosne papire (dionice). Naime, prema Zakonu o tržištu kapitala (2018), investicijska društva su dužna svoje klijente razvrstati s obzirom na njihovo znanje, iskustvo, financijsku situaciju i ulagačke ciljeve na male i profesionalne ulagatelje (investitore). Profesionalni ulagatelj je klijent koji posjeduje dovoljno iskustva, znanja i stručnosti za samostalno donošenje odluka o ulaganjima i pravilnu procjenu povezanih rizika. U profesionalne ulagatelje ubrajaju se 1) subjekti koji za djelovanje na financijskom tržištu trebaju imati odobrenje ili podliježu nadzoru nadležnog tijela (investicijska društva, kreditne institucije, društvo za osiguranje, subjekt za zajednička ulaganja, mirovinski fondovi i društva za upravljanje mirovinskim fondovima, trgovac robnim izvedenicama i slično); 2) velika poduzeća koja zadovoljavaju najmanje dva uvjeta, odnosno iznos aktive od najmanje 150 milijuna kuna, neto prihod najmanje 300 milijuna kuna, kapital od najmanje 15 milijuna kuna; 3) nacionalna ili regionalna vlada, središnja banka i slične međunarodne institucije i 4) drugi institucionalni ulagatelji, čija je glavna aktivnost ulaganje u financijske instrumente, uključujući i subjekte koji se bave sekuritizacijom imovine ili drugim transakcijama financiranja. Nasuprot tome, mali ulagatelj je klijent investicijskog društva, koji u skladu s odredbama ovoga Zakona ne ispunjava kriterije za profesionalnog ulagatelja. Kvalificirani nalogodavatelj, prema ovom Zakonu, je osoba (investicijsko društvo, kreditna institucija, društvo za osiguranje, UCITS fond i društvo za upravljanje UCITS fondom, društvo za upravljanje mirovinskim fondovima i mirovinski fond, nacionalna vlada i javno tijelo za upravljanje javnim dugom i središnja banka, nadnacionalna organizacija i druge financijske institucije koje podliježu ishođenju odobrenja za rad po posebnim

propisima) za čiji račun ili s kojom investicijsko društvo izvršava naloge i/ili zaprima i prenosi naloge i/ili trguje za vlastiti račun i/ili joj pruža pomoćne usluge izravno povezane s tim transakcijama. Kvalificirani nalogodavatelj može od investicijskog društva zatražiti status profesionalnog ili malog ulagatelja, u skladu s Delegiranom uredbom (EU) br. 2017/565. Naime, mali ulagatelji imaju pravo na viši stupanj zaštite, koji dobivaju od investicijskog društva, koje je prilikom pružanja usluga dužno procijeniti jesu li usluga i financijski instrumenti primjereni za klijenta, a posebno jesu li u skladu sa spremnošću klijenta na preuzimanje rizika i njegovom sposobnošću za podnošenje gubitaka. Procjenu prikladnosti investicijsko društvo izrađuje na temelju podataka o znanju i iskustvu klijenta u području investicija, relevantnom za uslugu ili proizvod koji se nudi ili traži. Upravo zbog manjka znanja, stručnosti ili iskustva, ponašanje malih ulagatelja je pod većim rizikom značajnijeg odstupanja od racionalnog i može biti pod utjecajem potencijalnih manipulacija profesionalnih i kvalificiranih investitora te su i istraživanja usmjerena upravo na male ulagatelje, kako bi im se i s te strane pružila saznanja o ponašanju koja će im pomoći u postizanju većeg stupnja zaštite.

Anketni upitnik kreiran je putem Google obrasca (*Google Forms*) i podijeljen je na četiri temeljna dijela. Prvi dio pitanja odnosio se na demografske karakteristike ispitanika. U drugom dijelu ispitanici su trebali na ljestvici od 1 do 5 procijeniti razinu slaganja s određenim tvrdnjama vezanim za svoje obrasce ponašanja na financijskom tržištu. Unutar ovih obrazaca ponašanja promatrani su bihevioralni faktori, i to: heuristike (18 pitanja prema Waweru, Munyoki i Uliana (2008), Lin (2011b), Phuoc Luong i Thi Thu Ha (2011), Shah, Ahmad i Mahmood (2018) i Rekha (2020)), elementi prospektne teorije (13 pitanja prema Waweru, Munyoki i Uliana (2008), Phuoc Luong i Thi Thu Ha (2011) i Rekha (2020)), ponašanje krda (6 pitanja prema Lin (2011b), Phuoc Luong i Thi Thu Ha (2011) i Rekha (2020)), kao i razmatranje tržišnih faktora (7 pitanja prema Phuoc Luong i Thi Thu Ha (2011) i Rekha (2020)). Treći dio ankete sadržavao je 13 pitanja povezanih s emocijama i raspoloženjem investitora, kreiranih prema Charles i Kasilingam (2016), te 23 pitanja o karakteristikama osobnosti (John i Srivastava, 1999), od kojih se 9 odnosi na prilagodljivost, a 14 na stabilnost. Posljednji, četvrti dio ankete odnosio se na odluku o ulaganju (6 pitanja formiranih prema Rekha (2020)) te zadovoljstvo investicijskim performansama (4 pitanja prema Phuoc Luong i Thi Thu Ha (2011) i Trang i Tho (2017)). Kao i u drugom dijelu ankete, u trećem i četvrtom dijelu ankete također su pitanja formirana kao određene tvrdnje, gdje su ispitanici trebali odrediti svoju

razinu slaganja na ljestvici od 1 do 5, gdje je vrijednost 1 označavala potpuno neslaganje, a vrijednost 5 potpuno slaganje s tvrdnjom.

Distribucija ankete provedena je elektronskim putem (*online*), i to prvenstveno putem investicijskih društava, koja su proslijedila poveznicu na anketni upitnik svojim investitorima. Investicijska društva koja su sudjelovala u distribuciji anketnih upitnika su Interkapital vrijednosni papiri d.o.o. i Fima-vrijednosnice d.o.o., koji zajedno obuhvaćaju najveći udio (gotovo 40%) u prometu dionicama na Zagrebačkoj burzi (Zagrebačka burza, 2021). Osim toga, posredstvom Predsjednice Upravnog odbora Udruge dioničara AD Plastik d.d., anketa je distribuirana i dioničarima navedenog poduzeća. Konačno, anketni upitnik podijeljen je i na Forumu o trgovanju vezanim za dionice, obveznice i druge vrijednosne papire, Dionice.NET na njihovoj web stranici, putem administratora. Istraživanje je provedeno od 31. svibnja do 7. srpnja 2021. godine. Ukupno je prikupljeno 310 ispunjenih anketnih upitnika, od kojih su svi važeći, što čini 86.11% predviđene potrebne veličine uzorka i smatra se zadovoljavajućom veličinom uzorka za provedbu strukturalnog modeliranja.

5.2 Opis uzorka

Deskriptivnom statistikom mogu se utvrditi osnovne karakteristike uzorka istraživanja. Uzorak čini 310 ispitanika, od kojih je 220 muškog (70.97%) i 90 ženskog spola (29.03%). Ovakva struktura pomalo je i očekivana, s obzirom da su prema istrživanjima (Barber i Odean, 2001; Galbraith, 2009) muškarci odvažniji u prihvaćanju rizičnijih poslova, a isto tako još uvijek zarađuju više od žena te višak novca lakše usmjeravaju u investicije. Galbraith (2009) također navodi kako je ulaganje u dionice „najuzbudljivija kapitalistička igra muškaraca“.

Tablica 5.1. Ispitanici prema spolu

Spol	N	%
Muško	220	70.97
Žensko	90	29.03
Ukupno	**310**	**100.00**

Izvor: izračun autorice

Većina ispitanika stara je od 36 do 45 godina (32.26%), a ukupno je preko polovine ispitanika (56.13%) staro 45 godina ili manje. Najmanji je broj najmlađih (do 25 godina) i najstarijih

ispitanika (66 i više godina). Osim toga, više od polovine ispitanika (59.35%) nalazi se u rasponu od 36 do 55 godina.

Tablica 5.2. Ispitanici prema dobi

Dob	N	%	Kumulativ (%)
18-25	7	2.26	2.26
26-35	67	21.61	23.87
36-45	100	32.26	56.13
46-55	84	27.10	83.23
56-65	46	14.84	98.06
66 i više	6	1.94	100.00
Ukupno	**310**	**100.00**	

Izvor: izračun autorice

Razmatrajući navedene karakteristike ispitanika kombinirano, postoje razlike. Naime, najčešća starost ispitanika od 36 do 45 godina, kakva prevladava u cjelokupnom uzorku, odgovara i dijelu ispitanika muškog spola. Međutim, kod ženskih ispitanika najviše je onih u rasponu od 46 do 55 godina. Niti jedna žena ne pripada skupini ispitanika do 25 godina, a samo jedna pripada skupini najstarijih. S druge strane, kod muškaraca je neznatno veći udio najmlađih u odnosu na najstarije ispitanike. Bitna je razlika i u ostalim skupinama. Naime, od svih muškaraca znatno je više onih koji imaju 45 godina ili manje (62.27%), dok je kod žena obrnuta situacija i prevladavaju ispitanice starosti od 46 godina i više (58.89%). Stoga se može zaključiti kako se mlađi muškarci češće odlučuju na investiranje i teže dodatnoj zaradi, dok se žene na takve poteze odlučuju kasnije.

Tablica 5.3. Ispitanici prema spolu i dobi

			Dob						Ukupno
			18-25	26-35	36-45	46-55	56-65	66 i više	
Spol	Muško	N	7	54	76	55	23	5	220
		%	3.18%	24.55%	34.55%	25.00%	10.45%	2.27%	100.00%
	Žensko	N	0	13	24	29	23	1	90
		%	0.00%	14.44%	26.67%	32.22%	25.56%	1.11%	100.00%
Ukupno		N	7	67	100	84	46	6	310
		%	2.26%	21.61%	32.26%	27.10%	14.84%	1.94%	100.00%

Izvor: izračun autorice

Velika većina ispitanika je u braku (63.87%), dok sa znatno manjim udjelom slijede slobodni ispitanici, zatim oni koji su u vezi, a potom razvedeni. Zaručenih je samo 1.94%, dok se jednak udio ispitanika nije želio izjasniti o bračnom statusu.

Tablica 5.4. Ispitanici prema bračnom statusu

Bračni status	N	%
Slobodan	51	16.45
U vezi	32	10.32
Zaručen	6	1.94
U braku	198	63.87
Razveden	17	5.48
Ne želim odgovoriti	6	1.94
Ukupno	**310**	**100.00**

Izvor: izračun autorice

Što se tiče radnog iskustva, najveći udio ispitanika ima radno iskustvo preko 20 godina (39.35%). Ostatak ispitanika (60.65%) ima radno iskustvo 20 godina ili manje. Od njih, najviše je onih koji rade od 11 do 15 godina, dok najmanji udio čine ispitanici s radnim iskustvom manjim od 5 godina (7.42%). Ipak, malo više od polovine ispitanika (56.45%) ima radno iskustvo od 16 i više godina pa se može zaključiti kako su ispitanici poprilično iskusni što se tiče rada.

Tablica 5.5. Ispitanici prema radnom iskustvu

Radno iskustvo	N	%	Kumulativ (%)
Manje od 5 godina	23	7.42	7.42
5-10 godina	51	16.45	23.87
11-15 godina	61	19.68	43.55
16-20 godina	53	17.10	60.65
Više od 20 godina	122	39.35	100.00
Ukupno	**310**	**100.00**	

Izvor: izračun autorice

Nadalje, što se tiče iskustva ispitanika na financijskom tržištu, najveći udio trguje više od 10 godina (36.13%), što čini udio najiskusnijih investitora. Ostali ispitanici (63.87%) čine izrazito velik dio uzorka, a predstavljaju investitore koji se bave trgovanjem na financijskom tržištu 10 godina ili manje. Ovakvi investitori smatraju se manje iskusnima. Osim toga, unutar neiskusnijih investitora, čak malo više od četvrtine ispitanika (28.06%) zasad se bavi trgovanjem samo 3 godine ili manje. Temeljem ovakve strukture, može se zaključiti da su ispitanici poprilično neiskusni što se tiče

trgovanja na financijskom tržištu, što zasigurno može poticati izražajnije bihevioralne sklonosti i/ili nesigurnije odluke kod njih.

Tablica 5.6. Ispitanici prema iskustvu trgovanja na financijskom tržištu

Koliko dugo se bavite trgovanjem na financijskom tržištu?	N	%	Kumulativ (%)
Manje od 1 godine	39	12.58	12.58
1-3 godine	48	15.48	28.06
4-6 godina	52	16.77	44.84
7-10 godina	59	19.03	63.87
Više od 10 godina	112	36.13	100.00
Ukupno	**310**	**100.00**	

Izvor: izračun autorice

Aktivnost na financijskim tržištima ipak nije ista kod oba spola. Naime, dok kod muškaraca prevladavaju najiskusniji trgovci dionicama (39.55%), kod žena je najviše onih koje trguju od 7 do 10 godina (33.33%). Značajnija razlika javlja se kod najneiskusnijih, gdje se pokazalo da je više žena koje trguju kraće od jedne godine, njih 18.89%, dok je takvih muškaraca 10%. Također, ako se iznimno iskusnima smatraju investitori koji trguju dulje od 10 godina, opet je više žena s manje iskustva trgovanja (kraće od 10 godina). Takvih žena u uzorku je 72.22%, a muškaraca 60.45%.

Tablica 5.7. Ispitanici prema spolu i iskustvu trgovanja na financijskom tržištu

			Koliko dugo se bavite trgovanjem na financijskom tržištu?					Ukupno
			Manje od 1 godine	1-3 godine	4-6 godina	7-10 godina	Više od 10 godina	
Spol	Muško	N	22	42	40	29	87	220
		%	10.00%	19.09%	18.18%	13.18%	39.55%	100.00%
	Žensko	N	17	6	12	30	25	90
		%	18.89%	6.67%	13.33%	33.33%	27.78%	100.00%
Ukupno		N	39	48	52	59	112	310
		%	12.58%	15.48%	16.77%	19.03%	36.13%	100.00%

Izvor: izračun autorice

Razmatrajući radno iskustvo i iskustvo trgovanja, može se zaključiti da s porastom radnog iskustva raste i iskustvo trgovanja na financijskom tržištu. Naime, gotovo polovina ispitanika s radnim iskustvom manjim od 5 godina trguje na financijskom tržištu manje od 1 godine (47.83%), dok samo jedan takav ispitanik, unatoč kratkom radnom iskustvu, trguje na financijskom tržištu već više od 10 godina. Od ispitanika s radnim iskustvom od 5 do 10 godina prevladavaju oni koji trguju

od 4 do 6 godina (31.37%). S porastom radnog iskustva iznad 10 godina, povećava se i broj ispitanika koji trguju dulje od 10 godina. Ipak, ispitanici s radnim iskustvom od 11 do 15 godina najčešće trguju od 1 do 6 godina, a neznatno manje njih bavi se trgovanjem na financijskom tržištu 7 godina i više. Kako se dalje povećava radno iskustvo, razlike među grupama se opet povećavaju, no u drugom smjeru. Od ispitanika s radnim iskustvom od 16 do 20 godina, gotovo polovina trguje na financijskom tržištu više od 10 godina (49.06%), dok je neznatan broj onih koji trguju do 3 godine. Udio najiskusnijih investitora dodatno raste kod ispitanika s radnim iskustvom više od 20 godina i iznosi 57.38%. Zaključno, može se reći da se ove dvije varijable prate, pa kada raste radno iskustvo, raste i iskustvo trgovanja na financijskom tržištu. Ovo je logičan zaključak, jer se većina ljudi odlučuje na investiranje tek nakon zaposlenja, kada imaju stalne prihode. Ipak, postoje i iznimke, poput jednog ispitanika s manjim radnim iskustvom od iskustva trgovanja na financijskom tržištu. Isto tako, kod ispitanika s najvećim radnim iskustvom (preko 20 godina) ipak postoji dio njih (11.48%) koji se bave trgovanjem na financijskom tržištu tek 3 godine ili manje. Dakle, ipak postoji određen dio ispitanika koji su se tek nakon značajnijeg radnog iskustva odlučili iskušati u ulozi investitora.

Tablica 5.8. Ispitanici prema radnom iskustvu i iskustvu trgovanja na financijskom tržištu

			Koliko dugo se bavite trgovanjem na financijskom tržištu?					Ukupno
			Manje od 1 godine	1-3 godine	4-6 godina	7-10 godina	Više od 10 godina	
Radno iskustvo	Manje od 5 godina	N	11	8	3	0	1	23
		%	47.83%	34.78%	13.04%	0.00%	4.35%	100.00%
	5-10 godina	N	10	15	16	7	3	51
		%	19.61%	29.41%	31.37%	13.73%	5.88%	100.00%
	11-15 godina	N	6	15	15	13	12	61
		%	9.84%	24.59%	24.59%	21.31%	19.67%	100.00%
	16-20 godina	N	4	4	5	14	26	53
		%	7.55%	7.55%	9.43%	26.42%	49.06%	100.00%
	Više od 20 godina	N	8	6	13	25	70	122
		%	6.56%	4.92%	10.66%	20.49%	57.38%	100.00%
Ukupno		N	39	48	52	59	112	310
		%	12.58%	15.48%	16.77%	19.03%	36.13%	100.00%

Izvor: izračun autorice

Mjesečna primanja ispitanika najčešće su u rasponu od 5001 i 10000 kn, tj. u 41.29% slučajeva. Također, 79.68% ispitanika ima razinu mjesečnih primanja od 15000 kn ili manje, a neznatan udio

ispitanika pripada skupini „najbogatijih“ s primanjima preko 20000 (8.71%). Unatoč tome, najmanji je udio ipak onih investitora s mjesečnim primanjima do 5000 kn (6.77%), što je očekivano. Naime, takvi ispitanici moraju prvenstveno podmiriti osnovne životne troškove i rjeđe imaju višak novca, koji će radije potrošiti na kupnje koje si možda ne mogu inače priuštiti ili na štednje, nego na ulaganje u rizične aktivnosti na financijskom tržištu.

Tablica 5.9. Ispitanici prema mjesečnim primanjima

Mjesečna primanja	N	%	Kumulativ (%)
Do 5000 kn	21	6.77	6.77
5001-10000 kn	128	41.29	48.06
10001-15000 kn	98	31.61	79.68
15001-20000 kn	36	11.61	91.29
20001 kn i više	27	8.71	100.00
Ukupno	**310**	**100.00**	

Izvor: izračun autorice

Među spolovima očekivano postoji razlika u mjesečnim primanjima. Dok je kod oba spola najzastupljeniji iznos mjesečnih primanja od 5001 do 10000 kn, razlike se pojavljuju kod najnižih i najviših iznosa mjesečnih primanja. Naime, iako muškarci prevladavaju u uzorku, udio muškaraca s mjesečnim primanjima do 5000 kn je 8.18%, odnosno radi se o samo 18 od 220 muških ispitanika. Od svih promatranih muškaraca, jednak broj njih mjesečno zarađuje od 15001 do 20000 kn i preko 20000 kn, točnije njih 24, odnosno 10.91%. Kumulativno, udio muškaraca s primanjima iznad 15000 kn je 21.82%. Za žene taj kumulativni postotak iznosi 16.67%, od čega samo 3.33% otpada na žene koje zarađuju više od 20000 kn, što potvrđuje razliku u primanjima u korist muškaraca. Ipak, isti udio (3.33%) odnosi se i na žene koje zarađuju do 5000 kn.

Tablica 5.10. Ispitanici prema spolu i mjesečnim primanjima

			Mjesečna primanja					Ukupno
			Do 5000 kn	5001-10000 kn	10001-15000 kn	15001-20000 kn	20001 kn i više	
Spol	Muško	N	18	88	66	24	24	220
		%	8.18%	40.00%	30.00%	10.91%	10.91%	100.00%
	Žensko	N	3	40	32	12	3	90
		%	3.33%	44.44%	35.56%	13.33%	3.33%	100.00%
Ukupno		N	21	128	98	36	27	310
		%	6.77%	41.29%	31.61%	11.61%	8.71%	100.00%

Izvor: izračun autorice

Ispitanici u uzorku visoko su obrazovani. Niti jedan ispitanik nema samo osnovno obrazovanje. Najčešća je visoka stručna sprema (VSS), koju posjeduje preko polovine ispitanika (53.87%). Osim toga, samo 14.84% nema nikakvu fakultetsku naobrazbu, već srednjoškolsko obrazovanje. Najmanji je udio doktora znanosti (2.26%).

Tablica 5.11. Ispitanici prema razini obrazovanja

Razina obrazovanja	N	%	Kumulativ (%)
Srednjoškolsko obrazovanje	46	14.84	14.84
VŠS, završen preddiplomski sveučilišni ili stručni studij	50	16.13	30.97
VSS (završen diplomski sveučilišni ili stručni studij; mag. ili dipl.)	167	53.87	84.84
Mr. sc. ili univ. spec. (završen magistarski studij ili poslijediplomski specijalistički studij)	40	12.90	97.74
Dr. sc. (završen doktorski studij)	7	2.26	100.00
Ukupno	**310**	**100.00**	

Izvor: izračun autorice

Kada se promatra razina obrazovanja kroz različite skupine ispitanika s obzirom na iskustvo trgovanja na financijskom tržištu, može se vidjeti da u svakoj skupini uvjerljivo prevladava udio ispitanika s VSS. Međutim, značajna je razlika u udjelima najviše i najmanje obrazovanih. Naime, kod ispitanika koji trguju više od 10 godina, udio magistara i doktora znanosti je čak 25%, dok je takvih samo 10.26% u skupini ispitanika koji trguju manje od 1 godine. S druge strane, udio ispitanika sa srednjoškolskim obrazovanjem najveći je u skupini onih koji trguju manje od 1 godine (25.64%), dok samo 9.82% ispitanika koji trguju više od 10 godina ima srednjoškolsko obrazovanje. Dakle, može se zaključiti da za najnižu i najvišu razinu obrazovanja u uzorku postoje razlike u iskustvu trgovanja na financijskom tržištu, dok ipak, kao u kompletnom uzorku, prevladavaju ispitanici s VSS u svim skupinama.

Tablica 5.12. Ispitanici prema iskustvu trgovanja na financijskom tržištu i razini obrazovanja

	Razina obrazovanja	Ukupno

			Srednjoškolsko obrazovanje	VŠS, završen preddiplomski sveučilišni ili stručni studij	VSS (završen diplomski sveučilišni ili stručni studij; mag. ili dipl.)	Mr. sc. ili univ. spec. (završen magistarski studij ili poslijediplomski specijalistički studij)	Dr. sc. (završen doktorski studij)	
Koliko dugo se bavite trgovanjem na financijskom tržištu?	Manje od 1 godine	N	10	8	17	4	0	39
		%	25.64%	20.51%	43.59%	10.26%	0.00%	100.00%
	1-3 godine	N	7	12	23	5	1	48
		%	14.58%	25.00%	47.92%	10.42%	2.08%	100.00%
	4-6 godina	N	9	9	27	6	1	52
		%	17.31%	17.31%	51.92%	11.54%	1.92%	100.00%
	7-10 godina	N	9	10	38	1	1	59
		%	15.25%	16.95%	64.41%	1.69%	1.69%	100.00%
	Više od 10 godina	N	11	11	62	24	4	112
		%	9.82%	9.82%	55.36%	21.43%	3.57%	100.00%
Ukupno		N	46	50	167	40	7	310
		%	14.84%	16.13%	53.87%	12.90%	2.26%	100.00%

Izvor: izračun autorice

Ispitanici su podjednako raspoređeni prema tome jesu li ikada u sklopu formalnog i/ili neformalnog obrazovanja pohađali edukacije o trgovanju na burzi. Njih 44.52% pohađalo je edukacije, dok ostalih 55.48% nije pohađalo nikakve edukacije o trgovanju na burzi.

Tablica 5.13. Ispitanici prema pohađanju edukacije o trgovanju na burzi

Jeste li pohađali ikakvu edukaciju o trgovanju na burzi (u sklopu formalnog i/ili neformalnog obrazovanja)	N	%
Da	138	44.52
Ne	172	55.48
Ukupno	**310**	**100.00**

Izvor: izračun autorice

Promatrajući pohađanje edukacije o trgovanju na burzi za svaki spol pojedinačno, može se zaključiti da je kod muškaraca niži udio onih koji su pohađali edukacije (40.45%), dok je kod žena taj udio veći (54.44%). Dakle, može se zaključiti da je kod ženskog dijela ispitanika većina pohađala edukacije o trgovanju na burzi, što nije slučaj kod muškaraca. Usprkos tome, prethodno je ustanovljeno da više muškaraca trguje na financijskom tržištu dulje od 10 godina (Tablica 5.7.).

Tablica 5.14. Ispitanici prema spolu i pohađanju edukacije o trgovanju na burzi

			Jeste li pohađali ikakvu edukaciju o trgovanju na burzi (u sklopu formalnog i/ili neformalnog obrazovanja)		Ukupno
			Da	Ne	
Spol	Muško	N	89	131	220
		%	40.45%	59.55%	100.00%
	Žensko	N	49	41	90
		%	54.44%	45.56%	100.00%
Ukupno		N	138	172	310
		%	44.52%	55.48%	100.00%

Izvor: izračun autorice

Iako su generalno u cijelom uzorku udjeli ispitanika koji su pohađali edukacije o trgovanju na burzi i onih koji ih nisu pohađali relativno ravnomjerno raspoređeni, postoje neke značajnije razlike kada se gleda s obzirom na iskustvo trgovanja na financijskom tržištu. Naime, kod ispitanika koji se bave ulaganjem na tržištu manje od 1 godine, njih čak 74.36% nije pohađalo edukacije. Kod ispitanika koji se bave trgovanjem od 1 do 3 godine, ti udjeli se međusobno približavaju (41.67% pohađalo, a 58.33% nije pohađalo edukaciju). U skupinama ispitanika koji trguju od 4 do 6 godina te od 7 do 10 godina udjeli su otprilike jednaki, s tim da je ipak malo više onih koji su pohađali edukacije o trgovanju na burzi. Međutim, taj udio je opet obrnut kod najiskusnijih investitora, koji trguju više od 10 godina, a kod kojih je ipak veći udio onih koji nisu pohađali edukacije (55.36%). Stoga, za sve skupine ispitanika različitog iskustva trgovanja na financijskom tržištu, jedino kod najmanje iskusnih postoji značajnija razlika u tome jesu li ispitanici pohađali edukacije ili nisu.

Tablica 5.15. Ispitanici prema iskustvu trgovanja na financijskom tržištu i pohađanju edukacije o trgovanju na burzi

			Jeste li pohađali ikakvu edukaciju o trgovanju na burzi (u sklopu formalnog i/ili neformalnog obrazovanja)		Ukupno
			Da	Ne	
Koliko dugo se bavite trgovanjem na financijskom tržištu?	Manje od 1 godine	N	10	29	39
		%	25.64%	74.36%	100.00%
	1-3 godine	N	20	28	48
		%	41.67%	58.33%	100.00%
	4-6 godina	N	27	25	52
		%	51.92%	48.08%	100.00%
	7-10 godina	N	31	28	59
		%	52.54%	47.46%	100.00%
		N	50	62	112

	Više od 10 godina	**%**	44.64%	55.36%	100.00%
Ukupno		**N**	138	172	310
		%	44.52%	55.48%	100.00%

Izvor: izračun autorice

U nastavku je dan prikaz deskriptivne statistike za svaki bihevioralni faktor, kao i za investicijske odluke i performanse, kao dva glavna zavisna faktora istraživačkog modela. Promatrane varijable, čije se karakteristike ispituju, odnose se na anketna pitanja kojima se odražava svaki pojedini faktor. Za svaki faktor stoga je prikazana oznaka, koja će u strukturalnom modeliranju biti korištena radi jednostavnosti, pripadajuće pitanje te njegova aritmetička sredina, medijan, mod i standardna devijacija. Kako je već napomenuto, ova su pitanja iskazana kao tvrdnje, čiji se odgovori nalaze na skali od 1 do 5, gdje 1 predstavlja potpuno neslaganje, a 5 potpuno slaganje s danom tvrdnjom.

Može se zaključiti da su ispitanici umjereno skloni pojedinim heuristikama pri donošenju svojih odluka. Što se tiče reprezentativnosti, ispitanici su češće skloni analizi trenda reprezentativnih dionica i češće su oprezni pri ulaganju u poduzeća koja su nedavno ostvarila gubitke. Osim toga, najveći broj ispitanika u potpunosti se slaže s tvrdnjom da će radije kupovati domaće dionice zbog veće dostupnosti informacija. Također, poprilično često ispitanici imaju tendenciju oslanjati se na svoja prethodna iskustva pri donošenju investicijskih odluka, što odražava njihov veći stupanj samouvjerenosti. Suprotno tome, najveći broj ispitanika u potpunosti se ne slaže s tvrdnjom o sigurnosti da njihova odluka nikada ne može pogriješiti. Dakle, iako se ispitanici češće oslanjaju na svoja iskustva i znanje, pokazujući time da su dovoljno samouvjereni na tržištu, ipak ne smatraju da nikada ne mogu pogriješiti u odluci.

Tablica 5.16. Deskriptivna statistika faktora heuristika

Oznaka	Pitanje	Aritmetička sredina	Medijan	Mod	Standardna devijacija
H1	Kupujem popularne dionice i izbjegavam dionice koje su nedavno imale loše performanse.	3.23	3.00	3	1.192
H2	Koristim analizu trenda reprezentativnih dionica u svrhu donošenja investicijskih odluka.	3.29	3.00	4	1.106
H3	Smatram da mi moje vještine i znanje o tržištu dionica mogu pomoći da nadigram tržište.	2.95	3.00	3	1.124
H4	Oslanjam se na svoja prethodna iskustva na tržištu za donošenje odluka o budućim investicijama.	3.74	4.00	4	1.009

H5	Siguran sam da mogu donijeti ispravnu investicijsku odluku.	3.18	3.00	3	0.979
H6	Smatram da su tržišni trendovi često u skladu s mojim očekivanjima.	2.98	3.00	3	0.859
H7	Smatram da je povrat od ulaganja u dionicu uvijek ostvaren zbog moje uspješne investicijske strategije.	2.85	3.00	3	0.933
H8	Prognoziram promjene u cijenama dionica temeljem najnovijih kretanja cijena dionica.	2.87	3.00	3	1.003
H9	Obično mogu predvidjeti kada će završiti razdoblja dobrih ili loših povrata na tržištu.	2.71	3.00	2	1.033
H10	Radije kupujem domaće dionice nego međunarodne, jer su mi dostupnije informacije o njima.	3.27	4.00	5	1.481
H11	Pretpostavljam da će dionice s dobrom prethodnom zaradom i u budućnosti donijeti veće prinose.	3.14	3.00	4	1.049
H12	Uvijek sam siguran da moja odluka o ulaganju nikada ne može pogriješiti.	1.99	2.00	1	0.959
H13	Tijekom ulaganja vjerujem u svoje prosudbe više nego u bilo koji tržišni pokazatelj.	2.64	2.50	2	0.985
H14	Moja ulaganja neovisna su o onome u što vjeruju tržišni stručnjaci.	2.81	3.00	2	1.031
H15	Ne slijedim investicijske smjernice savjetnika ako su one suprotne onome u što vjerujem.	2.98	3.00	2	1.128
H16	Nastavljam ulagati u dionice čije cijene padaju, jer bi se njihova vrijednost mogla povećati nakon određene točke.	2.65	3.00	3	1.085
H17	Neću ulagati u dionice s neprekidno rastućim cijenama, jer će uskoro pasti.	3.14	3.00	3	1.143
H18	Oprezan sam dok ulažem u dionice tvrtki koje su u posljednje vrijeme ostvarile gubitke.	3.88	4.00	4	1.082

Izvor: izračun autorice (n=310)

U tablici 5.17. vidljivo je da su za sva pitanja vezana za elemente prospektne teorije ispitanici u prosjeku neutralni pa se može zaključiti da njihovo ponašanje nije pod velikim utjecajem ovih elemenata. U većem broju ispitanici preferiraju dugoročnu sigurnost svojih sredstava u odnosu na kratkoročne novčane dobitke, što ukazuje na to da nisu skloni gubitku. Međutim, ipak se poprilično slažu s tvrdnjom da je moguće ostvariti veću dobit uz preuzimanje većih rizika, a ujedno se uglavnom ne slažu s tvrdnjom da ne vole volatilne dionice, što može ukazivati na ponešto češću sklonost riziku među ispitanicima.

Tablica 5.17. Deskriptivna statistika faktora prospektne teorije

Oznaka	Pitanje	Aritmetička sredina	Medijan	Mod	Standardna devijacija
PT1	Nakon prethodnog dobitka, više sam sklon riziku nego obično.	3.24	3.00	4	1.109
PT2	Nakon prethodnog gubitka postajem manje sklon riziku.	3.43	4.00	4	1.160
PT3	Izbjegavam prodaju dionica kojima je pala vrijednost.	3.20	3.00	4	1.140
PT4	Brzo prodajem dionice kojima je porasla vrijednost.	2.58	3.00	2	0.991
PT5	Osjećam više tuge zbog predugog držanja dionica koje nose gubitak, nego zbog prerane prodaje dionica koje nose dobit.	3.01	3.00	3	1.155
PT6	Tretiram svaki element svog investicijskog portfelja odvojeno.	3.16	3.00	3 i 4	1.081
PT7	Preferiram dugoročnu sigurnost svojih sredstava nego kratkoročne novčane dobitke.	3.62	4.00	4	1.069
PT8	Od početka ulažem u sigurnije dionice.	3.38	3.00	4	1.026
PT9	Ne volim volatilne dionice jer ulažem ogromna novčana ulaganja.	2.57	2.00	2	1.094
PT10	Vjerujem da se na tržištu dionica može ostvariti veća dobit ako se preuzmu veći rizici.	3.61	4.00	4	1.020
PT11	Preferiram manja ulaganja kako bih imao koristi od kratkoročnog uspona na tržištu.	2.83	3.00	3	1.029
PT12	Uložit ću u volatilnu dionicu ako može donijeti bolji povrat.	3.30	3.00	4	1.079
PT13	Ulažem u vrijednosne papire s niskim prinosom jer želim uštedjeti za mirovinu.	2.60	3.00	3	1.121

Izvor: izračun autorice (n=310)

Prema vrijednostima iz tablice 5.18., može se primijetiti kako ispitanici nisu previše skloni ponašanju krda. Naime, većinom se srednje vrijednosti varijabli kreću oko 3, što označava neutralan stav prema tvrdnjama koje odražavaju ponašanje krda. Ispitanici se češće ne slažu da bi investirali prema sugestijama svojih prijatelja, a češće sami prate tržišne informacije i povode se za njima u odlučivanju.

Tablica 5.18. Deskriptivna statistika faktora ponašanja krda

Oznaka	Pitanje	Aritmetička sredina	Medijan	Mod	Standardna devijacija
K1	Obično brzo reagiram na promjene drugih investitora i pratim njihove reakcije na tržištu.	2.86	3.00	3	1.080
K2	Uložio bih u dionice prema sugestijama svojih prijatelja.	2.45	2.00	2	0.996

K3	Pratim tržišne informacije u svrhu trgovanja.	3.86	4.00	4	1.011
K4	Slijedim postojeći tržišni trend dok donosim odluku o ulaganju.	3.39	3.00	4	0.938
K5	Slijedim ono što moj savjetnik sugerira tijekom ulaganja.	2.81	3.00	3	1.115
K6	Slijedim savjete ostalih investitora dok kupujem dionice jer nemam odgovarajuće znanje.	2.64	3.00	3	1.049

Izvor: izračun autorice (n=310)

Kao i za ostale faktore, investitori su poprilično neutralni što se tiče emocija i raspoloženja. Češće se pozitivne emocije manifestiraju u sretnom raspoloženju i kod investitora s pozitivnim pogledom na život. Također, ispitanici često ostaju pozitivni i u situacijama kada se tržište kreće protiv njih, vjerujući i ne odustajući od investicije. Isto tako, pri kupnji dionica koje postanu profitabilne, obnavljaju vjeru i nadu u svoje buduće investicije. Najčešće nisu pogođeni negativnim emocijama, koje bi ih pri dužem periodu gubitaka odbile od ponovne kupnje dionica. Stoga, može se zaključiti da kod ispitanika u uzorku ipak prevladavaju pozitivnije emocije pri investiranju.

Tablica 5.19. Deskriptivna statistika faktora emocija i raspoloženja

Oznaka	Pitanje	Aritmetička sredina	Medijan	Mod	Standardna devijacija
ER1	Kad se osjećam sretno, to utječe na moju tržišnu aktivnost.	3.07	3.00	4	1.241
ER2	Kad se osjećam ljuto, ne sudjelujem u tržišnim aktivnostima.	2.92	3.00	3	1.186
ER3	Kad se osjećam umorno, to utječe na moju tržišnu aktivnost.	3.17	3.00	4	1.224
ER4	Kad se osjećam tužno, ne sudjelujem u tržišnim aktivnostima.	2.94	3.00	3	1.150
ER5	Moj pozitivan pogled na život potiče me da ulažem u dionice.	3.47	4.00	4	1.122
ER6	Radujem se svojoj sljedećoj prilici za ulaganje nakon dubokog pada na tržištu.	3.41	3.00	3	1.131
ER7	Ne znam što dalje učiniti nakon što iskoristim sve svoje ideje.	2.49	2.00	2	1.088
ER8	Ako se tržište kreće protiv mene, kažem sebi da sam dugoročni investitor i da će sve moje ideje na kraju uspjeti.	3.28	3.00	4	1.086
ER9	Ako se dogodi gubitak u mojoj investiciji, prodat ću sve svoje dionice da izbjegnem daljnje gubitke.	2.24	2.00	2	1.069
ER10	Ako se gubici nastave, ne želim više nikada kupovati dionice.	1.95	2.00	1	1.063
ER11	Ako se gubitak u mojoj investiciji nastavi, zbunjen sam kad donosim odluku o daljnjim ulaganjima.	2.33	2.00	2	1.142

ER12	Ako kupim dionice koje postanu profitabilne, obnavljam vjeru da postoji budućnost u investiranju.	3.38	4.00	4	1.105
ER13	Jako sam oduševljen ulaganjem tijekom faze rasta ili oporavka tržišta.	3.36	3.00	3	1.082

Izvor: izračun autorice (n=310)

Iz tablice 5.20. može se zaključiti da u uzorku prevladavaju ekstrovertirani ispitanici koji su otvoreni novim iskustvima. Većina ispitanika smatra se energičnim i entuzijastičnim, a najviše od svega su samopouzdani, što objašnjava i njihovo uključivanje u rizične aktivnosti, kao što je trgovanje na financijskom tržištu. Nadalje, ispitanici se također često smatraju prilično maštovitima i inventivnima, ukazujući na njihovu spremnost prilagodbi novim situacijama koje mogu nastupiti na financijskom tržištu. Stoga, može se zaključiti da su ispitanici u uzorku većinom prilagodljive osobnosti.

Tablica 5.20. Deskriptivna statistika faktora prilagodljivosti

Oznaka	Pitanje	Aritmetička sredina	Medijan	Mod	Standardna devijacija
PRIL1	Pričljiv sam.	3.32	3.00	3	0.964
PRIL2	Rezerviran sam.	2.64	3.00	3	1.064
PRIL3	Pun sam energije.	3.53	4.00	3	0.930
PRIL4	Stvaram puno entuzijazma.	3.46	4.00	4	0.919
PRIL5	Samopouzdan sam.	3.81	4.00	4	0.909
PRIL6	Ponekad sam sramežljiv i ukočen.	2.51	2.00	2	1.090
PRIL7	Genijalan sam i dubok mislilac.	3.05	3.00	3	1.002
PRIL8	Imam aktivnu maštu.	3.61	4.00	4	0.895
PRIL9	Inventivan sam.	3.48	4.00	4	0.913

Izvor: izračun autorice (n=310)

Nadalje, ispitanici u uzorku su savjesni i smatraju se jako pouzdanima, kako općenito, tako i u radu. Organizirani su, slijede svoje zacrtane planove i nisu lijeni te su učinkoviti u svemu što rade. Ugodni su u društvu, s obzirom da su nesebični i vole surađivati s drugima. Osim toga, ispitanici nisu neurotični, već su emocionalno stabilni, odnosno ne pokazuju stres, pretjeranu brigu i nemir u napetim situacijama. Sve ove karakteristike stabilne osobnosti izrazito prevladavaju u uzorku, što je jako bitno za stabilnost i smirenost u investicijskim odlukama, kod kojih je fokus na stabilnosti dugoročnih ciljeva investitora.

Tablica 5.21. Deskriptivna statistika faktora stabilnosti

Oznaka	Pitanje	Aritmetička sredina	Medijan	Mod	Standardna devijacija
STAB1	Radim temeljit posao.	3.84	4.00	4	0.891
STAB2	Pouzdan sam radnik.	4.18	4.00	4	0.795
STAB3	Imam tendenciju biti neorganiziran.	2.07	2.00	1	1.063
STAB4	Sklon sam lijenosti.	2.22	2.00	2	1.048
STAB5	Ustrajem u zadatku dok nije gotov.	3.97	4.00	4	0.872
STAB6	Općenito radim sve učinkovito.	3.83	4.00	4	0.850
STAB7	Pravim planove i slijedim ih.	3.75	4.00	4	0.893
STAB8	Pomažem i nesebičan sam prema drugima.	3.73	4.00	4	0.937
STAB9	Općenito sam pouzdan.	4.15	4.00	4	0.801
STAB10	Volim surađivati s drugima.	3.65	4.00	4	0.954
STAB11	Opušten sam i dobro podnosim stres.	3.49	3.50	3	1.042
STAB12	Mnogo se brinem.	2.86	3.00	3	1.056
STAB13	Emocionalno sam stabilan, nije me lako uznemiriti.	3.56	4.00	4	0.959
STAB14	Ostajem smiren u napetim situacijama.	3.51	4.00	4	1.010

Izvor: izračun autorice (n=310)

Tržišni faktori su i dalje pokretači pri investicijskim odlukama. Naime, ispitanici najčešće razmatraju tržišne informacije, kao što su trendovi kretanja cijena dionica, podaci o poslovanju poduzeća i dividendama, financijska izvješća poduzeća, te koriste fundamentalnu analizu da bi se odlučili gdje ulagati. Stoga, tržišni faktori i njihova analiza bitan su čimbenik za ispitanike u uzorku, jer mogu oblikovati njihovo ponašanje. Naime, tržišni trendovi često mogu biti sugestivni i pokazivati da su određena ulaganja dobra, što se ne mora pokazati točnim. Ovo može utjecati na ponašanje investitora u smislu olakog povođenja za nekim trendom (poticanje ponašanje krda) ili stavljanje naglaska isključivo na nedavne informacije o dionicama i poduzeću iz posljednjih izvještaja, što može potaknuti sklonost heuristike reprezentativnosti.

Tablica 5.22. Deskriptivna statistika tržišnih faktora

Oznaka	Pitanje	Aritmetička sredina	Medijan	Mod	Standardna devijacija
TF1	Pažljivo razmatram promjene cijena dionica u koje želim uložiti.	3.89	4.00	4	0.872
TF2	Smatram da su tržišne informacije važne za moje ulaganje u dionice.	4.08	4.00	4	0.935
TF3	Razmatram prethodne trendove dionica prilikom svog ulaganja.	3.85	4.00	4	0.900
TF4	Prije donošenja investicijskih odluka, koristim fundamentalnu analizu za procjenu vrijednosti dionica.	3.68	4.00	4	1.171

TF5	Ulažem u poduzeća koja su u prošlosti isplaćivala veće dividende svojim dioničarima.	3.28	3.00	3	1.089
TF6	Pomno pratim financijska izvješća poduzeća prije nego što kupim njihove dionice.	3.69	4.00	4	1.074
TF7	Ulažem samo u poduzeća čije su dionice u prošlosti imale dobre performanse.	3.04	3.00	3	0.983

Izvor: izračun autorice (n=310)

Kako je prethodno spomenuto, investicijske odluke razmatraju se u smislu raspodjele novčanih sredstava i preferencija prema kratkoročnim ili dugoročnim investicijama. Unutar uzorka može se zaključiti da ispitanici snažnije preferiraju dugoročna ulaganja naspram kratkoročnih i pažljivo donose svoje odluke. Dakle, ispitanici su skloniji boljim investicijskim odlukama, jer izbjegavaju samo brze kratkoročne transakcije, gdje mogu zaraditi na razlici kupnje i prodaje, već dulje drže određene dionice u svom portfelju i na taj način dugoročno ostvaruju koristi od stabilnih i/ili rastućih cijena, redovitih dividendi i sl.

Tablica 5.23. Deskriptivna statistika faktora investicijskih odluka

Oznaka	Pitanje	Aritmetička sredina	Medijan	Mod	Standardna devijacija
IO1	Ulažem u investicije koje će donijeti dugoročne koristi.	3.95	4.00	4	0.951
IO2	Zbog neizvjesnosti na tržištu, preferiram kratkoročna ulaganja.	2.41	2.00	2	1.090
IO3	Redovito pregledam, usporedim i potom donesem odluke o svom investicijskom potezu.	3.82	4.00	4	0.887
IO4	Istražujem tržište prije bilo kakvog kratkoročnog ulaganja.	3.79	4.00	4	0.977
IO5	Ulažem više sredstava u dugoročne nego kratkoročne investicije.	3.71	4.00	4	1.052
IO6	Ulažem više sredstava u kratkoročne nego dugoročne investicije.	2.27	2.00	2	1.062

Izvor: izračun autorice (n=310)

Investitori su uglavnom neutralni što se tiče zadovoljstva svojim investicijskim performansama, iako blago naginju većoj razini zadovoljstva. Skloniji su zadovoljstvu stopom prinosa svojih ulaganja te odlukama o kupnji dionica, dok su malo manje zadovoljni odlukama o prodaji dionica gledajući proteklu godinu dana.

Tablica 5.24. Deskriptivna statistika faktora investicijskih performansi

Oznaka	Pitanje	Aritmetička sredina	Medijan	Mod	Standardna devijacija
IP1	Zadovoljan sam stopom prinosa svojih nedavnih ulaganja u dionice.	3.44	3.00	4	0.949
IP2	Smatram da je prinos na dionice u koje ulažem bolji od prinosa većine drugih dionica.	3.09	3.00	3	0.901
IP3	Zadovoljan sam svojim odlukama o kupnji dionica u protekloj godini dana.	3.35	3.00	3	0.999
IP4	Zadovoljan sam svojim odlukama o prodaji dionica u protekloj godini dana.	3.09	3.00	3	1.118

Izvor: izračun autorice (n=310)

5.3 Analiza CB-SEM modela

Prije provedbe strukturalnog modeliranja putem CB-SEM metode, ispitano je postojanje univarijatne i multivarijatne normalnosti, kao i potencijalna netipična opažanja (outlieri) te problem multikolinearnosti kroz programe Amos i IBM SPSS Statistics, verzija 23.

U tablici 5.25. prikazani su rezultati analize univarijatne i multivarijatne normalnosti podataka. Nazivi varijabli prikazani su kraticama, koje su objašnjene u prethodnom poglavlju, a kod varijabli osobnosti, za nekoliko varijabli rekodirana je skala. Univarijatna normalnost ispitana je putem testova kritičnih vrijednosti koeficijenata asimetrije i zaobljenosti za svaku varijablu posebno. Može se primijetiti kako za određene varijable testna veličina premašuje graničnih ± 1.96 za razinu signifikantnosti od 0.05. To je donekle i očekivano, s obzirom da se radi o varijablama koje su iskazane na Likertovoj skali od 1 do 5, naročito kod varijabli gdje su ispitanici snažnije iskazali veću razinu slaganja ili neslaganja s navedenim tvrdnjama. Osim toga, Mardia testom multivarijatne zaobljenosti testirana je pretpostavka multivarijatne normalnosti distribucije podataka. Vidljivo je kako je i ovaj rezultat statistički značajan, odnosno pretpostavka multivarijatne normalnosti nije zadovoljena. Ovi rezultati sugeriraju da bi procjena CB-SEM modela ML metodom mogla dati nepouzdane rezultate značajnosti parametara i prilagodbe modela. Stoga, budući da se ovdje koriste podaci iskazani na redoslijednoj skali, robusne WLS metode koje su posebno razvijene za kategorijalne i ordinalne varijable smatraju se prikladnima za korištenje u ovom istraživanju, naročito jer ni pretpostavka multivarijatne normalnosti nije zadovoljena.

Tablica 5.25. Prikaz analize univarijatne i multivarijatne normalnosti podataka

Var.	Asi-metrija	z	Zaob-ljenost	z	Var.	Asi-metrija	z	Zaob-ljenost	z
H1	-0.311	-2.233	-0.667	-2.397	**ER9**	0.559	4.019	-0.445	-1.598

H2	-0.404	-2.907	-0.424	-1.523	**ER10**	0.880	6.325	-0.244	-0.879
H3	-0.056	-0.399	-0.686	-2.466	**ER11**	0.423	3.040	-0.928	-3.335
H4	-0.571	-4.107	-0.291	-1.047	**ER12**	-0.555	-3.990	-0.297	-1.067
H5	-0.222	-1.596	-0.301	-1.083	**ER13**	-0.378	-2.716	-0.328	-1.178
H6	-0.117	-0.838	-0.292	-1.048	**PRIL1**	-0.101	-0.729	-0.433	-1.556
H7	0.059	0.425	-0.394	-1.416	**PRIL2R**	-0.160	-1.152	-0.704	-2.530
H8	-0.183	-1.317	-0.602	-2.163	**PRIL3**	-0.266	-1.913	-0.097	-0.350
H9	0.083	0.594	-0.754	-2.711	**PRIL4**	-0.396	-2.848	0.092	0.329
H10	-0.268	-1.929	-1.377	-4.949	**PRIL5**	-0.634	-4.557	0.287	1.030
H11	-0.373	-2.683	-0.504	-1.811	**PRIL6R**	-0.169	-1.218	-0.914	-3.285
H12	0.489	3.518	-0.729	-2.621	**PRIL7**	-0.232	-1.669	-0.306	-1.100
H13	0.291	2.093	-0.580	-2.084	**PRIL8**	-0.345	-2.480	-0.142	-0.510
H14	0.251	1.806	-0.529	-1.902	**PRIL9**	-0.470	-3.382	0.046	0.164
H15	0.221	1.587	-0.773	-2.778	**STAB1**	-0.676	-4.859	0.354	1.273
H16	0.108	0.779	-0.803	-2.886	**STAB2**	-1.024	-7.360	1.622	5.831
H17	-0.214	-1.541	-0.723	-2.600	**STAB3R**	-0.807	-5.799	-0.076	-0.274
H18	-0.904	-6.500	0.250	0.899	**STAB4R**	-0.602	-4.329	-0.228	-0.821
PT1	-0.296	-2.126	-0.604	-2.172	**STAB5**	-0.796	-5.720	0.707	2.541
PT2	-0.343	-2.464	-0.693	-2.490	**STAB6**	-0.909	-6.531	1.294	4.650
PT3	-0.200	-1.438	-0.889	-3.195	**STAB7**	-0.551	-3.963	0.132	0.475
PT4	0.215	1.548	-0.480	-1.726	**STAB8**	-0.407	-2.928	-0.266	-0.956
PT5	-0.126	-0.907	-0.752	-2.702	**STAB9**	-1.136	-8.165	2.167	7.787
PT6	-0.117	-0.839	-0.730	-2.625	**STAB10**	-0.520	-3.737	0.257	0.924
PT7	-0.503	-3.619	-0.345	-1.240	**STAB11**	-0.232	-1.669	-0.587	-2.110
PT8	-0.406	-2.916	-0.234	-0.842	**STAB12R**	-0.074	-0.529	-0.640	-2.301
PT9	0.324	2.328	-0.581	-2.088	**STAB13**	-0.329	-2.365	-0.320	-1.150
PT10	-0.609	-4.380	-0.031	-0.110	**STAB14**	-0.206	-1.477	-0.780	-2.803
PT11	0.108	0.773	-0.625	-2.245	**TF1**	-0.659	-4.739	0.187	0.673
PT12	-0.252	-1.813	-0.655	-2.355	**TF2**	-1.011	-7.265	0.794	2.855
PT13	0.109	0.783	-0.889	-3.196	**TF3**	-0.671	-4.820	0.289	1.038
K1	-0.162	-1.162	-0.870	-3.125	**TF4**	-0.621	-4.464	-0.482	-1.731
K2	0.281	2.021	-0.448	-1.611	**TF5**	-0.287	-2.064	-0.462	-1.659
K3	-0.937	-6.737	0.601	2.160	**TF6**	-0.608	-4.373	-0.243	-0.873
K4	-0.282	-2.024	-0.250	-0.897	**TF7**	-0.030	-0.216	-0.379	-1.361
K5	-0.216	-1.554	-0.865	-3.109	**IO1**	-0.826	-5.934	0.541	1.946
K6	0.094	0.679	-0.719	-2.584	**IO2**	0.314	2.256	-0.773	-2.778
ER1	-0.190	-1.364	-0.941	-3.382	**IO3**	-0.705	-5.064	0.537	1.929
ER2	-0.030	-0.218	-0.865	-3.110	**IO4**	-0.935	-6.719	0.846	3.041
ER3	-0.356	-2.562	-0.810	-2.911	**IO5**	-0.494	-3.552	-0.383	-1.377
ER4	-0.155	-1.115	-0.734	-2.638	**IO6**	0.440	3.165	-0.653	-2.347
ER5	-0.706	-5.072	-0.255	-0.916	**IP1**	-0.395	-2.838	0.022	0.080
ER6	-0.241	-1.729	-0.626	-2.248	**IP2**	0.041	0.297	-0.284	-1.022
ER7	0.282	2.026	-0.773	-2.779	**IP3**	-0.213	-1.529	-0.249	-0.893

ER8	-0.476	-3.418	-0.432	-1.554	**IP4**	-0.060	-0.428	-0.643	-2.313
					Multivarijatna zaobljenost (Mardia test)			**762.34**	**52.152**
** R = rekodirana skala*									

Izvor: izračun autorice

Analizom veličina Cookove udaljenosti (eng. *Cook's Distance*) za opažanja, odnosno ispitanike u uzorku, može se zaključiti da ne postoji niti jedno opažanje čija je vrijednost Cookove udaljenosti veća od 1, što ukazuje na nepostojanje outliera (netipičnih opažanja). Ipak, međusobnom usporedbom ovih vrijednosti te grafičkim prikazom (Slika 5.1.), može se zaključiti da opažanja 122, 266 i 11 više odstupaju od vrijednosti za ostala opažanja, što znači da bi ta opažanja mogla predstavljati potencijalne outliere. Međutim, udio ovih opažanja izrazito je malen (0.968%) te je preporuka zadržati ih u uzorku ako se ne može dokazati da su izrazito pogrešnih vrijednosti i nereprezentativni za uzorak (Hair et al., 2019a). U ovom istraživanju ne može se utvrditi da navedena opažanja nisu reprezentativna, a i njihov udio nije značajan, stoga su zadržani za daljnju analizu. U svrhu usporedbe, ipak je paralelno provedena i analiza bez navedenih opažanja, kojom se pokazalo da su rezultati slični onima koji se dobiju koristeći cijeli uzorak.

Tablica 5.26. Rezultati analize multivarijatnih outliera putem Cookove udaljenosti

Isp.	***Cook's Distance***	**Isp.**	***Cook's Distance***	**Isp.**	***Cook's Distance***	**Isp.**	***Cook's Distance***	**Isp.**	***Cook's Distance***
1	0.00666	63	0.00067	125	0.00959	187	0.00555	249	0.00001
2	0.03653	64	0.00307	126	0.00435	188	0.00068	250	0.00025
3	0.01215	65	0.00004	127	0.00509	189	0.00701	251	0.00246
4	0.00751	66	0.00339	128	0.00187	190	0.00071	252	0.00747
5	0.00531	67	0.01163	129	0.00101	191	0.00112	253	0.00756
6	0.00334	68	0.00003	130	0.00264	192	0.00214	254	0.02648
7	0.01010	69	0.00339	131	0.00295	193	0.00951	255	0.00420
8	0.00148	70	0.00006	132	0.00747	194	0.00011	256	0.00137
9	0.00757	71	0.00261	133	0.00169	195	0.00013	257	0.00809
10	0.00320	72	0.00002	134	0.00182	196	0.00357	258	0.03626
11	0.05064	73	0.01976	135	0.00046	197	0.00433	259	0.00265
12	0.01180	74	0.00841	136	0.00555	198	0.00011	260	0.00858
13	0.00488	75	0.00791	137	0.00095	199	0.00047	261	0.00190
14	0.00307	76	0.00632	138	0.00214	200	0.00075	262	0.00006
15	0.00256	77	0.00070	139	0.01599	201	0.00011	263	0.00098
16	0.00007	78	0.00116	140	0.00105	202	0.01117	264	0.00201
17	0.01293	79	0.00127	141	0.00000	203	0.00009	265	0.00212
18	0.00962	80	0.01166	142	0.00013	204	0.00149	266	0.05296
19	0.00326	81	0.00076	143	0.00000	205	0.00645	267	0.00083

20	0.00148	82	0.00065	144	0.00358	206	0.00067	268	0.00072
21	0.00225	83	0.00833	145	0.00011	207	0.00171	269	0.00046
22	0.00796	84	0.01230	146	0.00003	208	0.00187	270	0.00701
23	0.00927	85	0.00197	147	0.00801	209	0.00007	271	0.00267
24	0.01163	86	0.00022	148	0.00146	210	0.00073	272	0.00000
25	0.00341	87	0.00535	149	0.00037	211	0.00075	273	0.00233
26	0.00001	88	0.00001	150	0.00198	212	0.00007	274	0.02389
27	0.00800	89	0.00177	151	0.00038	213	0.00173	275	0.00119
28	0.00128	90	0.00448	152	0.00315	214	0.00226	276	0.00013
29	0.02311	91	0.00136	153	0.00011	215	0.00211	277	0.01180
30	0.00237	92	0.00033	154	0.00471	216	0.00029	278	0.00354
31	0.01161	93	0.00116	155	0.00301	217	0.00039	279	0.02724
32	0.00454	94	0.00020	156	0.00058	218	0.00504	280	0.01074
33	0.02147	95	0.00509	157	0.00511	219	0.00000	281	0.01884
34	0.00166	96	0.00290	158	0.00181	220	0.00013	282	0.02369
35	0.01165	97	0.00281	159	0.00246	221	0.00017	283	0.01178
36	0.00621	98	0.00318	160	0.00015	222	0.00010	284	0.01016
37	0.00000	99	0.00069	161	0.00170	223	0.00016	285	0.00590
38	0.01092	100	0.00056	162	0.00108	224	0.00913	286	0.00002
39	0.00945	101	0.01366	163	0.00093	225	0.00023	287	0.00006
40	0.01313	102	0.00424	164	0.00075	226	0.00007	288	0.00573
41	0.00189	103	0.00042	165	0.00071	227	0.00060	289	0.00141
42	0.00315	104	0.00038	166	0.00011	228	0.00000	290	0.00008
43	0.00013	105	0.01337	167	0.00056	229	0.00889	291	0.00048
44	0.01553	106	0.00188	168	0.00210	230	0.00012	292	0.00017
45	0.01049	107	0.01175	169	0.00221	231	0.02099	293	0.00408
46	0.00031	108	0.00747	170	0.03470	232	0.00026	294	0.00004
47	0.00755	109	0.00050	171	0.00008	233	0.00387	295	0.00000
48	0.00000	110	0.00739	172	0.01197	234	0.01292	296	0.00177
49	0.00638	111	0.00068	173	0.00037	235	0.00464	297	0.00113
50	0.00064	112	0.00017	174	0.00958	236	0.00407	298	0.00115
51	0.00158	113	0.00294	175	0.00869	237	0.00038	299	0.00089
52	0.00657	114	0.00005	176	0.00050	238	0.02326	300	0.00100
53	0.00953	115	0.00146	177	0.00020	239	0.00171	301	0.00502
54	0.00560	116	0.00324	178	0.00610	240	0.00036	302	0.00019
55	0.00213	117	0.00733	179	0.00827	241	0.00285	303	0.00297
56	0.00081	118	0.01118	180	0.00021	242	0.00981	304	0.00117
57	0.01335	119	0.00652	181	0.00225	243	0.00388	305	0.00006
58	0.00165	120	0.00000	182	0.00621	244	0.03190	306	0.00012
59	0.00106	121	0.00499	183	0.00570	245	0.01653	307	0.00319
60	0.00008	122	0.07695	184	0.00232	246	0.01393	308	0.00709
61	0.03043	123	0.00003	185	0.00266	247	0.01013	309	0.00841
62	0.00700	124	0.00097	186	0.00490	248	0.00017	310	0.03921

Izvor: izračun autorice

Slika 5.1. Grafički prikaz ispitanika prema Cookovim udaljenostima

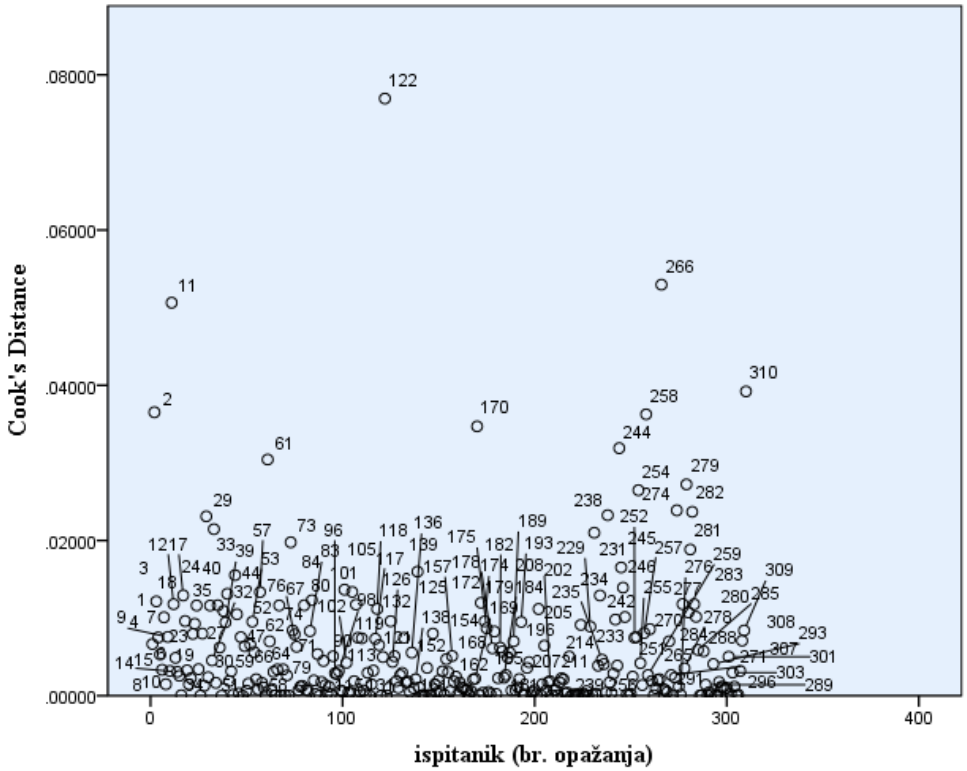

Izvor: izrada autorice temeljem izračuna u programu SPSS

Potencijalna multikolinearnost ispitana je putem pokazatelja tolerancije (TOL) i faktora inflacije varijance (VIF). Iz tablice 5.27. vidljivo je da su za sve varijable vrijednosti TOL veće od 0.1, a sve vrijednosti VIF manje su od 10. Stoga, može se zaključiti da niti jedna varijabla ne uzrokuje problem multikolinearnosti (Hair et al., 2010; Kline, 2011).

Tablica 5.27. Rezultati analize multikolinearnosti

Varijabla	TOL	VIF	Varijabla	TOL	VIF	Varijabla	TOL	VIF
H1	0.414	2.417	**PT13**	0.413	2.419	**PRIL4**	0.313	3.196
H2	0.438	2.284	**K1**	0.408	2.449	**PRIL5**	0.322	3.104
H3	0.340	2.944	**K2**	0.480	2.084	**PRIL6R**	0.349	2.869
H4	0.374	2.677	**K3**	0.260	3.846	**PRIL7**	0.430	2.324
H5	0.352	2.842	**K4**	0.354	2.822	**PRIL8**	0.429	2.331
H6	0.345	2.894	**K5**	0.320	3.128	**PRIL9**	0.392	2.550
H7	0.341	2.934	**K6**	0.419	2.388	**STAB1**	0.319	3.136
H8	0.413	2.418	**TF1**	0.263	3.805	**STAB2**	0.249	4.017
H9	0.405	2.470	**TF2**	0.274	3.650	**STAB3R**	0.372	2.685

H10	0.427	2.343	**TF3**	0.240	4.165	**STAB4R**	0.356	2.806
H11	0.477	2.097	**TF4**	0.311	3.214	**STAB5**	0.357	2.797
H12	0.301	3.324	**TF5**	0.378	2.643	**STAB6**	0.360	2.777
H13	0.394	2.540	**TF6**	0.334	2.993	**STAB7**	0.333	2.999
H14	0.378	2.645	**TF7**	0.346	2.890	**STAB8**	0.276	3.618
H15	0.393	2.543	**ER1**	0.268	3.731	**STAB9**	0.254	3.931
H16	0.489	2.043	**ER2**	0.244	4.099	**STAB10**	0.326	3.070
H17	0.395	2.529	**ER3**	0.256	3.901	**STAB11**	0.251	3.984
H18	0.460	2.173	**ER4**	0.236	4.229	**STAB12R**	0.469	2.130
PT1	0.461	2.168	**ER5**	0.346	2.892	**STAB13**	0.264	3.782
PT2	0.372	2.689	**ER6**	0.394	2.535	**STAB14**	0.199	5.033
PT3	0.513	1.950	**ER7**	0.401	2.492	**IO1**	0.276	3.624
PT4	0.561	1.782	**ER8**	0.482	2.076	**IO2**	0.317	3.156
PT5	0.511	1.958	**ER9**	0.465	2.152	**IO3**	0.241	4.157
PT6	0.525	1.903	**ER10**	0.293	3.414	**IO4**	0.278	3.591
PT7	0.306	3.266	**ER11**	0.314	3.188	**IO5**	0.250	4.003
PT8	0.373	2.680	**ER12**	0.311	3.213	**IO6**	0.358	2.796
PT9	0.462	2.164	**ER13**	0.379	2.641	**IP1**	0.280	3.572
PT10	0.502	1.991	**PRIL1**	0.302	3.309	**IP2**	0.388	2.574
PT11	0.452	2.215	**PRIL2R**	0.286	3.495	**IP3**	0.277	3.612
PT12	0.416	2.406	**PRIL3**	0.357	2.798	**IP4**	0.347	2.880

Izvor: izračun autorice

Zaključno, prilikom preliminarne provjere prikupljenih podataka, može se zaključiti da je veličina uzorka od 310 opažanja zadovoljavajuća za provedbu SEM analize, a beznačajan udio potencijalnih outliera ne predstavlja problem pa su oni zadržani u analizi. Osim toga, ne postoji problem multikolinearnosti. Međutim, Mardia test pokazuje da pretpostavka multivarijatne normalnosti nije zadovoljena, zbog čega će se u CB-SEM analizi koristiti robusna WLS metoda, posebno razvijena za kategorijalne i ordinalne varijable, a upravo ordinalne varijable su ključne za istraživački model.

5.3.1 Analiza CB-SEM mjernog modela bihevioralnih financija

Nakon provjere preduvjeta za CB-SEM analizu, utvrđena je potreba korištenja robusne WLS metode. Modeliranje je provedeno u programu Mplus, verzija 7. U prvom koraku modeliranja ispitan je mjerni model, kroz koji je utvrđena validnost i pouzdanost faktora (konstrukata) u modelu. Bihevioralni faktori razmatrani u modelu su: heuristike, elementi prospektne teorije, ponašanje krda, emocije i raspoloženje, prilagodljivost i stabilnost. Ovi faktori predstavljaju utjecajne varijable, a u SEM modelu smatraju se egzogenim faktorima. Investicijske odluke su

zavisna varijabla, tj. endogeni faktor, te se promatra kako navedeni faktori ponašanja utječu na odlučivanje. Istovremeno, investicijske odluke utječu na investicijske performanse, koje također čine endogeni faktor u SEM modelu.

Inicijalni model sadržavao je sva anketna pitanja, prikazana u poglavlju 5.2., kao indikatore za navedenih šest bihevioralnih faktora, kao i za investicijske odluke i performanse. Međutim, kako bi se postigao zadovoljavajući mjerni model, postepenim izbacivanjem indikatora prema kriterijima validnosti i značajnosti, došlo se do konačnog CB-SEM modela. Indikatori faktora koji su ostali zadržani u konačnom modelu prikazani su u tablici 5.28., zajedno sa skraćenim oznakama svakog faktora i pripadajućih indikatora. Što se tiče heuristika, sva pitanja, tj. indikatori koji su ostali u modelu se odnose na samouvjerenost investitora, dok su za prospektnu teoriju preostala dva indikatora povezana sa sklonosti riziku. Za faktore emocija i raspoloženja te stabilnosti ostao je veći broj indikatora (8 za emocije i raspoloženje te 11 za stabilnost), što ukazuje na kompleksnost modela. Ipak, unatoč kompleksnijem modelu, postignuto je optimalno rješenje.

Tablica 5.28. Indikatori faktora u konačnom CB-SEM modelu

Heuristike (HEU)
H3 - Smatram da mi moje vještine i znanje o tržištu dionica mogu pomoći da nadigram tržište. H4 - Oslanjam se na svoja prethodna iskustva na tržištu za donošenje odluka o budućim investicijama. H5 - Siguran sam da mogu donijeti ispravnu investicijsku odluku. H6 - Smatram da su tržišni trendovi često u skladu s mojim očekivanjima. H7 - Smatram da je povrat od ulaganja u dionicu uvijek ostvaren zbog moje uspješne investicijske strategije.
Elementi prospektne teorije (PT)
PT1 - Nakon prethodnog dobitka, više sam sklon riziku nego obično. PT2 - Nakon prethodnog gubitka postajem manje sklon riziku.
Ponašanje krda (KRDO)
K2 - Uložio bih u dionice prema sugestijama svojih prijatelja. K5 - Slijedim ono što moj savjetnik sugerira tijekom ulaganja. K6 - Slijedim savjete ostalih investitora dok kupujem dionice jer nemam odgovarajuće znanje.
Emocije i raspoloženje (ER)
ER1 - Kad se osjećam sretno, to utječe na moju tržišnu aktivnost. ER2 - Kad se osjećam ljuto, ne sudjelujem u tržišnim aktivnostima. ER3 - Kad se osjećam umorno, to utječe na moju tržišnu aktivnost. ER4 - Kad se osjećam tužno, ne sudjelujem u tržišnim aktivnostima. ER5 - Moj pozitivan pogled na život potiče me da ulažem u dionice. ER10 - Ako se gubici nastave, ne želim više nikada kupovati dionice. ER11 - Ako se gubitak u mojoj investiciji nastavi, zbunjen sam kad donosim odluku o daljnjim ulaganjima. ER12 - Ako kupim dionice koje postanu profitabilne, obnavljam vjeru da postoji budućnost u investiranju.

Stabilnost (STAB)
STAB1 - Radim temeljit posao. STAB2 - Pouzdan sam radnik. STAB5 - Ustrajem u zadatku dok nije gotov. STAB6 - Općenito radim sve učinkovito. STAB7 - Pravim planove i slijedim ih. STAB8 - Pomažem i nesebičan sam prema drugima. STAB9 - Općenito sam pouzdan. STAB10 - Volim surađivati s drugima. STAB11 - Opušten sam i dobro podnosim stres. STAB13 - Emocionalno sam stabilan, nije me lako uznemiriti. STAB14 - Ostajem smiren u napetim situacijama.
Prilagodljivost (PRIL)
PRIL3 - Pun sam energije. PRIL4 - Stvaram puno entuzijazma. PRIL5 - Samopouzdan sam. PRIL8 - Imam aktivnu maštu. PRIL9 - Inventivan sam.
Investicijske odluke (IO)
IO1 - Ulažem u investicije koje će donijeti dugoročne koristi. IO3 - Redovito pregledam, usporedim i potom donesem odluke o svom investicijskom potezu. IO4 - Istražujem tržište prije bilo kakvog kratkoročnog ulaganja.
Investicijske performanse (IP)
IP1 - Zadovoljan sam stopom prinosa svojih nedavnih ulaganja u dionice. IP2 - Smatram da je prinos na dionice u koje ulažem bolji od prinosa većine drugih dionica. IP3 - Zadovoljan sam svojim odlukama o kupnji dionica u protekloj godini dana. IP4 - Zadovoljan sam svojim odlukama o prodaji dionica u protekloj godini dana.

Izvor: izrada autorice

Za utvrđivanje konvergentne validnosti i pouzdanosti faktora u modelu, izračunati su pokazatelji prosječne izlučene varijance (eng. *average variance extracted*, AVE), pouzdanost konstrukta (eng. *construct reliability*, CR) te Cronbach's alpha koeficijent. Rezultati za CB-SEM model vidljivi su u tablici 5.29. Može se zaključiti da su sva faktorska opterećenja (eng. *factor loadings)* statistički značajna, i to pri razini signifikantnosti od 1%. Standardizirana faktorska opterećenja za većinu indikatora imaju vrijednosti između 0.5 i 0.7 ili više, što ukazuje na to da dobro odražavaju latentnu varijablu koju mjere. Jedan indikator (ER5) s vrijednosti standardiziranog faktorskog opterećenja manjim od 0.5 zadržan je u modelu, s obzirom da ne pogoršava kriterij validnosti faktora, tj. konstrukta kojeg predstavlja. Za sve konstrukte u modelu validnost je zadovoljavajuća, s obzirom da su vrijednosti svih AVE pokazatelja veće od 0.5, što ukazuje da je svakim konstruktom u modelu objašnjeno barem 50% varijance u svojim indikatorima. Najveća objašnjenost varijance je među

indikatorima faktora investicijskih performansi (0.659, tj. 65.9%). AVE je konzervativnija procjena validnosti mjernog modela i smatra se da se temeljem CR pokazatelja također može donijeti zaključak o konvergentnoj validnosti modela (Lam, 2012). Ovaj pokazatelj uostalom ukazuje i na pouzdanost konstrukta, gdje je donja granica dobre pouzdanosti vrijednost 0.7, što je zadovoljeno u ovom modelu. Iznimka je CR faktora prospektne teorije, čija je vrijednost 0.672. Ipak, i ova je vrijednost također prihvatljiva, jer je validnost svih ostalih faktora u modelu zadovoljavajuća. Stoga se može zaključiti da svi indikatori u modelu dosljedno predstavljaju odgovarajući latentni konstrukt ili faktor (Hair et al., 2010; MacKenzie, Podsakoff i Podsakoff, 2011; Hair et al., 2017a; Civelek, 2018). Osim toga, pouzdanost je ispitana i putem Cronbach's alpha koeficijenta. Za sve faktore, izuzev prospektne teorije i ponašanja krda, ovaj pokazatelj nalazi se iznad poželjne granice vrijednosti 0.7. Za dva navedena faktora kod kojih to nije slučaj, pokazatelji su jako blizu te vrijednosti, odnosno vrijednosti su im između 0.6 i 0.7, što je također prihvatljivo. Može se reći da Cronbach's alpha koeficijenti za sve faktore pokazuju umjerenu (0.5-0.7) ili visoku (>0.7) pouzdanost (Hinton et al., 2004). Dakle, utvrđena je i interna konzistentnost indikatora svih promatranih faktora u modelu. Prema svim analiziranim pokazateljima validnosti i pouzdanosti, zaključeno je da izabrani indikatori dobro objašnjavaju faktor koji predstavljaju.

Tablica 5.29. Rezultati analize konvergentne validnosti i pouzdanosti CB-SEM modela

	Standardizirani *factor loading*	**AVE**	**CR**	**Cronbach's alpha**
Heuristike (HEU)				
H3	0.673**	0.509	0.838	0.797
H4	0.715**			
H5	0.806**			
H6	0.702**			
H7	0.663**			
Elementi prospektne teorije (PT)				
PT1	0.618**	0.510	0.672	0.612
PT2	0.799**			
Ponašanje krda (KRDO)				
K2	0.530**	0.507	0.749	0.692
K5	0.782**			
K6	0.792**			
Emocije i raspoloženje (ER)				
ER1	0.759**	0.521	0.893	0.849
ER2	0.850**			
ER3	0.829**			
ER4	0.865**			
ER5	0.411**			
ER10	0.698**			
ER11	0.672**			

ER12	0.569**			
Stabilnost (STAB)				
STAB1	0.734**	0.562	0.934	0.896
STAB2	0.771**			
STAB5	0.731**			
STAB6	0.738**			
STAB7	0.723**			
STAB8	0.705**			
STAB9	0.786**			
STAB10	0.660**			
STAB11	0.801**			
STAB13	0.738**			
STAB14	0.843**			
Prilagodljivost (PRIL)				
PRIL3	0.756**	0.539	0.852	0.802
PRIL4	0.745**			
PRIL5	0.859**			
PRIL8	0.614**			
PRIL9	0.674**			
Investicijske odluke (IO)				
IO1	0.561**	0.520	0.760	0.738
IO3	0.837**			
IO4	0.739**			
Investicijske performanse (IP)				
IP1	0.906**	0.659	0.885	0.846
IP2	0.745**			
IP3	0.821**			
IP4	0.765**			
*** značajno na razini 0.01*				

Izvor: izračun autorice

Nadalje, testirana je i diskriminantna validnost procijenjenog modela prema Fornell-Larcker kriteriju. Ovom analizom utvrđuje se je li određeni faktor zaista različit od ostalih. Rezultati analize prikazani su u tablici 5.30., koja zapravo predstavlja korelacijsku matricu među latentnim varijablama (faktorima, konstruktima). Vrijednosti na dijagonali matrice prikazuju vrijednosti drugog korijena iz svake pojedine AVE vrijednosti i one se uspoređuju s korelacijskim koeficijentima za svaki faktor u relevantnim redcima i stupcima. Za sve faktore ove vrijednosti veće su od visine korelacije s ostalim faktorima u modelu. Potencijalni problem diskriminantne validnosti postoji kod faktora IO i IP, koji su visoko korelirani. Ipak, kontrolnom provedbom eksplorativne faktorske analize (EFA) koristeći izabrane indikatore IO i IP, rješenje daje dva faktora s indikatorima koji su i specificirani prije procjene CB-SEM modela.

Tablica 5.30. Rezultati analize diskriminantne validnosti CB-SEM modela

	HEU	PT	KRDO	ER	STAB	PRIL	IO	IP

HEU	**0.714**							
PT	0.023	**0.714**						
KRDO	-0.120	0.613	**0.712**					
ER	-0.118	0.665	0.543	**0.722**				
STAB	0.469	-0.152	-0.115	-0.122	**0.750**			
PRIL	0.489	0.041	-0.010	0.095	0.713	**0.734**		
IO	0.698	-0.079	-0.251	-0.110	0.577	0.524	**0.721**	
IP	0.587	-0.067	-0.211	-0.092	0.485	0.441	0.841	**0.812**

Izvor: izračun autorice

5.3.2 Analiza CB-SEM strukturalnog modela bihevioralnih financija

Kako je već spomenuto, latentne varijable (faktori) u istraživačkom modelu su: heuristike (HEU), elementi prospektne teorije (PT), ponašanje krda (KRDO), emocije i raspoloženje (ER), stabilnost (STAB) i prilagodljivost (PRIL) kao dva faktora osobnosti, investicijske odluke (IO) te investicijske performanse (IP). Njihove indikatore čine anketna pitanja, odnosno tvrdnje, čiji se odgovori nalaze na skali od 1 do 5, tj. od potpunog neslaganja do potpunog slaganja s tvrdnjom. Oni su prethodno objašnjeni u tablici 5.28. Upravo zbog prirode varijabli, odnosno indikatora, model je procijenjen pomoću WLSMV (*mean and variance adjusted weighted least squares*) metode, koja je dostupna u programu Mplus.

Tablica 5.31. prikazuje rezultate strukturalnog modela s njegovim pokazateljima prilagodbe. Model se sastoji od 8 faktora s ukupno 41 indikatorom, 227 slobodnih parametara te ima 757 stupnjeva slobode, što ga čini previše identificiranim i prikladnim za analizu. Što se tiče pokazatelja prilagodbe modela, vrijednost hi-kvadrat testa je statistički značajna (p-vrijednost ≤ 0.001). Međutim, već je naglašeno da ovaj test može biti osjetljiv na veličinu uzorka, naročito ako se radi o velikim uzorcima. Tada se vrijednost hi-kvadrata povećava zajedno s povećanjem veličine uzorka. Često se spominje veličina uzorka od 200 jedinica kao primjer većeg uzorka, dok ovo istraživanje obuhvaća 310 jedinica, tj. ispitanika, što je značajnije veća vrijednost. Stoga, ovakav rezultat hi-kvadrat testa nije iznenađujući. Osim toga, varijable u modelu ne zadovoljavaju uvjet multivarijatne normalnosti pa testna veličina vjerojatno ne slijedi hi-kvadrat distribuciju. Uslijed odstupanja od normalnosti, češće se može doći do pogrešnog zaključka. Svakako je potrebno, osim hi-kvadrata, pregledati još nekoliko relevantnih pokazatelja prilagodbe. Vrijednost pokazatelja RMSEA iznosi 0.091, a i gornja granica njegove intervalne procjene je ispod 0.10, što se smatra prihvatljivim. Međutim, pokazatelji CFI i TLI malo su niži od granice od 0.90, koja bi ukazivala na dobru prilagodbu modela (CFI=0.825 i TLI=0.810).

Dakle, prema navedenim pokazateljima, može se zaključiti da model ne reproducira matricu kovarijance među varijablama indikatora dovoljno dobro. Relativno poboljšanje istraživačkog modela u odnosu na *null* model, mjereno CFI i TLI pokazateljima, poprilično je visoko, no ima prostora za daljnje poboljšanje. Model je prihvatljiv što se tiče prosječne kvadratne pogreške procjene, koja je relativno mala. Zaključno, mjere prilagodbe modela su osrednje kvalitete, ukazujući na potrebu potencijalne respecifikacije ili procjene drugom metodom.

U tablici 5.31. također su prikazani i standardizirani koeficijenti za strukturalni model s pripadajućim *p*-vrijednostima. Otprilike polovina pretpostavljenih uzročno-posljedičnih veza je statistički značajna. Prvenstveno, utjecaj heuristika na investicijske odluke pozitivan je i značajan pri razini signifikantnosti od 1%. Razmatrajući indikatore ovog faktora, jasno je da češće korištenje heuristikom samouvjerenosti kod investitora u uzorku dovodi do dugoročno korisnih odluka o ulaganju. Ovaj zaključak u suprotnosti je s postavljenom hipotezom H1, koja se stoga odbacuje. Ponašanje krda kod investitora značajno negativno utječe na investicijske odluke. Drugim riječima, investitori koji se više oslanjaju na sugestije prijatelja, savjetnika ili drugih investitora na tržištu, donose manji broj dugoročno korisnih odluka. Temeljem ovog zaključka, odbacuje se i hipoteza H3. Može se primijetiti da se zaključci za ova dva faktora razlikuju od onih koji su dobiveni u pilot istraživanju. Razlog tome može biti razlika između studentskih percepcija o svom hipotetskom ponašanju na financijskom tržištu i iskustvenih doživljaja i ponašanja pravih investitora na tržištu. Još jedan faktor koji značajno utječe na investicijske odluke je stabilnost kao karakteristika osobnosti. Ovaj faktor pozitivno i značajno utječe na investicijske odluke, čime se potvrđuje pomoćna hipoteza H5.1: Investitori sa stabilnijom osobnošću donose značajno veći broj dugoročno korisnih odluka o ulaganju na financijskom tržištu. S druge strane, prilagodljivost, kao druga dimenzija osobnosti, ne utječe značajno na donošenje odluka o ulaganju pa se pomoćna hipoteza H5.2 ne prihvaća. Povezujući ove dvije karakteristike osobnosti, može se reći da se hipoteza H5 djelomično prihvaća, s obzirom da jedna dimenzija osobnosti ima značajan utjecaj na odlučivanje, a druga nema. Od preostalih faktora, elementi prospektne teorije, koji se u konkretnom modelu odnose na sklonost riziku, te emocije i raspoloženje ne utječu statistički značajno na donošenje investicijskih odluka. Dakle, i hipoteze H2 i H4 mogu se odbaciti. Konačno, potvrđen je značajan pozitivan utjecaj investicijskih odluka na investicijske performanse. Ovaj rezultat pokazuje da su investitori koji donose dugoročno korisne odluke o ulaganju posljedično i zadovoljniji vlastitim investicijskim performansama. Time se zaključuje da se može prihvatiti hipoteza H7: Dugoročno

korisne odluke o ulaganju pozitivno utječu na zadovoljstvo investicijskim performansama investitora na financijskom tržištu. Ovaj utjecaj odluka na performanse ujedno je i najjači u modelu. S druge strane, od bihevioralnih faktora, heuristike, konkretno samouvjerenost, najviše utječe na investicijske odluke, a najslabiji je utjecaj ponašanja krda.

Tablica 5.31. Rezultati strukturalnog modela s pokazateljima prilagodbe (CB-SEM)

Pretpostavljena veza	Standardizirani koeficijenti	p-vrijednost
HEU → IO	0.521	<0.001
PT → IO	0.030	0.752
KRDO → IO	-0.217	0.011
ER → IO	0.079	0.215
STAB → IO	0.281	<0.001
PRIL → IO	0.058	0.474
IO → IP	0.841	<0.001
χ^2 = 2686.356, p-vrijednost ≤0.001, RMSEA (90% C.I.) = 0.091 (0.087-0.094), CFI=0.825, TLI=0.810		

Izvor: izračun autorice

Opisane veze sadržane u procijenjenom CB-SEM modelu prikazane su kroz *path* dijagram na slici 5.2. Kako je opisano u poglavlju 4, krugovi predstavljaju sve latentne varijable, odnosno faktore ili konstrukte u modelu. U konkretnom modelu, to su svi prethodno navedeni bihevioralni faktori, investicijske odluke i performanse. Svakom od faktora dodijeljen je određeni broj indikatora, koji su prikazani u obliku kvadrata. Naznačeno je i o kojem se točno indikatoru radi, prema oznakama, tj. kraticama, koje su dodijeljene pojedinim anketnim pitanjima kojima se faktori indirektno mjere, a koji su prikazani u tablici 5.28. Na strelicama koje se kreću od faktora prema indikatorima označene su vrijednosti standardiziranih faktorskih opterećenja, dok su na strelicama koje se kreću od jednog prema drugom faktoru ispisane vrijednosti standardiziranih koeficijenata. Na ovaj način pregledno i jednostavno se mogu ustanoviti smjer i jakost svake veze u strukturalnom modelu. Endogeni faktori imaju i komponentu pogreške, prikazanu kao broj od kojeg se strelica kreće prema faktoru. Za IO pogreška iznosi 0.401, a za IP 0.292. Iz ovih rezultata može se utvrditi koeficijent determinacije, odnosno R^2, za svaki pojedini faktor, na način da se od 1 oduzme vrijednost pogreške. Prema tome, njegova vrijednost za IO iznosi 0.599, a za IP 0.708, a pokazuje koliki udio varijance zavisnog faktora je objašnjen skupom nezavisnih varijabli, odnosno faktora. Može se zaključiti kako je objašnjenost kod oba faktora izrazito visoka, odnosno izabrani prediktori u modelu dobro objašnjavaju zavisne faktore IO i IP.

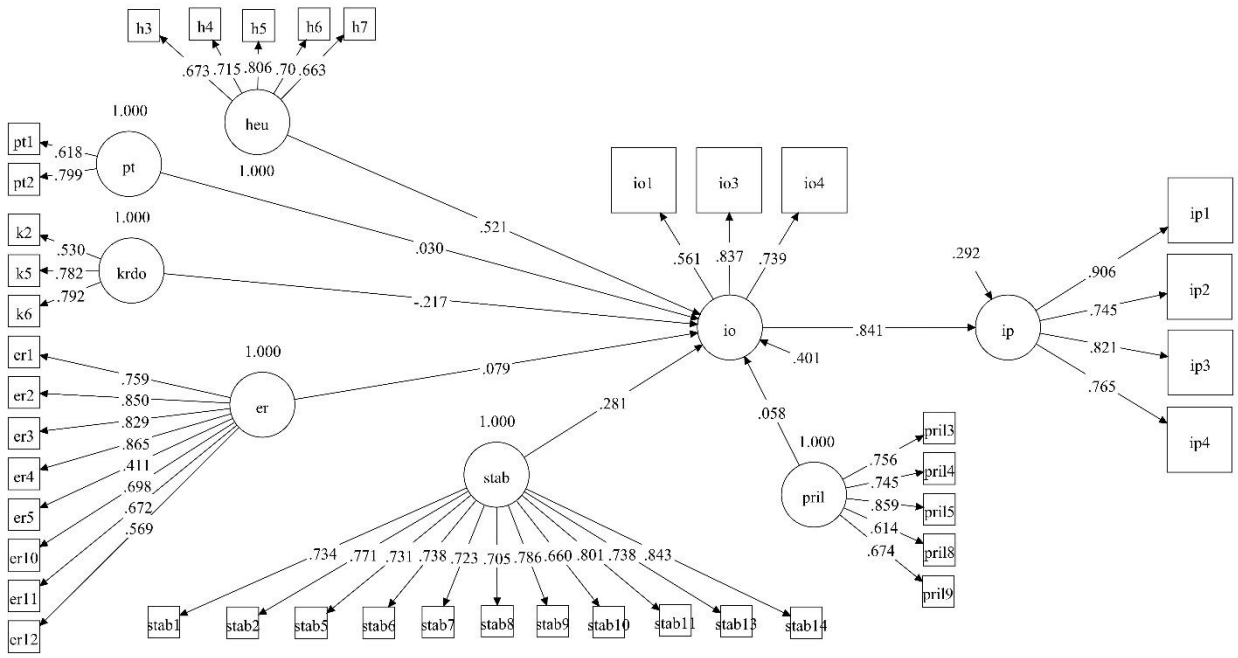

Slika 5.2. *Path* dijagram sa standardiziranim koeficijentima (CB-SEM model)

Izvor: izračun autorice uz pomoć programa Mplus

5.3.3 Analiza CB-SEM alternativnog mjernog modela bihevioralnih financija

U alternativnom modelu ponovljen je postupak modeliranja, s tim da su, uz prethodno analizirane bihevioralne faktore, kao nezavisna varijabla (egzogeni faktor) dodani i tržišni faktori. Stoga, alternativni model razmatra sedam utjecajnih varijabli, odnosno egzogenih faktora, a to su: heuristike, elementi prospektne teorije, ponašanje krda, emocije i raspoloženje, stabilnost, prilagodljivost i tržišni faktori. Promatra se njihovo simultano djelovanje na investicijske odluke, koje imaju ulogu endogenog faktora, a istovremeno se procjenjuje i utjecaj investicijskih odluka na investicijske performanse pojedinaca. Investicijske odluke zavisna su varijabla u odnosu na bihevioralne i tržišne faktore, a nezavisna u odnosu na investicijske performanse.

Ovaj model u konačnici sadrži sve iste indikatore kao i prethodni model, a za tržišne faktore, kao novi konstrukt u modelu, ostalo je 5 od 7 potencijalnih indikatora, tj. anketnih pitanja, kojima se odražavao stav ispitanika prema analiziranju ovih faktora pri ulaganju. Indikatori svih faktora u konačnom alternativnom CB-SEM modelu prikazani su u tablici 5.32.

Tablica 5.32. Indikatori faktora u konačnom alternativnom CB-SEM modelu

Heuristike (HEU)

H3 - Smatram da mi moje vještine i znanje o tržištu dionica mogu pomoći da nadigram tržište. H4 - Oslanjam se na svoja prethodna iskustva na tržištu za donošenje odluka o budućim investicijama. H5 - Siguran sam da mogu donijeti ispravnu investicijsku odluku. H6 - Smatram da su tržišni trendovi često u skladu s mojim očekivanjima. H7 - Smatram da je povrat od ulaganja u dionicu uvijek ostvaren zbog moje uspješne investicijske strategije.
Elementi prospektne teorije (PT)
PT1 - Nakon prethodnog dobitka, više sam sklon riziku nego obično. PT2 - Nakon prethodnog gubitka postajem manje sklon riziku.
Ponašanje krda (KRDO)
K2 - Uložio bih u dionice prema sugestijama svojih prijatelja. K5 - Slijedim ono što moj savjetnik sugerira tijekom ulaganja. K6 - Slijedim savjete ostalih investitora dok kupujem dionice jer nemam odgovarajuće znanje.
Emocije i raspoloženje (ER)
ER1 - Kad se osjećam sretno, to utječe na moju tržišnu aktivnost. ER2 - Kad se osjećam ljuto, ne sudjelujem u tržišnim aktivnostima. ER3 - Kad se osjećam umorno, to utječe na moju tržišnu aktivnost. ER4 - Kad se osjećam tužno, ne sudjelujem u tržišnim aktivnostima. ER5 - Moj pozitivan pogled na život potiče me da ulažem u dionice. ER10 - Ako se gubici nastave, ne želim više nikada kupovati dionice. ER11 - Ako se gubitak u mojoj investiciji nastavi, zbunjen sam kad donosim odluku o daljnjim ulaganjima. ER12 - Ako kupim dionice koje postanu profitabilne, obnavljam vjeru da postoji budućnost u investiranju.
Stabilnost (STAB)
STAB1 - Radim temeljit posao. STAB2 - Pouzdan sam radnik. STAB5 - Ustrajem u zadatku dok nije gotov. STAB6 - Općenito radim sve učinkovito. STAB7 - Pravim planove i slijedim ih. STAB8 - Pomažem i nesebičan sam prema drugima. STAB9 - Općenito sam pouzdan. STAB10 - Volim surađivati s drugima. STAB11 - Opušten sam i dobro podnosim stres. STAB13 - Emocionalno sam stabilan, nije me lako uznemiriti. STAB14 - Ostajem smiren u napetim situacijama.
Prilagodljivost (PRIL)
PRIL3 - Pun sam energije. PRIL4 - Stvaram puno entuzijazma. PRIL5 - Samopouzdan sam. PRIL8 - Imam aktivnu maštu. PRIL9 - Inventivan sam.
Tržišni faktori (TF)
TF1 - Pažljivo razmatram promjene cijena dionica u koje želim uložiti. TF2 - Smatram da su tržišne informacije važne za moje ulaganje u dionice. TF3 - Razmatram prethodne trendove dionica prilikom svog ulaganja. TF4 - Prije donošenja investicijskih odluka, koristim fundamentalnu analizu za procjenu vrijednosti dionica.

TF6 - Pomno pratim financijska izvješća poduzeća prije nego što kupim njihove dionice.
Investicijske odluke (IO)
IO1 - Ulažem u investicije koje će donijeti dugoročne koristi. IO3 - Redovito pregledam, usporedim i potom donesem odluke o svom investicijskom potezu. IO4 - Istražujem tržište prije bilo kakvog kratkoročnog ulaganja.
Investicijske performanse (IP)
IP1 - Zadovoljan sam stopom prinosa svojih nedavnih ulaganja u dionice. IP2 - Smatram da je prinos na dionice u koje ulažem bolji od prinosa većine drugih dionica. IP3 - Zadovoljan sam svojim odlukama o kupnji dionica u protekloj godini dana. IP4 - Zadovoljan sam svojim odlukama o prodaji dionica u protekloj godini dana.

Izvor: izrada autorice

Tablica 5.33. prikazuje rezultate analize konvergentne validnosti i pouzdanosti po istim kriterijima kao u prethodnom modelu, a to su AVE, CR i Cronbach's alpha koeficijent. I u ovom modelu sva su standardizirana faktorska opterećenja statistički značajna i njihove se vrijednosti kreću od 0.5 do 0.8. Nekoliko indikatora ima veće vrijednosti standardiziranih faktorskih opterećenja, što ide u korist validnosti faktora. AVE pokazatelji su veći od 0.5 za sve faktore u modelu, čime se utvrđuje da je svakim faktorom objašnjeno minimalno 50% varijance u pripadajućim indikatorima. Ove se vrijednosti neznatno razlikuju u odnosu na prethodno procijenjeni model te su većinom iste ili malo bolje, dok je najveća objašnjenost i dalje ostala kod IP. Što se tiče pouzdanosti modela, vrijednosti CR pokazatelja ne razlikuju se bitno u odnosu na prvi model, odnosno pouzdanost faktora u modelu je dobra, s obzirom da su vrijednosti za gotovo sve faktore veće od graničnih 0.7, a opet je iznimka faktor PT s vrijednosti CR-a od 0.677. Kako je ranije spomenuto, i ova se vrijednost može smatrati prihvatljivom, jer je validnost svih ostalih faktora u modelu zadovoljavajuća. Dakle, u alternativnom CB-SEM modelu također svi promatrani indikatori dosljedno predstavljaju pripadajuće latentne faktore. Cronbach's alpha koeficijenti imaju iste vrijednosti kao u originalnom modelu, ukazujući tako i na jednak zaključak o internoj konzistentnosti modela, koja je i u ovom modelu utvrđena. Vrijednost koeficijenta za tržišne faktore, koji su naknadno dodani kao nova utjecajna varijabla, također premašuje graničnu vrijednost od 0.7, potvrđujući tako i internu konzistentnost za navedeni faktor. Konačno, analiza konvergentne validnosti i pouzdanosti pokazuje zadovoljavajuće rezultate te se može reći da indikatori i u alternativnom modelu jednako dobro, ili čak malo bolje u odnosu na prvi model, objašnjavaju faktore koje predstavljaju.

Tablica 5.33. Rezultati analize konvergentne validnosti i pouzdanosti alternativnog CB-SEM modela

	Standardizirani *factor loading*	AVE	CR	Cronbach's alpha
Heuristike (HEU)				
H3	0.686**	0.512	0.839	0.797
H4	0.743**			
H5	0.779**			
H6	0.710**			
H7	0.653**			
Elementi prospektne teorije (PT)				
PT1	0.603**	0.518	0.677	0.612
PT2	0.820**			
Ponašanje krda (KRDO)				
K2	0.527**	0.506	0.749	0.692
K5	0.789**			
K6	0.786**			
Emocije i raspoloženje (ER)				
ER1	0.741**	0.570	0.901	0.851
ER2	0.849**			
ER3	0.822**			
ER4	0.864**			
ER10	0.710**			
ER11	0.698**			
ER12	0.555**			
Stabilnost (STAB)				
STAB1	0.738**	0.562	0.934	0.896
STAB2	0.772**			
STAB5	0.742**			
STAB6	0.741**			
STAB7	0.730**			
STAB8	0.702**			
STAB9	0.785**			
STAB10	0.651**			
STAB11	0.798**			
STAB13	0.736**			
STAB14	0.835**			
Prilagodljivost (PRIL)				
PRIL3	0.750**	0.541	0.854	0.802
PRIL4	0.732**			
PRIL5	0.866**			
PRIL8	0.623**			
PRIL9	0.686**			
Tržišni faktori (TF)				
TF1	0.837**	0.641	0.899	0.830
TF2	0.792**			
TF3	0.833**			
TF4	0.773**			
TF6	0.765**			
Investicijske odluke (IO)				
IO1	0.572**	0.558	0.787	0.738
IO3	0.867**			
IO4	0.772**			
Investicijske performanse (IP)				

IP1	0.913**	0.658	0.884	0.846
IP2	0.749**			
IP3	0.822**			
IP4	0.750**			
*** značajno na razini 0.01*				

Izvor: izračun autorice

Diskriminantna validnost testirana je prema Fornell-Larcker kriteriju, a rezultati su prikazani u tablici 5.34. Vrijednosti unutar korelacijske matrice među latentnim varijablama ne razlikuju se značajno u odnosu na prethodni model, dok dodatni faktor TF jače korelira s faktorima HEU i IO. Uspoređujući vrijednosti drugog korijena iz svakog AVE pokazatelja, koje se nalaze na dijagonali matrice, s vrijednostima korelacije u relevantnim redcima i stupcima, zaključuje se da ne postoji problem diskriminantne validnosti za gotovo sve faktore. Naime, sve vrijednosti na dijagonali matrice veće su od korelacijskih koeficijenata u odgovarajućim redcima i stupcima, osim jedne. Spomenuta iznimka su opet faktori IO i IP, koji snažnije koreliraju, pa se ovdje može primijetiti potencijalni problem diskriminantne validnosti. Međutim, postojanje potencijalnog problema može se primijetiti samo usporedbom drugog korijena iz AVE pokazatelja faktora IO s korelacijom između IO i IP, dok gledajući vrijednost drugog korijena AVE pokazatelja faktora IP u odnosu na korelaciju između IO i IP, problem diskriminantne validnosti ne postoji. Uz to, kako je i u prethodnom modelu provedena kontrola putem EFA, isti se zaključak o postojanju dvaju različitih faktora može donijeti i za alternativni model. Zaključno se može reći kako u alternativnom CB-SEM modelu ne postoji problem diskriminantne validnosti te je svaki faktor uistinu različit od ostalih faktora u modelu.

Tablica 5.34. Rezultati analize diskriminantne validnosti alternativnog CB-SEM modela

	HEU	PT	KRDO	ER	STAB	PRIL	TF	IO	IP
HEU	**0.716**								
PT	0.021	**0.720**							
KRDO	-0.119	0.607	**0.711**						
ER	-0.154	0.653	0.539	**0.755**					
STAB	0.468	-0.152	-0.114	-0.156	**0.750**				
PRIL	0.487	0.038	-0.011	0.043	0.712	**0.736**			
TF	0.635	0.358	0.191	0.131	0.409	0.395	**0.801**		
IO	0.713	-0.067	-0.249	-0.147	0.589	0.533	0.736	**0.747**	
IP	0.550	-0.052	-0.192	-0.113	0.455	0.412	0.568	0.772	**0.811**

Izvor: izračun autorice

5.3.4 Analiza CB-SEM alternativnog strukturalnog modela bihevioralnih financija

Ovaj model, uz bihevioralne faktore, promatra i tržišne faktore, odnosno stavove ispitanika o analiziranju tržišnih faktora prije ulaganja u dionice. U prethodnom poglavlju prikazani su indikatori svih faktora alternativnog modela, koji su većinom jednaki i prikazani su na ljestvici od 1 do 5. S obzirom da je ovaj model samo proširenje postojećeg prethodno procijenjenog modela, i u ovom slučaju izabrana metoda procjene je robusna WLSMV metoda. Modeliranje je također provedeno u programu Mplus.

U tablici 5.35. nalaze se rezultati strukturalnog modela te pokazatelji prilagodbe. U modelu se nalazi 9 faktora s ukupno 48 indikatora, 254 slobodna parametra, a ima 916 stupnjeva slobode. To ga čini previše identificiranim i prikladnim za analizu. Vrijednost hi-kvadrat testa i u ovom modelu je statistički značajna (p-vrijednost ≤ 0.001), što je očekivan rezultat, s obzirom na veličinu uzorka od 310 ispitanika, zbog koje se može dobiti veća vrijednost hi-kvadrata. Također se može opet napomenuti kako nije zadovoljen uvjet multivarijatne normalnosti pa je upitno slijedi li testna veličina hi-kvadrat distribuciju. Vrijednost pokazatelja RMSEA malo je bolja u odnosu na prethodni model i iznosi 0.081, što je manje od 0.10 i smatra se prihvatljivim. S druge strane, i ovaj model ima relativno slabije pokazatelje CFI i TLI, koji su ispod granice od 0.90 (CFI= 0.848, TLI= 0.836), ali malo su bolji u odnosu na prethodno procijenjeni model.

Promatrajući pokazatelje prilagodbe, vidljivo je da niti alternativni model ne reproducira matricu kovarijance među varijablama indikatora dovoljno dobro. Istovremeno, relativno poboljšanje modela u odnosu na *null* model, gledano kroz CFI i TLI, približava se granici prihvatljivog, no ipak još uvijek može biti bolje. Prosječna kvadratna pogreška procjene u modelu relativno je mala, ukazujući na dobru prilagodbu modela. Stoga, u alternativnom CB-SEM modelu pokazatelji prilagodbe poboljšani su u odnosu na originalni model, no ipak i dalje nisu u potpunosti zadovoljavajući.

U tablici 5.35. prikazani su i standardizirani koeficijenti strukturalnog modela s pripadajućim p-vrijednostima. Pet od osam pretpostavljenih uzročno-posljedičnih veza je statistički značajno, a zaključci su većinom isti kao u prethodnom modelu. Rezultati pokazuju da heuristike pozitivno i statistički značajno utječu na investicijske odluke, odnosno češćim korištenjem heuristikom samouvjerenosti povećava se broj dugoročno korisnih odluka o ulaganju kod ispitanika u uzorku. Stoga se i temeljem rezultata procjene alternativnog modela odbacuje hipoteza H1. Još jedna

statistički značajna veza je utjecaj ponašanja krda na investicijske odluke, koji je negativan i statistički značajan. Ovo opet ukazuje na zaključak da češće korištenje sugestija prijatelja, savjetnika ili ostalih investitora, kao temelja za odluke o ulaganju, dovodi do manjeg broja dugoročno korisnih odluka. Prema tome, hipoteza H3 se također odbacuje, jednako kao i u prethodnom modelu. Nadalje, u alternativnom modelu jednak je zaključak i za utjecaj karakteristika osobnosti. Naime, stabilnost utječe pozitivno i značajno na investicijske odluke, a prilagodljivost ne. Stoga se prihvaća pomoćna hipoteza H5.1., kojom se pretpostavlja da investitori sa stabilnijom osobnošću donose značajno veći broj dugoročno korisnih odluka o ulaganju. Pomoćna hipoteza H5.2. se odbacuje, jer utjecaj prilagodljivosti kao karakteristike osobnosti nije značajan. Stoga je i za hipotezu H5 zaključak jednak za oba modela, tj. ova se hipoteza djelomično prihvaća. Dodatni latentni faktor, nazvan tržišnim faktorima (TF), koji se pojavljuje samo u alternativnom modelu, također pokazuje značajan pozitivan utjecaj na investicijske odluke, što dovodi do zaključka o prihvaćanju hipoteze H6, tj. analiziranje tržišnih faktora značajno povećava broj dugoročno korisnih odluka o ulaganju investitora na financijskom tržištu. Ovaj zaključak u skladu je s prethodnim istraživanjima i pokazuje da ispitanici koji više analiziraju cijene, trendove, financijska izvješća poduzeća i sl., posljedično pažljivo razmatraju svaku investiciju i preferiraju one dugoročne, jer na taj način postižu veće koristi. Sklonost riziku, razmatrana kroz faktor prospektne teorije, kao i emocije i raspoloženje, ne utječu značajno na investicijske odluke, čime se odbacuju hipoteze H2 i H4, što je rezultat koji je jednak i u originalnom modelu. Još jednom utvrđeno je i da investicijske odluke pozitivno i značajno utječu na investicijske performanse. Drugim riječima, investitori koji preferiraju dugoročna ulaganja i pažljivo razmatraju potencijalne investicije, u konačnici su i zadovoljniji svojim performansama, koje se očituju u zadovoljstvu stopom prinosa te odlukama o kupnji i prodaji svojih dionica. Ovaj rezultat ponovo potvrđuje hipotezu H7: Dugoročno korisne odluke o ulaganju pozitivno utječu na zadovoljstvo investicijskim performansama investitora na financijskom tržištu. Od navedenih statistički značajnih utjecaja, najjači je utjecaj investicijskih odluka na performanse. Što se tiče bihevioralnih faktora, najjači utjecaj na odlučivanje ima analiziranje tržišnih faktora, a najslabiji karakteristika stabilne osobnosti.

Tablica 5.35. Rezultati alternativnog strukturalnog modela s pokazateljima prilagodbe (CB-SEM)

Pretpostavljena veza	Standardizirani koeficijenti	p-vrijednost

HEU → IO	0.189	0.011
PT → IO	-0.157	0.117
KRDO → IO	-0.269	<0.001
ER → IO	0.064	0.358
STAB → IO	0.125	0.058
PRIL → IO	0.107	0.130
TF → IO	0.622	<0.001
IO → IP	0.772	<0.001
χ^2 = 2762.920, p-vrijednost ≤0.001, RMSEA (90% C.I.) = 0.081 (0.077-0.084), CFI=0.848, TLI=0.836		

Izvor: izračun autorice

Navedene veze za alternativni CB-SEM model grafički su prikazane *path* dijagramom na slici 5.3. U ovom modelu broj faktora povećan je za jedan, odnosno kao utjecajna varijabla (egzogeni faktor) dodan je faktor tržišta (TF). Visine standardiziranih faktorskih opterećenja, prikazane u tablici 5.33., vidljive su na strelicama koje se kreću od faktora prema indikatorima, dok su vrijednosti standardiziranih koeficijenata strukturalnog modela vidljive na strelicama koje se kreću od zavisnog do nezavisnog faktora. Kod endogenih faktora opet su prikazane i komponente pogreške. Za faktor IO vrijednost pogreške je 0.208, a za IP 0.404. Izračunom koeficijenata determinacije (R^2) za ove faktore, dolazi se do vrijednosti R^2 od 0.792 za IO te 0.596 za IP, što znači da izabrani prediktori u alternativnom modelu jako dobro objašnjavaju zavisne faktore IO i IP. Ovakav zaključak dobiven je i procjenom originalnog modela.

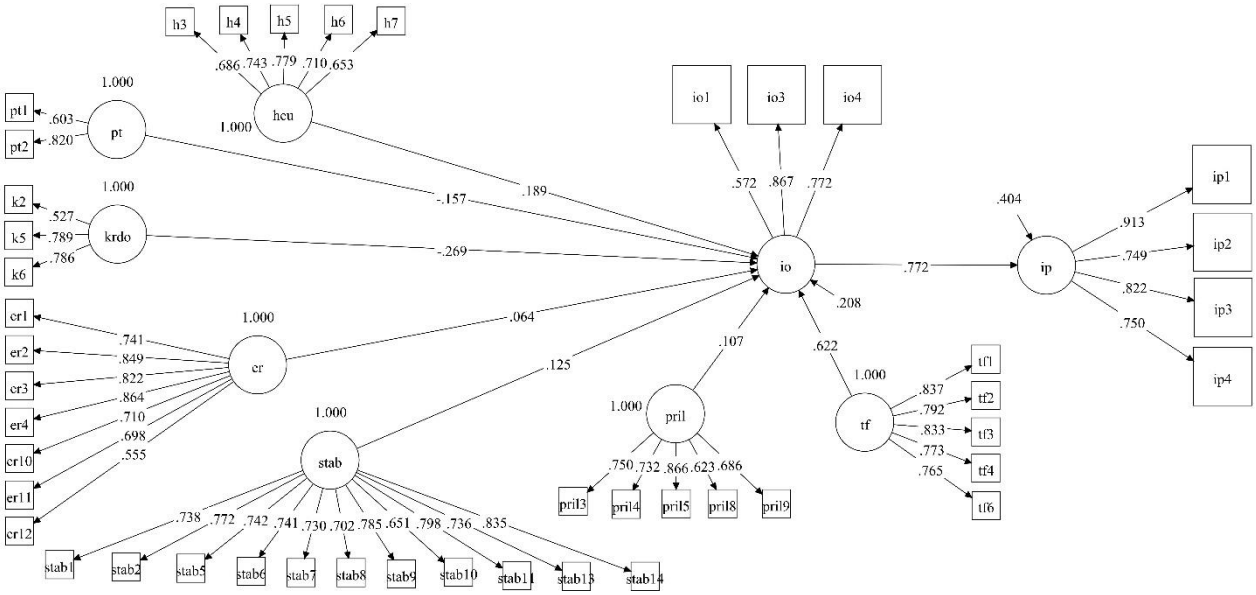

Slika 5.3. *Path* dijagram sa standardiziranim koeficijentima (alternativni CB-SEM model)

Izvor: izračun autorice uz pomoć programa Mplus

5.4 Analiza PLS-SEM modela

PLS-SEM metoda korištena je kao alternativa CB-SEM metodi, odnosno kao neparametrijski pristup procjeni modela. Kako je naglašeno u poglavlju 4.2., ova metoda ne zahtijeva pretpostavke normalnosti distribucije, što je istraživačima jedan od razloga korištenja PLS-SEM-a. Međutim, to ne može biti jedini razlog, s obzirom da i CB-SEM nudi alternativne metode procjene modela, poput WLSMV metode, koja je korištena u poglavlju 5.3. prilikom procjene CB-SEM originalnog i alternativnog modela. Ipak, s obzirom na to da prilagodba modela nije u potpunosti zadovoljavajuća, a daljnje respecifikacije modela ne dovode do poboljšanja, može se primijeniti neparametrijski PLS-SEM pristup. Osim toga, postojeća se teorija u ovom radu nastoji proširiti i istraživanje je donekle eksplorativno, jer model u ovakvom sveobuhvatnom obliku još uvijek nije testiran. Također, osim samog testiranja teorije, za praktičnu primjenu bitno je i predviđanje, što nudi upravo PLS-SEM. Model sadrži jako puno faktora i indikatora, tj. znatno je kompleksan, a također su i relevantni podaci, tj. varijable u bazi podataka iskazane kroz kvazi-omjernu skalu. Sve ovo upućuje na prednost korištenja PLS-SEM metode u odnosu na CB-SEM, kako je prethodno prikazano kroz smjernice odabira prikladne metode u tablici 4.4. Modeliranje PLS-SEM metodom provedeno je u programu SmartPLS, verzija 3.

5.4.1 Analiza PLS-SEM mjernog modela bihevioralnih financija

Kroz PLS-SEM modeliranje ponajprije je opet razmatran model koji ne uključuje tržišne faktore, s jednako pretpostavljenim vezama kao u CB-SEM modelu. Dakle, kao egzogene latentne varijable u modelu promatrani su: heuristike, elementi prospektne teorije, ponašanje krda, emocije i raspoloženje, prilagodljivost i stabilnost te se promatra njihov simultani utjecaj na investicijske odluke. Istovremeno se promatra i utjecaj investicijskih odluka na investicijske performanse. Ova dva faktora su endogene latentne varijable u modelu. Svi indikatori u modelu su reflektivni pa se sukladno tome i analizira mjerni model.

Prema smjernicama za modeliranje, također je inicijalni model obuhvaćao sva anketna pitanja kao indikatore za latentne varijable. U svrhu postignuća zadovoljavajućeg mjernog modela, indikatori su se postepeno izbacivali iz modela, ovisno o vrijednostima njihovih vanjskih opterećenja. Ovim pristupom došlo se i do konačnog PLS-SEM modela. Indikatori koji su ostali zadržani u konačnom modelu prikazani su u tablici 5.36. Ovi indikatori ne razlikuju se značajno od onih koji su uključeni u konačni CB-SEM model. Naime, iz područja heuristika također su u modelu ostali isključivo

indikatori koji su u anketi predstavljali tvrdnje vezane za pretjeranu samouvjerenost investitora. Što se tiče prospektne teorije, u PLS-SEM konačnom modelu, ostali su uključeni potpuno drugačiji indikatori u odnosu na CB-SEM model. Naime, dok su kod CB-SEM modela indikatori bili povezani sa sklonosti riziku, kod PLS-SEM modela konačni model obuhvaća indikatore koji se odnose na sklonost mentalnom računovodstvu te averziju prema gubitku. Faktor emocija i raspoloženja u ovom modelu uključuje znatno manji broj indikatora, koji se odnose na optimizam i nadu pri ulaganju dionica. Kod prilagodljivosti i stabilnosti nema značajnijih promjena u indikatorima u odnosu na CB-SEM, a isti je slučaj i kod endogenih latentnih varijabli, tj. investicijskih odluka i performansi. Nakon 10 iteracija, postignuto je rješenje PLS-SEM modela.

Tablica 5.36. Indikatori faktora u konačnom PLS-SEM modelu

Heuristike (HEU)
H3 - Smatram da mi moje vještine i znanje o tržištu dionica mogu pomoći da nadigram tržište. H4 - Oslanjam se na svoja prethodna iskustva na tržištu za donošenje odluka o budućim investicijama. H5 - Siguran sam da mogu donijeti ispravnu investicijsku odluku. H6 - Smatram da su tržišni trendovi često u skladu s mojim očekivanjima. H7 - Smatram da je povrat od ulaganja u dionicu uvijek ostvaren zbog moje uspješne investicijske strategije. H9 - Obično mogu predvidjeti kada će završiti razdoblja dobrih ili loših povrata na tržištu.
Elementi prospektne teorije (PT)
PT6 - Tretiram svaki element svog investicijskog portfelja odvojeno. PT7 - Preferiram dugoročnu sigurnost svojih sredstava nego kratkoročne novčane dobitke. PT8 - Od početka ulažem u sigurnije dionice.
Ponašanje krda (KRDO)
K2 - Uložio bih u dionice prema sugestijama svojih prijatelja. K5 - Slijedim ono što moj savjetnik sugerira tijekom ulaganja. K6 - Slijedim savjete ostalih investitora dok kupujem dionice jer nemam odgovarajuće znanje.
Emocije i raspoloženje (ER)
ER5 - Moj pozitivan pogled na život potiče me da ulažem u dionice. ER6 - Radujem se svojoj sljedećoj prilici za ulaganje nakon dubokog pada na tržištu. ER13 - Jako sam oduševljen ulaganjem tijekom faze rasta ili oporavka tržišta.
Prilagodljivost (PRIL)
PRIL3 - Pun sam energije. PRIL4 - Stvaram puno entuzijazma. PRIL5 - Samopouzdan sam. PRIL7 - Genijalan sam i dubok mislilac. PRIL8 - Imam aktivnu maštu. PRIL9 - Inventivan sam.
Stabilnost (STAB)
STAB1 - Radim temeljit posao. STAB2 - Pouzdan sam radnik.

STAB5 - Ustrajem u zadatku dok nije gotov. STAB6 - Općenito radim sve učinkovito. STAB7 - Pravim planove i slijedim ih. STAB8 - Pomažem i nesebičan sam prema drugima. STAB9 - Općenito sam pouzdan. STAB10 - Volim surađivati s drugima. STAB11 - Opušten sam i dobro podnosim stres. STAB14 - Ostajem smiren u napetim situacijama.
Investicijske odluke (IO)
IO1 - Ulažem u investicije koje će donijeti dugoročne koristi. IO3 - Redovito pregledam, usporedim i potom donesem odluke o svom investicijskom potezu. IO4 - Istražujem tržište prije bilo kakvog kratkoročnog ulaganja. IO5 - Ulažem više sredstava u dugoročne nego kratkoročne investicije.
Investicijske performanse (IP)
IP1 - Zadovoljan sam stopom prinosa svojih nedavnih ulaganja u dionice. IP2 - Smatram da je prinos na dionice u koje ulažem bolji od prinosa većine drugih dionica. IP3 - Zadovoljan sam svojim odlukama o kupnji dionica u protekloj godini dana. IP4 - Zadovoljan sam svojim odlukama o prodaji dionica u protekloj godini dana.

Izvor: izrada autorice

S obzirom da su svi indikatori u modelu reflektivni, mjerni model se analizira putem validnosti i pouzdanosti konstrukata. Konvergentna validnost i pouzdanost u PLS-SEM modelima zahtijeva sličnu analizu kao i CB-SEM model. Naime, za konstrukte mjernog modela potrebno je ispitati vrijednosti i značajnost vanjskih opterećenja te izračunati pokazatelje AVE, kompozitnu pouzdanost (ρ_c) i Cronbach's alpha koeficijent. Rezultati ove analize za PLS-SEM model prikazani su u tablici 5.37. Sva vanjska opterećenja statistički su značajna, a njihove vrijednosti kreću se većinom od 0.6 prema većim vrijednostima. Izuzetak su dva indikatora (H9 i ER5) koji imaju malo manju vrijednost od 0.6, no zadržani su u modelu, jer ne narušavaju kriterij validnosti pripadajućih konstrukata. Kroz ove vrijednosti može se zaključiti da svi indikatori dobro odražavaju konstrukte koje mjere. Konvergentna validnost ispitana je putem AVE pokazatelja, od kojih su svi veći od 0.5, odnosno minimalno 50% varijance indikatora objašnjeno je svakim konstruktom. Pouzdanost konstrukata ispitana je preko Cronbach's alpha koeficijenta i kompozitne pouzdanosti (ρ_c). Svi Cronbach's alpha pokazatelji premašuju vrijednost od 0.60, izuzev faktora ER s vrijednosti pokazatelja od 0.561. Osim toga, Cronbach's alpha vrijednosti za PT i KRDO nalaze se između 0.6 i 0.7, odnosno malo su niže od ostalih. S obzirom da sva tri spomenuta faktora imaju po tri indikatora, a Cronbach's alpha koeficijent je osjetljiv na broj indikatora, tu se može pronaći objašnjenje ovih malo nižih vrijednosti. Općenito, ove vrijednosti ukazuju na umjerenu ili

visoku pouzdanost svih konstrukata u modelu (Hinton et al., 2004). Inače se u PLS-SEM analizi preferira pokazatelj kompozitne pouzdanosti (ρ_c), jer ne pretpostavlja da su sva vanjska opterećenja jednaka u populaciji, odnosno da su svi indikatori jednako pouzdani, što je u skladu s principom rada PLS-SEM algoritma, koji daje prioritet indikatorima temeljem njihovih pojedinačnih pouzdanosti tijekom procjene modela (Hair et al., 2014; Hair et al., 2017a). Vrijednosti kompozitne pouzdanosti za sve promatrane latentne konstrukte nalaze se iznad granice od 0.7, što ukazuje na zadovoljavajuću pouzdanost konstrukata u modelu. U konačnici, može se zaključiti da PLS-SEM analiza mjernog modela pokazuje da su izabrani indikatori prikladni te da jako dobro objašnjavaju svoje pripadajuće konstrukte u modelu.

Tablica 5.37. Rezultati analize konvergentne validnosti i pouzdanosti PLS-SEM modela

	Vanjsko opterećenje	AVE	ρ_c	Cronbach's alpha
Heuristike (HEU)				
H3	0.774**	0.512	0.862	0.816
H4	0.726**			
H5	0.778**			
H6	0.716**			
H7	0.690**			
H9	0.591**			
Elementi prospektne teorije (PT)				
PT6	0.656**	0.559	0.790	0.607
PT7	0.831**			
PT8	0.746**			
Ponašanje krda (KRDO)				
K2	0.771**	0.604	0.820	0.690
K5	0.720**			
K6	0.835**			
Emocije i raspoloženje (ER)				
ER13	0.724**	0.523	0.762	0.561
ER5	0.563**			
ER6	0.853**			
Prilagodljivost (PRIL)				
PRIL3	0.735**	0.509	0.861	0.807
PRIL4	0.718**			
PRIL5	0.781**			
PRIL7	0.615**			
PRIL8	0.687**			
PRIL9	0.732**			
Stabilnost (STAB)				
STAB1	0.759**	0.512	0.913	0.893
STAB10	0.640**			
STAB11	0.605**			
STAB14	0.647**			
STAB2	0.783**			

STAB5	0.739**			
STAB6	0.723**			
STAB7	0.727**			
STAB8	0.695**			
STAB9	0.813**			
Investicijske odluke (IO)				
IO1	0.787**	0.580	0.846	0.757
IO3	0.815**			
IO4	0.755**			
IO5	0.682**			
Investicijske performanse (IP)				
IP1	0.895**	0.689	0.898	0.849
IP2	0.790**			
IP3	0.860**			
IP4	0.770**			
*** značajno na razini 0.01*				

Izvor: izračun autorice

U PLS-SEM modelu, diskriminantna validnost ispitana je kroz dva kriterija. Prvi kriterij jednak je kao i kod CB-SEM modela, a radi se o Fornell-Larcker kriteriju. Stoga, u tablici 5.38. vidljiva je korelacijska matrica među konstruktima, dok se na dijagonali nalaze vrijednosti drugog korijena svake pojedine AVE vrijednosti konstrukata. U modelu ne postoji problem diskriminantne validnosti, s obzirom da su vrijednosti na dijagonali veće od korelacijskih koeficijenata u relevantnim redcima i stupcima. Drugim riječima, svaki konstrukt bolje objašnjava varijancu svojih indikatora u odnosu na indikatore ostalih konstrukata, tj. svaki je promatrani konstrukt uistinu različit od ostalih konstrukata u modelu.

Tablica 5.38. Rezultati analize diskriminantne validnosti PLS-SEM modela prema Fornell-Larcker kriteriju

	ER	HEU	IO	IP	KRDO	PRIL	PT	STAB
ER	**0.723**							
HEU	0.371	**0.715**						
IO	0.397	0.425	**0.761**					
IP	0.286	0.537	0.513	**0.830**				
KRDO	0.056	-0.066	-0.075	-0.246	**0.777**			
PRIL	0.299	0.447	0.370	0.390	-0.021	**0.713**		
PT	0.176	0.201	0.465	0.219	0.200	0.103	**0.748**	
STAB	0.356	0.404	0.485	0.443	-0.066	0.622	0.341	**0.716**

Izvor: izračun autorice

Drugi pristup analizi diskriminantne validnosti u PLS-SEM modelima je korištenje HTMT pokazatelja, koji se smatra najefikasnijim pristupom u utvrđivanju diskriminantne validnosti

(Henseler, Ringle i Sarstedt, 2015). U tablici 5.39. rezultati pokazuju da su sve HTMT vrijednosti ispod granične vrijednosti od 0.85, ukazujući na nepostojanje problema diskriminantne validnosti u modelu. Naime, ove manje vrijednosti HTMT-a pokazuju da su korelacije među indikatorima koje mjere različite konstrukte manje u odnosu na korelacije između indikatora koji mjere isti konstrukt. Upravo iz ovoga proizlazi zaključak da je diskriminantna validnost u modelu potvrđena.

Tablica 5.39. Rezultati analize diskriminantne validnosti PLS-SEM modela prema HTMT pokazatelju

	ER	HEU	IO	IP	KRDO	PRIL	PT	STAB
ER								
HEU	0.475							
IO	0.545	0.497						
IP	0.392	0.636	0.622					
KRDO	0.395	0.157	0.152	0.301				
PRIL	0.428	0.542	0.447	0.455	0.107			
PT	0.375	0.297	0.673	0.299	0.360	0.205		
STAB	0.478	0.448	0.581	0.515	0.134	0.725	0.440	

Izvor: izračun autorice

Kao dodatna potvrda nepostojanja problema kod diskriminantne validnosti, uz pomoć *bootstrapping* procedure u programu SmartPLS, izračunate su donja i gornja granica 95%-tnog intervala pouzdanosti svakog HTMT-a. Kao što se vidi iz tablice 5.40., niti jedan interval ne sadrži vrijednost 1, što je i očekivano s obzirom na vrijednosti HTMT-a u modelu. Stoga, i na ovaj način potvrđuje se diskriminantna validnost konstrukata u modelu.

Tablica 5.40. Intervali pouzdanosti HTMT-a (originalni PLS-SEM model)

	Originalni uzorak	**Donja granica**	**Gornja granica**
HEU → ER	0.475	0.338	0.626
IO → ER	0.545	0.376	0.711
IO → HEU	0.497	0.403	0.606
IP → ER	0.392	0.233	0.557
IP → HEU	0.636	0.530	0.719
IP → IO	0.622	0.524	0.709
KRDO → ER	0.395	0.281	0.566
KRDO → HEU	0.157	0.132	0.271
KRDO → IO	0.152	0.101	0.290
KRDO → IP	0.301	0.182	0.441
PRIL → ER	0.428	0.297	0.589
PRIL → HEU	0.542	0.444	0.641

PRIL → IO	0.447	0.304	0.594
PRIL → IP	0.455	0.340	0.560
PRIL → KRDO	0.107	0.101	0.227
PT → ER	0.375	0.201	0.586
PT → HEU	0.297	0.235	0.432
PT → IO	0.673	0.518	0.828
PT → IP	0.299	0.169	0.456
PT → KRDO	0.360	0.242	0.513
PT → PRIL	0.205	0.147	0.362
STAB → ER	0.478	0.335	0.616
STAB → HEU	0.448	0.353	0.558
STAB → IO	0.581	0.438	0.695
STAB → IP	0.515	0.399	0.629
STAB → KRDO	0.134	0.119	0.257
STAB → PRIL	0.725	0.637	0.799
STAB → PT	0.440	0.314	0.591

Izvor: izračun autorice

Zaključno, diskriminantna validnost je potvrđena koristeći Fornell-Larcker kriterij, kao i koristeći HTMT pokazatelj. Na ovaj način, dvostrukom provjerom utvrđeno je da su konstrukti međusobno različiti i da ih njihovi pripadajući indikatori dobro mjere.

5.4.2 Analiza PLS-SEM strukturalnog modela bihevioralnih financija

Strukturalni model opet prikazuje uzročno-posljedične veze između bihevioralnih faktora, investicijskih odluka i performansi, na isti način kao i prethodno procijenjeni CB-SEM model. Model se, dakle, sastoji od 8 konstrukata, od kojih je 6 egzogenih (bihevioralni faktori) i 2 endogena konstrukta (investicijske odluke i investicijske performanse). PLS algoritam postigao je rješenje nakon 10 iteracija te su dobiveni strukturalni koeficijenti, čija je statistička značajnost izračunata kroz *bootstrapping* proceduru. Za razliku od CB-SEM modela, u PLS-SEM modelu svi strukturalni koeficijenti su statistički značajni, što je vidljivo iz tablice 5.41.

PLS-SEM model također daje rješenje koje pokazuje pozitivan i statistički značajan utjecaj korištenja heuristika na investicijske odluke. S obzirom da se skup pitanja, tj. indikatora, koji predstavljaju heuristike ne razlikuje u odnosu na CB-SEM, može se zaključiti da se zapravo radi o pozitivnom utjecaju pretjerane samouvjerenosti investitora. Drugim riječima, investitori koji se više koriste heuristikom samouvjerenosti, posljedično će više ulagati u one dionice koje će im donijeti više dugoročnih koristi. Zaključak je još jednom u suprotnosti s postavljenom hipotezom

H1, koja se odbacuje. Elementi prospektne teorije također pozitivno i značajno utječu na investicijske odluke, a zaključak se razlikuje u odnosu na onaj temeljem CB-SEM modela, gdje ovaj bihevioralni faktor nije pokazao značajan utjecaj. Razlog ovome može se pronaći i u činjenici što su postupnim modeliranjem putem ove dvije metode kod elemenata prospektne teorije u konačnom modelu zadržani različiti indikatori. Kao što je prethodno spomenuto, indikatori ovog faktora odnose se na sklonost mentalnom računovodstvu i averziju prema gubitku. Dakle, može se utvrditi da ispitanici koji se više koriste pristranosti mentalnom računovodstvu i koji „igraju na sigurno“ u svojim ulaganjima, posljedično donose promišljenije odluke koje im donose dugoročne koristi. Na temelju ovih rezultata može se prihvatiti hipoteza H2. Isti zaključak kao u CB-SEM modelima donesen je za ponašanje krda. Naime, ovaj bihevioralni faktor statistički značajno negativno utječe na donošenje investicijskih odluka. Odnosno, investitori koji više slijede savjete prijatelja ili drugih investitora posljedično će manje ulagati u investicije koje će im donijeti dugoročne koristi. Ovaj rezultat ukazuje na zaključak o odbacivanju hipoteze H3. Nadalje, u ovom modelu na investicijske odluke značajno i pozitivno utječu i emocije i raspoloženje. Promatrajući indikatore ovog faktora, zaključuje se da ispitanici koji su više optimistični i polažu više nade pri svojim ulaganjima, odnosno ispitanici koji pokazuju više pozitivnih emocija, donose znatno veći broj dugoročno korisnih odluka, čime se potvrđuje hipoteza H4. Karakteristike osobnosti također značajno utječu na odlučivanje investitora. Naime, utjecaj dimenzije prilagodljivosti značajan je pri razini signifikantnosti od 10% i pozitivan je. Druga dimenzija osobnosti, tj. stabilnost, također značajno utječe na investicijske odluke, ali pri razini signifikantnosti od 5%, a njezin utjecaj također je pozitivan. Ovi rezultati ukazuju da ispitanici kod kojih se očituje ekstrovertirana i otvorena karakteristika osobnosti posljedično donose veći broj investicijskih odluka pomoću kojih će ostvariti koristi na dugi rok. Dodatno, ispitanici koji su u većoj mjeri savjesni i teže stabilnosti svojih ciljeva, isto tako donose veći broj dugoročno korisnih investicijskih odluka. Time se mogu potvrditi pomoćne hipoteze H5.1 i H5.2, kao i glavna hipoteza H5. Posljednja veza u modelu je ona veza između investicijskih odluka i performansi, gdje je zaključak isti kao za CB-SEM modele. Dakle, može se reći da investitori koji donose više dugoročno korisnih odluka u konačnici ostvaruju značajno veću razinu zadovoljstva svojim performansama, koje se odnose na vlastite odluke o kupnji i prodaji dionica, kao i ostvarenom stopom prinosa. Temeljem ovog zaključka, prihvaća se hipoteza H7: Dugoročno korisne odluke o ulaganju pozitivno utječu na zadovoljstvo investicijskim performansama investitora na financijskom tržištu. Ovaj je utjecaj ujedno najsnažniji u modelu, što

je vidljivo iz njegovog strukturalnog koeficijenta. Na investicijske odluke najveći utjecaj imaju elementi prospektne teorije.

Tablica 5.41. Rezultati strukturalnog modela (PLS-SEM)

Pretpostavljena veza	Strukturalni koeficijent	p-vrijednost
HEU → IO	0.162	0.003
PT → IO	0.363	<0.001
KRDO → IO	-0.135	0.046
ER → IO	0.196	<0.001
PRIL → IO	0.104	0.092
STAB → IO	0.152	0.026
IO → IP	0.513	<0.001

Izvor: izračun autorice

Na slici 5.4. prikazane su sve navedene uzročno-posljedične veze procijenjenog PLS-SEM modela kroz *path* dijagram. Oznake su iste kao u CB-SEM modelu, tj. krugovi predstavljaju latentne konstrukte, a pravokutnici indikatore. Na strelicama koje se kreću od latentnih konstrukata prema indikatorima vidljiva su vanjska opterećenja, koja su prethodno prikazana u tablici 5.37. Strelice koje se kreću od jednog prema drugom latentnom konstruktu prikazuju strukturalne koeficijente. Svi bihevioralni faktori opet prikazuju egzogene konstrukte, dok su investicijske odluke i investicijske performanse endogeni konstrukti. Osim toga, na dijagramu unutar krugova koji predstavljaju dva navedena endogena konstrukta, može se pronaći vrijednost koeficijenta determinacije (R^2), kao jedne od mjera eksplanatorne snage modela, o kojima će biti riječi u nastavku.

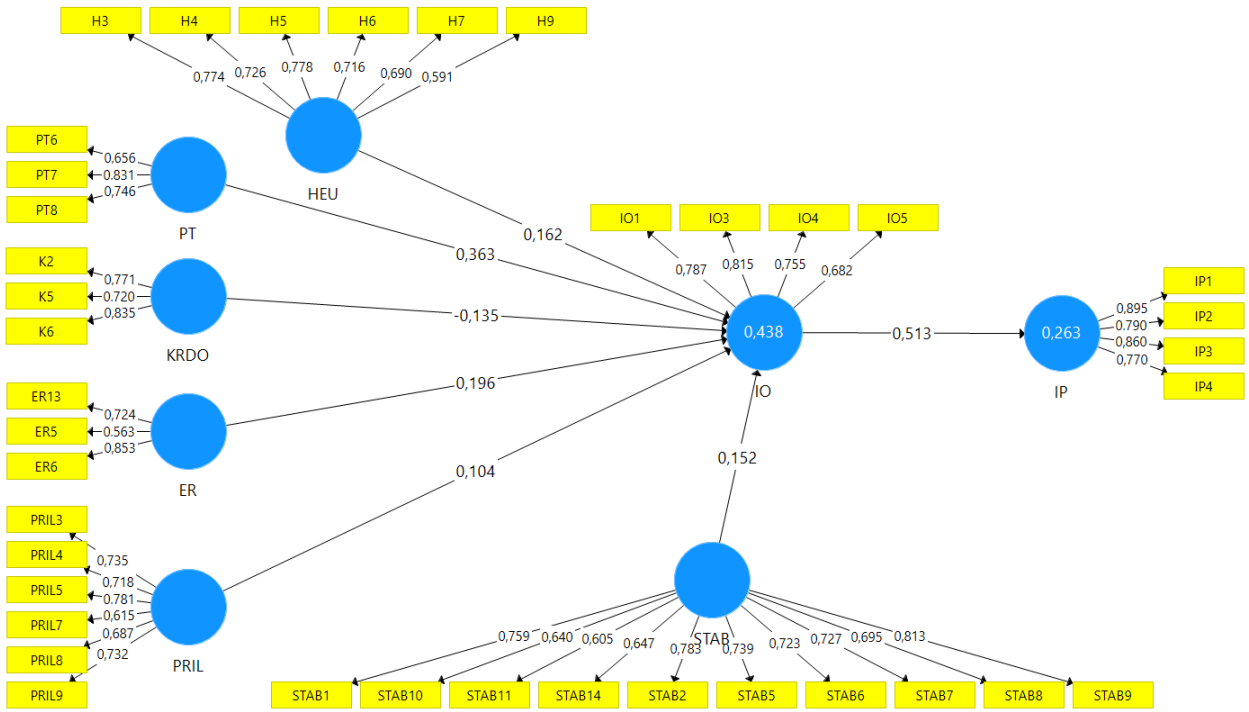

Slika 5.4. *Path* dijagram sa strukturalnim koeficijentima (PLS-SEM model)

Izvor: izračun autorice uz pomoć programa SmartPLS

Promatrajući eksplanatornu snagu procijenjenog PLS-SEM modela kroz tablicu 5.42., prvenstveno se može utvrditi da su koeficijenti determinacije (R^2) poprilično visoki. Naime, već je spomenuto da su za društvene i bihevioralne znanosti poželjne vrijednosti pokazatelja od 0.26 i više, kako bi se utvrdilo da model ima visoku eksplanatornu snagu. Za oba endogena konstrukta ovi su pokazatelji veći od navedene granice, što potvrđuje visoku eksplanatornu snagu procijenjenog modela. Koeficijentima determinacije utvrđuje se da je visok udio varijance u endogenim konstruktima (43.8% i 26.3%) objašnjen kombinacijom utjecaja egzogenih latentnih varijabli na endogenu latentnu varijablu. Vrijednosti korigiranih koeficijenata determinacije (R^2_{adj}) vrlo su slične. Još jedna mjera eksplanatorne snage je veličina efekta (f^2), koja je također prikazana u tablici 5.42. za utjecaj svakog pojedinog nezavisnog konstrukta na zavisni. Većina bihevioralnih faktora pokazuje slabu veličinu efekta na zavisni konstrukt, što se može vidjeti iz vrijednosti pokazatelja između 0.02 i 0.14. Faktor prilagodljivosti nema značajan utjecaj prema ovom pokazatelju, dok faktor prospektne teorije ima umjeren utjecaj. Uspoređujući ove veličine s visinama strukturalnih koeficijenata i njihovom statističkom značajnosti (tablica 5.41. i slika 5.4.),

rezultati su poprilično usklađeni. Prilagodljivost je statistički značajno utjecala na investicijske odluke tek pri razini signifikantnosti od 10%, što je u skladu sa zaključkom da ima najnižu, odnosno beznačajnu veličinu efekta. Investicijske odluke pokazuju značajno visok efekt (>0.35) na investicijske performanse, što je također u skladu s visinom i značajnosti tog strukturalnog koeficijenta.

Što se tiče prediktivne snage modela, rezultati su također dani u tablici 5.42. Prvenstveno je ispitan Stone-Geisser Q^2 pokazatelj, dobiven putem *blindfolding* procedure. Kod IO on iznosi 0.241, a kod IP 0.173. Ove vrijednosti nalaze se u rasponu između 0.15 i 0.35, ukazujući tako na postojanje umjerene prediktivne snage modela. Odnosno, model ima umjerenu sposobnost da adekvatno predvidi podatke koji nisu korišteni u procjeni modela. Nakon toga, provedena je i PLSpredict procedura, temeljena na konceptima odvojenih „*training*“ i „*holdout*“ uzoraka za procjenu parametara i prediktivne snage modela. Procjene su izračunate za endogene konstrukte IO i IP, odnosno njihove indikatore. Sukladno proceduri (Shmueli et al., 2019), najprije su ispitane vrijednosti $Q^2_{predict}$ veličine, gdje su se sve vrijednosti pokazale kao pozitivne, tj. veće od nula. Stoga se nastavlja analiza usporedbom RMSE procijenjenog PLS-SEM modela u odnosu na RMSE LM modela. Za konstrukt IO jednak broj RMSE vrijednosti manji je kod PLS-SEM modela u odnosu na LM model, dok je kod konstrukta IP samo jedna RMSE vrijednost veća kod PLS-SEM modela u odnosu na LM model. Gledajući oba endogena konstrukta sveukupno za ovaj model, za većinu indikatora PLS-SEM procjene pogreške RMSE manje su u usporedbi s onima iz LM modela. Prateći smjernice za interpretaciju, zaključno se može ustanoviti da ovaj model ima srednje jaku, tj. umjerenu prediktivnu snagu.

Tablica 5.42. Rezultati analize eksplanatorne i prediktivne snage modela (PLS-SEM)

	R^2	R^2_{ajd}	Q^2	f^2	IO	IP	PLSpredict	Q^2 predict	PLS RMSE	LM RMSE
IO	0.438	0.427	0.241	ER	0.055		IO3	0.218	0.787	0.801
IP	0.263	0.261	0.173	HEU	0.033		IO1	0.307	0.793	0.771
				IO		0.357	IO4	0.174	0.890	0.915
				IP			IO5	0.192	0.949	0.890
				KRDO	0.030		IP1	0.205	0.847	0.848
				PRIL	0.011		IP3	0.165	0.914	0.921
				PT	0.187		IP2	0.142	0.836	0.836
				STAB	0.021		IP4	0.170	1.020	0.997

Izvor: izračun autorice

Iako pokazatelji prilagodbe modela za PLS-SEM nisu u potpunosti razvijeni, u tablici 5.43. prikazana su dva pokazatelja, SRMR i RMS_{theta}. Temeljem njihovih vrijednosti, može se zaključiti da SRMR neznatno prelazi granicu od 0.10, što bi ukazivalo da prilagodba modela nije zadovoljavajuća. S druge strane, vrijednost RMS_{theta} se nalazi ispod granice od 0.14, ukazujući na zadovoljavajuću prilagodbu modela. Ipak, ove rezultate treba uzeti s rezervom, s obzirom da je za mjere prilagodbe modela u PLS-SEM analizi potrebno daljnje unaprjeđenje.

Tablica 5.43. Pokazatelji prilagodbe modela (PLS-SEM)

Pokazatelj prilagodbe modela	
SRMR	0.101
RMS_{theta}	0.138

Izvor: izračun autorice

5.4.3 Analiza PLS-SEM alternativnog mjernog modela bihevioralnih financija

Alternativni PLS-SEM model sadrži dodatni egzogeni latentni konstrukt, uz već postojeće konstrukte iz prethodno procijenjenog modela. Naime, radi se o latentnom konstruktu koji predstavlja tržišne faktore kao još jednu nezavisnu varijablu. Dakle, u ovom modelu pojavljuje se sedam egzogenih konstrukata, a to su: heuristike, elementi prospektne teorije, ponašanje krda, emocije i raspoloženje, prilagodljivost, stabilnost i tržišni faktori. Još jednom promatrano je njihovo djelovanje na endogeni konstrukt investicijske odluke, a istovremeno se promatra i utjecaj investicijskih odluka na investicijske performanse, kao još jedan endogeni konstrukt. Ovako specificiran model, odnosno konstrukti i veze među njima, jednake su alternativnom CB-SEM modelu. Kao i svi bihevioralni faktori, koji su procijenjeni u PLS-SEM modelu, tako je i dodatni konstrukt tržišnih faktora reflektivan. U skladu s tim, mjerni model se analizira na isti način kao u prvotno postavljenom PLS-SEM modelu. Indikatori koji su zadržani u konačnom modelu jednaki su onima iz prethodnog modela za sve bihevioralne faktore te investicijske odluke i performanse. Što se tiče tržišnih faktora, konačni model obuhvaća 6 od 7 potencijalnih indikatora ovog konstrukta. Indikatori svih faktora alternativnog PLS-SEM modela prikazani su u tablici 5.44.

Tablica 5.44. Indikatori faktora u konačnom alternativnom PLS-SEM modelu

Heuristike (HEU)
H3 - Smatram da mi moje vještine i znanje o tržištu dionica mogu pomoći da nadigram tržište.
H4 - Oslanjam se na svoja prethodna iskustva na tržištu za donošenje odluka o budućim investicijama.
H5 - Siguran sam da mogu donijeti ispravnu investicijsku odluku.

H6 - Smatram da su tržišni trendovi često u skladu s mojim očekivanjima. H7 - Smatram da je povrat od ulaganja u dionicu uvijek ostvaren zbog moje uspješne investicijske strategije. H9 - Obično mogu predvidjeti kada će završiti razdoblja dobrih ili loših povrata na tržištu.
Elementi prospektne teorije (PT)
PT6 - Tretiram svaki element svog investicijskog portfelja odvojeno. PT7 - Preferiram dugoročnu sigurnost svojih sredstava nego kratkoročne novčane dobitke. PT8 - Od početka ulažem u sigurnije dionice.
Ponašanje krda (KRDO)
K2 - Uložio bih u dionice prema sugestijama svojih prijatelja. K5 - Slijedim ono što moj savjetnik sugerira tijekom ulaganja. K6 - Slijedim savjete ostalih investitora dok kupujem dionice jer nemam odgovarajuće znanje.
Emocije i raspoloženje (ER)
ER5 - Moj pozitivan pogled na život potiče me da ulažem u dionice. ER6 - Radujem se svojoj sljedećoj prilici za ulaganje nakon dubokog pada na tržištu. ER13 - Jako sam oduševljen ulaganjem tijekom faze rasta ili oporavka tržišta.
Prilagodljivost (PRIL)
PRIL3 - Pun sam energije. PRIL4 - Stvaram puno entuzijazma. PRIL5 - Samopouzdan sam. PRIL7 - Genijalan sam i dubok mislilac. PRIL8 - Imam aktivnu maštu. PRIL9 - Inventivan sam.
Stabilnost (STAB)
STAB1 - Radim temeljit posao. STAB2 - Pouzdan sam radnik. STAB5 - Ustrajem u zadatku dok nije gotov. STAB6 - Općenito radim sve učinkovito. STAB7 - Pravim planove i slijedim ih. STAB8 - Pomažem i nesebičan sam prema drugima. STAB9 - Općenito sam pouzdan. STAB10 - Volim surađivati s drugima. STAB11 - Opušten sam i dobro podnosim stres. STAB14 - Ostajem smiren u napetim situacijama.
Tržišni faktori (TF)
TF1 - Pažljivo razmatram promjene cijena dionica u koje želim uložiti. TF2 - Smatram da su tržišne informacije važne za moje ulaganje u dionice. TF3 - Razmatram prethodne trendove dionica prilikom svog ulaganja. TF4 - Prije donošenja investicijskih odluka, koristim fundamentalnu analizu za procjenu vrijednosti dionica. TF5 - Ulažem u poduzeća koja su u prošlosti isplaćivala veće dividende svojim dioničarima. TF6 - Pomno pratim financijska izvješća poduzeća prije nego što kupim njihove dionice.
Investicijske odluke (IO)
IO1 - Ulažem u investicije koje će donijeti dugoročne koristi. IO3 - Redovito pregledam, usporedim i potom donesem odluke o svom investicijskom potezu. IO4 - Istražujem tržište prije bilo kakvog kratkoročnog ulaganja.

IO5 - Ulažem više sredstava u dugoročne nego kratkoročne investicije.
Investicijske performanse (IP)
IP1 - Zadovoljan sam stopom prinosa svojih nedavnih ulaganja u dionice. IP2 - Smatram da je prinos na dionice u koje ulažem bolji od prinosa većine drugih dionica. IP3 - Zadovoljan sam svojim odlukama o kupnji dionica u protekloj godini dana. IP4 - Zadovoljan sam svojim odlukama o prodaji dionica u protekloj godini dana.

Izvor: izrada autorice

Za sve konstrukte analizirane su vrijednosti i statistička značajnost svih vanjskih opterećenja, kako bi se utvrdila pouzdanost indikatora. Osim toga, još jednom su izračunati pokazatelji AVE, kompozitna pouzdanost (ρ_c) i Cronbach's alpha, u svrhu utvrđivanja konvergentne validnosti i pouzdanosti konstrukata. Iz rezultata iz tablice 5.45., može se primijetiti kako su sva vanjska opterećenja statistički značajna. Njihove vrijednosti ne razlikuju se značajnije u odnosu na one iz prethodnog modela, odnosno vrijednosti se kreću većinom od 0.6 ili 0.7 i više. Malo manje vrijednosti opet se pronalaze kod indikatora H9 i ER5, kao i kod indikatora TF5, no oni su ipak i dalje zadržani u modelu, jer ne narušavaju validnost konstrukata koje mjere. AVE pokazatelji za sve konstrukte imaju vrijednosti veće od 0.5, ukazujući da je svakim konstruktom objašnjeno barem 50% varijance indikatora. Što se tiče pouzdanosti konstrukta, putem Cronbach's alpha koeficijenta, zaključak je jednak kao u prethodnom PLS-SEM modelu. Oni većinom pokazuju umjerenu ili visoku pouzdanost konstrukata. Faktor ER ima pokazatelj vrijednosti 0.561, dok su vrijednosti za PT i KRDO između 0.6 i 0.7. Kako ovi konstrukti imaju po tri indikatora, opet se u toj činjenici može pronaći dodatni razlog ovakvih rezultata, s obzirom da je koeficijent osjetljiv na broj indikatora. Prethodno je već navedeno da se kod PLS-SEM analize stoga preporučuje dati prednost pokazatelju kompozitne pouzdanosti (ρ_c). Vrijednosti ovog pokazatelja za sve promatrane konstrukte u modelu veće su od 0.7, potvrđujući zadovoljavajuću pouzdanost konstrukata u modelu. Dakle, prema svim analiziranim pokazateljima, zaključuje se da izabrani indikatori dobro objašnjavaju konstrukte koje mjere u modelu.

Tablica 5.45. Rezultati analize konvergentne validnosti i pouzdanosti alternativnog PLS-SEM modela

	Vanjsko opterećenje	AVE	ρ_c	Cronbach's alpha
Heuristike (HEU)				
H3	0.776**	0.513	0.863	0.816
H4	0.719**			
H5	0.777**			
H6	0.718**			

H7	0.694**			
H9	0.598**			
Elementi prospektne teorije (PT)				
PT6	0.672**	0.558	0.790	0.607
PT7	0.819**			
PT8	0.743**			
Ponašanje krda (KRDO)				
K2	0.783*	0.596	0.814	0.690
K5	0.688*			
K6	0.837**			
Emocije i raspoloženje (ER)				
ER13	0.727**	0.524	0.763	0.561
ER5	0.564**			
ER6	0.851**			
Prilagodljivost (PRIL)				
PRIL3	0.734**	0.509	0.861	0.807
PRIL4	0.717**			
PRIL5	0.780**			
PRIL7	0.620**			
PRIL8	0.686**			
PRIL9	0.733**			
Stabilnost (STAB)				
STAB1	0.758**	0.512	0.913	0.893
STAB10	0.639**			
STAB11	0.607**			
STAB14	0.648**			
STAB2	0.782**			
STAB5	0.740**			
STAB6	0.724**			
STAB7	0.727**			
STAB8	0.694**			
STAB9	0.812**			
Tržišni faktori (TF)				
TF1	0.794**	0.540	0.873	0.826
TF2	0.811**			
TF3	0.797**			
TF4	0.730**			
TF5	0.481**			
TF6	0.744**			
Investicijske odluke (IO)				
IO1	0.758**	0.579	0.845	0.757
IO3	0.839**			
IO4	0.784**			
IO5	0.650**			
Investicijske performanse (IP)				
IP1	0.894**	0.689	0.898	0.849
IP2	0.791**			
IP3	0.860**			
IP4	0.769**			
** značajno na razini 0.05* *** značajno na razini 0.01*				

Izvor: izračun autorice

Diskriminantna validnost najprije je ispitana prema Fornell-Larcker kriteriju. Unutar korelacijske matrice među latentnim konstruktima, prikazane kroz tablicu 5.46., na dijagonali su vidljive vrijednosti drugog korijena AVE pokazatelja svakog konstrukta. Sve ove vrijednosti s dijagonale veće su u odnosu na korelacijske koeficijente s drugim konstruktima iz relevantnih redaka i stupaca. To upućuje na zaključak da ne postoji problem diskriminantne validnosti, odnosno svaki konstrukt se doista razlikuje od ostalih konstrukata u modelu i bolje objašnjava varijancu svojih indikatora, nego onih koji pripadaju drugim konstruktima.

Tablica 5.46. Rezultati analize diskriminantne validnosti alternativnog PLS-SEM modela prema Fornell-Larcker kriteriju

	ER	HEU	IO	IP	KRDO	PRIL	PT	STAB	TF
ER	**0.724**								
HEU	0.368	**0.716**							
IO	0.397	0.432	**0.761**						
IP	0.286	0.537	0.517	**0.830**					
KRDO	0.063	-0.066	-0.071	-0.250	**0.772**				
PRIL	0.298	0.448	0.380	0.390	-0.025	**0.713**			
PT	0.178	0.203	0.451	0.221	0.196	0.107	**0.747**		
STAB	0.355	0.403	0.482	0.444	-0.069	0.622	0.341	**0.716**	
TF	0.363	0.569	0.666	0.366	0.170	0.398	0.427	0.410	**0.735**

Izvor: izračun autorice

Korištenjem HTMT pokazatelja, iz tablice 5.47. može se vidjeti da su sve njegove vrijednosti manje od 0.85, pokazujući time da su korelacije među indikatorima koji mjere različite konstrukte manje od korelacija među indikatorima koji mjere isti konstrukt. Upravo ovo je i poželjno, jer znači da je potvrđena diskriminantna validnost u modelu.

Tablica 5.47. Rezultati analize diskriminantne validnosti alternativnog PLS-SEM modela prema HTMT pokazatelju

	ER	HEU	IO	IP	KRDO	PRIL	PT	STAB	TF
ER									
HEU	0.475								
IO	0.545	0.497							
IP	0.392	0.636	0.622						
KRDO	0.395	0.157	0.152	0.301					
PRIL	0.428	0.542	0.447	0.455	0.107				
PT	0.375	0.297	0.673	0.299	0.360	0.205			
STAB	0.478	0.448	0.581	0.515	0.134	0.725	0.440		
TF	0.531	0.663	0.801	0.411	0.294	0.478	0.633	0.468	

Izvor: izračun autorice

Jednako kao u prethodnom modelu, kroz *bootstrapping* proceduru pomoću programa SmartPLS, izračunate su donja i gornja granica 95%-tnog intervala pouzdanosti svakog HTMT-a, a rezultati su prikazani u tablici 5.48. Nijedan procijenjeni interval ne sadrži vrijednost 1, čime se dodatno može potvrditi postojanje diskriminantne validnosti konstrukata alternativnog PLS-SEM modela.

Tablica 5.48. Intervali pouzdanosti HTMT-a (alternativni PLS-SEM model)

	Originalni uzorak	Donja granica	Gornja granica
HEU → ER	0.475	0.342	0.636
IO → ER	0.545	0.386	0.743
IO → HEU	0.497	0.412	0.616
IP → ER	0.392	0.247	0.564
IP → HEU	0.636	0.540	0.733
IP → IO	0.622	0.515	0.715
KRDO → ER	0.395	0.295	0.562
KRDO → HEU	0.157	0.139	0.265
KRDO → IO	0.152	0.093	0.301
KRDO → IP	0.301	0.179	0.437
PRIL → ER	0.428	0.302	0.608
PRIL → HEU	0.542	0.431	0.647
PRIL → IO	0.447	0.306	0.603
PRIL → IP	0.455	0.347	0.574
PRIL → KRDO	0.107	0.094	0.230
PT → ER	0.375	0.210	0.613
PT → HEU	0.297	0.220	0.431
PT → IO	0.673	0.526	0.816
PT → IP	0.299	0.160	0.463
PT → KRDO	0.360	0.239	0.522
PT → PRIL	0.205	0.144	0.375
STAB → ER	0.478	0.339	0.641
STAB → HEU	0.448	0.359	0.558
STAB → IO	0.581	0.431	0.703
STAB → IP	0.515	0.408	0.623
STAB → KRDO	0.134	0.121	0.251
STAB → PRIL	0.725	0.640	0.799
STAB → PT	0.440	0.315	0.586
TF → ER	0.531	0.384	0.716
TF → HEU	0.663	0.577	0.761
TF → IO	0.801	0.701	0.891
TF → IP	0.411	0.304	0.537

TF → KRDO	0.294	0.185	0.422
TF → PRIL	0.478	0.330	0.624
TF → PT	0.633	0.474	0.761
TF → STAB	0.468	0.345	0.588

Izvor: izračun autorice

5.4.4 Analiza PLS-SEM alternativnog strukturalnog modela bihevioralnih financija

U ovom modelu dodan je novi konstrukt TF, odnosno tržišni faktori, uz sve ostale konstrukte iz prethodnog modela. Dakle, postoji 9 konstrukata u modelu, od kojih je 7 egzogenih (bihevioralni i tržišni faktori) te 2 endogena faktora (investicijske odluke i performanse). Nakon 13 iteracija postignuto je rješenje kroz PLS algoritam, a statistička značajnost koeficijenata u strukturalnom modelu dobivena je putem *bootstrapping* procedure u programu SmartPLS. Postoje razlike u ovim koeficijentima u odnosu na prethodno procijenjeni PLS-SEM model, a njihove visine i pripadajuće *p*-vrijednosti prikazane su u tablici 5.49.

Rezultati PLS-SEM analize ovoga modela pokazuju kako heuristike, konkretno samouvjerenost, ne utječu statistički značajno na investicijske odluke. Ovaj zaključak u suprotnosti je sa zaključcima iz oba procijenjena CB-SEM modela, kao i iz prethodno procijenjenog PLS-SEM modela. U svakom slučaju, hipoteza H1 se odbacuje temeljem ovog rezultata. Elementi prospektne teorije pokazuju statistički značajan pozitivan utjecaj na investicijske odluke, što znači da investitori koji se više oslanjaju na mentalno računovodstvo i manje su skloni gubitku pa ulažu u sigurnije investicije, posljedično povećavaju broj dugoročno korisnih odluka. Iz ovog zaključka slijedi da se prihvaća hipoteza H2. Ponašanje krda kod investitora značajno negativno djeluje na investicijske odluke, tj. investitori koji su skloniji slijediti preporuke prijatelja i ostalih sudionika na financijskom tržištu, donose manji broj dugoročno korisnih odluka. Time se odbacuje hipoteza H3. Faktor emocija i raspoloženja značajno pozitivno utječe na donošenje investicijskih odluka. Time se potvrđuje hipoteza H4, odnosno pozitivne emocije i raspoloženje značajno povećavaju broj dugoročno korisnih odluka o ulaganju investitora na financijskom tržištu. Što se tiče karakteristika osobnosti, rezultat je različit u odnosu na prethodni model. Naime, utjecaj faktora prilagodljivosti na investicijske odluke nije statistički značajan, čime se odbacuje pomoćna hipoteza H5.2. S druge strane, utjecaj stabilnosti je pozitivan i statistički značajan, čime se prihvaća pomoćna hipoteza H5.1. Odnosno, ispitanici koji su savjesni i žele stabilnost svojih ciljeva, donose veći broj dugoročno korisnih odluka. Ovi rezultati ukazuju na djelomično prihvaćanje hipoteze H5,

kojom se tvrdi da karakteristike osobnosti investitora donose značajno veći broj dugoročno korisnih odluka o ulaganju na financijskom tržištu. Tržišni faktori, kao novi konstrukt u modelu, pokazuju statistički značajan pozitivan utjecaj na investicijske odluke. Prema samim indikatorima ovog konstrukta, to bi značilo da ispitanici koji su skloniji analizi cijena, trendova, fundamentalnoj analizi itd. posljedično preferiraju dugoročno korisne investicije. Dakle, može se prihvatiti istraživačka hipoteza H6. Ovo je u skladu s rezultatom CB-SEM alternativnog modela, koji je procijenjen na temelju istih podataka. Konačno, investicijske odluke statistički značajno i pozitivno utječu na investicijske performanse, uz najveći strukturalni koeficijent, jednako kao u svim dosad procijenjenim modelima. Time se prihvaća i posljednja hipoteza H7, odnosno dugoročno korisne odluke o ulaganju pozitivno utječu na zadovoljstvo investicijskim performansama investitora na financijskom tržištu.

Tablica 5.49. Rezultati strukturalnog modela (alternativni PLS-SEM model)

Pretpostavljena veza	Strukturalni koeficijent	p-vrijednost
HEU → IO	-0.038	0.496
PT → IO	0.207	<0.001
KRDO → IO	-0.201	0.011
ER → IO	0.144	<0.001
PRIL → IO	0.047	0.363
STAB → IO	0.122	0.055
TF → IO	0.513	<0.001
IO → IP	0.517	<0.001

Izvor: izračun autorice

Na slici 5.5. prikazan je *path* dijagram alternativnog PLS-SEM modela, gdje su vidljiva sva vanjska opterećenja svakog konstrukta, kao i sve prethodno analizirane strukturalne veze. Osim toga, unutar dvaju latentnih konstrukata opet su prikazane i vrijednosti koeficijenta determinacije (R^2). Na ovaj način pregledno se mogu ustanoviti mjerna svojstva vanjskog modela, tj. pouzdanost indikatora, kao i smjer i intenzitet utjecaja jednog latentnog konstrukta na drugi, tj. veze u strukturalnom modelu. Putem dijagrama se može, s obzirom na koeficijent determinacije, utvrditi i jedan element eksplanatorne snage modela. Kroz sve ove pokazatelje, koji se mogu pronaći na jednom dijagramu, istraživači mogu steći općeniti dojam o stavkama modela prije detaljnije analize.

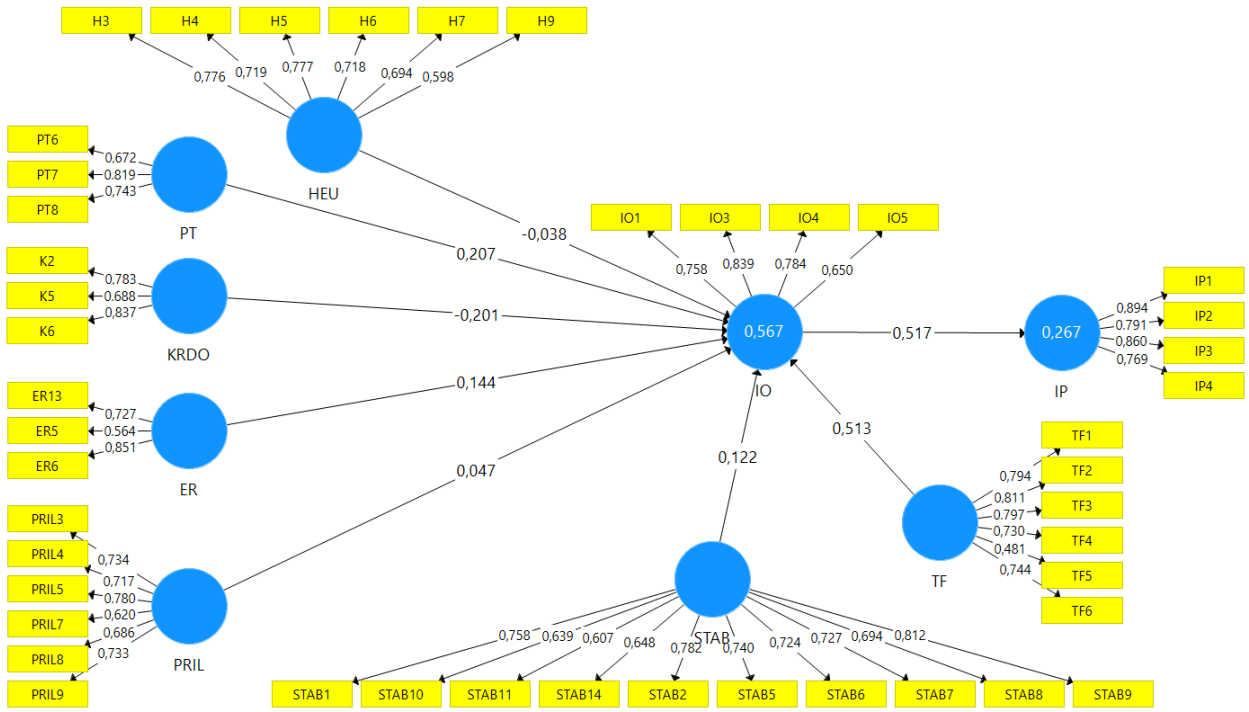

Slika 5.5. *Path* dijagram sa strukturalnim koeficijentima (alternativni PLS-SEM model)

Izvor: izračun autorice uz pomoć programa SmartPLS

Koeficijenti determinacije (R^2) endogenih konstrukata u alternativnom PLS-SEM modelu prikazani su u tablici 5.50., a pokazuju visoku eksplanatornu snagu modela, jer su vrijednosti oba koeficijenta veća od 0.26. Dakle, količina varijance u endogenim konstruktima koja je objašnjena svim povezanim egzogenim konstruktima je poprilično visoka (56.7% i 26.7%). Korigirani koeficijenti determinacije (R^2_{adj}), koji mogu služiti za usporedbu različitih modela, imaju vrlo slične vrijednosti R^2. Osim toga, unutar iste tablice može se vidjeti veličina efekta (f^2) svakog nezavisnog konstrukta na zavisni. U ovom modelu, PT, KRDO i ER pokazuju slabu veličinu efekta na IO, dok TF pokazuju umjereno jaku veličinu efekta. Faktori HEU, PRIL i STAB ne pokazuju značajan utjecaj na IO. S druge strane, IO imaju jak efekt na IP. Ovdje se mogu uočiti razlike u odnosu na originalni PLS-SEM model, a one su povezane i s razlikama u visinama i značajnosti strukturalnih koeficijenata. Oni faktori koji nisu pokazali statistički značajan utjecaj na IO, ne pokazuju ni značajan efekt kroz ovaj pokazatelj. Slično tome, faktor STAB ima dosta nisku vrijednost strukturalnog koeficijenta, a njegova *p*-vrijednost je malo veća od 5%. Najveća razlika

alternativnog u odnosu na originalni model je značajna promjena u korist novog konstrukta TF, koji pokazuje iznimno značajan utjecaj na IO, istovremeno umanjujući utjecaj drugih faktora.

Mjere prediktivne snage također su prikazane u tablici 5.50. Najprije su izračunati Stone-Geisser Q^2 pokazatelji putem *blindfolding* procedure u programu SmartPLS. Za konstrukt IO ovaj pokazatelj iznosi 0.315, a za IP 0.176, što ukazuje na umjerenu prediktivnu snagu modela, jer se vrijednosti kreću u intervalu od 0.15 do 0.35. Može se zaključiti da model ima umjerenu sposobnost za adekvatno predviđanje podataka koji nisu korišteni u procjeni modela. Potom je provedena i PLSpredict procedura, čiji su rezultati također dani u tablici 5.50. Vrijednosti $Q^2_{predict}$ pozitivne su za sve indikatore, omogućujući tako nastavak analize, gdje su uspoređene vrijednosti procijenjene pogreške RMSE za PLS-SEM model i za LM model. Može se zaključiti da je za konstrukt IO za dva indikatora RMSE PLS-SEM modela manji u odnosu na LM model, a za preostala dva je veći. Isti slučaj je i s konstruktom IP, kod kojeg je također jednak broj RMSE vrijednosti u PLS-SEM modelu manji u odnosu na LM model. Dakle, i ukupno gledajući među svim indikatorima oba endogena konstrukta u modelu, jednak je broj RMSE vrijednosti manji za PLS-SEM nego za LM model. Ovakav odnos vrijednosti upućuje na postojanje srednje jake, odnosno umjerene prediktivne snage modela.

Tablica 5.50. Rezultati analize eksplanatorne i prediktivne snage modela (alternativni PLS-SEM model)

	R^2	R^2_{ajd}	Q^2	f^2	IO	IP	PLSpredict	Q^2 predict	PLS RMSE	LM RMSE
IO	0.567	0.557	0.315	ER	0.038		IO4	0.313	0.811	0.827
IP	0.267	0.265	0.176	HEU	0.002		IO3	0.180	0.954	0.891
				IO		0.364	IO1	0.391	0.693	0.726
				IP			IO5	0.294	0.799	0.763
				KRDO	0.083		IP3	0.125	1.048	1.009
				PRIL	0.003		IP1	0.204	0.848	0.858
				PT	0.071		IP4	0.129	0.842	0.855
				STAB	0.017		IP2	0.155	0.920	0.916
				TF	0.316					

Izvor: izračun autorice

Tablica 5.51. pokazuje vrijednosti mjera prilagodbe modela. Kao relevantne mjere prikazani su SRMR i RMS_{theta}. Njihove se vrijednosti nalaze ispod granica prihvaćanja zadovoljavajuće prilagodbe modela. Naime, SRMR je manji od 0.10, dok je RMS_{theta} manji od 0.14. Međutim,

potrebno je napomenuti kako se i ovi rezultati uzimaju s rezervom, jer pokazatelji prilagodbe PLS-SEM modela nisu do kraja razvijeni te ih je potrebno unaprijediti.

Tablica 5.51. Pokazatelji prilagodbe modela (alternativni PLS-SEM model)

Pokazatelj prilagodbe modela	
SRMR	0.095
RMS_{theta}	0.131

Izvor: izračun autorice

5.5 Usporedba rezultata CB-SEM i PLS-SEM modela i odabir adekvatnog SEM modela

Nakon procjene četiri relevantna modela, mogu se usporediti njihovi rezultati. Glavne stavke usporedbe su karakteristike mjernog i strukturalnog modela te zaključci o prihvaćanju ili odbacivanju istraživačkih hipoteza. Na ovaj način istražuje se koji model daje najpouzdanije rezultate i dolazi se do konačnog zaključka o istraživačkim hipotezama. Ove stavke usporedno su prikazane za sva četiri procijenjena modela u tablici 5.52.

Između originalnog i alternativnog CB-SEM modela ne postoje značajne razlike. Naime, mjerna svojstva oba modela, u pogledu vrijednosti faktorskih opterećenja, AVE, CR i Cronbach's alpha pokazatelja, daju zadovoljavajuće rezultate. Vrijednosti ovih pokazatelja vrlo su slične u oba modela, no malo su povoljnije u alternativnom modelu. Potencijalni problem diskriminantne validnosti, ispitan prema Fornell-Larcker kriteriju, postoji između investicijskih odluka i performansi u prvotno procijenjenom CB-SEM modelu, iako se daljnjom analizom može zaključiti da su faktori ipak međusobno različiti. U alternativnom modelu ovaj problem ne postoji. Kod dvaju procijenjenih PLS-SEM modela, mjerna svojstva također se pokazuju zadovoljavajućim te među njima ne postoje značajnije razlike. Vrijednosti vanjskih opterećenja, kao i pokazatelja AVE, kompozitne pouzdanosti i Cronbach's alpha koeficijenta, prihvatljive su i potvrđuju konvergentnu validnost i pouzdanost konstrukata te indikatora. Uz to, u oba PLS-SEM modela, putem Fornell-Larcker kriterija i HTMT pokazatelja, potvrđena je i diskriminantna validnost konstrukata.

Što se tiče strukturalnog modela, CB-SEM modeli mogu se uspoređivati po pokazateljima prilagodbe modela, koja u niti jednom od dva procijenjena modela nije u potpunosti zadovoljavajuća. Naime, kako je već spomenuto pri analizi strukturalnih modela, hi-kvadrat veličine statistički su značajne. Iako to može biti i pod utjecajem veličine uzorka, pokazatelji CFI i TLI također nisu na zadovoljavajućoj razini, pa se ne može reći da se model dobro prilagođava

podacima. Jedino pokazatelj RMSEA nalazi se unutar granica prihvatljivosti, a između dvaju CB-SEM modela, svi pokazatelji malo su povoljniji u alternativnom modelu. Za PLS-SEM modele prikazana su dva pokazatelja, SRMR i RMS_{theta}, od kojih je samo RMS_{theta} povoljan u originalnom modelu, dok su oba pokazatelja zadovoljavajuća u alternativnom PLS-SEM modelu. Prema ovim rezultatima, moglo bi se zaključiti da najbolju prilagodbu pruža upravo alternativni PLS-SEM model, no ovdje treba biti oprezan, jer ove mjere za PLS-SEM još uvijek nisu razvijene u dovoljnoj mjeri. Iz tog razloga, kao i zbog toga što se radi o djelomično eksplorativnom istraživanju, kod ove analize veći je naglasak na prediktivnoj snazi modela, iako istraživači namjeravaju dalje unaprijediti i mjere prilagodbe. PLS-SEM je uzročno-prediktivna (eng. *causal-predictive*) tehnika te se sve više nastoji pronaći rješenje za odabir modela koji je točno specificiran i daje uzročno-posljedična objašnjenja, a istovremeno je prikladan za predviđanje (Sharma et al., 2021). U ovom istraživanju, prema predloženim pokazateljima prilagodbe, već je zaključeno da je bolji alternativni model. Što se tiče eksplanatorne i prediktivne snage, zaključci su isti: eksplanatorna snaga je visoka, dok je prediktivna snaga modela umjerena. Ipak, usporede li se konkretne vrijednosti pokazatelja eksplanatorne i prediktivne snage iz tablica 5.42. i 5.50, može se dati mala prednost alternativnom modelu. Naime, usporedbom ovih dvaju različitih modela kroz korigirani koeficijent determinacije, vidljivo je da su njegove vrijednosti veće u alternativnom modelu. Isto vrijedi i za Stone-Geisser Q^2 pokazatelj prediktivne snage, čije su vrijednosti također povoljnije za alternativni PLS-SEM model. PLSpredict procedura ne razlikuje se značajno među modelima.

Nadalje, bitno je usporediti zaključke o prihvaćanju ili odbacivanju hipoteza kroz svaki pojedini model, što se zapravo odnosi na usporedbu značajnosti i relevantnosti uzročno-posljedičnih veza strukturalnih modela. Ove su veze po smjeru, intenzitetu i značajnosti već opisane kroz detaljniju analizu kroz odgovarajuća poglavlja, dok se u tablici 5.52. nalazi samo zaključak o prihvaćanju svake pojedine istraživačke hipoteze. Pri interpretaciji prihvaćenih ili odbačenih hipoteza promatraju se i indikatori svakog konstrukta. Stoga je bitno naglasiti da se ovi indikatori ne razlikuju značajno među promatranim modelima, izuzev faktora prospektne teorije te emocija i raspoloženja. Naime, u CB-SEM modelima faktor prospektne teorije obuhvaća dva indikatora povezana sa sklonosti riziku, dok u PLS-SEM modelima ovaj faktor obuhvaća tri indikatora povezana s mentalnim računovodstvom i averzijom prema gubitku. Što se tiče faktora emocija i raspoloženja, CB-SEM modeli obuhvaćaju velik broj indikatora povezanih s različitim tipovima

emocija, dok su u PLS-SEM modelima zadržana po tri indikatora, od kojih se svi odnose na pozitivne emocije i raspoloženje.

Prva istraživačka hipoteza odnosi se na utjecaj korištenja heuristika na donošenje dugoročno korisnih investicijskih odluka. Kao što je vidljivo u tablici 5.52., ova hipoteza nije prihvaćena u niti jednom modelu. CB-SEM modeli i originalni PLS-SEM pronalazili su pozitivan statistički značajan utjecaj, što je u suprotnosti s hipotezom, dok u alternativnom PLS-SEM modelu nije pronađen statistički značajan utjecaj. Hipoteza H2, koja se odnosi na utjecaj odlučivanja pod utjecajem elemenata prospektne teorije na investicijske odluke, nije prihvaćena kroz CB-SEM modele, dok je prihvaćena u oba PLS-SEM modela. Ovdje treba imati na umu i različite indikatore među modelima. Treća hipoteza pretpostavlja da ponašanje krda značajno povećava broj dugoročno korisnih odluka o ulaganju investitora na financijskom tržištu. Međutim, u svim modelima pronađen je statistički značajan negativan utjecaj ovog faktora na investicijske odluke, zbog čega se H3 odbacuje u svim modelima. Faktor emocija i raspoloženja u CB-SEM modelima ne pokazuje statistički značajan utjecaj na investicijske odluke, a u PLS-SEM modelima pokazuje pozitivan značajan utjecaj. Stoga, H4 se odbacuje temeljem rezultata CB-SEM modela, a prihvaća se temeljem rezultata PLS-SEM modela. Peta hipoteza vezana je za karakteristike osobnosti, a podijeljena je na dvije pomoćne hipoteze, od kojih se prva odnosi na dimenziju stabilnosti, a druga na dimenziju prilagodljivosti. Na temelju procjena sva četiri modela, može se prihvatiti prva pomoćna hipoteza H5.1: Investitori sa stabilnijom osobnošću donose značajno veći broj dugoročno korisnih odluka o ulaganju na financijskom tržištu. Međutim, kod druge pomoćne hipoteze većina modela daje statistički beznačajan utjecaj, izuzev originalnog PLS-SEM modela, gdje je utjecaj prilagodljivosti pozitivan i značajan, ali tek pri razini signifikantnosti od 10%. Sukladno tome, glavna hipoteza H5 prihvaća se u originalnom PLS-SEM modelu, dok se djelomično prihvaća na temelju rezultata svih ostalih procijenjenih modela. Hipoteza H6 odnosi se isključivo na alternativne modele, koji sadrže dodatni konstrukt, koji se odnosi na tržišne faktore. Ova hipoteza prihvaćena je na temelju oba relevantna modela, odnosno zaključuje se da analiziranje tržišnih faktora značajno povećava broj dugoročno korisnih odluka o ulaganju investitora na financijskom tržištu. Posljednja hipoteza (H7) ispituje utjecaj investicijskih odluka na investicijske performanse, a prihvaćena je na temelju svih procijenjenih modela, u kojima je pronađen pozitivan statistički značajan utjecaj. Dakle, zaključuje se da dugoročno korisne odluke o ulaganju pozitivno utječu na zadovoljstvo investicijskim performansama investitora na financijskom tržištu.

Tablica 5.52. Usporedba rezultata CB-SEM i PLS-SEM procijenjenih modela

	CB-SEM	alternativni CB-SEM	PLS-SEM	alternativni PLS-SEM
Mjerni model				
konvergentna validnost	da	da	da	da
pouzdanost	da	da	da	da
diskriminantna validnost	djelomično	da	da	da
Strukturalni model				
prilagodba modela	samo RMSEA	samo RMSEA	samo RMS_{theta}	da
eksplanatorna snaga	n.a.	n.a.	visoka	visoka
prediktivna snaga	n.a.	n.a.	umjerena	umjerena
Hipoteze				
H1: Korištenje heuristika značajno smanjuje broj dugoročno korisnih odluka o ulaganju investitora na financijskom tržištu.	ne	ne	ne	ne
H2: Odlučivanje pod utjecajem elemenata prospektne teorije značajno povećava broj dugoročno korisnih odluka o ulaganju investitora na financijskom tržištu.	ne	ne	da	da
H3: Ponašanje krda značajno povećava broj dugoročno korisnih odluka o ulaganju investitora na financijskom tržištu.	ne	ne	ne	ne
H4: Pozitivne emocije i raspoloženje značajno povećavaju broj dugoročno korisnih odluka o ulaganju investitora na financijskom tržištu.	ne	ne	da	da
H5: Karakteristike osobnosti investitora donose značajno veći broj dugoročno korisnih odluka o ulaganju na financijskom tržištu	djelomično	djelomično	da	djelomično
• H5.1: Investitori sa stabilnijom osobnošću donose značajno veći broj dugoročno korisnih odluka o ulaganju na financijskom tržištu.	da	da	da	da
• H5.2: Investitori s više prilagodljivom osobnošću donose značajno veći broj dugoročno korisnih odluka o ulaganju na financijskom tržištu.	ne	ne	da	ne
H6: Analiziranje tržišnih faktora značajno povećava broj dugoročno korisnih odluka o ulaganju investitora na financijskom tržištu.	n.a.	da	n.a.	da
H7: Dugoročno korisne odluke o ulaganju pozitivno utječu na zadovoljstvo investicijskim performansama investitora na financijskom tržištu.	da	da	da	da

Izvor: izrada autorice

Promatrajući sve analizirane kriterije prilikom usporedbe četiri procijenjena CB-SEM i PLS-SEM modela, može se zaključiti da PLS-SEM modeli daju bolja svojstva što se tiče diskriminantne validnosti, kao i cjelokupnog strukturalnog (unutarnjeg) modela. Naime, u CB-SEM modelima zaključuje se da se model ne prilagođava dovoljno dobro podacima, prema većini pokazatelja. S

obzirom da je CB-SEM konfirmatorna tehnika, ovakvi rezultati ne mogu biti zadovoljavajući. Već je korištena i robusna WLSMV metoda procjene zbog prirode izabranih varijabli, kao i zbog toga što podaci ne udovoljavaju pretpostavci multivarijatne normalnosti. Ipak, još uvijek model nije na zadovoljavajućoj razini. Još jednom se može napomenuti da model u ovom obliku, kada obuhvaća puno više različitih bihevioralnih faktora odjednom, nije dosad bio testiran. Iz tog razloga, kako je ovaj oblik modela u razvoju, istraživanje je u nekoj mjeri eksplorativno, što zahtijeva neparametrijski pristup procjene modela putem PLS-SEM metode. Kroz rezultate dvaju PLS-SEM modela, vidljivo je da su razlike minimalne, iako većina pokazatelja daje malu prednost alternativnom modelu. To se vidi kroz bolju prilagodbu modela, gdje i u PLS-SEM modelu, koji nije primarno i isključivo konfirmatorna tehnika, teoretski specificiran model je na zadovoljavajućoj razini. Osim toga, pokazatelji eksplanatorne i prediktivne snage malo su povoljniji u alternativnom u odnosu na originalni PLS-SEM model. U odabiru između ova dva modela, mogu se koristiti i informacijski kriteriji. Oni optimiziraju točnost predviđanja uspostavljanjem ravnoteže između prilagodbe i kompleksnosti modela (Sharma et al., 2019; 2021). Usporedba ovih modela prikazana je u tablici 5.53. prema pokazatelju Bayesovog informacijskog kriterija (eng. *Bayesian Information Criterion*, BIC), koji postiže dobar kompromis između prilagodbe (objašnjavanja) modela i njegove prediktivne snage. Vrijednosti BIC-a su negativne za oba modela, ali su manje u alternativnom modelu u odnosu na originalni. Na temelju ove analize, alternativni PLS-SEM model može se izabrati kao bolji model.

Tablica 5.53. Kriteriji usporedbe i odabira PLS-SEM modela

BIC (Bayesian Information Criteria)	PLS-SEM model	alternativni PLS-SEM model
IO	-139.418	-214.526
IP	-84.124	-85.842

Izvor: izračun autorice

U konačnici, može se zaključiti da je u ovom slučaju PLS-SEM adekvatnija metoda modeliranja u odnosu na CB-SEM. Od svih procijenjenih modela, kao najadekvatniji model za utvrđivanje utjecaja bihevioralnih faktora na donošenje odluka investitora i investicijske performanse na financijskom tržištu s najpouzdanijim rezultatima može se predložiti alternativni PLS-SEM model.

6. ZAKLJUČNA RAZMATRANJA

U ovom radu naglašena je važnost sve popularnije bihevioralne ekonomije i bihevioralnih financija te je na uzorku domaćih investitora istražen utjecaj bihevioralnih faktora na donošenje investicijskih odluka i njihove performanse na financijskom tržištu. Naime, uočena je potreba za analizom dodatnih, i to psiholoških faktora pri odlučivanju o ulaganjima u dionice, jer su primijećene različite anomalije, odnosno odstupanja od racionalnog ponašanja, koje je pretpostavljeno kroz teoriju efikasnog tržišta. U različitim eksperimentima i empirijskim istraživanjima, dokazano je da su u procesu donošenja odluka ljudi skloni određenim obrascima ponašanja, koji se mogu smatrati faktorima ponašanja, tj. bihevioralnim faktorima. Iako su neka istraživanja proučavala utjecaj bihevioralnih faktora na donošenje investicijskih odluka temeljem analize numeričkih podataka, kao što su kretanje cijena dionica, volumena trgovanja te različitih indeksa, ovo istraživanje stavlja naglasak upravo na same psihološke karakteristike investitora, koje najbolje odražavaju njihovo ponašanje. Stoga, kao instrument istraživanja korišten je anketni upitnik, kako bi ispitanici mogli na skali od 1 do 5 odabrati stupanj slaganja s tvrdnjama koje odražavaju bihevioralne faktore i karakteristike osobnosti. Osim toga, prepoznata je i potreba za korištenjem drugačijeg metodološkog pristupa u analizi utjecaja faktora ponašanja na odlučivanje, s obzirom da se radi o psihološkim karakteristikama, koje nije moguće direktno mjeriti, a u cilju istraživanja bilo je i simultano analiziranje utjecaja investicijskih odluka na investicijske performanse investitora. Uzevši sve navedeno u obzir, kao prikladna statistička metoda izabrana je metoda modeliranja strukturalnim jednadžbama (SEM), i to kroz parametrijski (CB-SEM) i neparametrijski pristup (PLS-SEM).

Sistematizacijom svih glavnih pojmova i koraka u CB-SEM i PLS-SEM analizi, prikazane su sve sličnosti i razlike dvaju navedenih pristupa. Polazeći od istraživačkog modela, u radu su procijenjena četiri modela, i to dva CB-SEM i dva PLS-SEM modela. Na ovaj način kroz svaki od dvaju pristupa uspoređen je polazni model, koji istražuje utjecaj bihevioralnih faktora (heuristike, elementi prospektne teorije, ponašanje krda, emocije i raspoloženje, faktori osobnosti) na investicijske odluke te njihov utjecaj na investicijske performanse, s alternativnim modelom, koji među utjecajnim faktorima promatra i tržišne faktore. Oni nisu vezani za određeni obrazac ponašanja, no mogu bitno utjecati na ponašanje investitora kod donošenja odluka, zbog čega su uzeti u obzir, a također su promatrani kroz anketni upitnik.

Rezultati istraživanja pokazali su da je strukturalnim modeliranjem putem CB-SEM i PLS-SEM pristupa utvrđeno postojanje utjecaja bihevioralnih faktora na investicijske odluke, kao i postojanje utjecaja investicijskih odluka na investicijske performanse. Kroz detaljnu analizu sva četiri procijenjena modela, donesen je zaključak o izboru PLS-SEM metode kao prikladnije metode za analizu uzročno-posljedičnih veza u istraživačkom modelu. Od svih procijenjenih modela, kao najadekvatniji model po svim pokazateljima pokazao se alternativni PLS-SEM model.

6.1 Rasprava o rezultatima istraživanja

Istraživanje je provedeno na uzorku od 310 investitora, odnosno malih ulagatelja koji trguju vrijednosnim papirima na uređenom tržištu. Na temelju deskriptivne analize može se zaključiti da među ispitanicima dominiraju muškarci, koji čine 70.97% uzorka, dok žene čine preostalih 29.03%. Većina ispitanika stara je od 36 do 45 godina, a najveći udio ispitanika ima radno iskustvo preko 20 godina. Na financijskom tržištu najviše je iskusnih investitora koji trguju više od 10 godina (36.13%). Prema mjesečnim primanjima, ispitanici se u najvećem postotku (41.29%) nalaze u rasponu od 5001 i 10000 kn, a najviše, i to preko polovine ispitanika (53.87%) posjeduje VSS. Veći dio ispitanika u sklopu formalnog i/ili neformalnog obrazovanja nije pohađao edukacije o trgovanju na burzi (55.48%), no ipak velik dio uzorka čine i investitori koji su takve edukacije pohađali (44.52%).

Na temelju četiri procijenjena modela, dobivene su relevantne mjere koje opisuju karakteristike svakog mjernog i strukturalnog modela, kao i veze unutar strukturalnog modela, putem kojih se donosi zaključak o prihvaćanju ili odbacivanju istraživačkih hipoteza. CB-SEM modeli procijenjeni su robusnom metodom za ordinalne podatke, WLSMV metodom, s obzirom da su varijable od interesa iskazane kao skala od 1 do 5.

CB-SEM modeli daju zadovoljavajuće rezultate mjernih modela. Točnije, vrijednosti AVE, CR i Cronbach's alpha koeficijenta nalaze se iznad granica prihvatljivosti, pa se može zaključiti da je u oba procijenjena CB-SEM modela zadovoljena konvergentna validnost i pouzdanost konstrukata. Iako su vrijednosti ovih pokazatelja relativno slične, malo su povoljnije u alternativnom modelu, koji uključuje i tržišne faktore kao nezavisnu varijablu. Prema Fornell-Larcker kriteriju, potencijalni problem diskriminantne validnosti postoji u polaznom CB-SEM modelu između investicijskih odluka i performansi. U alternativnom modelu postojanje potencijalnog problema može se primijetiti samo usporedbom drugog korijena iz AVE pokazatelja faktora IO s korelacijom

između IO i IP, dok gledajući vrijednost drugog korijena AVE pokazatelja faktora IP u odnosu na korelaciju između IO i IP, problem diskriminantne validnosti ne postoji. U oba slučaja dodatno je provedena faktorska analiza, kojom su izlučena dva faktora s pripadajućim indikatorima, kako je i bilo postavljeno u inicijalnom modelu. Za CB-SEM modele analizirani su pokazatelji prilagodbe. Hi-kvadrat za oba modela je statistički značajan, što ukazuje na nedovoljno dobru prilagodbu modela podacima. Međutim, ovaj je pokazatelj pod utjecajem veličine uzorka, a uzorak istraživanja od 310 ispitanika zasigurno ima utjecaja na povećanje hi-kvadrat vrijednosti. Ipak, čak i kad bi se zanemario ovaj rezultat, ni ostali pokazatelji ne daju dovoljno dobre rezultate. Naime, CFI i TLI imaju vrijednost ispod granice od 0.9, što pokazuje da relativno poboljšanje modela u odnosu na *null* model nije u potpunosti zadovoljavajuće. Prosječna kvadratna pogreška, iskazana kroz pokazatelj RMSEA, jedini je pokazatelj koji se nalazi unutar granica prihvatljivosti kod oba modela.

Mjerni modeli oba procijenjena PLS-SEM modela također daju zadovoljavajuće rezultate. U ovom slučaju, promatrani su AVE, kompozitna pouzdanost i Cronbach's alpha koeficijent, kao i vrijednosti vanjskih opterećenja (eng. *outer loadings*). I polazni i alternativni model pokazuju zadovoljavajuće pokazatelje i potvrđuje se konvergentna validnost i pouzdanost konstrukata i indikatora. Svi konstrukti uistinu su međusobno različiti, što je potvrđeno kroz ispitivanje diskriminantne validnosti putem Fornell-Larcker kriterija, kao i putem HTMT pokazatelja. Unutarnji ili strukturalni modeli pokazuju visoku eksplanatornu snagu, ispitanu kroz koeficijent determinacije, te umjerenu prediktivnu snagu, ispitanu kroz Stone-Geisser Q^2 pokazatelj i PLSpredict proceduru. Osim toga, i mjere prilagodbe modela (SRMR i RMS_{theta}), koje doduše još uvijek nisu dovoljno razvijene, nalaze se uglavnom u prihvatljivim granicama, izuzev SRMR u polaznom modelu, koji nije u potpunosti zadovoljavajući. Ipak, ove rezultate treba uzeti s rezervom. S obzirom na slične zaključke u vezi mjernog i strukturalnog modela, putem BIC informacijskog kriterija zaključeno je da je, između dva PLS-SEM modela, bolji alternativni model, s uključenim tržišnim faktorima.

Promatrajući CB-SEM modele u usporedbi s PLS-SEM modelima, vidljivo je kako su mjerna svojstva otprilike jednaka, dok su svojstva strukturalnog modela bolja u PLS-SEM modelima. Kako je CB-SEM isključivo konfirmatorna tehnika modeliranja, rezultati pokazatelja prilagodbe, koji nisu u potpunosti zadovoljavajući, zapravo ne potvrđuju teoretski postavljene veze dovoljno

dobro. Preliminarnom provjerom podataka utvrđeno je da nije zadovoljen uvjet multivarijatne normalnosti, zbog čega je, između ostalog, korištena WLSMV metoda procjene kod ovih modela. Ipak, model ne daje zadovoljavajuće rezultate unatoč odgovarajućoj metodi procjene, a niti dodatne respecifikacije modela ne uspijevaju u postizanju optimalnih rezultata procijenjenih CB-SEM modela. Iz tog razloga u nastavku se pristupilo procjeni modela neparametrijskim PLS-SEM pristupom. Kako je PLS-SEM uzročno-prediktivna tehnika, a u istraživanjima se sve više nastoji pronaći rješenje za odabir modela koji je točno specificiran i daje uzročno-posljedična objašnjenja, a istovremeno je prikladan za predviđanje, raste i njegova popularnost u društvenim istraživanjima. Također, kako je istraživački model u ovom radu jedinstven, odnosno nije dosad testiran na način da se uzima veći broj izabranih bihevioralnih faktora istovremeno kao utjecajne varijable, može se zaključiti da istraživanje nije samo konfirmatorne prirode, već i eksplorativne. PLS-SEM modeli pokazali su zadovoljavajuće rezultate gledajući i jedan i drugi cilj. Naime, pokazatelji prilagodbe su povoljni (iako su još u razvoju pa ih se uzima s rezervom), a istovremeno su pokazatelji eksplanatorne i prediktivne snage također na visokoj razini. Upravo ovakvi rezultati su i poželjni, jer se zaključuje da model dobro objašnjava postavljene veze, a istovremeno je sposoban adekvatno predvidjeti mjerljive informacije o novim opservacijama. Kao što je već spomenuto, temeljem BIC informacijskog kriterija, kao i detaljnijom analizom pojedinačnih pokazatelja, može se zaključiti da je, između dvaju PLS-SEM modela, bolji alternativni model.

Konačno, što se tiče modeliranja, može se zaključiti da je PLS-SEM adekvatnija metoda modeliranja u odnosu na CB-SEM. Kao najadekvatniji model za utvrđivanje utjecaja bihevioralnih faktora na donošenje odluka investitora i investicijske performanse na financijskom tržištu s najpouzdanijim rezultatima predlaže se alternativni PLS-SEM model.

S obzirom da je u cilju rada bilo pronaći strukturalni model kojim će se utvrditi koji bihevioralni faktori i s kojim intenzitetom utječu na donošenje investicijskih odluka i performanse, zaključci su izvučeni iz konačno odabranog najadekvatnijeg modela, tj. alternativnog PLS-SEM modela.

Rezultati pokazuju da heuristike ne utječu statistički značajno na investicijske odluke. Konkretno, u ovom slučaju, radi se o heuristikama samouvjerenosti investitora, iz razloga što su, postepenim modeliranjem, u modelu ostali indikatori koji se odnose na stavove ispitanika koji odražavaju razinu njihove samouvjerenosti pri ulaganju u dionice. Stoga, **hipoteza H1: Korištenje heuristika**

značajno smanjuje broj dugoročno korisnih odluka o ulaganju investitora na financijskom tržištu – odbacuje se.

Nadalje, utvrđeno je postojanje pozitivnog statistički značajnog utjecaja elemenata prospektne teorije na investicijske odluke. S obzirom da se indikatori koji predstavljaju ove elemente odnose na sklonost mentalnom računovodstvu i averziju (odbojnost) prema gubitku, ovaj rezultat ukazuje da investitori koji se više oslanjaju na mentalno računovodstvo i manje su skloni gubitku pa ulažu u sigurnije investicije, posljedično povećavaju broj dugoročno korisnih odluka. To se može objasniti činjenicom da investitori žele ulagati u dionice sa sigurnijim povratima, s obzirom da se u suprotnom suočavaju s problemom tzv. nepovratnih troškova, od kojih nisu stekli nikakve koristi. Iako racionalno ponašanje podrazumijeva promatranje rezultata ukupnog portfelja, investitori su skloni stvaranju mentalnih računa, pa su prema tome skloniji prodati svoje dobitne dionice, a držati one kojima vrijednost pada. U ovom slučaju, zadržavanje gubitnih dionica može imati smisla i čini se kao razumna odluka, ako se očekuje da je taj pad privremen, odnosno ako postoji razlog vjerovanja da je poduzeće još uvijek uspješno i stabilno, umjesto da se zadržavaju samo zato da se ne pretrpi neuspjeh. Prema tome, investitori se pouzdaju u fundamentalnu analizu i vjeruju u kvalitetu financijskog izvještavanja te tako smatraju da su ispravno odabrali poduzeća u čije će vrijednosne papire uložiti. Posljedično, uz takve stavove, investitori su više skloni dugoročnim i pomno proučenim ulaganjima, od kojih ostvaruju dugoročne koristi. Na temelju ovih zaključaka, **hipoteza H2: Odlučivanje pod utjecajem elemenata prospektne teorije značajno povećava broj dugoročno korisnih odluka o ulaganju investitora na financijskom tržištu – se prihvaća.**

Ponašanje krda pokazuje statistički značajan negativan utjecaj na investicijske odluke. Drugim riječima, investitori koji su skloni slijediti preporuke prijatelja, poznanika i ostalih investitora na financijskom tržištu, posljedično su manje skloni dugoročnom investiranju. Na temelju ovih saznanja, hipoteza **H3: Ponašanje krda značajno povećava broj dugoročno korisnih odluka o ulaganju investitora na financijskom tržištu – se odbacuje.** Naime, temeljem empirijskih istraživanja, nije utvrđen jedinstven zaključak o utjecaju ponašanja krda na investicijske odluke, a i samo pilot istraživanje ukazivalo je na pozitivan utjecaj, što se može objasniti činjenicom da, iako investitori koji slijede „krdo“ nemaju dovoljno znanja o trgovanju dionicama, oni reagiraju na akcije drugih investitora upravo da bi izvukli korisne informacije od onih iskusnijih. Ovaj rezultat, tj. pozitivan utjecaj ponašanja krda na investicijske odluke kod pilot istraživanja, moguće je

protumačiti neiskustvom osoba koje su sudjelovale u istraživanju, s obzirom da se ipak radi o studentima koji nemaju praktično iskustvo trgovanja, pa smatraju da pouzdanje u prosudbe većine može dovesti do zadovoljavajućih ishoda svojih odluka. Međutim, s obzirom na to da su eksperimenti dokazali da pojedinci pod pritiskom mase daju pogrešne odgovore, isto se može preslikati i na financijsko tržište. Investitori tako, zbog imitiranja odluka ostalih sudionika na tržištu, padaju pod njihov utjecaj i donose odluke koje ne rezultiraju dugoročnim investiranjem, čak i ako su svjesni da se svi drugi ponašaju poput stada (krda). To je naročito karakteristično za tržišta koja nisu dovoljno razvijena i za investitore koji nisu dovoljno iskusni, što je slučaj kod uzorka u ovom istraživanju. Bihevioralni financijski ekonomisti općenito savjetuju izbjegavanje ponašanja krda (stada), jer svaka investicija koja postane tema razgovora širokih razmjera vjerojatno će u određenom trenutku biti rizična. U tom smislu, čini se da je teško odoljeti euforiji kada se šire priče o spektakularnim dobitcima, kao što se i svaki put kod ubrzanog rasta tržišta zaboravi da se i taj put možda radi o napuhavanju mjehurića, pa sve više i više investitora zapravo kupuje na precijenjenim razinama i na kraju pretrpe gubitke kada dođe do obrata.

Emocije i raspoloženje pokazuju statistički značajan pozitivan utjecaj na investicijske odluke, što pokazuje da pozitivne emocije i raspoloženje kod investitora značajno povećavaju broj dugoročnih investicija, koje se očituju u dugoročnim koristima. Indikatori faktora emocija i raspoloženja odnose se na nadu i optimizam, gdje je nada emocija u očekivanju nagrade i očekivanog cilja, a optimizam je raspoloženje usko povezano s nadom. Stoga je ovakav zaključak logičan, jer su pojedinci raspoloženi za ulaganja i sudjelovanja u tržišnim aktivnostima, kada od takvih aktivnosti, tj. ulaganja, očekuju nekakvu nagradu, što se u ovom slučaju odnosi na nagradu za pametnu investicijsku odluku, koja se očituje u dugoročnoj investiciji sa zadovoljavajućim povratom. Optimisti su općenito spremniji riskirati, jer očekuju povoljne ishode svojih odluka. Također se i u burzovnom rječniku optimistima smatraju oni koji pokreću *bull* tržište, odnosno oni koji kupuju vjerujući da će dionice rasti i da će zaraditi na razlici između niže kupljene i više prodajne cijene, odnosno oni ulaze u „duge" pozicije. Suprotno od toga, pesimisti pokreću *bear* tržište, vjerujući da će se dogoditi pad cijena, te ulaze u „kratke" pozicije, a baš kao što i Kostolany (2008) navodi, puno je teže radovati se zaradi na padu tržišta, dok mnogobrojni trpe gubitke zbog pada. Pretjerani optimizam mogao bi biti štetan, ukoliko se ne sagledaju realni rizici, pa je u tom slučaju potrebno uključiti primjerene informacije u analizu ulaganja. U ovom uzorku prevladavaju pozitivne emocije i raspoloženje, što upućuje na ulagače koji očekuju dugoročnu korist od svojih ulaganja. Dakle,

hipoteza H4: Pozitivne emocije i raspoloženje značajno povećavaju broj dugoročno korisnih odluka o ulaganju investitora na financijskom tržištu – se prihvaća.

Stabilnost, kao jedna od dviju dimenzija osobnosti, pozitivno i statistički značajno utječe na investicijske odluke. Naime, investitori koji su savjesni, ustrajni, pouzdani u privatnom i poslovnom životu, spremni za suradnju s drugima, smireni, emocionalno stabilni i teže stabilnosti svojih ciljeva, posljedično temeljitije istražuju opcije ulaganja i odlučuju se za dugoročne investicije. Iz toga slijedi da se **pomoćna hipoteza H5.1: Investitori sa stabilnijom osobnošću donose značajno veći broj dugoročno korisnih odluka o ulaganju na financijskom tržištu – prihvaća.** S druge strane, prilagodljivost, kao druga dimenzija osobnosti, ne utječe značajno na donošenje investicijskih odluka, čime se **pomoćna hipoteza H5.2: Investitori s više prilagodljivom osobnošću donose značajno veći broj dugoročno korisnih odluka o ulaganju na financijskom tržištu – odbacuje.** Na temelju ovih rezultata, kojima se potvrđuje jedna, a odbacuje druga pomoćna hipoteza, zaključuje se da se **hipoteza H5: Karakteristike osobnosti investitora donose značajno veći broj dugoročno korisnih odluka o ulaganju na financijskom tržištu – djelomično prihvaća.**

Dodatni tržišni faktori, koji nisu uključeni u bihevioralne, analizirani su u ovom alternativnom modelu, jer mogu bitno utjecati na ponašanje investitora pri odlučivanju. Ipak, na neki način i ovaj konstrukt tržišnih faktora može se promatrati kroz bihevioralni aspekt, s obzirom da se tržišni faktori ne promatraju direktno kroz vrijednosti cijena, volumena trgovanja, pokazatelja iz financijskih izvještaja i sl., već su procijenjeni putem ankete. Rezultati pokazuju da postoji značajan pozitivan utjecaj tržišnih faktora na investicijske odluke. Prema tome, investitori koji su skloniji analizi cijena i trendova dionica, fundamentalnoj analizi i sl., u većoj mjeri detaljnije razmatraju opcije ulaganja i biraju dugoročne investicije. Ovakav rezultat je i očekivan temeljem prethodnih istraživanja, jer se na tržištu može pronaći najviše informacija i uz analizu tržišnih pokazatelja može se očekivati da investitori neće puno pogriješiti u svojim odlukama. Stoga, **hipoteza H6: Analiziranje tržišnih faktora značajno povećava broj dugoročno korisnih odluka o ulaganju investitora na financijskom tržištu – se prihvaća.**

Posljednja ispitana veza odnosi se na utjecaj investicijskih odluka na investicijske performanse. Prema rezultatima procijenjenog modela, utjecaj je pozitivan i statistički značajan. Uzevši u obzir indikatore dvaju ispitivanih konstrukata, može se zaključiti da su investitori koji pretežno ulažu

sredstva u dugoročne investicije te pomno razmatraju i istražuju tržište prije investicijskog poteza, posljedično zadovoljniji svojom vlastitom stopom prinosa te odlukama koje su donijeli o kupnji i prodaji dionica. Rezultat pokazuje logičnu povezanost ovih dviju varijabli, s obzirom da investitori koji se odlučuju za dugoročna ulaganja, od tih ulaganja ostvaruju i dugoročne koristi u vidu stabilne cijene dionice i redovite dividende. Veća razina dugoročnih koristi dovodi do veće razine zadovoljstva investicijskim performansama pojedinca. Dakle, posljednja **hipoteza H7: Dugoročno korisne odluke o ulaganju pozitivno utječu na zadovoljstvo investicijskim performansama investitora na financijskom tržištu – se prihvaća.**

6.2 Ograničenja provedenog istraživanja

Ovo istraživanje fokusirano je na identificiranje utjecaja bihevioralnih faktora na investicijske odluke i performanse investitora na financijskom tržištu putem strukturalnog modeliranja, a predstavljena su dva pristupa modeliranja: CB-SEM i PLS-SEM. U istraživanju se od bihevioralnih faktora promatraju heuristike, elementi prospektne teorije, ponašanje krda, emocije i raspoloženje te stabilnost i prilagodljivost kao faktori osobnosti, a dodatno se promatraju i tržišni faktori. Unatoč tome što ovakav oblik sveobuhvatnog modela dosad nije bio testiran, ipak se kroz neke od navedenih bihevioralnih faktora može identificirati nekoliko zasebnih dimenzija koje ih sačinjavaju. Zbog zahtjeva SEM analize i međusobne usporedivosti četiri procijenjena CB-SEM i PLS-SEM modela, ovo istraživanje obuhvaća samo glavne bihevioralne faktore, bez njihove podjele na posebne dimenzije. Naime, dodatnom podjelom bihevioralnih faktora na njihove komponente, tj. dimenzije, iz šest nezavisnih varijabli moglo bi ih proizaći i mnogo više, što bi značajno povećalo kompleksnost modela. U tom slučaju, javio bi se problem kod procjene i mogućnosti konvergencije modela, naročito kad se radi o CB-SEM pristupu. Međutim, razdvajanjem bihevioralnih faktora na njihove dimenzije, dobio bi se pregledniji uvid u način na koji određena vrsta ponašanja investitora utječe na njihovo donošenje investicijskih odluka. Dakle, može se reći da postoji ograničenje rada u smislu broja utjecajnih varijabli.

Nadalje, ovo istraživanje ispituje ponašanje investitora u određenom trenutku u vremenu. Međutim, s obzirom da su ljudi podložni promjenama ponašanja i ponekih karakteristika osobnosti tijekom života, postoji mogućnost da bi se kroz longitudinalno istraživanje dobili drugačiji rezultati. Osim toga, s vremenom se često mijenjaju i zakoni i regulative financijskog tržišta, što dodatno može utjecati na ljudsko ponašanje. Iz tog razloga, praćenje ponašanja investitora kroz više vremenskih

razdoblja, uz isti SEM model, može razjasniti postoje li promjene utjecaja bihevioralnih faktora na investicijske odluke i performanse kroz vrijeme, i kakve su te promjene ako postoje.

6.3 Implikacije za primjenu u praksi

Glavna skupina ljudi kojoj istraživanja na temu bihevioralnih financija mogu pomoći su upravo investitori, odnosno mali ulagatelji. Oni nisu uvijek dovoljno educirani o trgovanju, zbog čega se i pokazuje da su skloni različitim iracionalnim tipovima ponašanja. Prepoznavajući situacije i razloge svog ponašanja, kao i način na koji takva ponašanja utječu na njihove odluke i performanse, investitori mogu pokušati utjecati na svoje ponašanje u danim situacijama i mijenjati ga u smjeru koji će im osigurati povoljnije odluke, a samim time i investicijske performanse. S druge strane, rezultati ovakvog tipa istraživanja mogu biti zanimljivi i financijskim savjetnicima. Ukoliko financijski savjetnici znaju prepoznati situacije na tržištu koje bi mogle dovesti do masovnog iracionalnog ponašanja, mogu usmjeriti svoje klijente da ne srljaju s nepromišljenim i/ili pretjerano emocionalnim odlukama o investiranju te im objasniti razine prihvaćanja rizika određenih investicija. Na taj način financijski savjetnici mogu pomoći klijentima u ostvarivanju boljih rezultata od ulaganja u dionice. Osim toga, važno je da financijski savjetnici i brokeri ispravno usmjeravaju klijente, vodeći se isključivo njihovim interesima i da ih ne potiču na pretjerano trgovanje, što se negativno odražava na pojedince, kao i na cjelokupno tržište. Nadalje, razvojem sveobuhvatnog SEM modela koji promatra veze između ključnih varijabli bihevioralnih financija, istraživači mogu replicirati model u svrhu usporedbe dobivenih rezultata temeljem uzorka ovog istraživanja s rezultatima dobivenim na temelju drugog uzorka. Također, ovaj rad daje opsežan pregled literature, uvjete i upute za korištenje prikladne SEM metode u istraživanjima. To pridonosi boljem razumijevanju problematike strukturalnog modeliranja, što u konačnici može biti korisno za istraživače i praktičare koji će se susresti s potrebom razumijevanja i/ili korištenja SEM metode u svojim analizama.

6.4 Preporuke za daljnja istraživanja

Vodeći se prethodno navedenim ograničenjima rada, mogu se prepoznati i preporuke za buduća istraživanja.

U ovom radu fokus je na glavnim bihevioralnim faktorima i njihovom utjecaju na odluke i performanse investitora na financijskom tržištu. Dodatnim raščlanjivanjem ovih faktora na njihove

dimenzije, moguće je provesti detaljnije istraživanje. Na taj način može se zaključiti kakav je pojedinačni utjecaj svake vrste heuristika, svakog elementa prospektne teorije, različitih manjih skupina emocija i raspoloženja te velikih 5 varijabli osobnosti (umjesto dvije varijable koje ih obuhvaćaju) na odluke investitora i njihove performanse.

Osim toga, u budućim istraživanjima je moguće testirati medijaciju, odnosno postaviti model u kojem postoji i direktan i indirektan utjecaj svakog bihevioralnog faktora na investicijske performanse. Tada bi se moglo zaključiti je li promatrani bihevioralni faktori utječu na zadovoljstvo investicijskim performansama i, u slučaju da utjecaj postoji, je li taj utjecaj direktan ili je posljedica investicijskih odluka kao posredničke varijable. Drugim riječima, ispitalo bi se je li promjene u bihevioralnim faktorima uzrokuju promjenu u investicijskim odlukama, što konačno uzrokuje promjenu u investicijskim performansama, ili postoji direktan utjecaj, neovisan o investicijskim odlukama.

Nadalje, daljnja istraživanja mogu uzeti u obzir i ispitivanje razlika između određenih grupa na temelju nekih demografskih ili drugih obilježja ispitanika. Tako se može zaključiti postoje li razlike u uzročno-posljedičnim vezama istraživačkog modela između više grupa, npr. između muških i ženskih ispitanika, između ispitanika različite razine obrazovanja ili različite razine mjesečnih primanja, kao i između ispitanika s različitim razinama iskustva u radu i na financijskom tržištu i sl.

Također se mogu ispitati i odnosi među samim bihevioralnim faktorima. S obzirom da su neka istraživanja pokazala da karakteristike osobnosti utječu na sklonosti određenom načinu ponašanja, u daljnjim istraživanjima moguće je respecificirati model, na način da se osobnost promatra kao glavna nezavisna varijabla kroz nekoliko dimenzija, umjesto da se promatra njezin izravan utjecaj na investicijske odluke.

Konačno, buduća istraživanja mogu biti usmjerena i na ispitivanje ponašanja investitora kroz vrijeme. Ovakva analiza može pokazati postojanje potencijalnih promjena u utjecaju bihevioralnih faktora na investicijske odluke i performanse investitora kroz različite vremenske periode. Rezultati ovakvog istraživanja dali bi odgovor na pitanje je li na tržištu općenito konstantno vlada slično ponašanje investitora, neovisno o vremenskom periodu u kojem se vrši ispitivanje, ili ipak dolazi do većih promjena.

POPIS LITERATURE

1. Ab Hamid, M. R., Sami, W. i Sidek, M. M., 2017. Discriminant validity assessment: Use of Fornell & Larcker criterion versus HTMT criterion. *Journal of Physics: Conference Series*, Vol. 890 (1), str. 012163.
2. Abul, S. J., 2019. Factors influencing Individual Investor Behaviour: Evidence from the Kuwait Stock Exchange. *Asian Social Science*, Vol. 15 (3), str. 27-39.
3. Ackert, L. F., Church, B. K. i Deaves, R., 2003. Emotion and Financial Markets. *Economic Review, Federal Reserve Bank of Atlanta*, Vol. 88. (Q2), str. 33-41.
4. Aguinis, H., Gottfredson, R. K. i Culpepper, S. A., 2013. Best-practice recommendations for estimating cross-level interaction effects using multilevel modeling. *Journal of Management*, Vol. 39 (6), str. 1490-1528.
5. Akerlof, G. A. i Shiller, R. J., 2009. *Animal Spirits: How human psychology drives the economy, and why it matters for global capitalism*. Princeton: Princeton University Press.
6. Akerlof, G. A. i Shiller, R. J., 2015. *Phishing for Phools: The economics of manipulation and deception*. Princeton: Princeton University Press.
7. Allameh, S. M., Chitsaz, A., Hosseini, S-H. i Esfahani, S. I., 2015. Evaluating Behavioral Factors Influencing Performance of Investors in Teheran Stock Exchange. *International Research Journal of Management Sciences*, Vol. 3 (2), str. 43-48.
8. Alquraan, T., Alqisie, A. i Al Shorafa, A., 2016. Do Behavioral Factors Influence Stock Investment Decisions of Indidivudal Investors? (Evidences from Saudi Stock Market). *American International Journal of Contemporary Research*, Vol. 6 (3), str. 159-169.
9. Alrabadi, D. W. H., Al-Abdallah, S. Y. i Aljarayesh, N. I. A., 2018. Behavioral Biases and Investment Performance: Does Gender Matter? Evidence from Amman Stock Exchange. *Jordan Journal of Economic Sciences*, Vol. 5 (1), str. 77-91.
10. Alshamy, S. A., 2019. Factors Affecting Investment Decision Making: Moderating Role of Investors Characteristics. The Journal of Social Sciences Research, Vol. 5 (4), str. 965-974.
11. Altaras Penda, I., 2019. Devastacija hrvatskog tržišta kapitala – što dalje? *FIP - Financije i pravo*, Vol. 7 (1), str. 125-156.
12. Andrijanić, I. i Vidaković, N., 2015. *Poslovanje na burzama – načela i praksa*. Zagreb: Visoko učilište Effectus – visoka škola za financije i pravo.

13. Ardalan, K., 2018. Neurofinance versus the efficient markets hypothesis. *Global Finance Journal*, Vol. 35 (C), str. 170-176.
14. Aren, S. i Nayman Hamamci, H., 2020. Relationship between risk aversion, risky investment intention, investment choices: Impact of personality traits and emotion. *Kybernetes*, Vol. 49 (11), str. 2651-2682.
15. Ariely, D., 2019. *Predvidljivo iracionalni: Nevidljive sile koje upravljaju našim odlukama*. Zagreb: V.B.Z.
16. Avkiran, N. K., 2018. Rise of the partial least squares structural equation modeling: an application in banking. U: Avkiran, N. K. i Ringle, C. M. ur. *Partial least squares structural equation modeling-Recent Advances in Banking and Finance*. Cham: Springer, str. 1-29.
17. Awang, Z., 2012: *A Handbook on SEM: Structural equation modeling using amos graphics*. Kelantan: University Technology MARA Press.
18. Awang, Z., Afthanorhan, A., Mamat, M., 2016. The Likert scale analysis using parametric based Structural Equation Modeling (SEM). *Computational Methods in Social Sciences*, Vol. 4 (1), str. 13-21.
19. Babajide, A. A. i Adetiloye, K. A., 2012. Investors' Behavioural Biases and the Security Market: An Empirical Study of the Nigerian Security Market. *Accounting and Finance Research*, Vol. 1 (1), str. 219-229.
20. Bakar, S. i Yi, A. N. C., 2016. The Impact of Psychological Factors on Investors' Decision Making in Malaysian Stock Market: A Case of Klang Valley and Pahang. *Procedia Economics and Finance*, Vol. 35, str. 319-328.
21. Bandalos, D. L. i Gagné, P., 2012. Simulation methods in structural equation modeling. U: Hoyle, R. H. ur. *Handbook of structural equation modeling*. New York: The Guilford Press, str. 92-108.
22. Barber, B. M. i Odean, T., 2001. Boys will be Boys: Gender, Overconfidence, and Common Stock Investment. *The Quarterly Journal of Economics*, Vol. 116 (1), str. 261-292.
23. Barberis, N. i Thaler, R. H., 2005. A Survey Of Behavioral Finance. U: Thaler, R. H., ur. *Advances in Behavioral Finance*. 2. izd. New York: Princeton University Press, str. 636-711.

24. Baron, R. M. i Kenny, D. A., 1986. The moderator–mediator variable distinction in social psychological research: Conceptual, strategic, and statistical considerations. *Journal of Personality and Social Psychology*, Vol. 51 (6), str. 1173–1182.
25. Bauldry, S., 2015. Structural Equation Modeling. U: Wright, J. D. ur. *International Encyclopedia of the Social & Behavioral Sciences*. 2. izd. Oxford: Elsevier, str. 615-620.
26. Bazdan, Z., 2006. Najnoviji trendovi na financijskim tržištima: burze postaju virtualne financijske institucije. *Tourism and hospitality management*, Vol. 12 (1), str. 89-100.
27. Becker, J. M., Ringle, C. M. i Sarstedt, M., 2018. Estimating moderating effects in PLS-SEM and PLSc-SEM: Interaction term generation*data treatment. *Journal of Applied Structural Equation Modeling*, Vol. 2(2), str. 1-21.
28. Bergsma, K., Fodor, A. i Tedford, E., 2020. A Closer Look at the Disposition Effect in U.S. Equity Option Markets. Journal of Behavioral Finance, Vol. 20 (1), str. 66-77.
29. Bikas, E. i Saponaite, V., 2018. Behavior of the Lithuanian investors at the period of economic growth. *Entrepreneurship and Sustainability Issues*, Vol. 6 (1), str. 44-59.
30. Blackburn, R., Renwick, S. J. D., Donnelly, J. P. i Logan, C. 2004. Big Five or Big Two? Superordinate factors in the NEO Five Factor Inventory and the Antisocial Personality Questionnaire. *Personality and Individual Differences*, Vol. 37 (5), str. 957-970.
31. Bollen, K. A. i Noble, M. D., 2011. Structural equation models and the quantification of behavior. *Proceedings of the National Academy of Sciences*, Vol. 108 (3), str. 15639-15646.
32. Boomsma, A., Hoyle, R. H. i Panter, A. T., 2012. The structural equation modeling research report. U: Hoyle, R. H. ur. *Handbook of structural equation modeling*. New York: The Guilford Press, str. 341-358.
33. Brahmana, R., Hooy, C. W. i Ahmad, Z., 2012. The role of herd behaviour in determining the investor's Monday irrationality. *Asian Academy of Management Journal of Accounting & Finance*, Vol. 8. (2), str. 1-20.
34. Brajković, A. i Radman Peša, A., 2015. Bihevioralne financije i teorija "Crnog labuda". *Oeconomica Jadertina*, Vol. 5 (1), str. 65-93.
35. Brown, T. A. i Moore, M. T., 2012. Confirmatory factor analysis. U: Hoyle, R. H. ur. *Handbook of structural equation modeling*. New York: The Guilford Press, str. 361-379.
36. Brown, T. A. i Moore, M. T., 2012. Confirmatory factor analysis. U: Hoyle, R. H. ur. *Handbook of structural equation modeling*. New York: The Guilford Press, str. 361-379.

37. Brown, T. A., 2006. *Confirmatory factor analysis for applied research*. New York: The Guilford Press.

38. Bruhn, A., 2019. Relying on the heuristic of trust: a case study. *Accounting & Finance*, Vol. 59, str. 333-357.

39. Bulmer, M., Gibbs, J. i Hyman, L., 2006. The use of pre-existing survey questions: implications for data quality. European Conference on Quality in Survey Statistics, Cardiff, Ujedinjeno Kraljevstvo, 24.-26.04.2006.

40. Camerer, C. F., Loewenstein, G. i Prelec, D., 2004. Neuroeconomics: Why Economics Needs Brains. *The Scandinavian Journal of Economics*, Vol. 106 (3), str. 555-579.

41. Cangur, S. i Ercan, I., 2015. Comparison of model fit indices used in structural equation modeling under multivariate normality. *Journal of Modern Applied Statistical Methods*, Vol. 14 (1), str. 152-167.

42. Carifio, J. i Perla, R. J., 2007. Ten Common Misunderstandings, Misconceptions, Persistent Myths and Urban Legends about Likert Scales and Likert Response Formats and their Antidotes. *Journal of Social Sciences*, Vol. 3 (3), str. 106-116.

43. Carrión, G. C., Nitzl, C. i Roldán, J. L., 2017. Mediation Analyses in Partial Least Squares Structural Equation Modeling: Guidelines and Empirical Examples. U: Latan, H. i Noonan, R. ur. *Partial Least Squares Path Modeling*. Heidelberg: Springer, str. 173-195.

44. Charles, A. i Kasilingam, R., 2014a. Do Investors' Emotions Determine their Investment Personality? *Parikalpana - KIIT Journal of Management*, Vol. 10(II), str. 45-60.

45. Charles, A. i Kasilingam, R., 2014b. Do Framing Effects of Investors Determine their Investment Personality? *Anvesha*, Vol. 7 (2), str. 38-45.

46. Charles, A. i Kasilingam, R., 2016. Impact of selected behavioural bias factors on investment decisions of equity investors. *ICTACT Journal on Management Studies*, Vol. 2 (2), str. 297-311.

47. Cheah, J. H., Sarstedt, M., Ringle, C. M., Ramayah, T. i Ting, H., 2018. Convergent validity assessment of formatively measured constructs in PLS-SEM: On using single-item versus multi-item measures in redundancy analyses. *International Journal of Contemporary Hospitality Management*, Vol. 30 (11), str. 3192-3210.

48. Chen, F., Bollen, K. A., Paxton, P., Curran, P. J. i Kirby, J. B., 2001. Improper solutions in structural equation models: Causes, consequences, and strategies. *Sociological methods & research*, Vol. 29 (4), str. 468-508.

49. Chen, F., Curran, P. J., Bollen, K. A., Kirby, J. i Paxton, P., 2008. An empirical evaluation of the use of fixed cutoff points in RMSEA test statistic in structural equation models. *Sociological methods & research*, Vol. 36 (4), str. 462-494.

50. Cheong, J. i MacKinnon, D. P., 2012. Mediation/indirect effects in structural equation modeling. U: Hoyle, R. H. ur. *Handbook of structural equation modeling*. New York: The Guilford Press, str. 417-435.

51. Cheses, A., 2019. The Role of Behavioral Finance in Advising Clients. *Investments & Wealth Research*, Vol. 4, str. 1-7.

52. Chopde, S. i Kulkarni, N., 2017. Impact of Behavioral Biases on Investment Decisions of Individual Investors in Mumbai: A sample study. *International Journal on Recent and Innovation Trends in Computing and Communication, Special Issue: International Conference On Emanations in Modern Technology and Engineering (ICEMTE 2017)*, Vol. 5. (3), str. 74-77.

53. Civelek, M. E., 2018. *Essentials of Structural Equation Modeling*. Zea Lincoln, Nebraska: E-Books.

54. Cueva, C., Iturbe-Ormaetxe, I., Ponti, G., Tomás, J., 2019. An experimental analysis of the disposition effect: Who and when? *Journal of Behavioral and Experimental Economics*, Vol. 81, str. 207-215.

55. Cuong, P. K. i Jian Z., 2014. Factors Influencing Individual Investor Behavior: An Empirical Study of the Vietnamese Stock Market. *American Journal of Business and Management*, Vol. 3(2), str. 77-94.

56. Curtis, G., 2004. Modern Portfolio Theory and Behavioral Finance. *The Journal of Wealth Management*, Vol. 7 (2), str. 16-22.

57. Dabić, S. i Penavin, S., 2009. Utjecaj obujma trgovanja na kretanje tržišnog indeksa Crobex. *Ekonomski vjesnik: Review of Contemporary Entrepreneurship, Business, and Economic Issues*, Vol. XXII (1) str. 51-61.

58. De Bondt, W. F. M. i Thaler, R., 1985. Does the stock market overreact? *Journal of Finance*, Vol. 40 (3), str. 793-805.

59. De Bortoli, D., da Costa, N. Jr., Goulart, M. i Campara, J., 2019. Personality traits and investor profile analysis: A behavioral finance study. *PloS one*, Vol. 14 (3), str. e0214062.

60. De Carvalho, J. i Chima, F. O., 2014. Applications of Structural Equation Modeling in Social Sciences Research. *American International Journal of Contemporary Research*, Vol. 4. (1), str. 6-11.

61. Delegirana uredba Komisije (EU) 2016/522 od 17. prosinca 2015. o dopuni Uredbe (EU) br. 596/2014 Europskog parlamenta i Vijeća u pogledu izuzeća za određena javna tijela i središnje banke trećih zemalja, pokazatelja manipuliranja tržištem, pragova za objavljivanje, nadležnog tijela za obavijesti o odgodama, odobrenja trgovanja tijekom razdoblja zabrane trgovanja i vrste transakcija rukovoditelja o kojima se mora obavješćivati Tekst značajan za EGP. Dostupno na: http://data.europa.eu/eli/reg_del/2016/522/oj [pristupljeno 29.07.2021.]

62. Deng, L., Yang, M. i Marcoulides, K. M., 2018. Structural equation modeling with many variables: A systematic review of issues and developments. *Frontiers in psychology*, Vol. 9, str. 580.

63. DeYoung, C. G., 2006. Higher-Order Factors of the Big Five in a Multi-Informant Sample. *Journal of Personality and Social Psychology*, Vol. 91 (6), str. 1138-1151.

64. DeYoung, C. G., 2010. Toward a Theory of the Big Five. *Psychological Inquiry*, Vol. 21 (1), str. 26-33.

65. DeYoung, C. G., 2014. A cybernetic big five theory for personality psychology. *Personality and Individual Differences*, Vol. 60 (Supplement), str. S18.

66. Diamantopoulos, A., Sarstedt, M., Fuchs, C., Wilczynski, P. i Kaiser, S., 2012. Guidelines for choosing between multi-item and single-item scales for construct measurement: A predictive validity perspective. *Journal of the Academy of Marketing Science*, Vol. 40 (3), str. 434-449.

67. Direktiva 2014/65/EU Europskog parlamenta i Vijeća od 15. svibnja 2014. o tržištu financijskih instrumenata i izmjeni Direktive 2002/92/EZ i Direktive 2011/61/EU Tekst značajan za EGP. Dostupno na: http://data.europa.eu/eli/dir/2014/65/oj [pristupljeno 29.07.2021.]

68. Dolfin, M., Leonida, L. i Outada, N., 2017. Modeling Human Behavior in Economics and Social Science. *Physics of Life Reviews*, Vol. 22-23, str. 1-21.

69. Dragan, D. i Topolšek, D., 2014. Introduction to structural equation modeling: review, methodology and practical applications. *The 11th International Conference on Logistics & Sustainable Transport 2014*, 19–21. lipnja 2014, Celje, Slovenija, str. 1–27.

70. Duxbury, D., 2015. Behavioral Finance: Insights from experiments I: Theory and financial markets. *Review of Behavioral Finance*, Vol. 7 (1), str. 78 - 96.

71. Duxbury, D., Gärling, T., Gamble, A. i Klass, V., 2020. How emotions influence behavior in financial markets: a conceptual analysis and emotion-based account of buy-sell preferences. *The European Journal of Finance*, Vol. 26 (14), str. 1417-1438.

72. Elster, J., 1998. Emotions and economic theory. *Journal of Economic Literature*, Vol. 36 (1), str. 47-74.

73. Erdle, S., Irwing, P., Rushton, J. P. i Park, J., 2010. The general factor of personality and its relation to self-esteem in 628,640 internet respondents. *Personality and Individual Differences*, Vol. 48 (3), str. 343-346.

74. Evitiatini, H., 2014. Što su heuristike? U: Polšek, D. i Bovan, K. ur. *Uvod u bihevioralnu ekonomiju*. Zagreb: Institut društvenih znanosti Ivo Pilar, str. 423-441.

75. Fama, E. F., 1998. Market efficiency, long-term returns, and behavioral finance. *Journal of Financial Economics*, Vol. 49 (3), str. 283-306.

76. Fassott, G., Henseler, J. i Coelho, P. S., 2016. Testing moderating effects in PLS path models with composite variables. *Industrial Management & Data Systems*. Vol. 116 (9), str. 1887-1900.

77. Fenton-O'Creevy, M., Soane, E., Nicholson, N. i Willman, P., 2011. Thinking, feeling and deciding: The influence of emotions on the decision making and performance of traders. *Journal of Organizational Behavior*, Vol. 32 (8), str. 1044-1061.

78. Flora, D. B. i Curran, P. J., 2004. An empirical evaluation of alternative methods of estimation for confirmatory factor analysis with ordinal data. *Psychological methods*, Vol. 9 (4), str. 466-491.

79. Fornell, C. i Larcker, D. F., 1981. Evaluating structural equation models with unobservable variables and measurement error. *Journal of marketing research*, Vol. 18 (1), str. 39-50.

80. Frankel, J., 2021. What's Different About the GameStop Bubble? Project Syndicate. 3. veljača. Dostupno na: https://www.project-syndicate.org/commentary/gamestop-effect-on-financial-markets-by-jeffrey-frankel-2021-02 [pristupljeno 28.09.2021.]

81. Galbraith, J. K., 2009. *The Great Crash 1929*. Mariner Books.

82. Garson, G. D., 2016. *Partial Least Squares: Regression and Structural Equation Models*. Asheboro, NC: Statistical Associates Publishers.

83. Gefen, D., Straub, D. i Boudreau, M.C., 2000. Structural equation modeling and regression: Guidelines for research practice. *Communications of the Association for Information Systems*, Vol. 4 (1), str. 1-79.

84. Geldhof, G. J., Preacher, K. J. i Zyphur, M. J., 2014. Reliability estimation in a multilevel confirmatory factor analysis framework. *Psychological methods*, Vol. 19 (1), str. 72-91.

85. Ghalandari, K. i Ghahremanpour, J., 2013. The Effect of Market Variables and Herding Effect on Investment Decision as Factor Influencing Investment Performance in Iran. *Journal of Basic and Applied Scientific Research*, Vol. 3 (3), str. 313-318.

86. Goodboy, A. K. i Kline, R. B., 2017. Statistical and Practical Concerns With Published Communication Research Featuring Structural Equation Modeling. *Communication Research Reports*, Vol. 34 (1), str. 68-77.

87. Graham, B., Zweig, J. i Buffett, W., 2003. *The Intelligent Investor*. London: Harper Collins Publishers.

88. Graham, J. W. i Coffman, D. L., 2012. Structural equation modeling with missing data. U: Hoyle, R. H. ur. *Handbook of structural equation modeling*. New York: The Guilford Press, str. 277-295.

89. Griffith, J., Najand, M i Shen J., 2020. Emotions in the Stock Market. *Journal of Behavioral Finance*, Vol. 21 (1), str. 42-56.

90. Gudergan, S. P., Ringle, C. M., Wende, S. i Will, A., 2008. Confirmatory tetrad analysis in PLS path modeling. *Journal of business research*, Vol. 61 (12), str. 1238-1249.

91. Hair, J. F., Black, W. C., Babin, B. J. i Anderson, R. E., 2010. *Multivariate Data Analysis.* 7. izd. New York: Pearson.

92. Hair, J. F., Black, W. C., Babin, B. J. i Anderson, R. E., 2019a. *Multivariate Data Analysis.* 8. izd. Andover: Cengage Learning.

93. Hair, J. F., Hult, G. T. M., Ringle, C. M. and Sarstedt, M., 2017a. *A Primer on Partial Least Squares Structural Equation Modeling (PLS-SEM).* 2. izd. Los Angeles: Sage Publications.

94. Hair, J. F., Matthews, L. M., Matthews, R. L. i Sarstedt, M., 2017b. PLS-SEM or CB-SEM: updated guidelines on which method to use. *International Journal of Multivariate Data Analysis*, Vol. 1 (2), str. 107- 123.

95. Hair, J. F., Ringle, C. M. i Sarstedt, M., 2011. PLS-SEM: Indeed a Silver Bullet. *Journal of Marketing Theory and Practice*, Vol. 19 (2), str. 139-151.

96. Hair, J. F., Risher, J. J., Sarstedt, M. i Ringle, C. M., 2019b. When to use and how to report the results of PLS-SEM. *European Business Review*, Vol. 31 (1), str. 2-24.

97. Hair, J. F., Sarstedt, M., Hopkins, L. i Kuppelwieser, V. G., 2014. Partial least squares structural equation modeling (PLS-SEM): An emerging tool in business research. *European business review*, Vol. 26 (2), str.106-121.

98. Hair, J. F., Sarstedt, M., Pieper, T. M. i Ringle, C. M., 2012. The use of partial least squares structural equation modeling in strategic management research: a review of past practices and recommendations for future applications. *Long range planning*, Vol. 45 (5-6), str. 320-340.

99. Hair, J. F., Sarstedt, M., Ringle, C. M. i Gudergan, S. P., 2017c. *Advanced Issues in Partial Least Squares Structural Equation Modeling*. Los Angeles: Sage Publications.

100. Hanafiah, M. H., 2020. Formative Vs. Reflective Measurement Model: Guidelines for Structural Equation Modeling Research. *International Journal of Analysis and Applications*, Vol. 18 (5), str. 876-889.

101. Henseler, J. i Fassott, G., 2010. Testing moderating effects in PLS path models: An illustration of available procedures. U: Vinzi, V. E., Chin, W. W., Henseler, J. i Wang, H. ur. *Handbook of partial least squares*. Berlin, Heidelberg: Springer, str. 713-735.

102. Henseler, J., 2018. Partial least squares path modeling: Quo vadis?. *Quality & Quantity*, Vol. 52 (1), str. 1-8.

103. Henseler, J., Ringle, C. M. i Sarstedt, M., 2012. Using partial least squares path modeling in international advertising research: Basic concepts and recent issues. U: Okazaki, S. ur. *Handbook of research in international advertising*. Cheltenham, UK: Edward Elgar Publishing, str. 252-276.

104. Henseler, J., Ringle, C. M. i Sarstedt, M., 2015. A new criterion for assessing discriminant validity in variance-based structural equation modeling, *Journal of the Academy of Marketing Science*, Vol. 43 (1), str. 115-135.

105. Henseler, J., Ringle, C. M. i Sarstedt, M., 2016. Testing Measurement Invariance of Composites Using Partial Least Squares. *International Marketing Review*, Vol. 33 (3), str. 405-431.

106. Hinton, P., Brownlow, C., McMurray, I. i Cozens, B. 2004. *SPSS Explained*. London and New York: Routledge.

107. Ho, M.-h. R., Stark, S. i Chernyshenko, O., 2012. Graphical representation of structural equation models using path diagrams. U: Hoyle, R. H. ur. *Handbook of structural equation modeling*. New York: The Guilford Press, str. 43-55.

108. Hooper, D., Coughlan, J. i Mullen, M. R., 2008. Structural Equation Modelling: Guidelines for Determining Model Fit. *The Electronic Journal of Business Research Methods*, Vol. 6 (1), str. 53-60.

109. Hoyle, R. H., 2012. Introduction and Overview. U: Hoyle, R. H. ur. *Handbook of structural equation modeling*. New York: The Guilford Press, str. 3-16.

110. Hu, L.-t. i Bentler, P. M., 1998. Fit indices in covariance structure modeling: Sensitivity to underparameterized model misspecification. *Psychological Methods*, Vol. 3 (4), str. 424-453.

111. Jabeen, S., Shah, S. Z. A., Sultana, N. i Khan, A., 2020. Impact of Socio-Psychological Factors on Investment Decisions: The Mediating Role of Behavioral Biases. *Abasyn Journal of Social Sciences*, Vol. 13 (1), str. 25-39.

112. Jamshidinavid, B., Chavoshani, M. i Amiri, S., 2012. The Impact of Demographic and Psychological Characteristics on the Investment Prejudices in Tehran Stock. *European Journal of Business and Social Sciences*, Vol. 1 (5), str. 41-53.

113. Jelić, N., 2014. Bihevioralna ekonomija, neuroekonomija, neuromarketing. *Jahr: Europski časopis za bioetiku*, Vol. 5 (1), str. 193-209.

114. John, O. P. i Srivastava, S., 1999. The Big Five Trait taxonomy: History, measurement, and theoretical perspectives. U: Pervin, L. A. i John, O. P. ur. *Handbook of personality: Theory and research.* Guilford Press, str.102-138.

115. Johnson, N., Zhao, G., Hunsader, E., Meng, J., Ravindar, A., Carran, S. i Tivnan, B., 2012. Financial black swans driven by ultrafast machine ecology. Working paper. *Cornel University*. Dostupno na: https://arxiv.org/abs/1202.1448 [pristupljeno 05.08.2021.]

116. Jurevičiene, D. i Ivanova, O., 2013. Behavioural Finance: Theory and Survey. *Mokslas – Lietuvos ateitis/Science – Future of Lithuania*, Vol. 5 (1), str. 53-58.

117. Kahneman, D. i Tversky A., 2014. Suđenje u uvjetima neizvjesnosti. U: Polšek, D. i Bovan, K. ur. *Uvod u bihevioralnu ekonomiju*. Zagreb: Institut društvenih znanosti Ivo Pilar, str. 223-257.

118. Kahneman, D. i Tversky, A., 1974. Judgement under Uncertainty: Heuristics and Biases. *Science*, Vol. 85 (4157), str. 1124-1131.

119. Kahneman, D. i Tversky, A., 1979. Prospect Theory: An Analysis of Decision under Risk. *Econometrica*, Vol. 47 (2), str. 263-292.

120. Kahneman, D., 2013. *Misliti, brzo i sporo*. Mozaik knjiga: Zagreb.

121. Kallinterakis, V., Munir, N. i Radović-Marković, M., 2010. Herd Behaviour, Illiquidity and Extreme Market States: Evidence from Banja Luka. *Journal of Emerging Market Finance*, Vol. 9 (3), str. 305-324.

122. Kenny, D. A. i Milan, S., 2012. Identification: A nontechnical discussion of a technical issue. U: Hoyle, R. H. ur. *Handbook of structural equation modeling*. New York: The Guilford Press, str. 145-163.

123. Kenny, D. A., 2018. Moderation. Dostupno na: http://davidakenny.net/cm/moderation.htm [pristupljeno 21.07.2021.]

124. Khamis, A. B., Kamarudin, N. K. K., Nor, M. E., Saharan, S. i Asrah, N. M., 2017. Covariance Based and Partial Least Square Structural Equation Modeling to Model Job Satisfaction among Lecturers. *Scientific Research Journal(SCIRJ)*, Vol. 5 (3), str. 19-28.

125. Khan, H. H., Naz, I., Qureshi, F. i Ghafoor, A., 2017. Heuristics and stock buying decision: Evidence from Malaysian and Pakistani stock markets. *Borsa Istanbul Review*, Vol. 17 (2), str. 97-110.

126. Kim, K. A. i Nofsinger, J. R., 2008. Behavioral finance in Asia. *Pacific-Basin Finance Journal*, Vol. 16 (1-2), str. 1–7.

127. Kline, R. B., 2011. *Principles and Practice of Structural Equation Modeling*. 3. izd. New York: The Guilford Press.

128. Kline, R. B., 2012. Assumptions in structural equation modeling. U: Hoyle, R. H. ur. *Handbook of structural equation modeling*. New York: The Guilford Press, str. 111-125.

129. Kline, R. B., 2015. The Mediation Myth. *Basic and Applied Social Psychology*, Vol. 37 (4), str. 202-213.

130. Kostolany, A., 2008. *Psihologija burze*. Zagreb: Masmedia.

131. Kübilay, B. i Bayrakdaroğlu, A., 2016. An Empirical Research on Investor Biases in Financial Decision-Making, Financial Risk Tolerance and Financial Personality. *International Journal of Financial Research*, Vol. 7 (2), str. 171-182.

132. Kumar, S. i Goyal, N., 2016. Evidence on rationality and behavioural biases in investment decision making. *Qualitative Research in Financial Markets*, Vol. 8 (4), str. 270-287.

133. Lai, C. P., 2019. Personality Traits and Stock Investment of Individuals. *Sustainability*, Vol. 11 (19), str. 54-74.

134. Lam, L. W., 2012. Impact of competitiveness on salespeople's commitment and performance. *Journal of Business Research*, Vol. 65 (9), str. 1328-1334.

135. Langer, E., 1975. The illusion of control. *Journal of Personality and Social Psychology*, Vol. 32 (2), str. 311–328.

136. Le Bon, G., 1896. *The Crowd: A Study of the Popular Mind*. New York: Macmillan.

137. Lei, P.-W. i Wu, Q., 2012. Estimation in structural equation modeling. U: Hoyle, R. H. ur. *Handbook of structural equation modeling*. New York: The Guilford Press, str. 164-180.

138. Lewis, M., 2016. *Munjeviti momci s Wall Streeta*. Zagreb: Profil knjiga.

139. Li, C. H., 2016. Confirmatory factor analysis with ordinal data: Comparing robust maximum likelihood and diagonally weighted least squares. *Behavior research methods*, Vol. 48 (3), str. 936-949.

140. Lin, H-W., 2011a. Elucidating the Influence of Demographic and Psychological Traits on Investment Biases. *International Journal of Economics and Management Engineering*, Vol. 5 (5), str. 424-429.

141. Lin, H-W., 2011b. Elucidating rational investment decisions and behavioral biases: Evidence from the Taiwanese stock market. *African Journal of Business Management*, Vol. 5 (5), str. 1630-1641.

142. Liu, H., Qi, L. i Li, Z., 2019. Insider trading, representativeness heuristic insider, and market regulation. *The North American Journal of Economics and Finance*, Vol. 47, str. 48-64.

143. Lo, A. W., 2004. The Adaptive Markets Hypothesis. *The Journal of Portfolio Management*, Vol. 30 (5), str. 15-29.

144. Loehlin, J. C., 2004. *Latent Variable Models: An Introduction to Factor, Path, and Structural Equation Analysis*. 4. izd. Mahwah, New Jersey: Lawrence Erlbaum Associates.

145. Loewenstein, G., 2000. Emotions in Economic Theory and Economic Behavior. *The American Economic Review*, Vol. 90 (2), str. 426-432.

146. Lohmöller, J., 1989., *Latent Variable Path Modeling with Partial Least Squares*. Heidelberg: Springer.

147. MacKenzie, S. B., Podsakoff, P. M. i Podsakoff, N. P., 2011. Construct measurement and validation procedures in MIS and behavioral research: Integrating new and existing techniques. *MIS Quarterly*, Vol. 35 (2), str. 293-334.

148. MacKinnon, D. P., Fairchild, A. J. i Fritz, M. S., 2007. Mediation Analysis. *Annual Review of Psychology*, Vol. 58 (1), str. 593–614.

149. Malkiel, G. B., 2019. *Uspješna startegija burzovnog trgovanja*, Zagreb: Masmedia.

150. Matthews, L., 2017. Applying multigroup analysis in PLS-SEM: A step-by-step process. U: Latan, H. i Noonan, R. ur. *Partial least squares path modeling*. Heidelberg: Springer, str. 219-243.

151. Mayfield, C., Perdue, G. i Wooten, K., 2008. Investment management and personality type. Financial Services Review, Vol. 17 (3), str. 219-236.

152. McDonald, R.P. i Ho, M-H.R., 2002. Principles and Practice in Reporting Structural Equation Analyses. *Psychological Methods*, Vol. 7 (1), str. 64-82

153. Miendlarzewska, E., Kometer, M. i Preuschoff, K., 2017. Neurofinance. *Organizational Research Methods*, Vol. 22 (5), str. 1-27.

154. Miller, M. i Modigliani, F., 1961. Dividend policy, growth, and the valuation of shares. *Journal of Business*, Vol. 34 (4), str. 411-433.

155. Milošević, K., 2016. Novosti koje na tržišta kapitala donosi direktiva MiFID II. *Računovodstvo, revizija i financije*, Vol. 16 (8), str. 126-133.

156. Mîndrilă, D., 2010. Maximum Likelihood (ML) and Diagonally Weighted Least Squares (DWLS) Estimation Procedures: A Comparison of Estimation Bias with Ordinal and Multivariate Non-Normal Data. *International Journal of Digital Society*, Vol. 1 (1), str. 60-66.

157. Mlikotić, S. 2010. Globalna financijska kriza - uzroci, tijek i posljedice. *Pravnik*, Vol. 44 (89), str. 83-94.

158. Mohamad, M., Afthanorhan, A., Awang, Z. i Mohammad, M., 2019. Comparison Between CB-SEM and PLS-SEM: Testing and Confirming the Maqasid Syariah Quality of Life Measurement Model. *The Journal of Social Sciences Research*, Vol. 5 (3), str. 608-614

159. Mushinada, V. N. C., 2020. Are individual investors irrational or adaptive to market dynamics? *Journal of Behavioral and Experimental Finance*, Vol. 25 (C), str. 1-9.

160. Muthén, B. i Asparouhov, T., 2012. Bayesian structural equation modeling: a more flexible representation of substantive theory. *Psychological Methods*. Vol. 17 (3), str. 313-335.

161. Narodne novine, 2018. Zakon o tržištu kapitala. Zagreb: Narodne novine, d.d., 65/18.

162. Narodne novine, 2020. Zakon o izmjenama i dopunama Zakona o tržištu kapitala. Zagreb: Narodne novine, d.d., 17/20.

163. Neal, L., 2015. *A Concise History of International Finance: From Babylon to Bernanke*. Cambridge: Cambridge University Press.

164. Newsom, J. T., 2018. Practical Approaches to Dealing with Nonnormal and Categorical Variables. *Structural Equation Modeling handouts*. Department of Psychology, Portland State University.

165. Newsom, J. T., 2020. Alternative Estimation Methods. *Structural Equation Modeling handouts*. Department of Psychology, Portland State University.

166. Nga, J. K. H. i Ken Yien, L., 2013. The influence of personality trait and demographics on financial decision making among Generation Y. *Young Consumers*, Vol. 14 (3), str. 230-243.

167. Olsson, U. H., Foss, T., Troye, S. V. i Howell, R. D., 2000. The performance of ML, GLS, and WLS estimation in structural equation modeling under conditions of misspecification and nonnormality. *Structural Equation Modeling*, Vol. 7 (4), str. 557-595.

168. Peng, D. X. i Lai, F., 2012. Using partial least squares in operations management research: A practical guideline and summary of past research. *Journal of operations management*, Vol. 30 (6), str. 467-480.

169. Phuoc Luong, L. i Thi Thu Ha, D., 2011. *Behavioral factors influencing individual investors' decision-making and performance: A survey at the Ho Chi Minh Stock Exchange*. Magistarski rad, Umeå School of Business. Dostupno na:

https://www.researchgate.net/publication/328277613_Behavioral_factors_influencing_individual_investors_decision-making_and_performance_A_survey_at_the_Ho_Chi_Minh_Stock_Exchange [pristupljeno 03.05.2019.]

170. Pimenta, A. i Fama, R., 2014. Behavioral Finance: A Bibliometric Mapping of Academic Publications in USA Since 1993. *SSRN Electronic Journal*. Dostupno na: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=2406763 [pristupljeno 26.06.2019.]

171. Pompian, M., 2016. *Risk Profiling through a Behavioral Finance Lens*. CFA Institute Research Foundation. Dostupno na: https://www.cfainstitute.org/-/media/documents/article/rf-brief/rfbr-v2-n1-1-pdf.ashx [pristupljeno 03.05.2019.]

172. Prelec, D. 2006. Rebuilding the Boat While Staying Afloat: The Modeling Challenge for Behavioral Economics. *Journal of Marketing Research*, Vol. 43 (3), str. 332–336.

173. Qasim, M., Hussain, R., Mehboob, I. i Arshad, M., 2019. Impact of herding behavior and overconfidence bias on investors' decision-making in Pakistan. *Accounting*, Vol. 5 (2), str. 81-90.

174. Rabaa'i, A. A., 2017. Holistic procedures for contemporary formative construct validation using PLS: a comprehensive example. *International Journal of Business Information Systems*, Vol. 25 (3), str. 279-318.

175. Rabe-Hesketh, S., Skrondal, A. i Zheng, X., 2012. Multilevel structural equation modeling. U: Hoyle, R. H. ur. *Handbook of structural equation modeling*. New York: The Guilford Press, str. 512-531.

176. Rahman, M. i Gan, S. S., 2020. Generation Y investment decision: an analysis using behavioural factors. *Managerial Finance*, Vol. 46 (8), str. 1023-1041.

177. Ramayah, T., Cheah, J., Chuah, F., Ting, H. i Memon, M.A., 2018. *Partial Least Squares Structural Equation Modeling (PLS-SEM) using SmartPLS 3.0: An Updated and Practical Guide to Statistical Analysis*. 2. izd. Kuala Lumpur, Malaysia: Pearson.

178. Rasoolimanesh, S. M. i Ali, F., 2018. Partial least squares-structural equation modeling in hospitality and tourism. *Journal of Hospitality and Tourism Technology*, Vol. 9 (3), str. 238-248.

179. Raut, R. K., Das, N. i Mishra, R., 2020. Behaviour of Individual Investors in Stock Market Trading: Evidence from India. *Global Business Review*, Vol. 21 (3), str. 818-833.

180. Raykov, T. i Marcoulides, G. A., 2006. *A First Course in Structural Equation Modeling*. 2. izd. Mahwah, New Jersey: Lawrence Erlbaum Associates.

181. Rekha. D.M., 2020. Determinants of behavioral finance influencing investment decisions with respect to income: A study on investment in the equity market. *International Journal of Advanced Science and Technology*, Vol. 29 (8), str. 5015-5028.

182. Rhemtulla, M., Brosseau-Liard, P. É. i Savalei, V., 2012. When can categorical variables be treated as continuous? A comparison of robust continuous and categorical SEM estimation methods under suboptimal conditions. *Psychological Methods*, Vol. 17 (3), str. 354–373.

183. Rigdon, E. E., 1996. CFI versus RMSEA: A comparison of two fit indexes for structural equation modeling. *Structural Equation Modeling: A Multidisciplinary Journal*, Vol. 3 (4), str. 369-379.

184. Ringle, C. M. i Sarstedt, M., 2016. Gain more insight from your PLS-SEM results: The importance-performance map analysis. *Industrial Management & Data Systems*, Vol. 116 (9), str. 1865-1886.

185. Ringle, C., Silva, D. i Bido, D., 2014. Structural Equation Modeling with the Smartpls. *Brazilian Journal Of Marketing*, Vol. 13 (2), str. 56-73.

186. Sajter, D., 2013. Algoritamsko i visoko-frekventno trgovanje. *Ekonomska misao i praksa*, Vol. 22 (1), str. 321-336.

187. Sarstedt, M., Hair, J. F., Cheah, J. H., Becker, J. M. i Ringle, C. M., 2019. How to specify, estimate, and validate higher-order constructs in PLS-SEM. *Australasian Marketing Journal*, Vol. 27 (3), str. 197-211.

188. Sarstedt, M., Hair, J. F., Ringle, C. M., Thiele, K. O. i Gudergan, S. P., 2016. Estimation issues with PLS and CBSEM: Where the bias lies! *Journal of Business Research*, Vol. 69 (10), str. 3998-4010.

189. Sarstedt, M., Henseler, J. i Ringle, C. M., 2011. Multi-group Analysis in Partial Least Squares (PLS) Path Modeling: Alternative Methods and Empirical Results. *Advances in International Marketing*, Vol. 22, str. 195–218.

190. Sarstedt, M., Ringle, C. M. i Hair, J. F., 2017a. Partial least squares structural equation modeling. U: Homburg, C., Klarmann, M. i Vomberg, A. E. ur. *Handbook of market research*. Cham: Springer.

191. Sarstedt, M., Ringle, C. M. i Hair, J. F., 2017b. Treating unobserved heterogeneity in PLS-SEM: A multi-method approach. U: Latan, H. i Noonan, R. ur. *Partial Least Squares Path Modeling*. Heidelberg: Springer, str. 197-217.

192. Schermelleh-Engel, K., Moosbrugger, H. i Müller, H., 2003. Evaluating the Fit of Structural Equation Models: Tests of Significance and Descriptive Goodness-of-Fit Measures. *Methods of Psychological Research*, Vol. 8 (2), str. 23-74.

193. Schreiber, J. B., Nora, A., Stage, F. K. , Barlow, E. A. i King, J., 2006. Reporting Structural Equation Modeling and Confirmatory Factor Analysis Results: A Review. *The Journal of Educational Research*, Vol. 99 (6), str. 323-337.

194. Schumacker, R. E. i Lomax, R. G., 2010. *A beginner's guide to structural equation modeling*. 3. izd. New York: Routledge/Taylor & Francis Group.

195. Shah, S. Z. A., Ahmad, M. i Mahmood, F., 2018. Heuristic biases in investment decision-making and perceived market efficiency: A survey at the Pakistan stock exchange. *Qualitative Research in Financial Markets*, Vol. 10 (1), str. 85-110.

196. Sharma, P. N., Shmueli, G., Sarstedt, M., Danks, N. i Ray, S., 2021. Prediction-oriented model selection in partial least squares path modeling. *Decision Sciences*, Vol. 52 (3), str. 567-607.

197. Sharma, P., Sarstedt, M, Shmueli, G., Kim, K. H. i Thiele, K. O., 2019. PLS-Based Model Selection: The Role of Alternative Explanations in Information Systems Research. *Journal of the Association for Information Systems*, Vol. 20 (4), str. 346-397.

198. Shefrin, H. i Statman, M., 1985. The disposition to sell winners too early and ride losers too long: theory and evidence. *Journal of Finance*, Vol. 40 (3), str. 777-790.

199. Shefrin, H. M. i Statman, M. 1984. Explaining Investor Preference for Cash Dividends. *Journal of Financial Economics*, Vol. 13 (2), str. 253-282.

200. Shiller, R. J., 2015. *Irrational Exuberance*. 3. izd. Princeton: Princeton University Press.

201. Shiller, R., J., 2019. Was the Stock Market Boom Predictable? Project Syndicate. 29. ožujak. Dostupno na: https://www.project-syndicate.org/commentary/was-ten-year-stock-market-boom-predictable-by-robert-j--shiller-2019-03 [pristupljeno 28.09.2021.]

202. Shiller, R., J., 2020. Understanding the Pandemic Stock Market. Project Syndicate. 7. srpanj. Dostupno na: https://www.project-syndicate.org/commentary/understanding-us-pandemic-stock-market-by-robert-j-shiller-2020-07 [pristupljeno 28.09.2021.]

203. Shmueli, G., Ray, S., Velasquez Estrada, J. M. i Chatla, S. B., 2016. The elephant in the room: Evaluating the predictive performance of PLS models. *Journal of Business Research*, Vol. 69 (10), str. 4552-4564.

204. Shmueli, G., Sarstedt, M., Hair, J. F., Cheah, J.-H., Ting, H., Vaithilingam, S. i Ringle, C. M., 2019. Predictive model assessment in PLS-SEM: guidelines for using PLSpredict. *European Journal of Marketing*, Vol. 53, str. 2322-2347.

205. Siddiqui, K., 2015. Heuristics of Using Structural Equation Modeling in Social Research. *Sci.Int.(Lahore)*, Vol. 27 (6), str. 6381-6384.

206. Siraji, M., 2019. Heuristics Bias and Investment Performance: Does Age Matter? Evidence from Colombo Stock Exchange. *Asian Journal of Economics, Business and Accounting*, Vol. 12 (4), str. 1-14.

207. Sowinski, M., Schnusenberg, O. i Materne, S., 2011. "Sprechen Sie Bias?" An investigation of cultural differences in behavioral finance biases between Germany and the United States. *Journal of Behavioral Studies in Business*, Vol. 3 (4), str. 53-76.

208. Središnje klirinško depozitarno društvo, 2021. Statistički bilten – II. tromjesečje 2021. godine. Dostupno na: https://www.skdd.hr/portal/f?p=100:602:5287412280669::NO::: [pristupljeno 26.07.2021.]

209. Statman, M., 2008. Countries and Culture in Behavioral Finance. *CFA Institute Conference Proceedings Quarterly*, Vol. 25 (3), str. 38-44.

210. Statman, M., 2014. Behavioral finance: Finance with normal people. *Borsa Istanbul Review*, Vol. 14, str. 65-73.

211. Statman, M., 2017. *Finance for normal people: How Investors and Markets Behave*. New York: Oxford University Press.

212. Statman, M., 2018. A Unified Behavioral Finance. *The Journal of Portfolio Management*, Vol. 44 (7), str. 124–134.

213. Stride, C., 2017. *Multilevel Modelling using Mplus*, lecture notes, Falcon Training – Statistical Consultancy and Training Service, London School of Economics.

214. Stride, C., 2018. *Testing Mediation and Moderation using Mplus*, lecture notes, Falcon Training – Statistical Consultancy and Training Service, London School of Economics.

215. Suhr, D., 2006. The basics of structural equation modeling. *SAS User Group of the Western Region of the United States (WUSS)*. Rujan, 2006., Irvine, Kalifornija, SAD. Dostupno na: http://www.lexjansen.com/wuss/2006/tutorials/TUT-Suhr.pdf [pristupljeno 24.05.2021.]

216. Šimić, G., 2019. Hipokampus i pamćenje. U: Šimić, G. ur. *Uvod u neuroznanost učenja i pamćenja*. Zagreb: Naklada Ljevak, str. 65-98.

217. Šonje, V., 2014. Financije i racionalnost: što možemo naučiti od bihevioralnih financija. U: Polšek, D. i Bovan, K. ur. *Uvod u bihevioralnu ekonomiju*. Zagreb: Institut društvenih znanosti Ivo Pilar, str. 223-257.

218. Tabachnick, B. G. i Fidell, L. S., 2007. *Using Multivariate Statistics*. 5. izd. Boston: Pearson.

219. Tarka, P., 2018. An overview of structural equation modeling: its beginnings, historical development, usefulness and controversies in the social sciences. *Quality & Quantity*, Vol. 52 (1), str. 313-354.

220. Tauni, M. Z., Yousaf, S. i Ahsan, T., 2020. Investor-advisor Big Five personality similarity and stock trading performance. *Journal of Business Research*, Vol. 109, str. 49-63.

221. Tavakol, M., Dennick, R., 2011. Making sense of Cronbach's alpha. *International Journal of Medical Education*, Vol. 2, str. 53-55.

222. Thaler, R. H., 2020. *Nerazumno ponašanje – Stvaranje bihevioralne ekonomije*. Zagreb: Školska knjiga.

223. Tissen, M. V., 2012. The development and formation of financial science in a world context. *Bulletin of Scientific Research Result*, Vol. 3 (4), str. 197-206.

224. Toma, F-M., 2015. Behavioral Biases of the Investment Decisions of Romanian Investorson the Bucharest Stock Exchange. *Procedia Economics and Finance*, Vol. 32, str. 200-207.

225. Tomarken, A. J. i Waller, N. G., 2005. Structural Equation Modeling: Strengths, Limitations, and Misconceptions. *Annual Review of Clinical Psychology*. Vol. 1 (1), str. 31-65.

226. Trang, P. T. M. i Tho, N. H., 2017. Perceived Risk, Investment Performance and Intentions in Emerging Stock Markets. *International Journal of Economics and Financial Issues*, Vol. 7 (1), str. 269-278.

227. Uredba (EU) br. 596/2014 Europskog parlamenta i Vijeća od 16. travnja 2014. o zlouporabi tržišta (Uredba o zlouporabi tržišta) te stavljanju izvan snage Direktive 2003/6/EZ Europskog parlamenta i Vijeća i direktiva Komisije 2003/124/EZ, 2003/125/EZ i 2004/72/EZ Tekst značajan za EGP. Dostupno na: http://data.europa.eu/eli/reg/2014/596/oj [pristupljeno 29.07.2021.]

228. Uredba (EU) br. 600/2014 Europskog parlamenta i Vijeća od 15. svibnja 2014. o tržištima financijskih instrumenata i izmjeni Uredbe (EU) br. 648/2012 Tekst značajan za EGP. Dostupno na: http://data.europa.eu/eli/reg/2014/600/oj [pristupljeno 29.07.2021.]

229. Van Kesteren, E. J. i Oberski, D., 2019. Structural Equation Models as Computation Graphs. *ZPID-Kolloquium*. Listopad 2019, Trier, Njemačka. Dostupno na: https://arxiv.org/abs/1905.04492 [pristupljeno 24.05.2021.]

230. Wamae, J. N., 2013. Behavioural factors influencing investment decision in stock market: A survey of investment banks in Kenya. *International Journal of Social Sciences and Entrepreneurship*, Vol. 1 (6), str. 68-83.

231. Wang, X.L., Shi, K. i Fan, H. X., 2006. Psychological mechanisms of investors in Chinese Stock Markets. *Journal of Economic Psychology*, Vol. 27, str. 762-780.

232. Waweru, N. M., Gitau Mwangi, G. i Parkinson, J., 2014. Behavioural factors influencing investment decisions in the Kenyan property market. *Afro-Asian Journal of Finance and Accounting*, Vol. 4 (1), str. 26 - 49.

233. Waweru, N. M., Munyoki, E. i Uliana, E., 2008. The effects of behavioral factors in investment decision-making: a survey of institutional investors operating at the Nairobi Stock Exchange. *International Journal of Business and Emerging Markets*, Vol. 1 (1), str. 24-41.

234. Wessels, D., Goedhart, M. i Koller T., 2005. What really drives the market? *MIT Sloan Management Review*, Vol. 47 (1), str. 21-23.

235. West, S. G., Taylor, A. B. i Wu, W., 2012. Model fit and model selection in structural equation modeling. U: Hoyle, R. H. ur. *Handbook of structural equation modeling*. New York: The Guilford Press, str. 209-231.

236. Wong, K. K. K., 2013. Partial least squares structural equation modeling (PLS-SEM) techniques using SmartPLS. *Marketing Bulletin*, Vol. 24 (1), str. 1-32.

237. Wong, K. K. K., 2016. Mediation analysis, categorical moderation analysis, and higher-order constructs modeling in Partial Least Squares Structural Equation Modeling (PLS-SEM): A B2B Example using SmartPLS. *Marketing Bulletin*, Vol. 26 (1), str. 1-22.

238. Yadav, A. i Narayanan, G. B., 2021. Do personality personality traits predict biasdness while making investment decisions? *International Journal of Accounting & Finance Review*, Vol. 6 (1), str. 19-33.

239. Zagrebačka burza, 2021. Rang lista članova. Dostupno na: https://zse.hr/hr/clanovi/52 [pristupljeno 14.08.2021.]

240. Zagrebačka burza. Dostupno na: https://zse.hr/hr/popis-clanova/146 [pristupljeno 23.02.2021.]

241. Zaiţ, A. i Bertea, P., 2011. Methods for testing discriminant validity. *Management & Marketing Journal*, Vol. IX (2), str. 217-224.

242. Zelić, M. i Lukavac, M., 2018. Bihevioralni pristup ekonomiji – objašnjenje tržišnih neefikasnosti s naglaskom na financijsko tržište. *Oeconomica Jadertina*, Vol. 8 (1), str. 51-62.

243. Zelić, M., 2017. *Bihevioralna ekonomija i efikasnost financijskih tržišta*. Diplomski rad, Sveučilište u Zadru, Odjel za ekonomiju.

244. Zhang, Y. i Zheng, X., 2015. A Study Of The Investment Behavior Based On Behavioral Finance. *European Journal of Business and Economics*, Vol. 10 (1), str. 1-5.

245. Zhao, X., Lynch, J. G. i Chen, Q., 2010. Reconsidering Baron and Kenny: Myths and Truths about Mediation Analysis. *Journal of Consumer Research*, Vol. 37 (2), str. 197-206.

246. Zhou, Z., Xu, K. i Zhao, J., 2018. Tales of emotion and stock in China: volatility, causality and prediction. *World Wide Web*, Vol. 21 (4), str. 1093–1116.

247. Zweig, J., 2007. *Your Money and Your Brain: How the New Science of Neuroeconomics Can Help Make You Rich*. New York: Simon & Schuster.

248. Žigman, A., 2020. Što nakon koronakrize? Izazov promjene. Listopad, 2020., Rovinj, Hrvatska. Dostupno na: https://www.hanfa.hr/media/5115/hanfa_izazov_promjene_rovinj_10_2020.pdf [pristupljeno 28.09.2021.]

249. Žigman, A., 2021. Kako omogućiti oporavk nakon pandemije? Novac.hr. 29. srpanj. Dostupno na: https://novac.jutarnji.hr/novac/rasprave-i-rjesenja/kako-omoguciti-oporavak-nakon-pandemije-15091554 [pristupljeno 05.08.2021.]

POPIS KRATICA I OZNAKA

ADF – metoda proizvoljne funkcije distribucije (eng. *arbitrary distribution function*)

AGFI – prilagođeni indeks prikladnosti modela (eng. *adjusted goodness-of-fit index*)

AVE – prosječna izlučena varijanca (eng. *average variance extracted*)

BIC – Bayesov informacijski kriterij (eng. *Bayesian Information Criterion*)

CAPM – Model vrednovanja kapitalne imovine (eng. *Capital Asset Pricing Model*)

CB-SEM – modeliranje strukturalnim jednadžbama temeljeno na kovarijanci (eng. *covariance-based SEM*)

CFA – konfirmatorna faktorska analiza (eng. *confirmatory factor analysis*)

CFI – indeks komparativne prilagodbe (eng. *comparative fit index*)

CR – pouzdanost konstrukta (eng. *construct reliability*)

CTA – konfirmatorna analiza tetrada (eng. *confirmatory tetrad analysis*)

ECNs – elektroničke komunikacijske mreže (eng. *electronic communication networks*)

EFA – eksplorativna faktorska analize (eng. *exploratory factor analysis*)

EMH – Teorija (hipoteza) efikasnog tržišta (eng. *Efficient Market Hypothesis*)

ESMA – Europsko nadzorno tijelo za vrijednosne papire i tržišta kapitala (eng. *European Securities Markets Authority*)

ETF – fondovi čijim se udjelima trguje na burzi (eng. *exchange traded funds*)

EU – Europska Unija

FIMIX-PLS – *finite mixture* PLS metoda (eng. *finite mixture* PLS)

FIX – Informacijski protokol za razmjenu financijskih informacija (eng. *Financial Information eXchange*)

fMRI – funkcionalna magnetska rezonancija (eng. *functional magnetic resonance imaging*)

GFI – indeks prikladnosti modela (eng. *goodness-of-fit index*)

GLS – metoda generaliziranih najmanjih kvadrata (eng. *generalized least squares*)

GM – Geweke-Meese kriterij (eng. *Geweke-Meese Criterion*)

HANFA – Hrvatska agencija za nadzor financijskih usluga

HCM – model hijerarhijskih komponenata (eng. *hierarchical component model*)

HOC – komponenta višeg reda (eng. *higher-order component*)

HTMT – *heterotrait-monotrait* omjer (eng. *heterotrait-monotrait ratio*)

ICC – pokazatelj mjere u kojoj je ukupna varijanca pripisana razlikama između grupa (eng. *intra-class correlation*)

IPMA – analiza važnosti i učinka (eng. *importance-performance map analysis*)

LGM – model latentnog rasta (eng. *latent growth model*)

LM – model linearne regresije (eng. *linear regression model*)

LOC – komponenta nižeg reda (eng. *lower-order components*)

MAE – prosječna apsolutna pogreška (eng. *mean absolute error*)

MAPE – prosječna apsolutna postotna pogreška (eng. *mean absolute percentage error*)

MAR – podaci koji nedostaju slučajno (eng. *missing at random*)

MCAR – podaci koji nedostaju potpuno slučajno (eng. *missing completely at random*)

MGA – analiza više grupa (eng. *multigroup analysis*)

MI – modifikacijski indeksi (eng. *modification indices*)

MICOM – procedura za procjenu mjerne nepromjenjivosti kompozitnih modela (eng. *measurement invariance of composite models*)

MiFID – Direktiva o tržištima financijskih instrumenata (eng. *Markets in Financial Instruments Directive*)

MiFIR – Uredba o tržištima financijskih instrumenata (eng. *Markets in Financial Instruments Regulation*)

ML – metoda najveće vjerodostojnosti (eng. *maximum likelihood*)

MLM – modeliranje na više razina (eng. *multilevel modeling*)

MOST – Multioperativni Sustav Trgovine

MTP – multilateralna trgovinska platforma

MTP – Teorija modernog portfelja (eng. *Modern Portfolio Theory*)

NASDAQ – američka elektronička burza dionica sa sjedištem u New Yorku (akronim za *National Association of Securities Dealers Automated Quotations*)

NC – normirani hi-kvadrat (eng. *normed chi-square*)

NFI – nenormirani indeks prikladnosti (eng. *non-normed fit index*)

NFI – normirani indeks prikladnosti (eng. *normed fit index*)

NYSE – Njujorška burza (eng. *New York Stock Exchange*)

OLS – metoda najmanjih kvadrata (eng. *ordinary least squares*)

OTC – trgovanje „preko pulta" (eng. *over-the-counter*)

OTG – skupni test grupnih razlika (eng. *omnibus test of group differences*)

OTP – organizirana trgovinska platforma

PLSc – konzistentni PLS algoritam (eng. *consistent PLS*)

PLS-POS – segmentacija orijentirana na predviđanje (eng. *prediction-oriented segmentation in PLS-SEM*)

PLS-SEM – modeliranje strukturalnim jednadžbama metodom parcijalnih najmanjih kvadrata (eng. *partial least squares SEM*)

RIFSM – model slučajnog konstantnog člana i fiksnog koeficijenta smjera (eng. *Random Intercept and Fixed Slope Model*)

RIRSM – model slučajnog konstantnog člana i slučajnog koeficijenta smjera (eng. *Random Intercept and Random Slope Model*)

RMR – korijen prosječnog kvadratnog odstupanja (eng. *root mean square residual*)

RMSE – korijen prosječne kvadratne pogreške (eng. *root mean squared error*)

RMSEA – korijen prosječne kvadratne pogreške procjene (eng. *root mean square error of approximation*)

RMS_{theta} – korijen prosječnog kvadratnog odstupanja kovarijance (eng. *root mean square residual covariance*)

SEC – Komisija za vrijednosnice i burzu Sjedinjenih Američkih Država (eng. *Securities and Exchange Commission*)

SEM – modeliranje strukturalnim jednadžbama (eng. *structural equation modeling*)

SI – sistematski internalizator

SKDD – Središnje klirinško depozitarno društvo

SMC – kvadratna višestruka korelacija (eng. *squared multiple correlation*)

SRMR – standardizirani korijen prosječnog kvadratnog odstupanja (eng. *standardized root mean square residual*)

TEST – Telekomunikacijski Sustav Trgovine

TLI – Tucker Lewis indeks

TOL – tolerancija (eng. *tolerance*)

ULI – ograničenje vrijednosti parametra njegovim fiksiranjem na vrijednost 1 (eng. *unit loading identification constraint*)

ULS – metoda neponderiranih najmanjih kvadrata (eng. *unweighted least squares*)

UVI – ograničenje vrijednosti varijance faktora fiksiranjem na vrijednost 1 (eng. *unit variance identification constraint*)

VAF – uračunata varijanca (eng. *variance accounted for*)

VIF – faktor inflacije varijance (eng. *variance inflation factor*)

WLS – metoda ponderiranih najmanjih kvadrata (eng. *weighted least squares*)

WLSM – težinska metoda najmanjih kvadrata (eng. *mean-adjusted weighted least squares*)

WLSMV – metoda dijagonalno ponderiranih najmanjih kvadrata (eng. *mean and variance adjusted weighted least squares*)

ZSE – Zagrebačka burza (eng. *Zagreb Stock Exchange*)

POPIS SLIKA I TABLICA

SLIKE:

Slika 1.1. Konceptualni model istraživanja 7
Slika 4.1. Prikaz simbola SEM-a u path dijagramu 70
Slika 4.2. Primjer SEM modela 72
Slika 4.3. Prikaz općih jednadžbi SEM modela u matričnom obliku 74
Slika 4.4. Faze SEM modeliranja 80
Slika 4.5. Primjeri razina identifikacije modela 83
Slika 4.6. Primjeri različitih parametara u modelu 85
Slika 4.7. Razlika između formativnog i reflektivnog modela 87
Slika 4.8. Primjer modifikacije CFA modela u strukturalni model 88
Slika 4.9. Razlika između rekurzivnog i nerekurzivnog modela 89
Slika 4.10. SEM model s prikazom direktnih i indirektnih utjecaja 112
Slika 4.11. Prikaz efekta medijacije 114
Slika 4.12. Prikaz paralelne medijacije 117
Slika 4.13. Prikaz serijske medijacije 117
Slika 4.14. Grafički prikaz moderacije 117
Slika 4.15. Model s efektom interakcije 118
Slika 4.16. Primjer LGM modela 120
Slika 4.17. Kontrast modela prvog i drugog reda 122
Slika 4.18. Prikaz jednostavnog PLS-SEM modela 125
Slika 4.19. Razlika reflektivnog i formativnog načina mjerenja modela 132
Slika 4.20. Postupak ispitivanja relevantnosti vanjskog opterećenja indikatora 137
Slika 4.21. Postupak procjene diskriminantne validnosti putem HTMT kriterija 141
Slika 4.22. Postupak procjene kolinearnosti u formativnim mjernim modelima koristeći pokazatelj VIF 144
Slika 4.23. *Bootstrapping* procedura 145
Slika 4.24. Proces donošenja odluke o zadržavanju ili uklanjanju formativnih indikatora 147
Slika 4.25. Primjer PLSpredict procedure s 5 podgrupa 154
Slika 4.26. Smjernice za interpretaciju PLSpredict rezultata 157
Slika 4.27. Shema općeg medijacijskog modela 160
Slika 4.28. Proces analize medijacije 162
Slika 4.29. Primjer paralelne i serijske medijacije 163
Slika 4.30. Pretvorba konceptualnog modela s moderatorom u statistički model 164
Slika 4.31. Pristup produkta indikatora 165
Slika 4.32. Ortogonalizacijski pristup 167
Slika 4.33. Dvoetapni pristup 168
Slika 4.34. Smjernice za izbor pristupa za kreiranje interakcijskog efekta 169
Slika 4.35. Vrste modela hijerarhijskih komponenata 172
Slika 4.36. Pristup ponovljenih indikatora 173
Slika 4.37. Prošireni pristup ponovljenih indikatora 174

Slika 4.38. Dvoetapni pristup HOC 175
Slika 4.39. Grafički prikaz IPMA 177
Slika 4.40. Pristupi testiranju MGA u PLS-SEM modelima 178
Slika 4.41. MICOM procedura 181
Slika 5.1. Grafički prikaz ispitanika prema Cookovim udaljenostima 206
Slika 5.2. *Path* dijagram sa standardiziranim koeficijentima (CB-SEM model) 215
Slika 5.3. *Path* dijagram sa standardiziranim koeficijentima (alternativni CB-SEM model) 222
Slika 5.4. *Path* dijagram sa strukturalnim koeficijentima (PLS-SEM model) 232
Slika 5.5. *Path* dijagram sa strukturalnim koeficijentima (alternativni PLS-SEM model) 242

TABLICE:

Tablica 4.1. Pokazatelji prilagodbe modela s granicama prihvaćanja 104
Tablica 4.2. Karakteristike različitih pokazatelja prilagodbe modela pri različitim uvjetima modeliranja 105
Tablica 4.3. Preporuke veličine uzorka za PLS-SEM pri snazi testa od 80% 128
Tablica 4.4. Smjernice za odabir između CB-SEM i PLS-SEM metode 129
Tablica 4.5. Smjernice za odabir između reflektivne i formativne specifikacije modela 133
Tablica 5.1. Ispitanici prema spolu 186
Tablica 5.2. Ispitanici prema dobi 187
Tablica 5.3. Ispitanici prema spolu i dobi 187
Tablica 5.4. Ispitanici prema bračnom statusu 188
Tablica 5.5. Ispitanici prema radnom iskustvu 188
Tablica 5.6. Ispitanici prema iskustvu trgovanja na financijskom tržištu 189
Tablica 5.7. Ispitanici prema spolu i iskustvu trgovanja na financijskom tržištu 189
Tablica 5.8. Ispitanici prema radnom iskustvu i iskustvu trgovanja na financijskom tržištu 190
Tablica 5.9. Ispitanici prema mjesečnim primanjima 191
Tablica 5.10. Ispitanici prema spolu i mjesečnim primanjima 191
Tablica 5.11. Ispitanici prema razini obrazovanja 192
Tablica 5.12. Ispitanici prema iskustvu trgovanja na financijskom tržištu i razini obrazovanja 192
Tablica 5.13. Ispitanici prema pohađanju edukacije o trgovanju na burzi 193
Tablica 5.14. Ispitanici prema spolu i pohađanju edukacije o trgovanju na burzi 194
Tablica 5.15. Ispitanici prema iskustvu trgovanja na financijskom tržištu i pohađanju edukacije o trgovanju na burzi 194
Tablica 5.16. Deskriptivna statistika faktora heuristika 195
Tablica 5.17. Deskriptivna statistika faktora prospektne teorije 196
Tablica 5.18. Deskriptivna statistika faktora ponašanja krda 197
Tablica 5.19. Deskriptivna statistika faktora emocija i raspoloženja 198
Tablica 5.20. Deskriptivna statistika faktora prilagodljivosti 199

Tablica 5.21. Deskriptivna statistika faktora stabilnosti 199
Tablica 5.22. Deskriptivna statistika tržišnih faktora 200
Tablica 5.23. Deskriptivna statistika faktora investicijskih odluka 201
Tablica 5.24. Deskriptivna statistika faktora investicijskih performansi 201
Tablica 5.25. Prikaz analize univarijatne i multivarijatne normalnosti podataka 202
Tablica 5.26. Rezultati analize multivarijatnih outliera putem Cookove udaljenosti 204
Tablica 5.27. Rezultati analize multikolinearnosti 206
Tablica 5.28. Indikatori faktora u konačnom CB-SEM modelu 208
Tablica 5.29. Rezultati analize konvergentne validnosti i pouzdanosti CB-SEM modela .. 210
Tablica 5.30. Rezultati analize diskriminantne validnosti CB-SEM modela 211
Tablica 5.31. Rezultati strukturalnog modela s pokazateljima prilagodbe (CB-SEM) 214
Tablica 5.32. Indikatori faktora u konačnom alternativnom CB-SEM modelu 215
Tablica 5.33. Rezultati analize konvergentne validnosti i pouzdanosti alternativnog CB-SEM modela 217
Tablica 5.34. Rezultati analize diskriminantne validnosti alternativnog CB-SEM modela 219
Tablica 5.35. Rezultati alternativnog strukturalnog modela s pokazateljima prilagodbe (CB-SEM) 221
Tablica 5.36. Indikatori faktora u konačnom PLS-SEM modelu 224
Tablica 5.37. Rezultati analize konvergentne validnosti i pouzdanosti PLS-SEM modela. 226
Tablica 5.38. Rezultati analize diskriminantne validnosti PLS-SEM modela prema Fornell-Larcker kriteriju 227
Tablica 5.39. Rezultati analize diskriminantne validnosti PLS-SEM modela prema HTMT pokazatelju 228
Tablica 5.40. Intervali pouzdanosti HTMT-a (originalni PLS-SEM model) 228
Tablica 5.41. Rezultati strukturalnog modela (PLS-SEM) 231
Tablica 5.42. Rezultati analize eksplanatorne i prediktivne snage modela (PLS-SEM) 233
Tablica 5.43. Pokazatelji prilagodbe modela (PLS-SEM) 234
Tablica 5.44. Indikatori faktora u konačnom alternativnom PLS-SEM modelu 234
Tablica 5.45. Rezultati analize konvergentne validnosti i pouzdanosti alternativnog PLS-SEM modela 236
Tablica 5.46. Rezultati analize diskriminantne validnosti alternativnog PLS-SEM modela prema Fornell-Larcker kriteriju 238
Tablica 5.47. Rezultati analize diskriminantne validnosti alternativnog PLS-SEM modela prema HTMT pokazatelju 238
Tablica 5.48. Intervali pouzdanosti HTMT-a (alternativni PLS-SEM model) 239
Tablica 5.49. Rezultati strukturalnog modela (alternativni PLS-SEM model) 241
Tablica 5.50. Rezultati analize eksplanatorne i prediktivne snage modela (alternativni PLS-SEM model) 243
Tablica 5.51. Pokazatelji prilagodbe modela (alternativni PLS-SEM model) 244
Tablica 5.52. Usporedba rezultata CB-SEM i PLS-SEM procijenjenih modela 247
Tablica 5.53. Kriteriji usporedbe i odabira PLS-SEM modela 248

PRILOZI

PRILOG 1 – Anketni upitnik

Utjecaj bihevioralnih faktora na odlučivanje i performanse investitora na financijskom tržištu

Poštovani,

cilj ove ankete je ispitati koji bihevioralni faktori (faktori ponašanja) investitora na financijskom tržištu utječu na njihovo odlučivanje i performanse. U istraživanju se u obzir uzimaju individualne razlike u obrascima ponašanja te različitim karakteristikama osobnosti investitora.

Anketa je sastavni dio istraživanja u svrhu izrade doktorske disertacije na Ekonomskom fakultetu Sveučilišta u Splitu. Anketa je u potpunosti anonimna i dobrovoljna te će se svi prikupljeni podaci koristiti u agregiranom obliku i isključivo u tu svrhu.

Anketa se sastoji od 4 dijela. Prvi dio odnosi se na Vaše demografske karakteristike. Drugi dio obuhvaća pitanja koja se odnose na obrasce ponašanja na financijskom tržištu. Treći dio ankete sadrži pitanja koja se odnose na Vaše emocije, raspoloženje i karakteristike osobnosti. Posljednji, četvrti dio ankete odnosi na Vašu namjeru i odluku o ulaganju te zadovoljstvo investicijskim performansama.

Kako bi rezultati istraživanja bili što pouzdaniji i kako bi se ostvario očekivani znanstveni doprinos rada, nadamo se Vašem odazivu za sudjelovanje u istraživanju u što većem broju.

Ukoliko imate dodatnih pitanja vezanih uz anketu, možete se javiti na e-mail marija.vukovic@efst.hr.

Spol:

- Muško
- Žensko

Dob:

- 18-25
- 26-35
- 36-45
- 46-55

- 56-65
- 66 i više

Bračni status:

- Slobodan
- U vezi
- Zaručen
- U braku
- Razveden
- Ne želim odgovoriti

Radno iskustvo:

- Manje od 5 godina
- 5-10 godina
- 11-15 godina
- 16-20 godina
- Više od 20 godina

Koliko dugo se bavite trgovanjem na financijskom tržištu?

- Manje od 1 godine
- 1-3 godine
- 4-6 godina
- 7-10 godina
- Više od 10 godina

Mjesečna primanja:

- Do 5000 kn
- 5001-10000 kn
- 10001-15000 kn
- 15001-20000 kn
- 20001 kn i više

Razina obrazovanja:

- Osnovno obrazovanje
- Srednjoškolsko obrazovanje
- Viša stručna sprema, završen preddiplomski sveučilišni ili stručni studij
- VSS (završen diplomski sveučilišni ili stručni studij; mag. ili dipl.)
- Mr. sc. ili univ. spec. (završen magistarski studij ili poslijediplomski specijalistički studij)
- Dr. sc. (završen doktorski studij)

Jeste li pohađali ikakvu edukaciju o trgovanju na burzi (u sklopu formalnog i/ili neformalnog obrazovanja)?

- Da
- Ne

Obrasci ponašanja

*Označite u kojoj mjeri se slažete s određenom tvrdnjom na skali od 1 do 5, gdje je 1=u potpunosti se ne slažem, a 5=u potpunosti se slažem.**

**Sve tvrdnje navedene su u muškom rodu, a odnose se i na muški i ženski spol.*

Heuristike:

1. Kupujem popularne dionice i izbjegavam dionice koje su nedavno imale loše performanse.
2. Koristim analizu trenda reprezentativnih dionica u svrhu donošenja investicijskih odluka.
3. Smatram da mi moje vještine i znanje o tržištu dionica mogu pomoći da nadigram tržište.
4. Oslanjam se na svoja prethodna iskustva na tržištu za donošenje odluka o budućim investicijama.
5. Siguran sam da mogu donijeti ispravnu investicijsku odluku.
6. Smatram da su tržišni trendovi često u skladu s mojim očekivanjima.
7. Smatram da je povrat od ulaganja u dionicu uvijek ostvaren zbog moje uspješne investicijske strategije.
8. Prognoziram promjene u cijenama dionica temeljem najnovijih kretanja cijena dionica.
9. Obično mogu predvidjeti kada će završiti razdoblja dobrih ili loših povrata na tržištu.
10. Radije kupujem domaće dionice nego međunarodne, jer su mi dostupnije informacije o njima.
11. Pretpostavljam da će dionice s dobrom prethodnom zaradom i u budućnosti donijeti veće prinose.
12. Uvijek sam siguran da moja odluka o ulaganju nikada ne može pogriješiti.
13. Tijekom ulaganja vjerujem u svoje prosudbe više nego u bilo koji tržišni pokazatelj.
14. Moja ulaganja neovisna su o onome u što vjeruju tržišni stručnjaci.
15. Ne slijedim investicijske smjernice savjetnika ako su one suprotne onome u što vjerujem.
16. Nastavljam ulagati u dionice čije cijene padaju, jer bi se njihova vrijednost mogla povećati nakon određene točke.
17. Neću ulagati u dionice s neprekidno rastućim cijenama, jer će uskoro pasti.
18. Oprezan sam dok ulažem u dionice tvrtki koje su u posljednje vrijeme ostvarile gubitke.

Faktori prospektne teorije:

1. Nakon prethodnog dobitka, više sam sklon riziku nego obično.
2. Nakon prethodnog gubitka postajem manje sklon riziku.
3. Izbjegavam prodaju dionica kojima je pala vrijednost.
4. Brzo prodajem dionice kojima je porasla vrijednost.

5. Osjećam više tuge zbog predugog držanja dionica koje nose gubitak, nego zbog prerane prodaje dionica koje nose dobit.
6. Tretiram svaki element svog investicijskog portfelja odvojeno.
7. Preferiram dugoročnu sigurnost svojih sredstava nego kratkoročne novčane dobitke.
8. Od početka ulažem u sigurnije dionice.
9. Ne volim volatilne dionice jer ulažem ogromna novčana ulaganja.
10. Vjerujem da se na tržištu dionica može ostvariti veća dobit ako se preuzmu veći rizici.
11. Preferiram manja ulaganja kako bih imao koristi od kratkoročnog uspona na tržištu.
12. Uložit ću u volatilnu dionicu ako može donijeti bolji povrat.
13. Ulažem u vrijednosne papire s niskim prinosom jer želim uštedjeti za mirovinu.

Ponašanje krda:

1. Obično brzo reagiram na promjene drugih investitora i pratim njihove reakcije na tržištu.
2. Uložio bih u dionice prema sugestijama svojih prijatelja.
3. Pratim tržišne informacije u svrhu trgovanja.
4. Slijedim postojeći tržišni trend dok donosim odluku o ulaganju.
5. Slijedim ono što moj savjetnik sugerira tijekom ulaganja.
6. Slijedim savjete ostalih investitora dok kupujem dionice jer nemam odgovarajuće znanje.

Tržišni faktori:

1. Pažljivo razmatram promjene cijena dionica u koje želim uložiti.
2. Smatram da su tržišne informacije važne za moje ulaganje u dionice.
3. Razmatram prethodne trendove dionica prilikom svog ulaganja.
4. Prije donošenja investicijskih odluka, koristim fundamentalnu analizu za procjenu vrijednosti dionica.
5. Ulažem u poduzeća koja su u prošlosti isplaćivala veće dividende svojim dioničarima.
6. Pomno pratim financijska izvješća poduzeća prije nego što kupim njihove dionice.
7. Ulažem samo u poduzeća čije su dionice u prošlosti imale dobre performanse.

Emocije, raspoloženje i karakteristike osobnosti

*Označite u kojoj mjeri se slažete s određenom tvrdnjom na skali od 1 do 5, gdje je 1=u potpunosti se ne slažem, a 5=u potpunosti se slažem.**

**Sve tvrdnje navedene su u muškom rodu, a odnose se i na muški i ženski spol.*

Emocije i raspoloženje:

1. Kad se osjećam sretno, to utječe na moju tržišnu aktivnost.
2. Kad se osjećam ljuto, ne sudjelujem u tržišnim aktivnostima.
3. Kad se osjećam umorno, to utječe na moju tržišnu aktivnost.
4. Kad se osjećam tužno, ne sudjelujem u tržišnim aktivnostima.
5. Moj pozitivan pogled na život potiče me da ulažem u dionice.
6. Radujem se svojoj sljedećoj prilici za ulaganje nakon dubokog pada na tržištu.

7. Ne znam što dalje učiniti nakon što iskoristim sve svoje ideje.
8. Ako se tržište kreće protiv mene, kažem sebi da sam dugoročni investitor i da će sve moje ideje na kraju uspjeti.
9. Ako se dogodi gubitak u mojoj investiciji, prodat ću sve svoje dionice da izbjegnem daljnje gubitke.
10. Ako se gubici nastave, ne želim više nikada kupovati dionice.
11. Ako se gubitak u mojoj investiciji nastavi, zbunjen sam kad donosim odluku o daljnjim ulaganjima.
12. Ako kupim dionice koje postanu profitabilne, obnavljam vjeru da postoji budućnost u investiranju.
13. Jako sam oduševljen ulaganjem tijekom faze rasta ili oporavka tržišta.

Karakteristike osobnosti:

1. Pričljiv sam.
2. Rezerviran sam.
3. Pun sam energije.
4. Stvaram puno entuzijazma.
5. Samopouzdan sam.
6. Ponekad sam sramežljiv i ukočen.
7. Genijalan sam i dubok mislilac.
8. Imam aktivnu maštu.
9. Inventivan sam.
10. Radim temeljit posao.
11. Pouzdan sam radnik.
12. Imam tendenciju biti neorganiziran.
13. Sklon sam lijenosti.
14. Ustrajem u zadatku dok nije gotov.
15. Općenito radim sve učinkovito.
16. Pravim planove i slijedim ih.
17. Pomažem i nesebičan sam prema drugima.
18. Općenito sam pouzdan.
19. Volim surađivati s drugima.
20. Opušten sam i dobro podnosim stres.
21. Mnogo se brinem.
22. Emocionalno sam stabilan, nije me lako uznemiriti.
23. Ostajem smiren u napetim situacijama.

Odluka o ulaganju i zadovoljstvo investicijskim performansama

Procijenite koje su Vaše preferencije u odlučivanju te koliko ste zadovoljni svojim odlukama.

*Označite u kojoj mjeri se slažete s određenom tvrdnjom na skali od 1 do 5, gdje je 1=u potpunosti se ne slažem, a 5=u potpunosti se slažem.**

**Sve tvrdnje navedene su u muškom rodu, a odnose se i na muški i ženski spol.*

Investicijske odluke:

1. Ulažem u investicije koje će donijeti dugoročne koristi.
2. Zbog neizvjesnosti na tržištu, preferiram kratkoročna ulaganja.
3. Redovito pregledam, usporedim i potom donesem odluke o svom investicijskom potezu.
4. Istražujem tržište prije bilo kakvog kratkoročnog ulaganja.
5. Ulažem više sredstava u dugoročne nego kratkoročne investicije.
6. Ulažem više sredstava u kratkoročne nego dugoročne investicije.

Investicijske performanse:

1. Zadovoljan sam stopom prinosa svojih nedavnih ulaganja u dionice.
2. Smatram da je prinos na dionice u koje ulažem bolji od prinosa većine drugih dionica.
3. Zadovoljan sam svojim odlukama o kupnji dionica u protekloj godini dana.
4. Zadovoljan sam svojim odlukama o prodaji dionica u protekloj godini dana.

SAŽETAK RADA

Investitori na financijskim tržištima često se ne ponašaju racionalno, već je njihovo ponašanje pod utjecajem različitih psiholoških i kognitivnih čimbenika te karakteristika osobnosti. Brojni su eksperimenti i istraživanja dokazali utjecaj ovih faktora na donošenje investicijskih odluka. Cilj ovog rada je, putem strukturalnog modela, utvrditi koji bihevioralni faktori i s kojim intenzitetom utječu na donošenje investicijskih odluka i performanse. Naime, SEM je najprikladnija metoda za navedenu analizu, s obzirom da promatra psihološke varijable, koje se smatraju latentnim, jer nisu direktno mjerljive, a također simultano promatra više uzročno-posljedičnih veza. Istraživanje je provedeno anketnim upitnikom od 31.5. do 7.7.2021. godine, na uzorku od 310 investitora (malih ulagatelja) koji trguju vrijednosnim papirima na uređenom tržištu. Procijenjena su ukupno četiri modela, od toga dva CB-SEM i dva PLS-SEM modela, kako bi se identificirala prikladnija metoda i model koji s najpouzdanijim rezultatima opisuje veze između bihevioralnih faktora, investicijskih odluka i performansi. Na temelju usporedbe karakteristika mjernih i strukturalnih modela, zaključeno je da je PLS-SEM pristup prikladniji za procjenu u ovakvom tipu istraživanja. Naime, PLS-SEM, kao uzročno-prediktivna tehnika, pronalazi rješenje za odabir modela koji je točno specificiran i daje uzročno-posljedična objašnjenja, a istovremeno je prikladan za predviđanje. Odabrani model daje zaključke o postojanju utjecaja bihevioralnih faktora na investicijske odluke. Ustanovljeno je da heuristike (samouvjerenost) ne utječu značajno na investicijske odluke, dok elementi prospektne teorije (odbojnost prema gubitku i korištenje mentalnog računovodstva) pozitivno utječu na investicijske odluke. Sklonost investitora ponašanju krda negativno utječe na investicijske odluke pojedinaca. Emocije i raspoloženje investitora imaju značajan i pozitivan utjecaj na dugoročno korisne investicijske odluke. Samo jedna dimenzija osobnosti, i to stabilnost, pozitivno utječe na investicijske odluke, dok prilagodljivost nema značajan utjecaj. Dodatno ispitan utjecaj analiziranja tržišnih faktora na donošenje investicijskih odluka je pozitivan. Investicijske odluke, promatrane kroz preferencije prema dugoročnim investicijama, koje donose dugoročne koristi, posljedično pozitivno utječu na zadovoljstvo investicijskim performansama.

KLJUČNE RIJEČI: bihevioralne financije, heuristike, prospektna teorija, ponašanje krda, emocije, raspoloženje, osobnost, investicijske odluke, investicijske performanse, modeliranje strukturalnim jednadžbama, CB-SEM, PLS-SEM.

SUMMARY

Investors in financial markets often do not behave rationally, but their behavior is influenced by various psychological and cognitive factors, as well as personality characteristics. Numerous experiments and research have proven the impact of these factors on investment decisions. The aim of this thesis is to determine which behavioral factors influence investment decision making and performance and with what intensity, by using a structural equation model. SEM is the most appropriate method for this analysis, since it observes psychological latent variables, which are not directly measurable, and it also simultaneously observes multiple cause-and-effect relationships. The research was conducted via survey questionnaire in the period from May 31 to July 7, 2021, on a sample of 310 investors on the stock market. Four models were estimated, including two CB-SEM and two PLS-SEM models, to identify a more appropriate method and a model which describes the relationships between behavioral factors, investment decisions and performance with the most reliable results. Based on a comparison of the measurement and structural model characteristics, it is concluded that the PLS-SEM approach is more appropriate for estimation in this type of research. PLS-SEM, as a causal-predictive technique, selects a model that is correctly specified and explains the causal relationships, while at the same time it is suitable for prediction. The selected model provides conclusions about the existence of the impact of behavioral factors on investment decisions. It has been found that heuristics (overconfidence) do not significantly affect investment decisions, while prospect theory elements (loss aversion and the use of mental accounting) positively influence investment decisions. Herding bias negatively affects the investment decisions of individuals. Investors' emotions and mood have a positive significant impact on long-term beneficial investment decisions. Only stability, as one personality dimension, has a positive effect on investment decisions, while plasticity has no significant impact. The additionally examined impact of analyzing market factors on investment decisions is positive. Investment decisions, observed through the preference for long-term investments, which yield long-term benefits, consequently have a positive effect on the investment performance satisfaction.

KEYWORDS: behavioral finance, heuristics, prospect theory, herd behavior, emotions, mood, personality, investment decisions, investment performance, structural equation modeling, CB-SEM, PLS-SEM.

ŽIVOTOPIS

Marija (Parat) Vuković rođena je 3. travnja 1992. godine u Splitu. Završila je srednju Ekonomsko-birotehničku školu u Splitu, kao najbolja učenica generacije, uz dobivena dva priznanja za najbolje srednjoškolce Dalmacije 2009. i 2010. godine. U okviru srednje škole ostvarila je i prvo mjesto na županijskom natjecanju „Mladi poduzetnik“. Nakon završetka srednje škole, 2011. godine upisuje Ekonomski fakultet u Splitu, gdje je 2014. godine završila sveučilišni preddiplomski, a 2016. godine diplomski studij Poslovne ekonomije, smjer Računovodstvo i revizija, kao najbolja studentica u svojoj generaciji. Pri tome, tijekom studiranja na diplomskom studiju, bila je zaposlena kao demonstratorica na kolegijima Poslovna statistika, Aktuarska matematika i Financijski menadžment. Dobitnica je dvije Dekanove nagrade (2014. i 2016. godine) te Rektorove nagrade 2016. godine. Tijekom cijelog razdoblja srednjeg i visokog obrazovanja, redovito je bila stipendistica grada Solina. Na Ekonomskom fakultetu u Splitu 2018. godine upisuje Poslijediplomski specijalistički studij Ekonomije i poslovne ekonomije, a 2019. Poslijediplomski sveučilišni studij Ekonomije i poslovne ekonomije. Primarno područje interesa Marije Vuković su statističke metode u znanstvenom istraživanju, s naglaskom na multivarijatnu tehniku modeliranja strukturalnim jednadžbama, i to putem CB-SEM i PLS-SEM pristupa, te bihevioralna ekonomija, a posebno bihevioralne financije. Aktivno se služi engleskim jezikom, a pasivno španjolskim i talijanskim jezikom. Služi se Microsoft Office alatima, statističkim paketima SPSS, Statistica, Mplus, Amos, SmartPLS i Stata. Također, poznaje i pakete za poslovno odlučivanje WinQSB i Decision Lab, te osnove LaTeX editora i računovodstvenog paketa Synesis.

Od rujna 2017. godine zaposlena je na radnom mjestu asistenta na Katedri za kvantitativne metode Ekonomskog fakulteta u Splitu. Sudjeluje u izvođenju nastave na kolegijima Statistika, Statistička analiza i Statistical Analysis na preddiplomskom sveučilišnom studiju te na kolegiju Statističke metode na diplomskom sveučilišnom studiju. Također, od 2020. godine sudjeluje u izvođenju nastave na kolegiju Poslovna statistika u sklopu preddiplomskog studija Hotelijerstvo i gastronomija Sveučilišta u Splitu.

Marija Vuković je članica Hrvatskog društva za operacijska istraživanja, Hrvatskog statističkog društva i Američkog statističkog društva. Nakon završetka diplomskog i tijekom poslijediplomskog studija, pohađala je različite radionice i seminare, u svrhu usavršavanja specifičnih znanja i vještina:

- 2016. Razvoj Start up-a, Global Entrepreneurship Week (GEW), Split
- 2016. Guerilla marketing, Global Entrepreneurship Week (GEW), Split
- 2016. The entrepreneurial mindset, Global Entrepreneurship Week (GEW), Split
- 2018. Structural Equation Modelling using Mplus, Falcon Training – Statistical Consultancy and Training Service, London School of Economics, London, Velika Britanija
- 2018. Moderation and Mediation using Mplus, Falcon Training – Statistical Consultancy and Training Service, London School of Economics, London, Velika Britanija
- 2018. Multilevel Modelling using Mplus, Falcon Training – Statistical Consultancy and Training Service, London School of Economics, London, Velika Britanija
- 2020. PLS-SEM: A comprehensive introduction, SmartPLS Academy, SmartPLS GmbH, Ahornstr. 54, 25474 Bönningstedt, Njemačka (online edukacija)
- 2020. Mediator analysis, SmartPLS Academy, SmartPLS GmbH, Ahornstr. 54, 25474 Bönningstedt, Njemačka (online edukacija)
- 2020. Moderator analysis, SmartPLS Academy, SmartPLS GmbH, Ahornstr. 54, 25474 Bönningstedt, Njemačka (online edukacija)
- 2020. Higher-order models, SmartPLS Academy, SmartPLS GmbH, Ahornstr. 54, 25474 Bönningstedt, Njemačka (online edukacija)
- 2020. Importance-performance map analysis (IPMA), SmartPLS Academy, SmartPLS GmbH, Ahornstr. 54, 25474 Bönningstedt, Njemačka (online edukacija)
- 2020. Multigroup analysis, SmartPLS Academy, SmartPLS GmbH, Ahornstr. 54, 25474 Bönningstedt, Njemačka (online edukacija)
- 2020. Measurement invariance, SmartPLS Academy, SmartPLS GmbH, Ahornstr. 54, 25474 Bönningstedt, Njemačka (online edukacija)
- 2020. Nonlinear relationships, SmartPLS Academy, SmartPLS GmbH, Ahornstr. 54, 25474 Bönningstedt, Njemačka (online edukacija)
- 2022. Usavršavanje nastavničkih kompetencija za visokoškolske nastavnike, Centar za istraživanje i razvoj cjeloživotnog obrazovanja Filozofskog fakulteta u Splitu (online edukacija)

Osim toga, aktivno je sudjelovala na osam međunarodnih znanstvenih konferencija, i to:

1. 2018. The 2nd International Statistical Conference in CROatia (ISCCRO'18), Opatija, Hrvatska.
2. 2018. 17th International Conference on Operational Research, Zadar, Hrvatska.
3. 2019. 13th International Conference "Challenges of Europe", Bol, Hrvatska.
4. 2019. The 15th International Symposium on Operations Research, Bled, Slovenija.
5. 2020. 18th International Conference on Operational Research, Šibenik, Hrvatska.
6. 2020. The 3rd International Statistical Conference in Croatia (ISCCRO'20), Virtualna online konferencija vođena iz Zagreba, Hrvatska.
7. 2021. The 16th International Symposium on Operations Research, Bled, Slovenija (online).
8. 2022. 77th International Scientific Conference on Economic and Social Development (online).

Marija Vuković je samostalno i u koautorstvu dosad objavila devet znanstvenih radova u časopisima i zbornicima konferencija:

1. Vuković, M. i Šodan, S., 2017. Utjecaj kvalitete dobiti na troškove financiranja. *Ekonomska misao i praksa,* Vol. 16 (2), pp. 270-287.
2. Vuković, M., Pivac, S. i Kundid, D., 2019. Structural equation modeling in the acceptance of internet banking in the city of Split. *Croatian Operational Research Review,* Vol. 10 (1), pp. 141-152.
3. Vuković, M., Pivac, S. i Kundid, D., 2019. Technology Acceptance Model for the Internet Banking Acceptance in Split. *Business systems research,* Vol. 10 (2), pp. 124-140.
4. Vuković, M., Pivac, S. i Šemanović, M., 2019. Waste management consequences - Case study on the island of Brač. *Proceedings of the 15th International Symposium on OPERATIONAL RESEARCH,* Bled, Slovenija, 25-27. rujna, pp. 366-371.
5. Vuković, M., Pivac, S. i Babić, Z., 2020. Comparative analysis of stock selection using a hybrid MCDM approach and modern portfolio theory. *Croatian Review of Economic, Business and Social Statistics,* Vol. 6 (2), pp. 58-68.
6. Mandić, A. i Vuković, M., 2021. Millennials attitudes, choices and behaviour - integrative analysis. *Journal of Ecotourism*. https://doi.org/10.1080/14724049.2021.1932925
7. Vuković, M. i Pivac, S., 2021. Does financial behavior mediate the relationship between self-control and financial security? *Croatian Operational Research Review,* Vol. 12 (1), pp. 27-36.

8. Vuković, M. i Pivac, S., 2021. The impact of business economics students' use of heuristics on their predispositions for long-term investment decisions. *Proceedings of the 16th International Symposium on OPERATIONAL RESEARCH*, Bled, Slovenija, 22-24. rujna, pp. 525-530.
9. Vuković, M., 2022. Personality as a predictor of students' heuristic and herding biases in determining their predispositions for long-term investment decisions. *77th International Scientific Conference on Economic and Social Development Book of Proceedings*, online conference, 27 January, 2022, pp. 53-62.