Karakteristike kontrolera i menadžera u funkciji efikasnoga donošenja odluka u uvjetima digitalizacije

Petrlić, Antonija

Doctoral thesis / Disertacija

2021

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Rijeka, Faculty of Economics and Business / Sveučilište u Rijeci, Ekonomski fakultet**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:192:974983

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-29**

SVEUČILIŠTE U RIJECI
EKONOMSKI FAKULTET

Repository / Repozitorij:

Repository of the University of Rijeka, Faculty of Economics and Business - FECRI Repository

UNIRI DIGITALNA KNJIŽNICA

Image not found or type unknown

SVEUČILIŠTE U RIJECI
EKONOMSKI FAKULTET

Antonija Petrlić

KARAKTERISTIKE KONTROLERA I MENADŽERA U FUNKCIJI EFIKASNOGA DONOŠENJA ODLUKA U UVJETIMA DIGITALIZACIJE

DOKTORSKI RAD

Rijeka, 2021.

SVEUČILIŠTE U RIJECI
EKONOMSKI FAKULTET

Antonija Petrlić

KARAKTERISTIKE KONTROLERA I MENADŽERA U FUNKCIJI EFIKASNOGA DONOŠENJA ODLUKA U UVJETIMA DIGITALIZACIJE

DOKTORSKI RAD

Mentor: Prof.dr.sc. Neda Vitezić

Rijeka, 2021.

UNIVERSITY OF RIJEKA
FACULTY OF ECONOMICS AND BUSINESS

Antonija Petrlić

CHARACTERISTICS OF CONTROLLERS AND MANAGERS IN THE FUNCTION OF EFFICIENCT DECISION-MAKING IN THE CONDITIONS OF DIGITIZATION

DOCTORAL THESIS

Rijeka, 2021

Mentor rada: Prof.dr.sc. Neda Vitezić

Doktorski rad obranjen je dana 7. srpnja 2021. na Ekonomskom fakultetu Sveučilišta u Rijeci, pred povjerenstvom u sastavu:

1. Dr.sc. Marija Kaštelan Mrak, redovita profesorica Ekonomskog fakulteta u Rijeci, predsjednica povjerenstva,
2. Dr.sc. Zdravko Zekić, redoviti profesor Ekonomskog fakulteta u Rijeci, član povjerenstva,
3. Dr.sc. Tina Vuko, izvanredna profesorica Ekonomskog fakulteta u Splitu, članica povjerenstva.

ZAHVALA

Želim zahvaliti svojoj mentorici, prof.dr.sc. Nedi Vitezić koja je pratila cijeli proces nastajanja ovog rada i koja me je svojim savjetima, širokim znanjem i neiscrpnom energijom usmjeravala kroz sve prepreke na koje sam naišla prilikom njegove izrade. Neizmjerno sam joj zahvalna.

Zahvaljujem se svim članovima Udruge hrvatskih kontrolera i ostalim kontrolerima i menadžerima u Republici Hrvatskoj koji su sudjelovali u istraživanju i omogućili nastajanje ove doktorske disertacije.

Posebno se želim zahvaliti Nataši Pavletić, Maji Watz i Heleni Pavletić koje su mi bile značajna stručna i moralna podrška na cijelom „putu" izrade disertacije.

Zahvaljujem se roditeljima, bratu i sestri, na podršci, pomoći i neizmjernoj ljubavi koju su mi pružali cijeli moj život, pa tako i tijekom pisanja ove disertacije.

I za kraj, mojem dragom Karlu hvala na konstantnom bodrenju, podršci, razumijevanju, i beskonačnoj ljubavi, osobito u trenutcima sumnje u samu sebe.

Još jednom hvala Vam svima.

SAŽETAK

Današnje dinamično okruženje zahtjeva od poduzeća stalnu prilagodbu koja se uglavnom ogleda u primjeni novih tehnologija, unaprjeđenju poslovnih procesa te prihvaćanju i implementiranju funkcija primjerenih poslovanju u digitalnim uvjetima. Obzirom na sve veću količinu internih i eksternih podataka kojima poduzeća raspolažu te prednostima i izazovima koje ti podaci pružaju donosiocima odluka, nameće se potreba za funkcijama koje kroz svoje aktivnosti mogu usmjeriti menadžment ka donošenju učinkovitih poslovnih odluka. Jedna od tih funkcija je kontroling, koja pruža adekvatne informacije donosiocima odluka tj. koja u velikom broju podataka odabire i analizira one ključne, interpretira ih, zaključuje i predlaže rješenja. Sukladno svojoj ulozi kontroling bi trebao predstavljati jednu od ključnih informacijskih i savjetodavnih funkcija unutar poduzeća. Stoga je svrha ove doktorske disertacije bila definirati i potvrditi utjecajne karakteristike koje u digitalnim uvjetima određuju efikasnost rada kontrolera i njegov utjecaj na donošenje odluka, te ujedno dokazati važnost kontrolinga kao potpore menadžmentu. Cilj disertacije bio istražiti i proširiti postojeće teorijske spoznaje kontrolinga te razviti i potvrditi konceptualni model za mjerenje povezanosti karakteristika kontrolera, menadžera, poduzeća i okruženja s kvalitetom kontrolerovog outputa i njegovog utjecaja na donošenje poslovnih odluka.

Za potrebe empirijskog istraživanja i testiranja postavljenog konceptualnog modela tj. hipoteza, u suradnji sa četiri kontrolera razvijen je anketni upitnik čija je valjanost i pouzdanost potvrđena kroz pilot testiranje na uzorku od 21 kontrolera. Konačni uzorak istraživanja činilo je 148 kontrolera i 64 menadžera iz velikih, srednjih i pojedinih malih poduzeća u Republici Hrvatskoj. Istraživanje je uključivalo testiranje konceptualnog modela kroz dva uzorka. Prvi uzorak podrazumijevao je testiranje modela isključivo na odgovorima kontrolera, a drugi na uparenim odgovorima menadžera i kontrolera. Primjenom multivarijatne statističke metode parcijalnih najmanjih kvadrata modeliranja strukturalnim jednadžbama (PLS-SEM) ispitana je valjanost i pouzdanog mjernog modela te su testirane hipoteze i potvrđena je eksploratorna i prediktivna moć strukturnog modela.

Rezultati istraživanja potvrdili su povezanost karakteristika kontrolera, poduzeća i okruženja s kvalitetom kontrolerovih outputa te povezanost kvalitete outputa s kontrolerovim utjecajem na donošenje poslovnih odluka. Istraživanjem jedino nije potvrđena veza karakteristika menadžera s kvalitetom kontrolerovih outputa, ali je potvrđeno da su karakteristike

menadžera značajno povezane s kontrolerovim utjecajem na donošenje poslovnih odluka. Navedeno je potvrđeno ispitivanjem modela sa stajališta kontrolera, ali i uključivanjem menadžera kroz ocjenjivanje karakteristika kontrolera, kvalitete njegovog outputa i utjecaja na donošenje odluka. Pri uključivanju menadžera tj. u drugom modelu nije jedino potvrđena veza između karakteristika okruženja i kontrolerovog utjecaja na donošenje odluka. U oba modela, kao najznačajnija karakteristika kontrolera pokazala se proaktivnost, a kod menadžera vođa i inicijator. Strateška orijentiranost potvrđena je kao najznačajnija karakteristika poduzeća, dok se aspekt okruženja dokazao intenzitet konkurentnosti. Sa stajališta samih kontrolera, tj. prvim modelom, također je potvrđeno da dužina radnog iskustva kontrolera u području kontrolinga pridonosi kvaliteti kontrolerovih outputa i ulozi u poslovnom odlučivanju. Značaj ostalih postavljenih kontrolnih varijabli nije dokazan izuzev načina organizacije kontrolinga (centraliziran/decentraliziran/kombiniran) kao čimbenika utjecaja kontrolera na poslovno odlučivanje u prvom modelu. Iako se primjena poslovne inteligencije nije dokazala kao značajni kontrolni čimbenik kvalitete kontrolerovog outputa, sukladno dobivenim mišljenjima o njenoj korisnosti i potrebi šire primjene, zaključilo se da će ti alati u budućnosti predstavljati neizostavan dio kontrolinga.

Sukladno navedenom, doktorski rad predstavlja osnovu za daljnja istraživanja i unaprjeđenje ostvarenog metodološkog i aplikativnog doprinosa, koji se prvenstveno ogleda u razvoju i potvrdi modela, mogućnosti njegovog testiranja na drugim zemljana i primjeni unutar poduzeća u svrhu ocjene interne efikasnosti kontrolinga, ali i razvoju studijskih programa kontroling. Osim toga, rad temeljem dobivenih saznanja empirijskog istraživanja i teorijske podloge pruža prijedlog budućeg razvoja kontrolinga s osnova digitalizacije.

Ključne riječi: kontroling, kontroler, menadžer, poslovno odlučivanje, poduzeće, digitalizacija, okruženje

SUMMARY

Today's dynamic environment requires companies to constantly adapt, which is mainly reflected in the application of new technologies, improvement of business processes and the acceptance and implementation of functions suitable for doing business in digital conditions. Given the growing amount of internal and external data that companies have and the benefits and challenges that this data provides to decision makers, there is a need for functions that, through their activities, can guide management to make effective business decisions. One of those functions is controlling, which provides adequate information to decision-makers, and which in large number of data selects and analyses the key ones, interprets them, and proposes solutions. According to its role, controlling should be one of the key information and advisory functions within today's companies. Therefore, the purpose of this doctoral dissertation was to define and confirm the influential characteristics that in digital conditions determine the efficiency of the controllers' work and their impact on decision making, but also to prove the importance of controlling as a support to management. Hence, this dissertation aimed to explore and expand existing theoretical knowledge of controlling and to develop and validate a conceptual model for measuring the relationship of controllers, managers, companies, and environmental characteristics with the quality of controller's outputs and its impact on decision-making.

For empirical research and testing of the set conceptual model, i.e. hypotheses, in cooperation with four controllers, a survey questionnaire was developed whose validity and reliability were confirmed through a pilot testing on a sample of 21 controllers. The final sample of the research were 148 controllers and 64 managers from large, medium, and few small companies in the Republic of Croatia. The research involved testing the conceptual model through two samples. The first sample involved testing the model solely on controller responses, and the second on paired manager and controller responses. The multivariate statistical method of partial least squares structural equations modeling (PLS-SEM) was used to test the validity and reliability of the measurement model, and to confirm the set hypotheses and the exploratory and predictive power of the structural model.

The results of the research confirmed the relationship between the set characteristics of the controllers, the company, and the environment with the quality of the controllers' outputs, and the relationship between the quality of their outputs and the controllers' influence on decision-

making. The research only did not confirm the relationship of managerial characteristics with the quality of the controller outputs, but it confirmed that managerial characteristics are significantly related to the controllers' influence on decision-making. This was confirmed by examining the model from the perception of controllers, but also by involving managers through the evaluation of controllers' characteristics, the quality of their outputs, and their impact on decision-making. In the second model, which includes perceptions of managers', only the relationship between the characteristics of the environment and the controllers' influence on decision-making was not confirmed. In both models, proactivity proved to be the most important characteristic of the controllers, and in the case of managers, leadership and initiator. Strategic orientation was confirmed as the most important characteristic of companies, while the intensity of competitiveness was proven as the most valuable environmental characteristic. From the perception of controllers', it was also confirmed that the length of the controller's work experience in the field of controlling contributes to the quality of the controller's outputs and decision-making role. The importance of other set control variables has not been proven, except the way controlling is organized (centralized/decentralized/combined). Hence, it has been proven as an important control variable of the controllers' influence on business decision-making only in the first model. Although the application of business intelligence has not been proven as a significant control variable of the quality of the controller's outputs, appropriate to the opinions obtained from the controllers on its usefulness and the need for wider application, it can be emphasized is that these tools will be an integral part of controlling in the future.

Accordingly, the doctoral thesis is the basis for further research and improvement of given methodological and applied contributions, which are primarily reflected in the developed and confirmed conceptual model, the possibility of testing it in other countries, and its applications within companies for assessing internal effectiveness of controlling, but also the development of study programs for controlling. In addition, based on the acquired knowledge of empirical research and theoretical background, the thesis provides a proposal for the future development of controlling based on digitalization.

Key words: controlling, controller, manager, decision-making, business, digitalization, environment

SADRŽAJ

1. UVOD 1

1.1. Problem i predmet istraživanja 2

1.2. Znanstvena hipoteza i pomoćne hipoteze 4

1.3. Svrha i ciljevi istraživanja 5

1.4. Pregled dosadašnjih istraživanja 6

1.5. Znanstvene metode 10

1.6. Struktura rada 11

2. KONCEPT KONTROLINGA U PROCESU POSLOVNOG ODLUČIVANJA 13

2.1. Kontroling jučer i danas - izazovi i prilike u digitalno doba 13

2.1.1. Kontroling, Big Data i robotika 19

2.1.2. Kontroling i poslovna inteligencija te analitika 23

2.2. Kontroleri i menadžeri u procesu odlučivanja 27

3. TEORIJSKE I EMPIRIJSKE PRETPOSTAVKE RAZVOJA KONCEPTUALNOG MODELA UTJECAJA KVALITETE KONTROLINGA NA POSLOVNO ODLUČIVANJE 37

3.1. Kvaliteta kontrolerovog outputa i njegov utjecaje na donošenje odluka 41

3.2. Utjecajne karakteristike kvalitete kontrolerovog outputa 49

3.2.1. Karakteristike kontrolera 49

3.2.1.1. Analitičnost 58

3.2.1.2. Komunikativnost 59

3.2.1.3. Asertivnost 61

3.2.1.4. Proaktivnost i kreativnost 62

3.2.2. Karakteristike menadžera 64

3.2.2.1. Vođa i inicijator 68

3.2.2.2. Uvažavanje kontrolera 68

3.2.2.3. Proaktivan i cilju usmjeren 69

3.2.3. Karakteristike poduzeća 71
3.2.3.1. Strateška orijentiranost 72
3.2.3.2. Organizacijska formalizacija 73
3.2.3.3. Kvaliteta informacijskog sustava 74
3.2.3.4. Digitalna transformacija 75
3.2.4. Karakteristike okruženja 76
3.2.5. Poslovna inteligencija, radno iskustvo i organizacijska obilježja 79
4. KONCEPTUALNI MODEL UTJECAJA KVALITETE KONTROLINGA NA POSLOVNO ODLUČIVANJE 81
5. EMPIRIJSKO ISTRAŽIVANJE UTJECAJA KONTROLINGA NA DONOŠENJE ODLUKA 88
5.1. Metodologija empirijskog istraživanja 88
5.1.1. Operacionalizacija varijabli i dizajn upitnika 88
5.1.2. Uzorak istraživanja 98
5.1.3. Metode statističke analize 106
5.2. Rezultati empirijskog istraživanja 107
5.2.1. Aktivnosti i razina informacijske uloge kontrolera 107
5.2.2. Deskriptivna statistička analiza latentnih varijabli modela 111
5.2.3. Rezultati PLS-SEM analize 119
5.2.3.1. Rezultati analize konceptualnog modela sa stajališta kontrolera - Model 1 .. 121
5.2.3.1.1. Procjena mjernog modela - Model 1 123
5.2.3.1.2. Procjena strukturnog modela - Model 1 130
5.2.3.2. Rezultati analize konceptualnog modela sa stajališta menadžera i kontrolera - Model 2 143
5.2.3.2.1. Procjena mjernog modela - Model 2 143
5.2.3.2.2. Procjena strukturnog modela - Model 2 147
5.3. Zaključna razmatranja i prijedlog budućeg razvoja kontrolinga s osnova digitalizacije 152

5.4. Doprinos empirijskog istraživanja 157
5.5. Ograničenja i implikacije budućih empirijskih istraživanja 160
6. ZAKLJUČAK 162
LITERATURA 168
POPIS TABLICA 190
POPIS GRAFIKONA 191
POPIS SLIKA 191
POPIS PRIVITAKA 192
PRIVICI 193

1. UVOD

Digitalno okruženje omogućava raspolaganje s velikim brojem informacija koje postaju važan input u stvaranju dodane vrijednosti. Zbog sve bržih promjena u okruženju, uspješnost poduzeća više nego ikad ovisi o donošenju ispravnih odluka baziranih na kvalitetnim podacima i informacijama. Odnosno, upravljanje poduzećem značajno ovisi o kvaliteti obrade podataka u cilju dobivanja kvalitetnih informacija koje se koriste u procesu poslovnog odlučivanja. Kontroling kao analitičko-informativna i savjetodavna funkcija potpore upravljanju jest ta koja pruža adekvatne informacije donosiocima odluka. Kontroler danas postaje poslovnim partnerom menadžmentu te ga pripadajuća analitičko-informativna uloga stavlja u poziciju sunositelja odgovornosti u procesu odlučivanja. Dok se efikasnost kontrolera ogleda u pretvaranju raznih podataka i informacija u kvalitetne analize i izvještaje, efektivnost proizlazi iz konačnog utjecaja tih outputa na donošenje menadžerskih odluka. Pri tome, konačni efekt utjecaja kontrolerovih outputa na donošenje poslovnih odluka ovisi o razini njihove kvalitete, ali i o drugim utjecajnim karakteristikama unutar i izvan poduzeća koje je potrebno poznavati. Karakteristike poduzeća koje se ističu su kvaliteta informacijskog sustava, strateška orijentiranost, razina formalizacije i upotreba digitalnih tehnologija, ali i osobne karakteristike kontrolera te menadžera usmjerenih prvenstveno na prihvaćenost kontrolinga kao funkcije i ambicije za ostvarenjem postavljenih ciljeva. Među karakteristikama kontrolera najviše se ističu proaktivnost, analitičnost, komunikativnost, kreativnost i asertivnost. Izvan poduzeća prvenstveni utjecaj imaju intenzitet konkurentnosti, turbulentnost tehnologije te rizičnost okruženja. Kako bi se mogla osigurati što veća efikasnost (uspješnost) i efektivnost (učinkovitost) kontrolinga tj. potvrditi značaj njegove uloge u donošenju poslovnih odluka važno je izučiti razinu povezanosti pojedinih utjecajnih karakteristika.

U nastavku ovog poglavlja definirani su problem i predmet istraživanja, te temeljna hipoteza i pomoćne hipoteze. Prikazana je svrha i ciljevi rada te pregled dosadašnjih istraživanja koji predstavljaju polazište ove doktorske disertacije. Osim toga, navedene su primijenjene znanstvene metode te je na kraju predočena struktura cjelokupnog rada.

1.1. Problem i predmet istraživanja

Kontroling je svoj dugogodišnji razvoj od 50-ih godina do danas doživio kroz različite definicije proizašle iz drugačijih poimanja i pristupa. Danas se gotovo u potpunosti prihvaća kao funkcija koja ne vrši samo statističku obradu i analizu podataka, već razjašnjava i predlaže rješenja te pomaže menadžmentu u donošenju odluka. Kontroling kao funkcija predstavlja potporu upravljanju koja proaktivno djeluje gledajući u budućnost i koja ima zadatak pružiti informacije koje će menadžerima pomoći u donošenju ispravnih i pravovremenih odluka, a u cilju stvaranja dodane vrijednosti. To podrazumijeva da se kontroling više na bavi samo svojim osnovnim aktivnostima kao što su analiza odstupanja od planiranih veličina, analiza i planiranje troškova i prihoda te analiza uspješnosti i efikasnosti poslovanja, već da se kao suvremena funkcija usmjerava na razvoj i praćenje ključnih pokazatelja poslovanja, prognoziranje i predviđanje te primjenu alata sa svrhom strateškog planiranja razvoja poduzeća. Pri tome izvršava dvije temeljne uloge, informacijsku i upravljačku. Upravljačka podrazumijeva da pomaže menadžmentu u ostvarenju postavljenih ciljeva kroz organizaciju, usmjeravanje i kontroliranje aktivnosti, dok informacijska podrazumijeva koordinaciju velike količine podataka, njihovo strukturiranje, analiziranje i prikazivanje u svrhu poslovnog odlučivanja.

Kontroleri kao nosioci aktivnosti i zadataka se opisuju kao poslovni partneri menadžmentu s obzirom da im kroz pružanje kvalitetnih outputa tj. informacija, analiza, izvještaja, prijedloga i zaključaka, omogućavaju donošenje preciznijih i bržih poslovnih odluka. Pri tome kontroleri koriste brojne interne i eksterne podatke i informacije kao inpute svojih analiza i izvještaja, ali se koriste i različitim tehnološkim rješenjima i alatima koje im olakšavaju proces prikupljena i obrade polustrukturiranih i strukturiranih podataka. U pogledu zadataka kontrolera, najznačajniju ulogu u digitalizaciji imaju kvaliteta informacijskog sustava i primjena poslovne inteligencije. Kvaliteta informacijskog sustava pored internih kontrola i revizije osigurava kvalitetu i dostupnost internih podataka, dok primjena i razina razvijenosti sustava poslovne inteligencije omogućuju izradu jednostavnih, preglednih i jasnih izvještaja. Odnosno, informacijski i upravljački usmjeren kontroling sve se više koristi brojnim podacima (engl. Big Data) kao i alatima poslovne analitike (engl. Business Analytics) usmjerenim na predviđanje i prognoziranje budućih događaja.

Kako bi osigurali ispunjenje svoje uloge, kontroleri trebaju kontinuirano pružati točne, ažurne, bitne i pravodobne podatke i informacije, na način jasan prvenstveno upravljačkoj

strukturi, ali i ostalim korisnicima. Odnosno, kontroleri moraju biti sigurni da menadžerima pružaju kvalitetne informacije. Brojni su čimbenici koji mogu utjecati na kvalitetu kontrolerovih outputa i posljedično njihov utjecaj na donošenje poslovnih odluka. Prvi i osnovni čimbenici jesu sposobnost i vještine kontrolera. Naravno, kvaliteta njihovih outputa ovisit će o njihovom stručnom znanju, poznavanju poslovnih procesa, vještinama primjene različitih digitalnih alata i drugim vještinama proizašlih iz znanja stečenog kroz obrazovanje, pohađanje seminara i sl. Međutim, u doba neprestanog rasta digitalne tehnologije, „tvrde" vještine, koje podrazumijevaju specijalizirana znanja i tehničke vještine, postaju nedostatan alat za uspjeh poduzeća. Iako se ne isključuje značaj njihove uloge u obavljanju kontrolerskog posla, ali i bilo kojeg drugog posla, može se reći da njihovo usvajanje predstavlja sve manji izazov novim generacijama, dok sve veći značaj dobivaju osobne, socijalne i metodološke kompetencije tj. tzv. „meke" vještine. Kontroleri kao sunositelji odgovornosti koji aktivno sudjeluju u donošenju poslovnih odluka kroz prezentaciju informacija i analiza, predlaganje akcija i preispitivanje postavljenih planova i mjera, moraju posjedovati tehnička znanja kako bi prikupili potrebne podatke, analizirali ih i prikazali na prikladan način. Međutim, kako bi mogli dati konstruktivne kritike na postavljene planove, prijedloge za budući razvoj poduzeća i kako bi iste mogli na adekvatan i razumljiv način predočiti menadžerima, kontroleri moraju posjedovati visoku razinu osobnih i socijalnih vještina.

Pored vještina kontrolera, brojni su čimbenici unutar i izvan poduzeća o kojima može ovisiti kvaliteta kontrolerovog outputa kao npr. intenzitet konkurentnosti, razina tehnoloških promjena, strateška orijentiranost poduzeća, razina implementacije digitalnih tehnologija u poduzeću, itd. Pored karakteristika kontrolera, drugi po redu bitan čimbenik jesu menadžerske karakteristike, kao što su sposobnost komuniciranja, sposobnost rada s drugim ljudima, orijentacija na rezultat i strateška orijentacija, potreba za postignućem, sposobnost vođenja i motiviranja zaposlenika, itd. Odnosno, gledano s razine kontrolerove uključenosti u poslovno odlučivanje, može se reći da karakteristike menadžera zapravo predstavljaju motivirajući čimbenik učinkovitog kontrolinga. Učinkoviti kontroling podrazumijeva da menadžeri zaista koriste kontrolerove outpute u svrhu poslovnog odlučivanja tj. da prihvaćaju kontrolere kao poslovne partnere u odlučivanju. Naime, ako menadžer kao osoba koja bi trebala koristiti kontrolerove outpute i oslanjati se na dane informacije i prijedloge ne uvažava kontroling kao funkciju, onda su nebitni utjecaji svi ostalih internih i eksternih čimbenika, ali i karakteristika kontrolera. Stoga je bitno ustanoviti razinu prihvaćenosti kontrolinga kao funkcije tj. kontrolera kao nositelja zadataka i temeljem toga odrediti čimbenike koji kontrolingu

osiguravaju izradu kvalitetnih outputa i sudjelovanje u poslovnom odlučivanju. Iako se u posljednje vrijeme teorija i praksa kontrolinga sve više razvija, ona je još uvijek nedovoljno zastupljena u znanstvenoj literaturi, a osobito u području njegove uloge u donošenju poslovnih odluka. Zato je ova doktorska disertacije usmjerena na izučavanje važnosti kontrolinga u poslovnom odlučivanju i utjecajnih karakteristika o kojima ovisi kvaliteta njihovih outputa koji su temelj donošenja ispravnih poslovnih odluka.

Iz postavljenog problema istraživanja određen je i **predmet istraživanja** doktorske disertacije koji glasi:

Analizom relevantne znanstvene i stručne literature razviti model povezanosti kvalitete kontrolinga sa poslovnim odlučivanjem i primjenom metode parcijalnih najmanjih kvadrata modeliranja strukturalnim jednadžbama (PLS-SEM) potvrditi njegovu valjanost. Naime, metodom će se ispitati povezanost karakteristika kontrolera, menadžera, poduzeća i okruženja s kvalitetom kontrolerovog outputa i njegovim utjecajem na donošenje poslovnih odluka.

1.2. Znanstvena hipoteza i pomoćne hipoteze

U okviru definiranog problema i predmeta istraživanja, a temeljem teorijskog izučavanja literature i analize prethodnih rezultata postavljena je temeljna znanstvena hipoteza:

U uvjetima digitalizacije karakteristike kontrolera, menadžera, poduzeća i okruženja imaju značajan utjecaj na učinke kontrolerovih aktivnosti i doprinos u donošenju poslovnih odluka.

Navedena temeljna znanstvena hipoteza potvrđena je pomoću šest pomoćnih hipoteza koje proizlaze iz definiranog konceptualnog modela i dubinskog pregleda dosadašnjih istraživanja:

H1: Karakteristike kontrolera su statistički značajno i pozitivno povezane s kvalitetom njegovog outputa.

H2: Karakteristike menadžera su statistički značajno i pozitivno povezane s kvalitetom kontrolerovog outputa.

H3: Karakteristike poduzeća su statistički značajno i pozitivno povezane s kvalitetom kontrolerovog outputa.

H4: Karakteristike okruženja su statistički značajno i pozitivno povezane s kvalitetom kontrolerovog outputa.

H5: Postoji statistički značajna i pozitivna povezanost između kvalitete kontrolerovog outputa i njegovog utjecaja na donošenje odluka.

H6: Menadžerska percepcija utjecaja kvalitete kontrolerovog outputa na donošenje poslovnih odluka, razlikuje se od kontrolerove percepcije.

1.3. Svrha i ciljevi istraživanja

Iz definiranog problema i predmeta istraživanja proizlazi svrha i ciljevi istraživanja.

Svrha ovog istraživanja je definirati i potvrditi utjecajne karakteristike koje u digitalnom okruženju određuju efikasnost rada kontrolera i njegov utjecaj na donošenje odluka, te ujedno dokazati važnost kontrolinga kao potpore menadžmentu.

Ciljevi istraživanja su:

- Analizom relevantne znanstvene i stručne literature:
  - utvrditi današnje trendove u području kontrolinga, izazove i prilike koje donosi digitalno doba i potrebe za uključenosti kontrolinga u poslovno odlučivanje,
  - razviti model utjecaja kvalitete kontrolinga na poslovno odlučivanje, kojim se povezuju karakteristike kontrolera, menadžera, poduzeća i okruženja s kvalitetom kontrolerovog outputa i njegovim utjecaja na donošenje poslovnih odluka,
  - odrediti najznačajnije karakteristike kontrolera, menadžera, poduzeća i okruženja, i način njihova mjerenja, te odrediti način mjerenja kvalitete kontrolerovog outputa i njegovog utjecaja na odlučivanje.

- Empirijskim istraživanjem:
  - ustanoviti razinu opće aktivnosti kontrolinga i njegove uključenosti u poslovno odlučivanje u Republici Hrvatskoj,
  - potvrditi postavljeni konceptualni model, tj. povezanost karakteristika kontrolera, menadžera, poduzeća i okruženja s kvalitetom kontrolerovog outputa. Odnosno,

potvrditi da u uvjetima digitalizacije kvaliteta kontrolerovog outputa ima značajnu povezanost s kontrolerovim utjecajem na donošenje poslovnih odluka,

- potvrditi da dužina radnog iskustva, način organizacije kontrolinga, prisutnost interne revizije te primjena alata poslovne inteligencije imaju značajan kontrolni učinak na kvalitetu kontrolerovog outputa tj. njegov utjecaj na donošenje poslovnih odluka,
- potvrditi da se kontroling s razlogom danas može zvati poslovnim partnerom menadžmentu sukladno ulozi u poslovnom odlučivanju te orijentiranosti na buduće događaje, aktivnosti predviđanja i prognoziranja,
- dati prijedlog budućeg razvoja kontrolinga kao profesije i kontrolera kao nosioca zadataka.

1.4. Pregled dosadašnjih istraživanja

U posljednje vrijeme teorija i praksa kontrolinga sve se više razvija, međutim još uvijek nedovoljno, osobito u području njegove uloge u donošenju poslovnih odluka (Nielsen *et al.*, 2015). Učinkovitost donošenja poslovnih odluka pod utjecajem je brojnih čimbenika. Među njima su raspoloživo vrijeme prije donošenja odluke, iskustvo donositelja odluka i kvaliteta podataka potrebnih za donošenje odluke (Fisher *et al.*, 2003), ali i razne druge kao npr. demografske karakteristike, okolišni i psihološki čimbenici, informacijski sustavi, itd. (Bulog, 2016; Omarli, 2017). Sukladno, i kontrolerova razina uključenosti u poslovnom odlučivanju pod utjecajem je različitih unutarnjih i vanjskih čimbenika poslovanja. Kvaliteta aktivnosti kroz koje je kontroler uključen u proces odlučivanja ovise o brojnim utjecajnim karakteristikama samih kontrolera, ljudi s kojima surađuju i pojavama koje ih okružuju.

Može se reći da je osnovu tih utjecaja postavio Sathe (1982), koji kontrolerovu involviranost u odlučivanje definira kao stupanj do kojeg kontroleri zapravo obavljaju različite uloge kao sudionici operativnog i strateškog poslovnog odlučivanja, to jest, ulogu prezentacije informacija i analiza, predlaganja akcijskih planova, kao i spremnost na izazove koje ti planovi nose. Prema njemu kontrolerova razina involviranosti u poslovno odlučivanje ovisi o tri osnovne kategorije karakteristika: kontrolera, menadžera te poduzeća i okruženja. Sukladno tome, kontrolerovoj ulozi u poslovnom odlučivanju zapravo se mogu pripisati tri prateće teorije: psihološka teorija (engl. psychological theory) za karakteristike kontrolera,

teorija uloga (engl. role theory) za odnos između menadžerskih zahtjeva i očekivanja te kontrolerove uloge pružanja informacija i teorija kontingencije (engl. contingency theory) za karakteristike tj. poduzeća i okruženja. Iako su daljnja istraživanja postavljenog Satheovog modela jako oskudna, Rouwelaar *et al.* (2018) naglašavaju značaj njegovog daljnjeg izučavanja. Stoga su kroz vlastito istraživanje, primjenom postavki Satheovog modela, potvrdili da je većina kontrolera u nizozemskim poduzećima, na razini poslovnih jedinica, uključeno u operativno, a u manjoj mjeri u strateško odlučivanje. Pri tome su ispitivali utjecaj organizacijskih karakteristika (decentralizacija i asimetrija informacija), karakteristika kontrolera i pojedinih kontrolnih varijabli. Slično istraživanje provedeno je od strane Zoni i Merchant (2007) u Italiji. Rezultati vezani za ukupnu involviranost su doveli do istih zaključaka, jedino što je operacionalizacija istraživanja bila obavljena kroz druge mjeritelje - okolišne promjene, financijsku stručnost menadžera, uspjeh, itd. Iako je Sathe (1982) teorijski karakteristike poduzeća i okruženja postavio kao jedan čimbenik utjecaja na uključenost kontrolinga u odlučivanju, unutar vlastitog istraživanja ih je postavlja i mjerio kao zasebne utjecaje. Međutim, ono što je za istaknuti je činjenica da teorijski postavljene karakteristike kontrolera nije uključio u vlastitom empirijskom istraživanju. Roozen i Steens (2006) su pak postavili model mjerenja razine kontrolerove efikasnosti, koja je s njihovog gledišta pod utjecajem stvarne razine kontrolerove involviranosti i nezavisnosti određene očekivanjima i doprinosima kontrolera te međuljudskim faktorima. Paterson i Vermaas (2011) u istraživanju među 20 nizozemskih tvrtki došli su do saznanja da kontrolerove kompetencije ocijenjene sa stajališta menadžera imaju značajnu ulogu u donošenju učinkovitih odluka. Kao najbitnije navode asertivnost, spremnost na izazove, nezavisnost, timski rad te znanje. Wolf *et al.* (2015) istraživali su kako kontrolerovo ponašanje u smislu sudjelovanja u procesu donošenja odluka, mjereno kroz stav (atraktivnost i smisao uključenosti) i subjektivnu normu (da li menadžeri cijene i očekuju kontrolerovu uključenost), utječe na njihov ukupni doprinos i u konačnici internu efikasnost i unaprjeđenje procesa. Ono po čemu se ovo istraživanje razlikuje od prethodno nabrojenih jest činjenica da uzima u obzir stajališta kontrolera i menadžera, a ne samo jedne strane. Isti pristup primijenili su u svojem istraživanju Pierce i O'Dea (2003), Weißenberger i Angelkort (2011) i Weißenberger *et al.* (2012). Odnosno, Pierce i O'Dea (2003) dokazali su postojanje tzv. „perception gap", između stajališta kontrolera i menadžera u pogledu vrste i opsega informacija koje menadžeri koriste, kvalitete informacija i upotrebe informacija kreiranih korištenjem određenih instrumenata kontrolinga. Weißenberger i Angelkort (2011) su u svojem empirijskom istraživanju analizirali utjecaj razine integriranosti menadžerskog informacijskog sustava (engl. Management Accounting

System – MAS) na efektivnost kontrolerovog doprinosa donošenju odluka, prikupljanjem jednog dijela odgovora za testiranje modela od kontrolera i jednog dijela od menadžera. Isti model Weißenberger *et al.* (2012) testirali su isključivo sa stajališta kontrolera. Rezultati su bili veoma slični, ali ono što je bitno jest da je pozitivni utjecaj kontrolerovih outputa na na donošenje odluka potvrđen u oba modela.

Kontrolerov utjecaj na odlučivanje potvrdili su i Fadhilah *et al.* (2015) kroz malo drugačiji pristup temeljen na tzv. „The DeLone and McLean Information System Success Model" (2003). Odnosno, potvrdili su pozitivni utjecaj kvalitete informacija i kvalitete usluga od strane kontrolera na zadovoljstvo korisnika (menadžera) i u konačnici neto koristi (donošenje odluka). Pri tome su za kontrolera primijenili četiri karakteristike koje Sathe (1983) ubraja u osobine „jakog" kontrolera. Može se reći da su Fadhilah *et al.* (2015) među prvima koji su karakteristike kontrolera i njihov utjecaj na donošenje odluka postavili i mjerili kroz skup ne tehničkih tj. „mekih" vještina. Postojanje značajne pozitivne povezanosti između kvalitete informacija i donošenja odluka potvrdili su i Wieder i Ossimitz (2015) kroz indirektnu povezanost upravljanja rješenjima poslovne inteligencije i odlučivanja. Empirijska istraživanja koja uključuju nove koncepte kao što su poslovna inteligencija i Big Data, uglavnom su ostvarena u području informatike, dok su u kontrolingu još uvijek zastupljeni teorijski modeli (Appelbaum *et al.*. 2017) i preporuke za istraživanje (Rikhardsson i Yigitbasioglu, 2018). Istraživanje koje se ističe u području kontrolinga provela je Gullkvist (2013). Istraživanje je potvrdilo pozitivni utjecaj poslovne inteligencije na kvalitetu podataka i zadatke kontrolera, njihov pozitivni utjecaj na efektivnost i konačno promjenu prakse kontrolera. Odnosno, potvrdila je da primjena poslovne inteligencije utječe na efektivnost poslovnog odlučivanja.

Nadalje, iako navedena istraživanja ne uključuju dio Satheovog modela koji se odnosi na karakteristike menadžera, u teoriji kontrolinga općeprihvaćena je činjenica da uspješnost poslovanja, implementacija kontrolinga, kao i razina kontrolerove suradnje s menadžmentom ovisi o stavu i karakteristikama menadžera (Meter i Šarčević, 2018; Očko i Švigir, 2009; Osmanagić Bedenik, 1998; Vitezić, 2016). U vidu empirijskih istraživanja navedeni odnos nije dovoljno istražen, osobito ne kroz primjenu naprednih statističkih metoda. Prema istraživanju kojeg su proveli Sikavica i Bahtijarević-Šiber (2004) uspješnost menadžmenta ovisi najviše o sposobnosti, znanju i vještinama menadžera i njegovih suradnika. Prema Šimić (2015) odlučivanje menadžmenta gotovo u jednakoj mjeri ovisi o njihovim vlastitim

karakteristikama, situaciji i karakteristikama suradnika. Feeney (2007) je u svojem istraživanju došla do saznanja da menadžeri mogu utjecati na ulogu kontrolera kroz svoja očekivanja, upravljačko usmjerenje, nezavisnost i međusobni odnos spram njega. Sukladno Meter i Šarčević (2018), od menadžera se očekuje da bolje razumiju važnost kontrolinga, da imaju veće povjerenje u njega, i da se angažiraju na poboljšanju međusobne komunikacije te stupnja educiranosti međuovisnih znanja.

Sve istaknuto podržava teoriju od Sathe (1983) koji navodi da je kvaliteta informacija i analiza koje kontroler stavlja na raspolaganje menadžmentu u svrhu provedbe aktivnosti i odlučivanja, odgovarajući kriterij za mjerenje kontrolerove efektivnosti. Odnosno, uzimajući u obzir navedeno i tretirajući menadžerski informacijski sustav (čiji utjecaj na efektivnost kontrolinga su Weißenberger i Angelkort indirektno potvrdili) kao dio organizacijske karakteristike, može se reći da te ali i druge karakteristike utječe na kvalitetu kontrolerovog outputa i posljedično na donošenje poslovnih odluka. Odnosno, brojna druga istraživanja u kontrolingu te psihologiji, informacijskim znanostima i drugim društvenim područjima dokazuju povezanosti pojedinih osobnih karakteristika, karakteristika suradnika i poduzeća na radni učinak zaposlenika i utjecaj na efikasnost poslovanja poduzeća. Odnosno, manji dio istraživanja potvrđuje i utjecaj vanjskih čimbenika na poslovanje poduzeća tj. kontroling. Detaljan pregled tih istraživanja dan je unutar ove disertacije, a u svrhu izrade konceptualnog modela.

Dakle, iako postoji od prije postavljen koncept utjecajnih karakteristika uključenosti kontrolinga u poslovno odlučivanje te je kroz istraživanja dokazan utjecaj pojedinih odrednica tih karakteristika na kvalitetu outputa i kontrolerov utjecaj na donošenje odluka, prema raspoloživoj literaturi, do sada nije istražen i ispitan model koji istodobno uzima u obzir karakteristike kontrolera, menadžera, poduzeća i okruženja. Osobito ne model koji karakteristike postavlja kao višedimenzionalne visoko-redne konstrukte kroz kombinaciju prethodno korištenih validnih mjernih ljestvica različnih područja društvenih znanosti.

1.5. Znanstvene metode

Radi provođenja teorijskog i empirijskog istraživanja te testiranja postavljenih hipoteza predloženog konceptualnog modela, a u svrhu ispunjenja prethodno postavljenih ciljeva istraživanja, korištene su raznovrsne analitičke i znanstvene metode.

Kako bi se prikupili sekundarni podaci iz dostupne znanstvene i stručne literature, odnosno kako bi se došlo do utemeljenih i jasnih spoznaja o proučavanoj tematici te sukladno postavio konceptualni model, primijenjene su sljedeće opće znanstvene metode: metoda analize i sinteze, metoda indukcije i dedukcije, metoda deskripcije, klasifikacije i komparacije, povijesna i grafička metoda.

Uz navedene metode, a s ciljem provedbe empirijskog istraživanja i testiranja valjanosti, pouzdanosti i prediktivne sposobnosti postavljenog konceptualnog modela korištena je metoda ispitivanja „licem u lice“, metoda anketiranja, te univarijatna i multivarijatna statistička analiza. Metoda ispitivanja „licem u lice“ primijenjena je u fazi izrade anketnog upitnika tj. prilikom detaljne analize prve verzije ankete od strane četiri stručnjaka-kontrolera. Metoda anketiranja primijenjena je kako bi se prikupili podaci od ispitanika, a koji su predstavljali ulazne podatke testiranja postavljenog konceptualnog modela. Univarijatna metoda korištena je za prikaz deskriptivne analize latentnih varijabli modela te analizu i interpretaciju dopunskih činjenica dobivenih kroz anketno ispitivanje sudionika istraživanja. Multivarijatna statistička analiza PLS-SEM tj. metoda parcijalnih najmanjih kvadrata modeliranja strukturalnim jednadžbama, korištena je za potvrdu valjanosti i pouzdanosti modela, testiranje postavljenih hipoteza te potvrdu prediktivne sposobnosti modela. Metoda anketiranja, deskriptivna statistička analiza i PLS-SEM metoda korištene su u fazi pilot testiranja ankete te provedbi cjelokupnog empirijskog istraživanja modela.

Pri tome su korištena različita softverska rješenja. Za prikupljane podatka korištena je besplatna aplikacija Google Form. Za obradu i pripremu istih korišten je Microsoft Excel odnosno statistički softver Stata14, dok je za provedbu PLS-SEM analize primijenjeno softversko rješenje SmartPLS (v. 3.3.3). U svrhu testiranja prikladne veličine uzorka također je korištena besplatna aplikacija G*Power (3.1.9.7.).

1.6. Struktura rada

Doktorska disertacija sistematizirana je u šest međusobno povezanih poglavlja.

U prvom poglavlju, *Uvodu,* definiran je problem i predmet istraživanja, prikazana je temeljna i pomoćne hipoteze te je određena svrha i ciljevi istraživanja. Osim toga, dan je pregled dosadašnjih istraživanja te je pojašnjena struktura rada kao i znanstvene metode korištene u njegovoj izradi.

U drugom poglavlju, *Koncept kontrolinga u procesu poslovnog odlučivanja*, teorijski je obrađena funkcija kontrolinga tj. dan je pregled izazova i prilika s kojima se susreće današnji kontroling u uvjetima digitalnog okruženja. Također, istražena je uloga kontrolera te odnos kontrolera i menadžera u procesu odlučivanja, kao i odnos kontrolinga s funkcijom podatkovnog znanstvenika.

Treće poglavlje nosi naslov *Teorijske i empirijske pretpostavke razvoja konceptualnog modela utjecaja kvalitete kontrolinga na poslovno odlučivanje,* te su u njemu dane temeljene teorijske postavke razvijenog konceptualnog modela. Odnosno u ovom poglavlju prikazan je detaljan pregled prethodnih istraživanja koja su služila kao temelj postavljanja konceptualnog modela ove doktorske disertacije. Pregled istraživanja uključuje prikaz najznačajnijih radova temeljem kojih je postavljen temeljni konceptualni model te detaljni prikaz istraživanja temeljem kojih su postavljene dimenzije pojedinih latentnih varijabli tj. karakteristika kontrolera, menadžera, poduzeća i okruženja. Također su obrazloženi razlozi tj. izvori odabira kontrolnih varijabli kvalitete kontrolerovog outputa i njegova utjecaja na donošenje poslovnih odluka.

U četvrtom poglavlju, *Konceptualni model utjecaja kvalitete kontrolinga na poslovno odlučivanje,* prikazan je konačni konceptualni model razvijen temeljem prikazanih teorijskih i empirijskih spoznaja u trećem poglavlju. Odnosno, objašnjena je struktura modela, dani su razlozi njegovog postavljanja kao hijerarhijsko komponentnog modela te su prikazane osnovne karakteristike, vrste i načini specifikacije i procjene takvih vrsta modela.

U petom poglavlju, *Empirijsko istraživanje utjecaja kontrolinga na donošenje odluka*, prikazana je metodologija i rezultati empirijskog istraživanja provedenog na uzorku kontrolera i menadžera u Republici Hrvatskoj, a kojim se potvrdilo da u uvjetima digitalizacije karakteristike kontrolera, poduzeća i okruženja imaju značajan utjecaj na učinke

kontrolerovih aktivnosti i doprinos u donošenju poslovnih odluka, koji ovisi o karakteristikama menadžera. Odnosno, na kraju poglavlja dana su zaključna razmatranja i prijedlozi budućeg razvoja kontrolinga, doprinos istraživanja te ograničenja i prijedlozi za buduća istraživanja.

Šesto poglavlje predstavlja *Zaključak* cjelokupnog rada. U njemu je prikazana sinteza svih spoznaja i rezultata do kojih se došlo tijekom pisanja rada, a s kojima se je dokazivala postavljena temeljna i pomoćne hipoteze.

Na kraju rada nalazi se popis korištene literature, popis tablica, grafikona, slika i privitaka kao potvrda iznesenih činjenica u radu.

2. KONCEPT KONTROLINGA U PROCESU POSLOVNOG ODLUČIVANJA

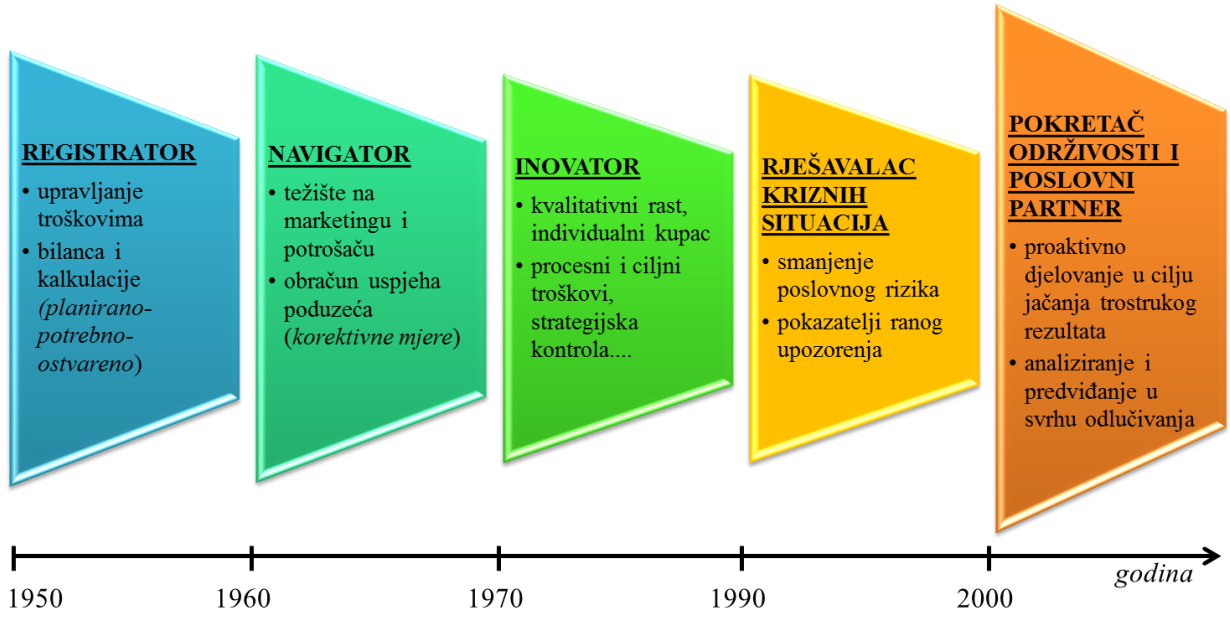
Današnje poslovanje postaje gotovo nemoguće bez uvođenja novih tehnologija i njima prilagođenih funkcija suodgovornih za upravljanje poduzećem. Kontroling, prvenstveno kao informativno-analitička i savjetodavna funkcija koja objedinjuje analizu, kontrolu, planiranje i izvještavanje, pruža menadžmentu najbolja moguća rješenja za izazove koji se javljaju unutar i izvan organizacijskog okruženja (Vitezić, 2008). Dok donošenje odluka predstavlja proces stvaranja vrijednosti za poslovanje, kroz planiranje, kontrolu i ocjenjivanje uspješnosti (Mihăilă, 2014), kontroling kao profesionalna funkcija ima zadatak pružiti informacije koje će menadžerima pomoći u donošenju ispravnih i pravovremenih odluka (Burns *et al.*, 2013 u Gärtner i Hiebl, 2018) te stvaranju dodane vrijednosti. Stoga, kontroling u današnjim uvjetima poslovanja predstavlja neizostavnu funkciju upravljanja gdje kontroler kao interni ekonomski stručnjak, poslovni analitičar, savjetnik i partner ima zadatak da analitičkom obradom prikupljenih informacija, savjetuje i usmjerava menadžment ka ostvarenju postavljenih strateških i operativnih ciljeva (Vitezić, 2011). Pri tome kontroleri koriste brojne interne i eksterne podatke i informacije kao inpute unutar kreiranih analiza i izvještaja tj. outputa, koje podnose menadžerima kao rezultat svojih aktivnosti. S Obzirom na sve veći utjecaj digitalizacije, dostupnosti velike količine podataka te alata koji omogućuju jednostavniju obradu i kreiranje kvalitetnih izvještaja, na kontroleru je da se prilagodi i prihvati prednosti koje će mu omogućiti da potpuno ostvari svoju ulogu poslovnog partnera.

2.1. Kontroling jučer i danas - izazovi i prilike u digitalno doba

Kontroling predstavlja suvremeni koncept upravljanja poslovnim rezultatom poduzeća koji pruža podršku menadžmentu u procesu odlučivanja. Kao funkcija osigurava učinkovito poslovno odlučivanje i pomaže menadžmentu u povećanju efikasnosti (uspješnost) i efektivnosti (učinkovitost) poslovanja. Iako se kontroling prvi put spominje u 15. stoljeću, početak njegova razvoja može se pridati razdoblju političkih i ekonomskih kriza te ubrzanom industrijskom razvoju Sjedinjenih američkih država u 19. stoljeću (Očko i Švigir, 2009). Odnosno, svoj prvi vrhunac kontroling postiže 60-tih godina 20. stoljeća, naročito u Njemačkoj i Austriji, gdje je i danas neizostavna funkcija upravljanja (Gänßlen *et al.*, 2012; Vitezić, 2020).

Do 90-tih godina 19. stoljeća razvoj kontrolinga se promatrao kroz tri osnovne generacije: registrator, navigator i inovator. Prva generacija je podrazumijevala da se uspjeh poduzeća temelji na zadovoljenju potražnje kroz racionalizaciju troškova. Druga generacija predstavljala je početke primjene poslovne usporedbe realiziranih i ostvarenih veličina te orijentiranosti prema okolini, dok je treća generacija tj. generacija dinamičkog okruženja i nesigurnih informacija, ona koja je kao ključni čimbenik uspješnosti prepoznala visoku kvalificiranost i motiviranost suradnika (Mreža znanja, 2012). Uslijed pojave globalne krize i razvoja koncepta održivosti, kontroler postaje rješavalac kriznih situacija i promotor održivosti. Odnosno, razvojem digitalizacije i s time povezane pojave velike količine podatka i informacija kontroling započinje svoju dosad najznačajniju ulogu poslovnog partnera.

Slika 1: Generacije kontrolinga



Izvor: izrada autora prema Vitezić (2020, str. 13)

Tijekom godina razvile su se brojne definicije kontrolinga. Odnosno, promjene u okruženju dovele su do različitosti u pogledu uloge i zadataka kontrolinga, područja njegovog djelovanja, organizacijske pozicije, povezanosti i srodnosti s drugim funkcijama, itd. Međunarodna institucija International Group of Controlling (ICV) još je u 2010. godini definirao kontroling kao „cjelokupni proces postavljanja ciljeva, planiranja i upravljanja u financijskom i ekonomskom području poslovanja poduzeća“ (IGC, 2013, str. 41). Vitezić (2002, 2020) definira kontroling kao moderni koncept tj. stručnu i savjetodavnu pomoć koja menadžmentu pomaže u prevladavanju poslovnih rizika, dostizanju postavljenih ciljeva i

ostvarenju dodane vrijednosti poduzeća. Luković i Lebefromm (2009) smatraju ga upravljačem svih aktivnosti ka ostvarenju postavljenih ciljeva gospodarskog subjekta, dok ga Osmanić Bedenik (2007, str. 15) definiraju kao „funkciju i podsustav menadžmenta kojim se pridonosi efikasnosti i efektivnosti u radu menadžmenta, čime se povećava sposobnost prilagođavanja poduzeća unutarnjim i vanjskim promjenama, povećava vitalnost poduzeća i njegova tržišna akceptabilnost“. Kontroling je funkcija koja pruža stalnu pomoć menadžmentu putem raznih metoda i tehnika i time omogućava upravljanje poduzećem u realnom vremenu (Očko i Švigir, 2009). On je prije svega funkcija koja pomaže poduzećima u povećanju efikasnosti i efektivnosti poslovanja te postizanju postavljenih ciljeva i vrijednosti kroz analizu različitih područja poslovanja uz primjenu raznovrsnih analitičkih alata (Vitezić i Lebefromm, 2019) te se sukladno tome, oduvijek smatra ključnim čimbenikom uspjeha poslovanja poduzeća (Gänßlen *et al.*, 2012).

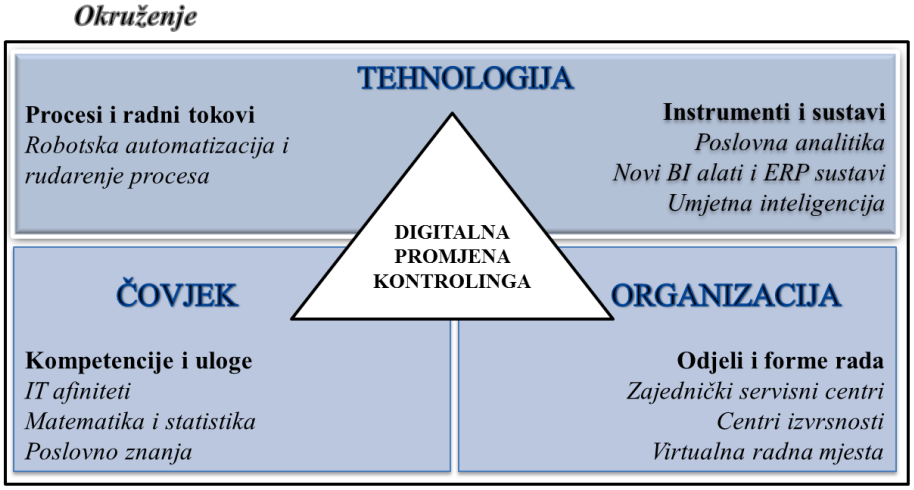
Iako je kontroling svoj razvoj doživio kroz više faza i time proizašlih različitih teorijskih polazišta kao pojma, procesa, funkcija shvaćanja (Vitezić, 2002), danas se najčešće tumači kao funkcija koja ne vrši samo statističku obradu i analizu podataka, već razrješava i predlaže rješenja te pomaže menadžmentu u donošenju odluka. Stoga se danas kontroling tumači kao potpora upravljanju koja proaktivno djeluje gledajući u budućnost, dok se kontroleri kao nosioci zadataka, slikovito opisuju kao „poslovni partneri“ menadžmentu (Vitezić i Petrlić, 2017; Weber i Schäffer, 2014), i „arhitekti“ upravljačkog sustava (Möller *et al.*, 2017).

Poput ostalih koncepata i funkcija, tako se i kontrolerska praksa danas razvija izuzetno brzo. Uzrok tome su stalne promjene u poslovnom svijetu te utjecaj digitalizacije i informatičke tehnologije (IT) koje iz dana u dan pružaju nove mogućnosti i time dovode kontroling sve bliže IT-u tj. IT sve bliže kontrolingu (Očko, 2018). Digitalna transformacija koja prije svega omogućuje da se iz velikog broja dostupnih izvora mogu identificirati što kvalitetniji podaci, spremiti i učiniti dostupnima osobama koje ih trebaju (Futivić, 2018), uključuje i temeljitu promjenu poslovnih procesa ili modela temeljenih na digitalnoj tehnologiji (Sejdić, 2019). Sukladno tome, kontroling s jedne strane ima veliki izazov prihvaćanja i usvajanja novih tehnologija kako bi mogao nastaviti tj. unaprijediti osnovnu ulogu podupiranja menadžmenta u poslovnom odlučivanju kroz dubinsku analizu i interpretaciju dostupnih podataka, a s druge strane ima i neizbježnu ulogu sunositelja provođenja digitalne transformacije unutar poduzeća. Može se reći da je kontroling „omogućitelj“ i „pokretač“ digitalne transformacije (ICV, 2018). Točnije, ICV (2018) ističe da kontroleri s kreativnom voljom, konceptualnom

snagom i potrebnim razumijevanjem tržišta i poslovanja već predstavljaju predvodioce inovacije digitalnih poslovnih modela unutar svojih poduzeća. Od kontrolinga se očekuje da postane digitalni kontroling tj. funkcija koja upotrebljava razne digitalne alate za potrebe prikupljanja, obrade i analize te informiranja (Vitezić, 2018). Keimer i Egle (2020) navode da se transformacija u digitalni kontroling može provesti jedino uz potpuno prihvaćanje digitalizacije u smislu podataka, tehnologije, procesa, metoda i kompetencija. Navedenih pet područja smatraju osnovnim domenama digitalnog kontrolinga.

Prema Sejdić (2019) proces digitalne transformacije kontrolinga mora sadržavati četiri osnovna područja podijeljena u tri dimenzije MTO (njem. Mensch, Technik, Organisation) koncepta - ljudi, tehnologija i organizacija, a to su: 1) procesi i radni tokovi, 2) instrumenti i sustavi, 3) kompetencije i uloge te 4) odjeli i forme rada.

Slika 2: Model digitalne transformacije kontrolinga

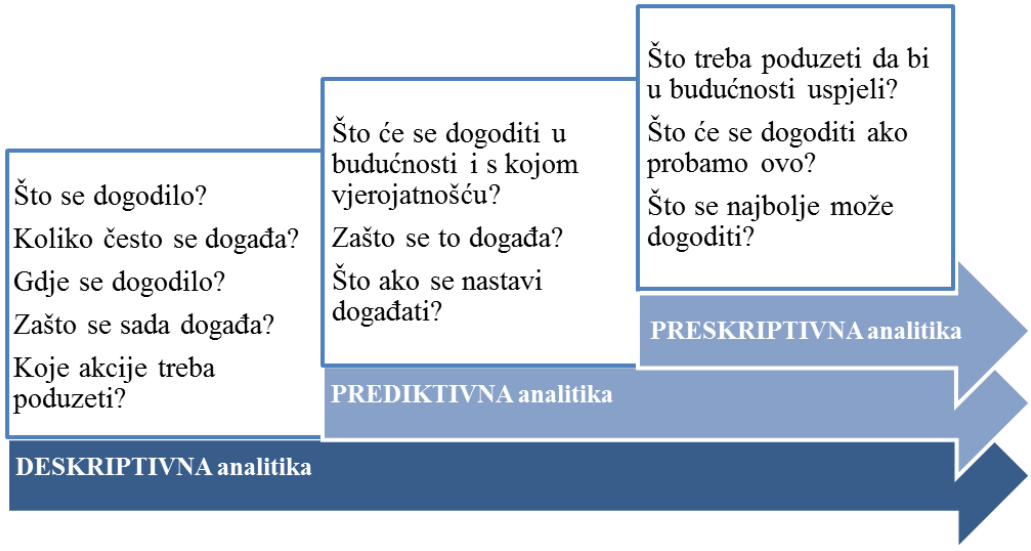


Izvor: izrada autora prema Sejdić (2019) i Ulich (2013)

Pretpostavka MTO-a je da su ljudi, tehnologija i organizacija međusobno ovisni i da se jedino konstantnom suradnjom sve tri dimenzije mogu postizati efikasni poslovni rezultati. Sukladno tome, kontroling treba prihvatiti digitalne procese automatizacije i robotizacije i prigrliti nove poslovne alate i sustave, bez kojih je nezamisliva obrada i analiza velike količine podataka koja danas stoji pred njim. Osim toga, kako bi dokazao svoju ulogu potpore poslovnom odlučivanju, kontroling treba više nego ikada unaprjeđivati svoje stručne, ali prije svega, IT i „meke“ vještine, koje prema Haselbergeru (2012, u Filipčić, 2019) uključuju osobne, socijalne i metodološke kompetencije. Samo tako kontroleri mogu biti primjereni partneri menadžmentu, ali i ostalim službama bez čijeg znanja i podrške kontroling teško može

ostvariti digitalnu transformaciju i u potpunosti izvršavati svoju ulogu. Naravno, sva četiri područja transformacije koje navodi Sejdić (2019) podjednako su značajne. Međutim, ako se uzme u obzir glavni zadatak kontrolinga u kontekstu generiranja izvještaja za poslovno odlučivanje, na prvo mjesto mogu se postaviti instrumenti i sustavi te kompetencije kontrolera. Naime, u prošlosti kontroling je bio fokusiran na prikupljanje i obradu podataka. Danas, uz dostupnost napredne tehnologije, kontroling ima više vremena za interpretaciju podataka, savjetovanje te predlaganje strategija i planova u realnom vremenu (Vitezić i Lebefromm, 2019). To podrazumijeva prelazak kontrolera s uloge deskriptora u preskriptora poslovnog odlučivanja. Pri tome, mora prihvatiti značaj i ulogu poslovne analitike u širem smislu koja podrazumijeva upotrebu matematičkih i statističkim tj. prognostičkih modela i metoda analize koje omogućuju uvid u budućnost poduzeća i pronalaženje načina dostizanja dugoročnih ciljeva poduzeća u uvjetima neizvjesnog okruženja. Kontroling se više ne može samo usmjeriti na klasičnu deskriptivnu i dijagnostičku analitiku (Bakhshaliyeva, 2017, u Vitezić i Lebefromm, 2019), već na metode prediktivne i preskriptivne (Appelbaum *et al.*, 2017; Evans, 2017; Nielsen, 2018; Sejdić, 2019, itd), autonomne (Davenport i Harris, 2017) i otkrivajuće analitike (Strajher, 2019) te sukladno tome razviti i svoje tehničke vještine predviđanja. Naime, alati za prediktivnu analitiku omogućuju i do 50% unaprjeđenja kvalitete prognoziranja (Tucker *et al.*, 2017) te bi stoga njihova svakodnevna primjena trebala postati ključni dio u obavljanju kontrolerovih zadataka.

Slika 3: Pregled razvoja poslovne analitike



Izvor: izrada autora prema Maisel i Cokins (2014), Strajher (2019), Davenport i Harris (2017)

Dakle, od kontrolinga se očekuje da više ne daje samo odgovore na pitanja: „Što se dogodilo, koliko puta i koliko često?“, „Zašto je došlo do problema i koje akcije treba poduzeti?“, već: „Što će se dogoditi u budućnosti i s kojom vjerojatnošću?“, „Zašto se to događa i što ako se nastavi događati?“ i „Što treba poduzeti da bi poduzeće u budućnosti uspjelo?“ (Maisel i Cokins., 2014; Strajher, 2019). Kako ističe Deinert (2013, str. 279), kontroleri se suočavaju s pet osnovnih promjena:

- od registratora do poslovnog partnera,
- od promatrača do člana tima,
- od savjetnika do vođe promjena,
- od izvješćivanja do dubinske analize i interpretacije i
- od reaktivnog do proaktivnog partnera.

Dakle, od kontrolera već se dugo vremena ne očekuje da samo bilježi i promatra promjene unutar poduzeća. Kao proaktivni poslovni partner, kontroler mora postati predlagač promjena koji kroz dubinsku analizu informacija inicira i vodi promjene unutar poduzeća. Sukladno, Vitezić (2018) također ističe promjenu orijentacije kontrolinga iz reaktivnog u proaktivni, ali i napredak s analitičkog u prediktivni te retrospektivnog u prospektivni. Točnije, ističe da retrospektivne analize više nisu toliko tražene, već da se u donošenju poslovnih odluka naglasak stavlja na predviđanje i proaktivnu ulogu kontrolinga. Od kontrolera se očekuje da se prilagode u svim svojim funkcijama, a prije svega u izvještavanju te planiranju i predviđanju. Također, očekuje se da učine procese planiranja fleksibilnijima, da unaprijede automatizaciju predviđanja i analize ostvarenja planova te da povećaju korištenje samoposlužnih (engl. self-service) aplikacija poslovnog izvještavanja kroz implementaciju i veću upotrebu poslovne analitike (Nobach, 2019).

Može se reći da je kontroling dosegao svoju razvojnu fazu poslovnog partnera upravo zbog pojave digitalizacije te četvrte industrijske revolucije tj. Industrije 4.0 (engl. Industry 4.0), i s njima povezanih koncepata - Velika količina podataka (engl. Big Data), poslovna inteligencija (engl. Business intelligence - BI), poslovna analitika (engl. Business analytics - BA), poslovna inteligencija i analitika (engl. Business intelligence and analytics - BI&A), robotska automatizacija procesa (engl. Robotic Process Automation - RPA), itd. Svi ti koncepti imaju utjecaj na poslovanje svakog poduzeća i funkcija unutar njih, uključujući kontroling. Samo poduzeća i funkcije koje prate trendove digitalne ere i koje se prilagođavaju istima imat će mogućnost opstanka i napretka.

2.1.1. Kontroling, Big Data i robotika

Dok je treća industrijska revolucija bila zasnovana na principu automatizacije, koncept Industrije 4.0. obuhvaća povezanost i nadogradnju između digitalizacije i robotizacije te umrežavanja u stvarnom vremenu (Sejdić, 2017). Zasnovana je na tzv. virtualno-fizičkim sustavima (engl. Cyber-Physical Systems) koji označavaju digitalnu integraciju i umrežavanje svih uređaja, strojeva i procesa putem Interneta (Wegener, 2019). Iako je Industrija 4.0 prvotno nastala kao pokušaj temeljite promjene Njemačke proizvodne industrije u svrhu jačanja međunarodne konkretnosti (Gleich *et al.*, 2016), do danas je značajno utjecala na razvoj brojnih funkcija unutar poduzeća, uključujući kontroling. Naime, digitalizacija i virtualno umrežavanje u stvarnom vremenu dovelo je do stvaranja nezamislive količine podataka izvan i unutar poduzeća, nazvanih „Big Data". Big Data se može opisati kao velika baza podatka (Manyika *et al*., 2011) koja se sastoji od mnoštva različitih nestrukturiranih, strukturiranih i polustrukturiranih podataka (Giri i Lone, 2014). Prema, Warren *et al.* (2015) Big Data predstavlja skup toliko velikih i nestrukturiranih podataka da ih niti jedan sustav ili softverski program ne mogu lako obraditi i analizirati. Appelbaum *et al.*(2017) ga vide kao sredstvo prikupljanja unutarnjih i vanjskih podataka prvenstveno namijenjenih donošenju poslovnih odluka. Big Data se također može smatrati i podacima u stvarnom vremenu, s obzirom na to da uključuje podatke dostupne u arhivi poduzeća, mobilnim aplikacija koje poduzeća primjenjuju, društvenim mreža, na Internetu, itd. Iako ne postoji jedinstvena definicija, Big Data se uglavnom karakterizira pomoću tri ili pet V-a (engl. V's): količina (engl. volume), brzina (engl. velocity) i raznovrsnost (engl. variety) (Brynjolfsson i McAfee, 2012), tj. pouzdanost (engl. veracity) i vrijednost (engl. value) (Ishwarappa i Anuradha, 2015). Neki autori čak ističu dodatne V-ove poput valjanosti (engl. validity), promjenjivosti (engl. variability), mjesta (engl. venue), rječnika (engl. vocabulary), kompleksnosti (engl. complexity), vizualizacije (engl. visualization), itd. (Arockia Panimalar *et al.*, 2017; Gärtner i Hiebl, 2018). Iako je Big Data relativno novi koncept i znanstveno nedovoljno istražen, brojni autori ističu jačinu njegova utjecaja na različite segmente kontrolinga - metode, instrumente, vještine, procese, IT-sistem i organizaciju (Kieninger *et al.*, 2016; Langmann, 2019; Vitezić i Lebefromm, 2019). Gärtner i Hiebl (2018) naglašavaju da kontroleri Big Data moraju shvatiti kao koncept koji utječe na njih i čije prednosti moraju iskoristiti, ali i čijih izazova i nedostatka moraju biti svjesni. Stoga su dali pregled najvažnijih prilika i izazova tj. prijetnji koje koncept Big Data donosi za funkciju kontrolinga razvrstanih u tri faze određene temeljem opće prihvaćenih definicija kontrolinga i Big Data.

Tablica 1: Prilike i izazovi/prijetnje Big Data za kontroling

Kontroling *„ je profesija koja nastoji pružiti informacije koje će pomoći menadžerima u donošenju odluka.“ (Burns et al., 2013, p.4)* ***Big Data*** *„odnosi se na stvaranje, pohranu, obradu, provjeru i analizu velikih, svestranih i brzo rastućih podataka s ciljem stvaranja vrijednih informacija.“(Ward i Baker's, 2013; Gärtner i Hiebl, 2018)*		
Faza	**Prilike**	**Izazovi / prijetnje**
1) Generiranje i pohrana podataka	• integracija novih podatkovnih kanala, nestrukturirani podaci • automatsko generiranje podataka • ušteda troškova • sve veća vrijednost podataka	• velike količine podataka • preopterećenost informacijama i istinitost podataka • nedostatak izvora (znanje i kvalificirani radnici)
2) Obrada, provjera i analiza podataka	• ušteda vremena • dostupnost podataka u stvarnom vremenu • automatizacija analize i obrade podataka	• nužnost novih tehnologija • gubitak suvereniteta podataka • automatizacija analize i obrade podataka
3) Izvješćivanje i potpora odlučivanju	• poboljšana podrška odlučivanju • poboljšano operativno planiranje • poboljšano strateško planiranje	• brže donošenje lažnih odluka • promjena strukture troškova

Izvor: izrada autora prema Gärtner i Hiebl (2018)

Iako Big Data donosi brojne prednosti za kontroling, osobito u području njegove uključenosti u proces poslovnog odlučivanja te strateškog planiranja, brojni su izazovi tj. prijetnje koje treba prihvatiti. Opće je poznato da podaci, pored ljudi, predstavljaju najvrjedniju nematerijalnu imovinu poduzeća. Sukladno tome, Big Data bi se mogao smatrati neiscrpnim izvorom bogatstava za donošenje ispravnih poslovnih odluka i konstantno povećanje efikasnosti poslovanja. Međutim, kako navode Gärtner i Hiebl (2018), velika količina podatka može predstavljati i prijetnju za one osobe koje ih nepravilno koriste. Njihovu upotrebu predstavljaju kao izazov za kontroling koji zahtjeva usvajanje novih tehnologija, znanja i vještina u svrhu smanjivanja rizika upotrebe neadekvatnih informacija i donošenje krivih poslovnih odluka. Istraživanje ICV (2015) također je potvrdilo da glavni izazov kontrolinga prije svega predstavlja upotreba novih alata i metoda analiza te selekcija samih podataka, iako se sama mogućnost analize podataka u stvarnom vremenu dokazala kao jedna od tri osnovne prednosti Industrije 4.0. Nadalje, Weichel i Herrmann (2016) ističu da kontroleri mogu imati

znatne koristi od Big Data, posebno u području planiranja i predviđanja, te analizi i izvještavanju kroz izgradnju analitičkih modela. Grönke *et al.* (2014) kao osnovne prednosti Big Data navode pojednostavljenje i bržu izradu izvještaja, razradu pravodobnih podataka i povećanje fleksibilnosti kontrolinga, dok Gleich *et al.* (2016) ističu dostupnost podataka u realnom vremenu i mogućnost kontrolinga da se usmjeri na interpretaciju podataka i izvođenje pravih zaključka za aktivno savjetovanje menadžmenta.

Prema radu Bhimani i Willcocks (2014) kontroleri moraju biti u stanju prepoznati potencijal i vrijednost nestrukturiranih podataka i njihovog utjecaj na financijsku perspektivu poslovanja. Analizom svih dostupnih podataka koje pruža Big Data, a među kojima se eksterni podaci ističu kao novina, kontroleri imaju mogućnost dobivanja tj. davanja informacija menadžmentu koje daleko premašuju tradicionalne veličine upravljanja. Stoga se u budućnosti očekuje da će sve veći udio u izvještavanju pripasti upravo eksternim informacijama (Grönke *et al.*, 2014). Ako već nisu, one će postati glavni izvor konkurentske prednosti poduzeća, a uloga kontrolera kao jednog od internih sakupljača podataka značajno će se smanjiti i zamijeniti njihovom upotrebom u svrhu predviđanja. Uslijed sve brže promjene okruženja i potrebe za predviđanjem, od kontrolera će se očekivati da pored analitičara povijesnih podataka, postane i analitičar eksternih podatka u realno vremenu. Morat će biti sposobni brzo prepoznati podatke koji su potrebni za poduzeće, odrediti način kako ih analizirati i koje akcije poduzeti temeljem dobivenih rezultata (Gray i Alles, 2015). Sve navedeno zahtijeva od kontrolera da se prilagode i prigrle nova znanja i vještine koje će im osigurati ulogu poslovnog partnera menadžmentu.

Naime, dok jedni smatraju da će upravo kontroling zbog svoje dugogodišnje prakse i dubinskog razumijevanja brojeva i poslovanja preuzeti glavnu ulogu u procesu odlučivanja i aktivnog sudjelovanja u strateškom razvoju poduzeća (Gleich *et al.*, 2016), drugi smatraju da je opstanak kontrolinga i značaj njegove uloge znatno ugrožen pojavom Big Data i očekivanjima koje postavlja pred njega. Pri tome, najveći izazov predstavlja usvajanje novih znanja u području matematike, informatike i statistike. Odnosno, postavlja se pitanje hoće li podatkovni znanstvenik (engl. Data Scientist), kao osoba koja vrši statističke analize, vađenje i pretraživanje velike količine podataka, kao nova digitaliziranija profesija s naprednim znanjem matematike, statistike i informatike, umanjiti značaj i ulogu kontrolinga u procesu poslovnog odlučivanja. Odgovor na to pitanje najbolje su dali Brynjolfsson i McAfee (2012) i Al-Htaybat i Alberti-Alhtaybat (2017). Ističu da godine osposobljavanja i stečenog znanja

kontrolera nisu zamjenjive, osim ako ne postoje podatkovni znanstvenici s dugogodišnjim obrazovanjem i praksom u kontrolingu (Al-Htaybat i Alberti-Alhtaybat, 2017), odnosno, da je gotovo nemoguće naći osobu koja posjeduje sva znanja kontrolera i podatkovnog znanstvenika, osobito u velikoj potražnji koju nam donosi digitalizacija (Brynjolfsson i McAfee, 2012). Dakle, za očekivati je jedino da kontroleri surađuju s podatkovnim znanstvenikom i tako ostvare zajedničke koristi. Naravno, pri tome će kontroler morati unaprijediti vještine iz područja podatkovnog znanstvenika, ali do razine koja će omogućiti razumijevanje tj. suradnju. Nije za očekivati da će kontroler postati podatkovni znanstvenik niti obrnuto, osim naravno pojedinih iznimaka.

Predviđa se da će „digitalni svemir" tj. podaci koji se stvaraju i kopiraju svake godine doseći 180 zetabajta do 2025. godine (Mališ, 2017). Upravo zbog sve veće tj. nezaustavljive ekspanzije internih i eksternih podatka, pored Big Data, veliku pozornost u promjeni poslovanja poduzeća i kontrolinga u posljednje vrijeme dobiva primjena robotske automatizacije procesa (RPA). RPA predstavlja „softver koji zamjenjuje (automatizira) svakodnevni ljudski rad na računalu" (Stamatović, 2019, str. 29). Iako je tehnologija relativno nova, već se ističu njezine brojne prednosti: smanjenje vremena na ponavljanje istih zadataka, veća kvaliteta izvršenja procesa uklanjanjem ljudskih pogrešaka, smanjenje troškova, usmjerenost zaposlenika na korisnije zadatke, povećanje zadovoljstva zaposlenika, ubrzanje procesnog ciklusa, neprekidnost poslovnih procesa, itd. (Deloitte, 2020; Stamatović, 2019). Sama primjena RPA u kontrolingu do sada je uglavnom negirana. Međutim, Reuschenbach *et al.* (2019) smatraju da jedan manji dio kontrolinga može znatno iskoristiti prednosti koje pruža RPA, i to u području operativnog planiranja i menadžerskog izvještavanja. Točnije, kroz objedinjavanje i konsolidaciju pojedinačnih planova te izradu izvještaja (brojčani prikaz), ne uključujući analizu odstupanja kroz komentare. Strateško planiranje, vrednovanje upravljanja i iniciranje mjera, kao i ostale radnje koje zahtijevaju izravnu ljudsku komponentu određuju kao područje neadekvatne primjene RPA. S navedenim se slažu i Alexander *et al.* (2018, str. 16) te navode da „procesi temeljeni na kompetencijama, kao što su stvaranje prognoza, sveobuhvatne analize, komentiranje izvještaja i savjetovanje uprave, uvijek zahtijevaju ljudsku interakciju i stoga se ne mogu riješiti sredstvima RPA". Zaključno, RPA može dati pozitivne učinke kontrolingu, a ponajviše u području izvještavanja. U idealnom slučaju ta primjena se provodi kroz ugrađene sustave poslovne inteligencije te analitike (Reuschenbach *et al.*, 2019), bez kojih je gotovo nezamisliva izrada današnjim poslovnih izvještaja i za koje se može reći da trenutno predstavljaju osnovi alat digitalnog kontrolinga.

2.1.2. Kontroling i poslovna inteligencija te analitika

Novi i suvremeni procesi, poslovne politike i strategije uvode se u poduzeće prvenstveno s ciljem smanjenja troškova te povećanja profitabilnosti i općenito efikasnosti. Poslovna inteligencija je alat koji može znatno pomoći u ostvarenju tih ciljeva. Sukladno istraživanju „2020 Global State of Enterprise Analytics“, od ukupnih 500 sudionika 65% je izjavilo da će u budućnosti znatno povećati svoje izdatke za poslovnu analitiku. Odnosno, 94% sudionika izjavilo je da su "podaci i analitika" presudni za rast poslovanja i uspješnu digitalnu transformaciju poduzeća (MicroStrategy, 2019). Côrte-real *et al.* (2014, str. 172) istaknuo je da “u eri velikih podataka, poslovna inteligencija i analitika mogu pomoći u poboljšanju organizacijske uspješnosti kao rezultat poboljšanja poslovnog odlučivanja“. Sukladno tome, upotreba poslovne inteligencije i analitike bitni su preduvjet opstanka i transformacije kontrolinga.

Poslovnu inteligenciju (BI) prvi je opisao Howard Dresner 1989. godine, kao skup metodologija i koncepata osmišljenih za poboljšanje donošenja odluka korištenjem činjenica i sustava utemeljenih na činjenicama (Chou *et al.*, 2005). Do danas, nastale su brojne definicije. Neki ga poistovjećuju s menadžerskim informacijskim sustavom, neki sa skladištem podataka, neki ga nazivaju filtrom velikih podataka ili upravljačkim sustavom (Schön, 2018). Manyika *et al.* (2011) ga definiraju kao aplikativni softver prvenstveno dizajniran za analizu i izvještavanje podataka prethodno pohranjenih u skladištu podataka (engl. Data Warehouse). Mrkonjić (2019) smatra da se BI odnosi na tehnologiju, aplikacije i praksu u prikupljanju, integraciji, analizi i prezentaciji poslovanja. Prema Williams i Williams (2007) BI je kombinacija proizvoda, metoda i tehnologija koje osiguravaju ključne informacije za upravljanje i poboljšanje profita i ukupne uspješnosti poslovanja poduzeća. Odnosno, on je sustav koji pretvara sirove podatke u smislene i korisne informacije za učinkovite strateške, taktičke i operativne poslovne odluke (Evelson, 2008).

Dobro je poznato da učinkovitost odlučivanja ovisi o pouzdanosti podataka. Iako se BI alati uglavnom koriste za vizualizaciju pojedinih analiza u poslovnom odlučivanju, s druge strane mogu biti i alat osiguranja kvalitete podataka kao inputa analize. Kao takvi, oni predstavljaju snažan i nezaobilazan alat u području rada kontrolera. Iako posljednje istraživanje o BI-u u Republici Hrvatskoj prikazuje vrlo nisku primjenu unutar poduzeća (Bilandžić i Lucić, 2018), zaključak se, s obzirom na veličinu uzorka i način provedbe istraživanja (cjelokupno poduzeće, a ne specifičan odjel), ne može prenijeti i na odjele kontrolinga. Anketno

istraživanje o trendovima u BI-u koje svake godine provodi Centar za istraživanje poslovnih aplikacija (engl. Business Application Research Center) među odvojenim BI organizacijama, odjelima za informatiku i financije/kontroling te menadžerima poduzeća, kao najvažnije karakteristike BI-a u 2019. godini istaknulo je kvalitetu podataka, otkrivanje/vizualizaciju podataka i kulturu vođenja podataka (Baier *et al.*, 2020). Da je vizualizacija jedna od najkorisnijih komponenti BI-a navodi i Evans (2017). Naime, ljudski mozak obrađuje slike 60.000 puta brže od teksta i 90% informacija koje prima su vizualne (Brewer *et al.*, 2019). Daryabari (2018) vezu između kontrolinga i BI-a naziva „jasnom" i „važnom" i pripisuje ju činjenici da bolje analize i poslovne odluke stvaraju nove vrijednosti za poduzeće. Iako ne postoji mnogo empirijskih istraživanja o odnosu između kontrolinga i BI, Gullkvist (2013) je potvrdila utjecaj BI-a na kvalitetu podataka i zadatke kontrolinga. Sukladno svemu navedenom, Appelbaum *et al.* (2017) navode brojne funkcije BI-a značajne za kontroling od kojih se najviše ističu sljedeće:

- Konsolidacija podataka
    - integracija unutarnjih i vanjskih podataka,
    - pojednostavljeno izdvajanje, transformacija i učitavanje podataka,
    - brisanje neželjenih i nepovezanih podataka
- Kvaliteta izvještajnih podataka
    - ispravak i priprema podataka za poboljšanje ukupne točnosti
    - korisnički definirana i standardna izvješća
    - prilagođena izvješća za različite razine upravljanja
- Predviđanje i modeliranje
    - podržavanje analitike koja se koristi u prediktivnoj i preskriptivnoj analitici, a koja koristi povijesne podatke i podatke u stvarnom vremenu
- Praćenje podataka u stvarnom vremenu
    - praćenje trenutnog napretka s definiranim ciljevima projekta/ključnim pokazateljima uspjeha
    - prioritiziranje oskudnih resursa
- Vizualizacija podataka
    - interaktivna izvješća i grafike, s mogućnošću ažuriranja u stvarnom vremenu
    - *Scorecardovi i Dashboardovi*

- Analiza podataka
    - deskriptivna analiza
    - što-ako analiza, analiza osjetljivosti/optimizacije, analiza ciljeva
- Mobilnosti, dijeljenje i brzina uvida
    - prenosivost na više uređaja i formata
    - slanje izvještaja putem e-maila u različitim formama
    - pregled detaljnih značajki tj. izvora kreiranja podataka (engl. drill-down)

Lorica (2013, u Futivić, 2018) također navodi funkcije koje takvi sustavi moraju imati kako bi zadovoljili potrebe korisnika: prošireni skup grafikona, grafikoni koji su jednostavni za mijenjanje, mogućnost izrade predložaka, jednostavno filtriranje, isključivanje ili istraživanje ekstrema, itd.

Nema sumnje da je BI presudan alat za učinkovitu potporu odlučivanju. No, u današnjem okruženju koje se sve više mijenja, napredne analitičke metode i modeli nužni su za predviđanje budućih događaja i smanjenje rizika. Stoga se kontroling također mora usmjeriti i na prediktivne i preskriptivne tehnike poslovne analitike. Poslovna analitika (BA) kao analitička komponenta BI-a uvedena je krajem 2000-ih (Chen *et al.*, 2012). Davenport i Harris (2007, u Appelbaum *et al.*, 2017) definirali su BA kao "upotrebu podataka, informacijske tehnologije, statističkih analize, kvantitativnih metoda i matematičkih ili računalnih modela kao pomoć menadžerima da steknu bolji uvid u svoje poslovanje i donesu bolje odluke utemeljene na činjenicama" (Appelbaum *et al.*, 2017). Galetto (2016) opisuje razliku između BI i BA na sljedeći način: BI se može tretirati kao prvi korak u donošenju odluka, tj. postupak prikupljanja podataka, dok BA predstavlja analizu odgovora koje je dao BI. Dok BI odgovara samo na pitanje što se dogodilo, BA ima sposobnost odgovoriti zašto se to dogodilo i predvidjeti hoće li se to ponoviti. U terminima tehnika, BI uključuje izvještavanje, automatizirano praćenje i upozoravanje, *dashboardove, scorcardove* i ad hoc upite (engl. ad hoc query), dok BA uključuje statističku i kvantitativnu analizu, rudarenje podataka (engl. Data Mining), prediktivno modeliranje i multivarijatno testiranje (Galetto, 2016). Ako se navedeno poveže s razvojnim fazama analitike, može se reći da je BI alat deskriptivne, a BA prediktivne i preskriptivne analitike.

Tablica 2: Orijentacija i tehnike poslovne analitike

Orijentacija	**Tehnike**
Deskriptivna	• Analiza pomoću pokazatelja • Modeli klasterizacije • Vizualizacija • Deskriptivna statistika • Rudarenje podatka • Što-ako analiza
Prediktivna (PD) i preskriptivna (PS)	• Optimizacija procesa (PD) • Bayesova mreža (PD) • Modeli teorije vjerojatnosti (PD) • Analitički hijerarhijski procesi (PD) • Strukturni modeli (PD) • Umjetne neuronske mreže (PD, PS) • Linearna regresija (PD, PS) • Logistička regresija (PD, PS) • Regresija vremenskih serija (PD, PS) • Univarijatna i multivarijatna regresijska analiza (PD, PS) • Autoregresivni integrirani pomični prosjek (PD, PS) • Monte Carlo simulacije (PD, PS) • Sustavi podrške grupnom odlučivanju/Ekspertni sustavi (PD, PS)

Izvor: izrada autora prema Appelbaum *et al.* (2017)

Zbog današnjeg okruženja, nesumnjivo je da se učinkovite i djelotvorne odluke mogu najbolje donijeti uz upotrebu tehnika deskriptivne, prediktivne i preskriptivne analitike. Zbog toga, ali i prije svega zbog svoje komplementarnosti, BI i BA danas se često povezuju u jedan pojam Poslovna inteligencija i analitika (BI&A). Ona uključuje sve pozitivne atribute BI i BA (Côrte-real *et al.*, 2014). Odnosno, BI&A sve više uključuje umjetnu inteligenciju (engl. Artificial intelligence - AI) i mogućnost strojnog učenja (engl. Machine Learning) što pred kontrolere stavlja još veći pritisak. Za razliku od RPA koji je softver „vođen pravilima“ (engl. rule-driven), AI tj. strojno učenje predstavlja „podatkovno vođeni“ (engl. data-driven) softver. Može se reći da kontroleri imaju mogućnost postati jedan od glavnih nositelja „podatkovno vođenih“ poduzeća. To su poduzeća budućnosti koja analiziraju prošlost i sadašnjost te predviđaju budućnost koristeći se pri tome poslovnom analitikom kao konkurentskom prednošću (Strajher, 2019). Za očekivati je i da će BA u budućnosti, zbog svoje sposobnosti prevladavanja složenih i dvosmislenih uvjeta odlučivanja, postati značajniji za kontroling nego BI (Richards *et al.*, 2017). Kontroleri će morati biti proaktivni partneri menadžmentu

sposobni u predviđanju budućih ishoda. Pri tome, na Big Data će gledati kao na izvor podataka, a na BI&A kao sredstvo napredne analize i izvještavanja za poslovno odlučivanje.

Osim toga, treba imati na umu da za dobru implementaciju i funkcioniranje sustava poslovne inteligencije i analitike treba raspolagati i s adekvatnim računovodstvenim i menadžerskim informacijskim sustavom te sustavom za planiranje resursa poduzeća (Mališ, 2017). Kako ističe Listeš (2019), koliko god bili dobri i korisni, alati poslovne inteligencije ne mogu sami po sebi maksimizirati korist za poduzeće, već se isto može ostvariti jedino kroz podatkovnu pismenost njihovih korisnika. Jedino se kroz tzv. „meke" vještine sirovi „podaci ili informacije mogu pretvoriti u znanje i poslovnu odluku" (Listeš, 2019, str. 39). Istraživanje provedeno od strane IGC-a u 2016. godini ukazalo je na to da najveći utjecaj na procesne standarde u kontrolingu imaju kompetencije zaposlenika, kontrola kvalitete podataka i veliki podaci te analitika (Meter i Šarčević, 2017). Vitezić i Lebefromm (2019, str. 19) navode da „sama tehnologija ne dovodi do uspjeha tvrtke u digitalnom dobu bez stručnjaka koji bi je mogli učinkovito koristiti". Temeljem svega navedenog može se zaključiti da će transformacija kontrolinga u smjeru primjene novih i produljivanja postojećih znanja i vještina postati neprekidan proces cjeloživotnog usavršavanja. Jedino primjenom potrebnih kompetencija kontroling će postati neizostavna funkcija unutar svakog poduzeća koja će kroz upravljačku tj. savjetodavnu ulogu pomagati menadžmentu u organiziranju, usmjeravanju i kontroliranju aktivnosti za ostvarenje postavljenih ciljeva, odnosno koja će kroz informacijsku ulogu koordinirati veliku količinu podataka i informacija te ih objedinjavati u smisleni sadržaj nužan za poslovno odlučivanje (Vitezić, 2020). Samo kontroling koji bude sposoban odgovoriti na sve zahtjeve koje pred njega stavlja digitalizacija, će moći pridonijeti uspješnom upravljanju poduzećem i postati adekvatan partner poslovnog odlučivanja.

2.2. Kontroleri i menadžeri u procesu odlučivanja

Dinamičke promjene u okruženju i sve veća vanjska i unutarnja kompleksnost, koju je prouzročila automatizacija i digitalizacija, pridodali su značaju i razvoju kontrolinga više nego ikada. Okruženje koje zbog svoje turbulentnosti sve više skraćuje vrijeme za donošenje odluka, a koje istodobno pruža obilje podataka i informacija, nameće kvalitetno donošenje odluka kao ključnu vještinu koja usmjerava organizaciju prema razvoju ili propasti. Odnosno, nameće potrebu menadžmenta na prilagođavanje novim trendovima i neizbježno prihvaćanje

suradničkih funkcija za donošenje poslovnih odluka. Već je opće poznato da je kontroling proces koji pomaže menadžmentu u procesu odlučivanja i ostvarenja postavljenih ciljeva i zato danas predstavlja koncept nužno potreban svakom poduzeću željnog uspjeha i budućeg razvoja.

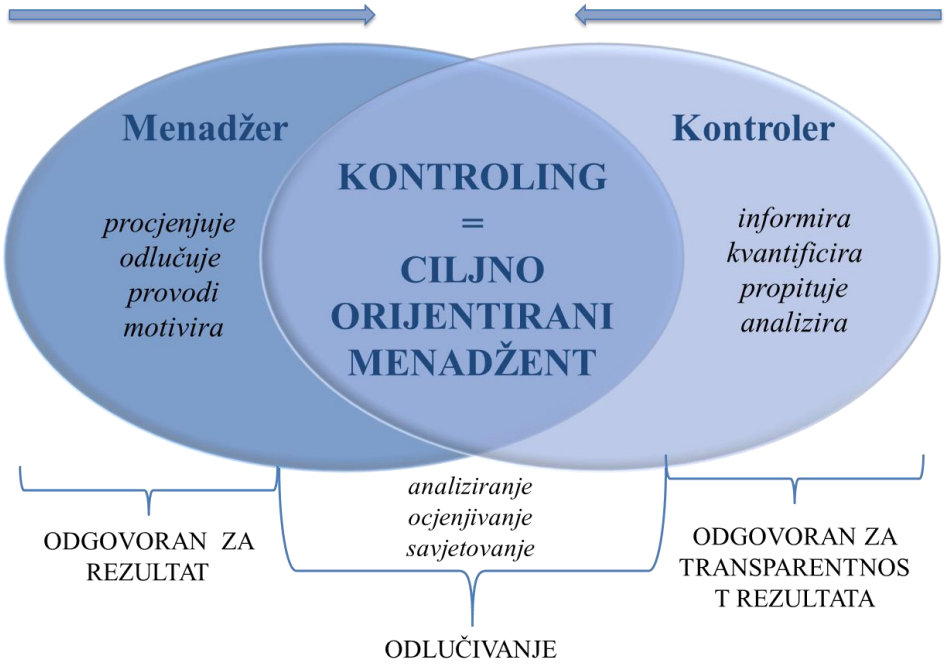
Iako se kontroling razvojno prvenstveno nazivao registrator, navigator i inovator, danas mu se najčešće pridaje naziv poslovnog partnera. Međutim, tijekom godina brojni autori definirali su različite druge nazive za njegovu ulogu unutar poduzeća. Tako su Schäffer i Weber (2015, u Labaš i Rajsman, 2020) klasificirali kontrolera u sljedećih dvanaest uloga: 1) interni konzultant (engl. Internal Consultant), 2) sparing partner menadžmentu (engl. Economic Conscience), 3) inspektor (engl. Inspector), 4) navigator (engl. Pilot), 5) perfekcionist (engl. Bloodhound/Watchdog), 6) komunikator (engl. Communicator), 7) brojač graška (engl. Bean Counter), 8) agent promjena (engl. Change Agent), 9) „partibrejker“ (engl. Wet Blanket), 10) inovator (engl. Innovator), 11) arhitekt (engl. Architect) i 12) dvorska luda (engl. Court Jester). Gleich i Lauber (2018) također navode da se u praksi stvaraju različite uloge od kojih se najviše ističu viđenja kontrolera kao analitičara tj. specijalista informacija, kontrolera, poslovnog partnera i agenta promjena. Prema CGMA (2014) kontroleri imaju četiri potencijalne uloge - podatkovni znanstvenik, podatkovni upravitelj (engl. Data manager), podatkovni prvak (engl. Data champion) i poslovni partner. Langmann (2019) pak navodi ulogu kontrolinga kao pružatelja ili stručnjaka za usluge (engl. service provider/service expert) u smislu planiranja, izvještavanja, izrade kalkulacija i upravljanja troškovima. Odnosno, ističe ulogu kontrolera kao poslovnog partnera, vodiča/inovatora (engl. Pathfinder/Innovator) i funkcionalnog upravitelja (engl. Governance/Functional Leader) (Langmann, 2019). Fadhilah *et al.*, (2015) predstavljaju kontroling kao pružatelja informacija i pružatelja usluga. Stefan Schnell, voditelj korporativnog kontrolinga u njemačkoj kemijskoj kompaniji BASF u sklopu strategije “Controlling 2025“, definirao je četiri osnovne uloge kontrolera (Schäffer, 2017): poslovni partner (engl. Business partner), čuvar (engl. Guardian), stručnjak za usluge (engl. Service expert) i vodič (engl. Pathfinder). Schäffer i Brückner (2019) su u istraživanju koje su proveli na uzorku od 448 kontrolera potvrdili da su uloge poslovnog partnera, stručnjaka za usluge, čuvara te funkcionalnog upravitelja one koje Nijemci vide kao najznačajnije. Prema Schacht (2020) funkcija kontrolinga u budućnosti ogleda se u ulozi poslovnog partnera za proaktivnu podršku i donošenje odluka i pružatelja usluga digitalnog upravljanja. Analizirajući druge autore, Wolf i Heidlmayer (2019) navode sljedećih pet uloga kontrolera: podatkovni znanstvenik, digitalni kontroler (engl. Digital

Controller), poslovni analitičar (engl. Business Analyst), glavni direktor za digitalne učinke (engl. Chief Digital Performance Officer) i poslovni partner 2.0. Oesterreich *et al.* (2019) pak naglašava da će kontroleri umjesto čistih pružatelja informacija morati postati aktivni poslovni partneri, analitičari i podatkovni znanstvenici.

Većina naziva razvila se ponajprije zbog povećane uloge kontrolinga unutar organizacija uslijed posljedica turbulentnosti okruženja, rizika koje ono nosi i prije svega pojave digitalizacije. Tako, na primjer, pod agentom promjena podrazumijeva se da kontroling pokreće promjene procesa, upotrebu novih tehnologija i razvoj novih poslovnih modela. Slično, vodič tj. inovator predstavlja pokretača promjena i zadužen je za uvođenje novih analitičkih tehnologija u kontroling. Točnije, on je taj koji je zadužen za buduće trendove, digitalizaciju i teme poslovne analitike. Dvorsku ludu opisuje činjenica da je kontroler jedina osoba u poduzeću koja može izraziti 'bolnu' istinu bez straha od negativnih reperkusija. Čuvar pazi na ostvarenje postavljeni financijskih ciljeva i prati prilike i rizike. Stručnjak usluga osigurava uvođenje, koordinaciju i konstantno poboljšanje procesa kontrolinga. Uloga poslovnog partnera ogleda se u konstantom kontaktu s menadžmentom u svrhu donošenja poslovnih odluka, a poslovni partner 2.0 uz to podrazumijeva i upotrebu i konstantno usvajanje alata koje pruža digitalizacija u svrhu informacijske i upravljačke uloge kontrolinga (Schäffer, 2017; Langmann, 2019; Schäffer i Brückner, 2019; Wolf i Heidlmayer, 2019; Labaš i Rajsman, 2020).

Sukladno svemu navedenom, može se uvidjeti da je u brojnim nazivima koji su nastali tijekom godina, najizraženija upravo uloga kontrolera kao poslovnog partnera, a koja se i u istraživanju Schäffer i Brückner (2019) potvrdila kao najznačajnija (56% značajnosti) i koju PwC (2017) svrstava u buduću proaktivnu ulogu stvaranja vrijednosti koja kontroleru osigurava mjesto „za stolom donošenja odluka". Odnosno, u svojem istraživanju dokazali su da su najvažnije karakteristike poslovnog partnera upravo one koje određuju i kontrolera budućnosti - analitičke vještine, vještine komunikacije i odnosa, znanje o poduzeću i vanjskom okruženju te vještine savjetovanja, planiranja, budžetiranja i predviđanja (PwC, 2017).

Slika 4: Odnos kontrolera i menadžera kao poslovnih partnera



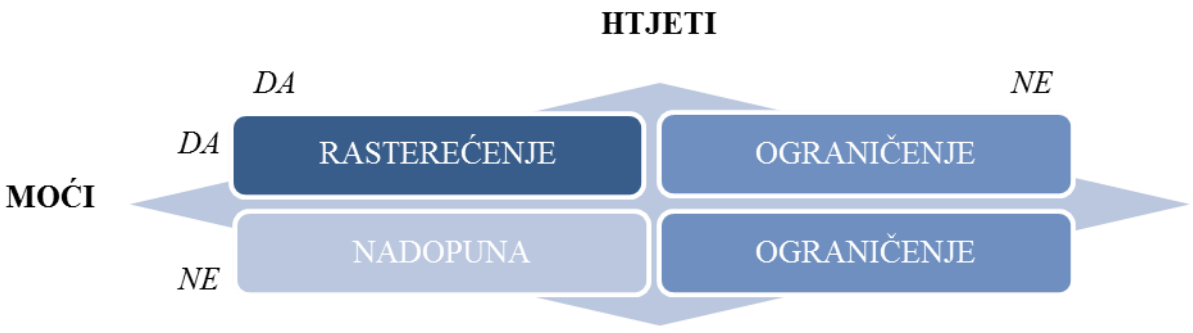
Izvor: izrada autora prema IGC (2013), Schäffer i Weber (n.d. u Vitezić i Lebefromm, 2019) i Vitezić (2020)

Iako se uloge kontrolera i menadžera isprepliću, područja odgovornosti oduvijek su bila razgraničena. Dok je menadžer prvenstveno odgovoran za odlučivanje i ostvarenje uspjeha poduzeća, kontroler je odgovaran za transparentnost tog rezultata. Kontroling ima za zadatak da analizira, ocjenjuje, informira i savjetuje, a menadžment da procjenjuje, provodi mjere, motivira i odlučuje. Pri tome, kontroler mora biti kompetentna, nepristrana i proaktivna osoba suodgovorna u procesu odlučivanja, koja informira, kvantificira, analizira i propituje rezultate. Menadžeri su oni koji postavljaju ciljeve, donose odluke i posljedično usmjeravaju budućnost organizacije. Kontroling s druge strane, pruža informacije o budućnosti i kao savjetodavna funkcija pomaže menadžerima u postizanju najboljih rezultata. Najjednostavnije rečeno, kontroling je proces koji je nastao kao rezultat usklađenih zajedničkih napora menadžmenta i kontrolera i kao takav jedino može opstati tj. razviti se uz međusobno uvažavanje te potpuno ostvarenje uloge kontrolinga kao poslovnog partnera.

Kontroler kao poslovni partner prvenstveno je usmjeren na menadžment i poslovno odlučivanje i time postaje više od samog opskrbljivača informacija. Njegova prava uloga ne završava s izradom izvještava već započinje. Kako navode Vitezić i Lebefromm (2019, str. 18): „Odnos menadžera i kontrolera se promijenio u digitalnoj eri. U prošlosti kontroleri su

bili 'službenici za prikupljanje podatka', a sada su 'glavni savjetnici za upravljanje'". Dakle, na kontroleru je da se više ne zadržava na prošlim podacima već da se usmjerava na budućnost, uzročno-posljedične odnose, indikatore ranog upozorenja, analize rizika i otkrivanje posljedica donesenih odluka (Nidžara Osmanagić Bedenik, 2018). Od njega se očekuje da kroz integraciju financijskih i nefinancijskih informacija bude uključen u operativno i strateško odlučivanje (Byrne i Pierce, 2007), da proaktivno sudjeluje u pokretanju i provođenju organizacijskih promjena (Burns *et al.*, 2014) i da pri tome bude sposoban stvarati (novu) dodanu vrijednost (Järvenpää, 2007). Stoga se naglasak stavlja na strateško razmišljanje, gledanje u budućnost i suradničku ulogu (Byrne i Pierce, 2007). Odnosno, kako navode Vareschi&Partners (n.d.), kontroleri koji žele biti ili postati poslovni partneri moraju steći kredibilitet i povjerenje od „(internih) kupaca" kroz poslovnu stručnost (znati o čemu se govori, znati prenijeti informacije) i prisutnost na poslu (biti na licu mjesta kada nastanu događaji i kada se donose odluke) te dijeljenje odgovornosti za ostvarene rezultate („biti u istom čamcu"). Međutim sve to je moguće jedino uz suradnju kontrolera i menadžera. Osmanagić Bedenik (2018) navodi da je menadžment kupac kontrolinga a time ujedno i najveći poticaj, ali i ograničenje njegova razvoja. Upravo zato, uspjeh kontrolinga i njegov utjecaj na stvaranje vrijednosti ne može se mjeriti samo kroz vještine, znanje i želju uključenosti samog kontrolera već i obilježja i očekivanja menadžmenta kao sparing partnera. Prema Weberu (2005, u Osmanagić Bedenik, 2018) literatura i praksa poznaju tri osnova oblika odnosa i suradnje menadžmenta i kontrolinga - ograničenje, rasterećenje i nadopuna.

Slika 5: Ovisnost kontrolinga o obilježjima menadžmenta



Izvor: izrada autora prema Osmanagić Bedenik (2018)

Ograničenje odnosa kontrolera i menadžera nastaje kada menadžer neće i ne može prihvatiti kontrolera kao stručnu pomoć. To se događa kada menadžment slijedi vlastite ciljeve na štetu ciljeva organizacije. Pri tome, kontroling služi kao funkcija kontrole i ne ispunjava niti svoju

prvotnu ulogu opskrbljivača informacija. Stanje nadopune nastaje kada menadžment hoće, ali ne može delegirati zadatke kontroleru. To se događa kada menadžment ne poznaje ili ne želi prepoznati ulogu, mogućnosti i značaj kontrolinga. Odnosno, kada je menadžment npr. druge stručne spreme i ne razumije ekonomsku struku i profesiju kontrolinga ili kada mu se suradnja s kontrolingom nameće s više instance iako ju on samovoljno ne prihvaća. U toj situaciji kontroler mora ulagati velike napore u dokazivanje koristi i svrhe kontrolinga te izgradnju povjerenja. Jedini pravi odnos je odnos rasterećenja. Samo se u tom odnosu mogu ostvariti sve koristi obje strane te se kontroler može nazvati poslovnim partnerom menadžmenta. Stanje rasterećenja nastaje kada menadžment hoće i može surađivati s kontrolerom (Nidžara Osmanagić Bedenik, 2018) i to bi trebalo biti jedino stanje koje postoji unutar poduzeća koje je implementiralo kontroling.

Da je menadžment istodobno najveći poticaj, ali i najveća barijera za razvoj kontrolinga u Republici Hrvatskoj, potvrdilo je istraživanje Osmanagić Bedenik (2015). Međutim, isto istraživanje dokazalo je i sve veći porast važnosti kontrolinga i njegovo prihvaćanje od strane menadžmenta. Da razina odnosa kontrolera i menadžera u Republici hrvatskoj nije na zadovoljavajućoj razini dokazuje i istraživanje koje su proveli Meter i Šarčević (2018). Naime, rezultati istraživanja ukazuju da je razina izvrsnosti poslovnog partnerstva i procesa odlučivanja ispodprosječna (ispod 4) te da bi se u budućnosti veći naglasak prvenstveno trebao staviti na internu komunikaciju između menadžmenta i kontrolinga te njegovu uključenost u poslovno odlučivanje. Međutim, iako je ocjena ispodprosječna, prema rezultatima istraživanja kontroling svejedno najveću uključenost ima u procesu operativnog planiranja, budžetiranja i prognoziranja te menadžerskog izvještavanja. Osim toga, najnovije istraživanje provedeno od strane Labaš i Rajsman (2020) potvrdilo je porast značaja uloge internog konzultanta i sparing partnera, osobito u uspješnim srednjim i velikim privatnim poduzećima. Wolf *et al.* (2015) dokazali su da uloga kontrolera kao poslovnog partnera ovisi o dva glavna faktora - očekivanju menadžmenta i osobnoj volji kontrolera. Na menadžerima je da uvaže kontroling kao stručnu podršku, ali i na kontrolerima je da tu ulogu prigrle i da imaju želju postati desna ruka menadžmentu. Jedino se suradnjom mogu ostaviti koristi za kontrolera i za menadžera, a posljedično i za cijelu organizaciju.

Prema Labaš i Rajsman (2020) šira definicija poslovnog partnera obuhvaća suradnju kontrolera s drugim poslovnim funkcijama. Sa stajališta literature i prakse, u budućnosti ta bi suradnja svakako trebala obuhvatiti najnoviju funkciju podatkovnog znanstvenika. Iako

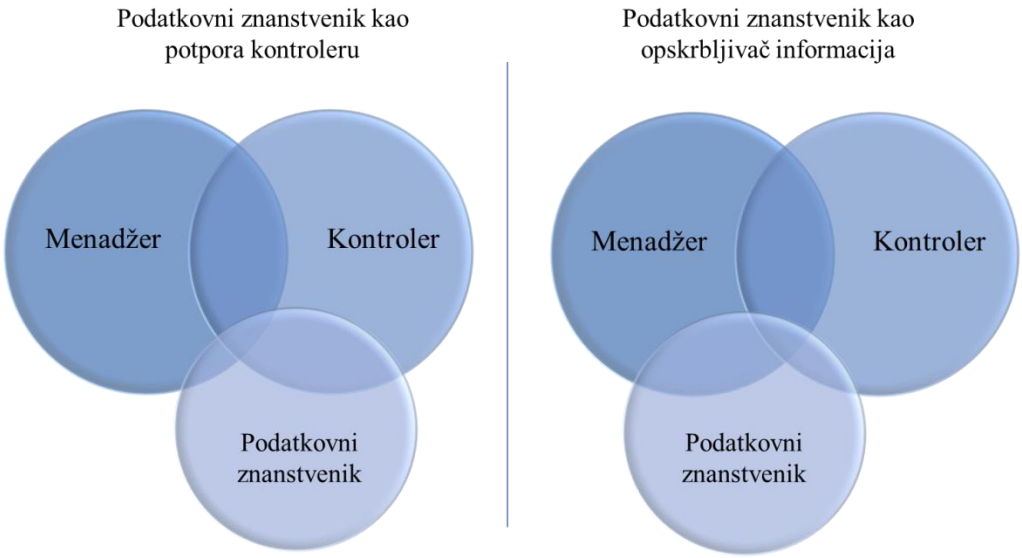
postaje rasprave o mogućoj budućoj ulozi kontrolera kao podatkovnog znanstvenika, brojni autori su se složili, a i zadnje istraživanje provedeno od strane Schäffer i Brückner (2019), potvrdilo je da uloga kontrolera kao podatkovnog znanstvenika u budućnosti ima najmanji značaj. Samo 5% tj. 3% ispitanika smatralo je da kontroleri moraju prigrliti ulogu podatkovnog znanstvenika unutar srednjih tj. velikih poduzeća. Prema Davenport (2014) klasični podatkovni znanstvenik ima pet ključnih profila i pripadajuće osobine:

- Haker
    - sposobnost kodiranja
    - razumijevanje arhitekture velikih podataka
- Znanstvenik
    - donošenje odluka na temelju dokaza
    - improvizacija
    - nestrpljivost i usmjerenost na rad
- Pouzdani savjetnik
    - snažne komunikacijske vještine i vještine odnosa
    - sposobnost oblikovanja odluka i razumijevanja procesa odlučivanja
- Kvantitativni analitičar
    - statistička analiza
    - vizualna analitika
    - strojno učenje
    - analiza nestrukturiranih podataka (kao npr. tekst, video ili slike)
- Poslovni stručnjak
    - razumjeti funkcioniranje poslovanja i način stvaranja novca
    - imati dobar osjećaj za područje primjene poslovne analitike i velikih podatka

Da postoje preklapanja u području rada kontrolera i podatkovnog znanstvenika pri pružanju informacija nadređenim, ali i da kontroler ne mora postati podatkovni znanstvenik već prihvatiti suradnju u svrhu donošenja efikasnih poslovnih odluka, potvrđuje istraživanje provedeno od strane Mayr *et al.* (2020) temeljem objavljenih oglasa za posao. U istraživanju su došli do saznanja da iako se uloge tih dviju funkcija preklapaju, osobito u sposobnostima analitičkog razmišljanja, timskog rada te komunikacijskim i prezentacijskim vještinama, pretežito su to osobine koje se i dalje traže od kontrolera. Tako se npr. "vještine komunikacije i prezentacije" pojavljuju u 46% svih oglasa za kontrolere, a samo u 28% oglasa za podatkovnog znanstvenika. Osim toga, jasne razlike prikazuju kroz usporedbu područja

djelovanja. Kod podatkovnog znanstvenika su zadaci više tehničke orijentacije dok su kod kontrolera ekonomskog usmjerenja. Iako postoje preklapanja u područjima odgovornosti 'analize podataka' i 'kontakt osobe za menadžment', bitno je naglasiti da se uloga poslovnog partnera javlja jedino kod zadataka kontrolera.

Slika 6: Budućnost odnosa menadžera, kontrolera i podatkovnog znanstvenika



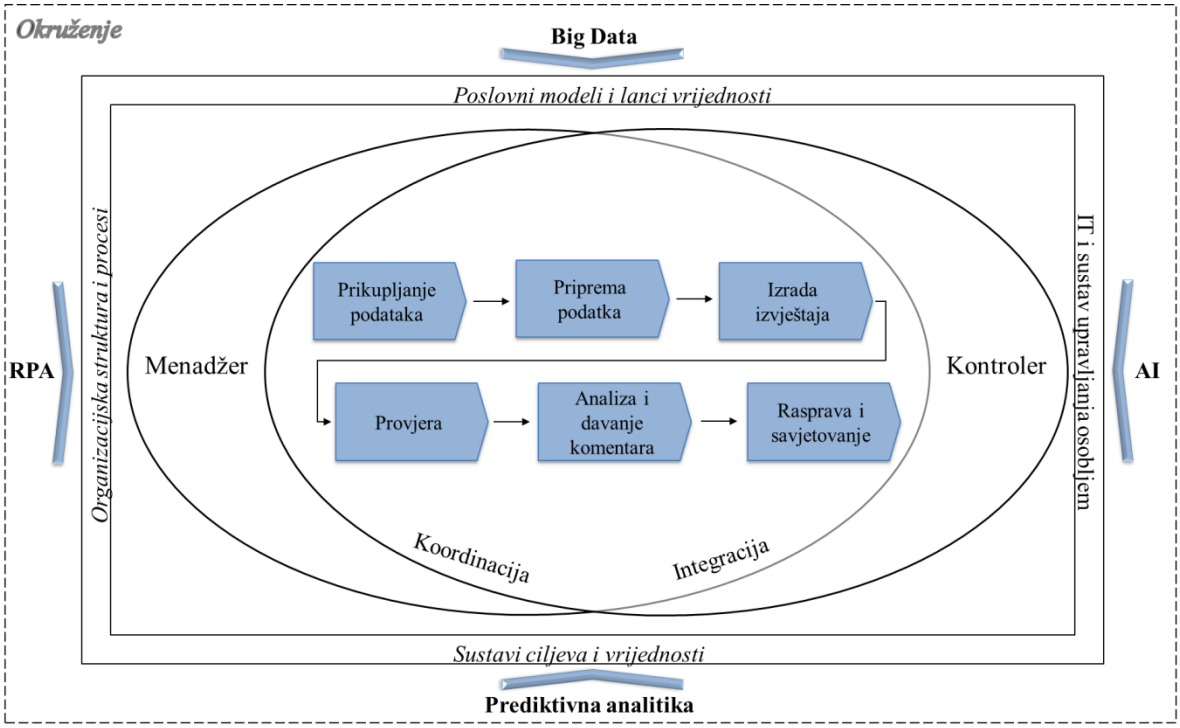
Izvor: izrada autora prema Mayr *et al.* (2020)

Sukladno istraženom, Mayr *et al.* (2020) predlažu kontrolera kao jedinog pravog partnera menadžmentu i podatkovnog znanstvenika kao njegovu potpornu funkciju koja u kontekstu pružanja informacija služi kao tehnička potpora (lijevi dio slike 6). U slučaju negativnog scenarija, podatkovni znanstvenik preuzima veću ulogu opskrbljivača informacija i pri tome zamjenjuje kontrolera do izvjesne granice (desni dio slike 6). Naime, unutar nove suradnje kontrolera, menadžera i podatkovnog znanstvenika i dalje je odgovornost kontrolera da spriječi pogrešno tumačenje podataka i osigura pronalazak ključnih i relevantnih podataka za odlučivanje (Vitezić i Lebefromm, 2019). Pri tome, kontroleri trebaju imati na umu da je za prvotni, očekivani, scenariji potrebna i aktivna promjena njihovih vještina i znanja usmjerenih na razumijevanje velikih podataka te alata poslovne inteligencije i prediktivne analitike.

Sukladno ulozi kontrolera kao poslovnog partnera u literaturi se naglašava sve veća značajnost određenih funkcija kontrolinga i utjecaj digitalizacije na njihovo izvršenje. Naime, ako se uzme u obzir da poslovno partnerstvo prije svega podrazumijeva analizu podataka te savjetovanje menadžmenta kroz izradu i prezentaciju izvještaja, onda je i za očekivati da će

određene funkcije koje su direktno vezane za tu ulogu u budućnosti dobiti na većem značaju, ali i da će kontroling u tom području morati implementirati nova sredstva rada. Sukladno onome što navodi Vitezić (2020) to su funkcije informiranja i savjetovanja. Nobach (2019) navodi da su u digitalnom dobu centralni zadaci kontrolinga usmjereni na upravljački koncept, planiranje, predviđanje i izvještavanje. Langmann (2019) pak ističe da su najveći utjecaji digitalizacije u području izvještavanja kao procesa izdvajanja i agregiranja podataka, izvještavanja, provjere ispravnosti i vjerodostojnosti, analize odstupanja i komentiranja te savjetovanja i rasprave o poduzimanju mjera.

Slika 7: Utjecaj digitalizacije na centralnu funkciju kontrolinga



Izvor: izrada autora prema Nobach (2019) i Langmann (2019)

Iako digitalizacija ima utjecaj na cjelokupni proces kontrolinga, ipak je taj utjecaj najveći kod izvješćivanja kao središnjeg i može se reći najvažnije dijela kontrolinga. To podrazumijeva da ta funkcija može i mora iskoristiti prednosti i prilike koje joj na raspolaganje stavlja digitalizacija. Naime, u većini slučajeva tradicionalni postupak izvještavanja podrazumijeva većinsku uključenost kontrolinga u prvim fazama procesa izvještavanja ne uključujući komentiranje, raspravu i savjetovanje. U današnje doba, razlozi za to su obično nedostatak standardizacije ili neadekvatna automatizacija pojedinih dijelova procesa. Pri tome, kontroleri nemaju vremena usmjeriti se na dubinsku analizu i komentiranje izvještaja te izradu mjera za unaprjeđenje, a posljedično dolazi i do nezadovoljnih korisnika izvještaja (Langmann, 2019).

Stoga, kontroleri u obilju informacija moraju prigrliti i adekvatno implementirati alate koje im nudi era digitalizacije. Jedino tako će uspjeti ostvariti osnovne zadaće u ulozi poslovnog partnera, a to podrazumijeva izradu kvalitetnih izvještaja za donošenje efikasnih i efektivnih poslovnih odluka te ostvarenje dodane vrijednosti za poduzeće. Sve to ujedno podrazumijeva i da kontroleri moraju proširiti i usavršiti svoje vještine i znanja.

Dakle, dokazano je da kontroleri neće morati postati podatkovni znanstvenici. Međutim, treba imati na umu da se današnji poslovi mijenjaju brže nego ikada tj. da se neprekidno stvaraju novi. Deloitte Insights (2019) ističe da većina velikih kompanija očekuje znatno povećanje digitalne tehnologije (AI, robotike, kognitivne tehnologije. itd) u bliskoj budućnosti i sukladno tome promjenu procesa, ali i redizajn i stvaranje novih poslovnih mjesta. Navode pojavu tzv. „superjobs“ tj. poslova koji kombiniraju rad i odgovornost iz više tradicionalnih poslova koristeći se pri tome tehnologijom ali i naprednim vještinama područja djelatnosti te ljudskim vještinama komunikacije, rješavanja problema, interpretacije i razvoja (Deloitte Insights, 2019). Sukladno, uloga kontrolera mora se dodatno ojačati kroz holističko analitičko-prospektivno razmišljanje koje će pridonijeti učinkovitijem donošenju odluka (Vitezić *et al.*, 2019). Kontroleri moraju konstantno ulagati u nova znanja i vještine, postati prilagodljivi ljudski kapital te se usmjeriti na usvajanje i razvoj „mekih“ vještina. U tom smjeru potrebno je konstantno istraživati trenutne i buduće kompetencije potrebne za izvršavanje upravljačke uloge kontrolinga koja se ogleda u konzistentnom pružanju relevantnih, točnih i pravovremenih informacija menadžmentu.

3. TEORIJSKE I EMPIRIJSKE PRETPOSTAVKE RAZVOJA KONCEPTUALNOG MODELA UTJECAJA KVALITETE KONTROLINGA NA POSLOVNO ODLUČIVANJE

U posljednje vrijeme teorija i praksa kontrolinga sve se više razvija, međutim još uvijek nedovoljno, osobito u području njegove uloge u donošenju poslovnih odluka (Nielsen *et al.*, 2015). Sukladno studiji Harvard Business Review Analytics Services (2014, u Butterfield, 2016) 42% globalnih poslovnih lidera nije samouvjereno u odluke koje donose, a kao osnovne razloge navode nedostatak informacija i jednostavnost pristupa istima. U skladu sa zadacima kontrolinga, Hilton i Platt (2014) navode pet osnovnih ciljeva kroz koje kontroling pridodaje vrijednosti poduzeću, a od kojih upravo pružanje informacija za donošenje odluka i planiranje stavljaju na prvo mjesto. Odnosno, kako navodi Herbert Simon, dobitnik Nobelove nagrade za ekonomiju, menadžeri od kontrolera očekuju tri stvari: da odrede da li je nešto dobro ili loše za poduzeće, da odrede probleme koji su prioritetni i da im u konačnici pomažu u rješavanju tih problema (u Breuer *et al.*, 2013).

Učinkovitost donošenja odluka pod utjecajem je brojnih čimbenika. Fisher *et al.* (2003) među njih ubrajaju raspoloživo vrijeme prije donošenja odluke, iskustvo donositelja odluka i kvalitetu podataka potrebnih za donošenje odluke. Bulog, (2016) tvrdi da demografske karakteristike utječu na pristup donošenja odluka, dok u svoj okvir uključuje i okolišne i psihološke čimbenike te menadžerski informacijski sustav. Prema Sathe (1982) kontrolerova razina involviranosti u poslovno odlučivanje ovisi o tri osnovne kategorije:

1. karakteristikama kontrolera (motiviranost, osobnost i međuljudski odnosi s menadžmentom),
2. karakteristikama menadžera (očekivanja, orijentiranost i radna filozofija) i
3. karakteristikama poduzeća i okruženja.

Sukladno tome, predlaže tri prateće teorije: psihološku teoriju (engl. psychological theory) za karakteristike kontrolera, teoriju uloga (engl. role theory) za odnos između menadžerskih zahtjeva i očekivanja te kontrolerove uloge pružanja informacijama, i teoriju kontingencije (engl. contingency theory) za treću kategoriju karakteristika tj. poduzeća i okruženja. Kontrolerovu involviranost definira kao stupanj do kojeg kontroleri zapravo obavljaju različite uloge kao sudionici operativnog i strateškog poslovnog odlučivanja, to jest, ulogu prezentacije informacija i analiza, predlaganja akcijskih planova, kao i spremnost na izazove

koje ti planovi nose (Sathe, 1982). Iako je Sathe navedeni konceptualni okvir postavio još 1982. godine, Rouwelaar *et al.* (2018) naglašavaju oskudnost njegovog daljnjeg istraživanja. Svoje istraživanje zasnovali su upravo na tom okviru tj. istražili su kolika je razina involviranosti kontrolera poslovnih jedinica u poslovnom odlučivanju na operativnoj i strateškoj razini. Pri tome su ispitivali utjecaj organizacijskih karakteristika (decentralizacija i asimetrija informacija), karakteristika kontrolera (kroz tzv. Big Five Model osobnosti) i pojedine kontrolne varijable. Rezultati su pokazali da većina kontrolera smatra da ima utjecaj na operativnoj, ali mali broj na strateškoj razini odlučivanja. Zoni i Merchant (2007) su napravili slično istraživanje na korporativnoj razini sedamnaest velikih talijanskih poduzeća. Rezultati vezani za ukupnu involviranost su doveli od istih zaključaka, jedino što je operacionalizacija istraživanja bila obavljena kroz druge varijable tj. mjeritelje - okolišne promjene, financijska stručnost linijskih menadžera, uspjeh, itd. Roozen i Steens (2006) su pak postavili model mjerenja razine kontrolerove efikasnosti koja je s njihovog gledišta pod utjecajem stvarne razine kontrolerove involviranosti i nezavisnosti, određene očekivanjima i doprinosima kontrolera te međuljudskim faktorima. Wolf *et al.* (2015) istraživali su kako kontrolerovo ponašanje u smislu sudjelovanja u procesu donošenja odluka, mjereno kroz stav (atraktivnost i smisao uključenosti) i subjektivnu normu (da li menadžeri cijene i očekuju kontrolerovu uključenost), utječe na njihov ukupni doprinos i u konačnici internu efikasnost i unaprjeđenje procesa. Pri tome su u obzir uzeli percepciju kontrolera i menadžera. Isti pristup primijenili su u svojem istraživanju Pierce i O'Dea (2003). Glavni cilj njihovog istraživanja bio je upravo dokazati razliku viđenja uloge kontrolinga kao opskrbljivača informacija sa stajališta obje funkcije. Istraživanje je dokazalo postojane tzv. „perception gap", pogodovanog prije svega tehničkom i organizacijskom ispravnošću, funkcijskim razlikama i inherentnom napetošću između istovremenih zahtjeva neovisnosti i uključenosti u proces odlučivanja. Upravo zato, od iznimne je važnosti razmatrati i menadžerske karakteristike kao faktor utjecaja na kvalitetu kontrolerovog outputa. Iako prethodno navedena istraživanja ne uključuju taj dio Satheovog modela, u teoriji kontrolinga općeprihvaćena je činjenica da uspješnost poslovanja, implementacija kontrolinga, kao i razina kontrolerove suradnje s menadžmentom ovisi o stavu i karakteristikama menadžmenta (Meter i Šarčević, 2018; Očko i Švigir, 2009; Osmanagić Bedenik, 1998; Vitezić, 2016).

Weißenberger i Angelkort (2011) tj. Weißenberger *et al.* (2012) su u svojem empirijskom istraživanju analizirali utjecaj razine integriranosti menadžerskog informacijskog sustava (engl. Management Accountign System – MAS) na efektivnost kontrolerovog doprinosa

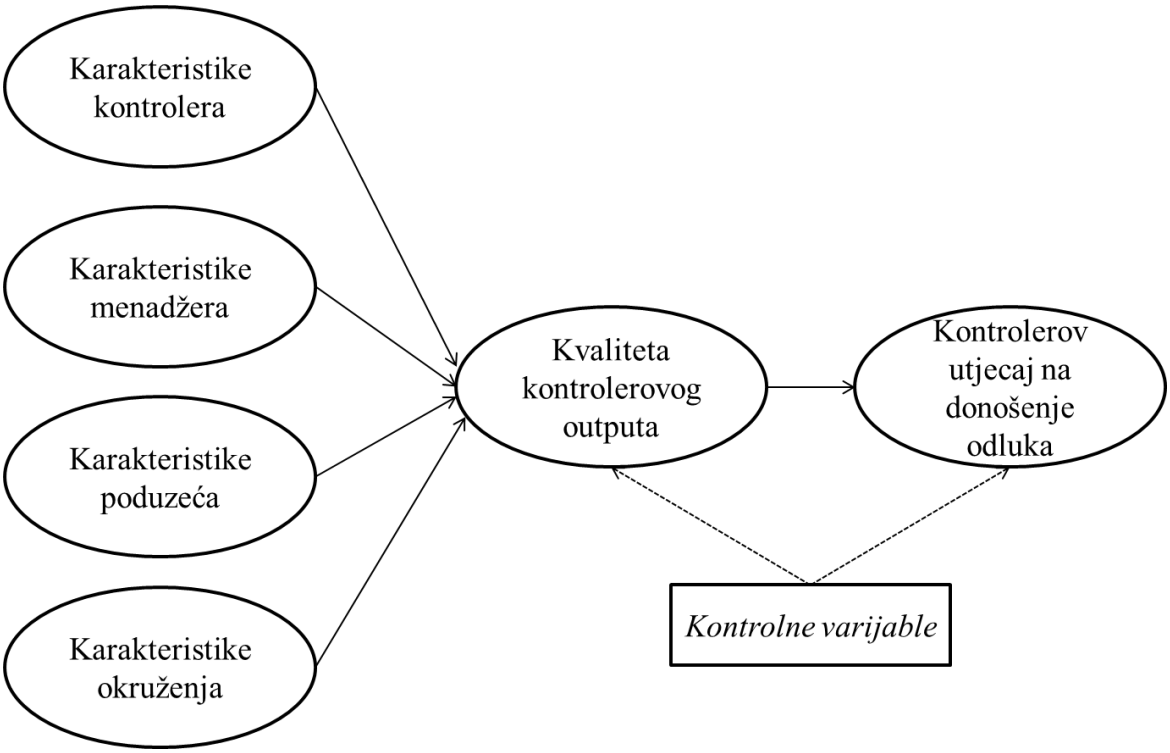
donošenju odluka, kroz uključivanje percepcije kontrolera i menadžera. Ukupnu razinu efektivnosti mjerili su kroz utjecaj kvalitete kontrolerovog outputa na razinu njegovog utjecaja na donošenje odluka, mjerenu kroz stvarnu upotrebu kontrolerovog outputa od strane menadžmenta. Pri tome, temelj su našli u teoriji racionalnog izbora (engl. rational choice theory) polazeći od činjenice da će povećanje kvalitete outputa, gledano iz percepcije menadžera, pozitivno utjecati na korištenje istih u procesu donošenja odluka. Fadhilah *et al.* (2015) su kroz malo drugačiji pristup, temeljen na „The DeLone and McLean Information System Success Model", potvrdili da kvaliteta informacija i kvaliteta usluge koju pruža kontroler imaju utjecaj na zadovoljstvo korisnika tj. menadžera i u konačnici donošenje odluka. Gullkvist (2013) je pak potvrdila utjecaj BI-a na kvalitetu podataka i zadatke kontrolinga, a Wieder i Ossimitz (2015) povezanost kvalitete informacija i donošenja odluka kroz indirektnu povezanost upravljanja BI-a rješenjima i odlučivanja. Nadalje, pojedina istraživanja dokazuju i da godine radnog iskustva (Rouwelaar *et al.*, 2018) te postojanje revizije (Gullkvist, 2013) imaju utjecaj na ostvarenje kontrolerove uloge unutar poduzeća.

Sve istaknuto podržava Satheovu (1983) teoriju koja navodi da je kvaliteta informacija i analiza koje kontroler stavlja na raspolaganje menadžmentu u svrhu upravljanja i odlučivanja, odgovarajući kriteriji za mjerenje kontrolerove efektivnosti. Uzimajući u obzir navedeno i tretirajući menadžerski informacijski sustav (čiji utjecaj na efektivnost kontrolinga su Weißenberger i Angelkort indirektno potvrdili) kao dio organizacijske karakteristike i kvalitetu pružanja usluga kao karakteristiku kontrolera (čiji utjecaj na neto koristi menadžera su potvrdili Fadhilah *et al.* u 2015.), može se reći da oni ali i druge čimbenici utječu na kvalitetu kontrolerovog outputa (informacija, analiza, izvještaja, prijedloga, zaključaka, itd.) i posljedično na donošenje poslovnih odluka. Osnovna zadaća kontrolera kao sunositelja odgovornosti jest pružiti menadžerima kvalitetne outpute tj. analize i izvještaje za donošenje pravovremenih i točnih poslovnih odluka. Dok se efikasnost kontrolera ogleda u pretvaranju raznih podataka i informacija u kvalitetne analize i izvještaje, efektivnost proizlazi iz konačnog utjecaja tih outputa na donošenje menadžerskih odluka. Pri tome, konačni efekt utjecaja kontrolerovih outputa na donošenje poslovnih odluka ovisi prije svega o pravovremenosti, točnosti, ažurnosti, značajnosti i preglednosti (engl. format), ali i o drugim utjecajno povezujućim karakteristikama koje je potrebno poznavati. Stoga se u ovom radu istražuje jačina povezanosti utjecajnih karakteristika na kvalitetu kontrolerovog outputa te donošenje poslovnih odluka. Odnosno, radom se želi potvrditi da, prije svega osobne karakteristike kontrolera, ali i karakteristike poduzeća i menadžmenta te okruženja koje

podržava digitalizaciju, imaju značajan utjecaj na učinke kontrolerovih aktivnosti i doprinos u donošenju poslovnih odluka. Pri tome, se polazi od pretpostavke da podaci i informacije koje kontroleri koriste kao ulazne veličine tj. inpute u analizama, zadovoljavaju sve kriterije kvalitete.

U svrhu empirijskog istraživanja razrađen je novi konceptualni model temeljem predočene literature i modela koje su postavili Sathe (1982) te Weißenberger i Angelkort (2011) tj. Weißenberger *et al.* (2012).

Slika 8: Temeljni konceptualni model istraživanja



Izvor: izrada autor

Iako temeljni konceptualni model uključuje prethodno postavljene utjecajne čimbenike kontrolerove uključenosti u poslovno odlučivanje, u današnjem novom, digitalnom i promjenjivom okruženju, postavljaju se zahtjevi za razradom potrebnih menadžerskih i prije svega kontrolerskih obilježja, ali i čimbenika okruženja i poduzeća koji utječu na kvalitetu outputa i poslovno odlučivanje. Stoga se u nastavku ovog poglavlja, pored već navedenih, prikazuje pregled dosadašnjih istraživanja koji potvrđuju značaj postavljenog konceptualnog model. Odnosno prikazuje se pregled istraživanja temeljem kojih su određeni pojedini elementi (konstrukti) četiri postavljena utjecajna obilježja kvalitete kontrolerovog outputa, same kvalitete outputa i utjecaja na odlučivanje, kao i pojedinih kontroling varijabli, a koje će

omogućiti empirijsko dokazivanje postavljenog modela i potvrdu značajnosti pojedinačnih utjecajnih karakteristika poslovnog odlučivanja. Pregled istraživanja danih u nastavku ujedno predstavljaju pregled i argumentaciju postavljenih hipoteza ove doktorske disertacije.

3.1. Kvaliteta kontrolerovog outputa i njegov utjecaje na donošenje odluka

Sukladno osnovnoj ulozi kontrolinga kao profesionalne funkcije koja za zadatak ima pružiti donosiocima odluka informacije koje će im pomoći u točnom i pravovremenom odlučivanju, a osobito u današnjoj digitalnoj i podatkovno brzorastućoj eri, neizmjerno je potrebna njegova uključenost u upravljačkoj strukturi. Točnije, sve je veća potreba za njegovom ulogom poslovnog partnera u čiju svrhu ispunjena kontroleri trebaju menadžmentu konzistentno pružati relevantne, točne i pravovremene outpute tj. analize i izvještaje. Jedino kroz pružanje kvalitetnih outputa kontroleri mogu osigurati maksimizacija svoje uloge i adekvatno utjecati na povećanje efikasnosti i efektivnosti poslovanja.

Kako je već navedeno, Weißenberger i Angelkort (2011) su jedni od nekolicine znanstvenika koji su dokazali da kvaliteta kontrolerovih outputa ima utjecaj na donošenje poslovnih odluka. Točnije, istražili su utjecaj razine integriranosti menadžerskog informacijskog sustava na efektivnost kontrolerovog doprinosa donošenju odluka, kroz uključivanje percepcije kontrolera i menadžera. Ukupnu razinu efektivnosti mjerili su kroz utjecaj kvalitete kontrolerovog outputa na razinu njegovog utjecaja na donošenje odluke, mjerenu kroz stvarnu upotrebu kontrolerovog outputa od strane menadžmenta. Iako direktni pozitivan utjecaj informacijskog sustava na efektivnost kontrolinga nije potvrđen, rezultati istraživanja dokazali su postojanje pozitivnog utjecaja kvalitete outputa na donošenje odluka. Pri tome, kvalitetu outputa odjela kontrolinga mjerili su kroz modificirane Bauer (2002) indikatore svrha, pravodobnost i točnost, a kontrolerov utjecaj na donošenje odluka kroz indikatore prvotno postavljenih od Spillecke (2006), koji uključuju prihvaćenost kontrolinga, njegove uloge i značaja u poslovnom odlučivanju. Isti model Weißenberger *et al.* (2012) testirali su iz percepcije samog kontrolera. Rezultati su bili veoma slični, ali ono što je bitno jest da je pozitivni utjecaj outputa na ishod potvrđen u oba modela. Glavni cilj Bauer (2002) istraživanja bio je utvrditi utjecaj kontrolera na menadžment kroz razinu efekta pojedinih unutarnjih i vanjskih čimbenika poduzeća. Rezultati su potvrdili pozitivan i signifikantna utjecaj stupnja delegiranja poslova, prava prigovora i prije svega kvalitete kontrolerovog rezultata tj. outputa. Osim toga, potvrđena je i kauzalnu veza utjecaja potencijalne kvalitete

kontrolinga, kvalitete procesa unutar kontrolinga i kvalitete kontrolerovih rezultata, kao i utjecaja kvalitete outputa na uspješnost poduzeća. Pri tome, kao kriterije mjerenja kvalitete kontrolerovog outputa koristili su ocjenu: 1) relevantnosti informacija 2) ispravnosti i točnosti podataka, 3) aktualnosti i vrijednosti informacija, 4) objektivnosti informacija, i 5) razumljivosti informacija i sljedivosti njihovog stvaranja. Spillecke (2006) je u svojem istraživanju potvrdio pozitivan utjecaj orijentiranosti kontrolinga prema „internom kupcu“ tj. menadžmentu, na kvalitetu kontrolerovog učinka te posljedično na kvalitetu upravljačkih procesa i uspjeh poduzeća. Točnije, potvrdio je da kvaliteta kontrolerovog rada, preko čimbenika zadovoljstva i povjerenja menadžmenta, ima pozitivan utjecaj na uključenost kontrolinga u procesu odlučivanja te uspjeh poduzeća.

Nadalje, Matejka (2002) je potvrdila da autonomija kontrolera, veličina poduzeća i nestabilnost okruženja imaju pozitivan utjecaj na razinu kontrolerove uključenosti u poslovnom odlučivanju. Iako izuzetno slabu, dokazuje i postojanje veze između autonomije kontrolera i menadžerske ocjene zadovoljstva pruženim uslugama od strane kontrolinga, mjerene kroz dimenzije koje su 1954. Simon *et al.* postavili kao glavne zadaće kontrolinga: pomaganje menadžmentu kroz analizu i interpretaciju informacija, pravovremenost izvještavanja i pružanje informacija za rješavanje poslovnih problema. Zoni i Merchant (2007) su dokazali da kontrolerova uključenost u donošenje odluka ima utjecaj na uspješnost poslovanja poduzeća. Po uzoru na Sathe (1982), u istraživanju su se usmjerili na razinu kontrolerove operativne i strateške uključenosti u vidu prezentiranja informacija i analiza, davanja preporuka i preispitivanja planova i akcija. Nadalje, kako bi analizirali pokretače povjerenja između kontrolera i menadžera, Nitzl i Hirsch (2016) koristili su dvije varijable koje smatraju organizacijskim faktorima utjecaja, a jedna od njih je tzv. organizacijska snaga koja podrazumijeva da: 1) kontroling igra važnu ulogu u procesu donošenja odluka i 2) da menadžment prije donošenja važnih odluka uvijek zatraži procjenu od kontrolinga. Pri tome, snagu definiraju kao značaj kontrolinga u donošenju odluka tj. situaciju u kojoj je jedna osoba ovisna o drugoj osobi. Wolf *et al.* (2015) potvrdili su da stav i želja kontrolera za sudjelovanje u poslovnom odlučivanju utječu na njegovu stvarnu uključeno i posljedično na njihov ukupni doprinos te priznavanje kontrolinga kao izvora konkurentske prednosti unutar poduzeća. Schäffer i Steiners (2004) potvrdili su da je korištenje kontrolerovih informacija u odlučivanju pozitivno povezano s načinom donošenja odluka. Odnosno, kontroleri menadžerima kroz dostavljene informacije pomažu u potvrdi pretpostavki te pravilnoj provedbi akcija tj. potiču ih na veću kreativnost, da preusmjere svoja razmišljanja, prošire pogled na rješavanje

problema i da preispituju svoje ideje i odluke. Prema istraživanju Feeney (2007) menadžeri pri tome očekuju da informacije koje im pruža kontroler budu relevantne, pouzdane, točne i pravodobne.

Kvalitetu kontrolerovih izvještaja iz perspektive utjecaja na donošenje odluka istraživala je i Butterfield (2016). Došla je do saznanja da gotovo 80% (od 52 ispitanika) menadžera svoje odluke baziraju na informacijama dobivenih iz izvještaja kontrolera. Odnosno, menadžeri se uglavnom pouzdaju u točnost informacija; smatraju da su informacije ažurne, razumljive i da odražavaju traženo. Međutim, kao najveću manu ističu jasnoću i vizualizacijski prikaz izvještaja. Citirajući Axson (2010, u Butterfield, 2016, str. 2) također ističe značaj uloge kontrolinga kao informacijskog opskrbljivača: „informacije su žila kucavica moderne korporacije. Bez njih se ne mogu donositi odluke, ne mogu se opsluživati kupci niti se ne može povećati zarada". Stoga je važno procjenjivati kvalitetu i sadržaj izvještaja kako bi se osigurala njihova upotrebljivost i važnost u procesu donošenja odluka. Pri tome treba posvetiti pažnju na jasnoću i ujednačenost, njihov sadržaj i relevantnost prikazanih informacija.

Utjecaj kvalitete kontrolerovog outputa na donošenje odluka potvrdili su i Fadhilah *et al.* (2015). Kao temelj svojeg istraživanja koristili su tzv. „The DeLone and McLean Information System Success Model" po kojem se uspješnost informacijskog sustava mjeri kroz utjecaj tri osnovnih dimenzija (kvaliteta informacija, kvaliteta sustava i kvaliteta usluga koje pruža) na zadovoljstvo korisnika i posljedično na njegove neto koristi (npr. donošenje odluka). Model podrazumijeva da će povećano zadovoljstvo korisnika, realizirano kroz tri dimenzije kvalitete, utjecati na povećanje želje za korištenjem sustava i time do uvećanja njegove neto koristi. Pri tome se na dimenziju kvalitete informacija gleda kao na „davatelja informacija", a na kvalitetu usluga kao „davatelja usluga". Navedeni model, Fadhilah *et al.* (2015) su preslikali na ulogu kontrolera kao poslovnog partnera tj. davatelja informacija i davatelja usluga koji utječe na zadovoljstvo menadžmenta kao korisnika i posljedično na donošenje poslovnih odluka tj. menadžerovu neto korist u vidu donošenja boljih odluka, efikasnijeg odlučivanja i učinkovitijeg dnevnog rada. Neto korist, ukazuje na to da menadžer ima koristi od sudjelovanja kontrolinga u procesu odlučivanja. Uvjet za dostizanje neto koristi pri tome predstavlja zadovoljstvo menadžera dobivenim outputima koje će ga motivirati da češće upotrijebi i traži kontrolerovu pomoć. Ukupni model je potvrdio pozitivni utjecaj kontrolerove kvalitete informacija i kvalitete usluga na zadovoljstvo menadžera i donošenje odluka.

Kvalitetu usluge smatraju važnim mostom kontrolera na putu do statusa poslovnog partnera. Pri tome, kvalitetu usluga tj. kvalitetu kontrolera kao davatelja usluga mjere kroz četiri dimenzije kontrolerovih karakteristika postavljenih od Sathe (1983): analitičke vještine, poznavanje poduzeća, komunikacijske i interpersonalne vještine. Kvalitetu informacija mjere kroz četiri dimenzije kvalitete informacija koje, prema Pierce i O'Dea-ove (2003), menadžeri očekuju da su odražene u kontrolerovim izvještajima, a koje su naglašavali i drugi autori u svojim istraživanjima (Byrne i Pierce, 2007; Hall, 2010, u Fadhilah *et al.*, 2015, itd.). To su relevantnost, točnost, cjelovitost i preglednost. Svaku od tih dimenzija Fadhilah *et al.* (2015) mjerili su pomoću mjeritelja razvijenih temeljem Iivari (2005) te Wixom i Todd (2005).

Iivari (2005) i Wixom i Todd (2005) su također potvrdili da kvaliteta sustava i informacija imaju pozitivan utjecaj na zadovoljstvo te radni učinak korisnika tj. sposobnost donošenja dobrih odluka, brže obavljanje posla, povećanje radne učinkovitosti i jednostavnije obavljanje posla. Pri tome Iivari (2005) je kvalitetu informacija definirala kroz šest dimenzija postavljeni od strane Bailey i Pearson (1983, u Iivari, 2005): potpunost, preciznost, točnost, pouzdanost, ažurnost i preglednost. Wixom i Todd (2005) su temeljem dotadašnje literature uključili četiri osnovne karakteristike informacijske kvalitete. To su: cjelovitost, preglednost, točnost i ažurnost. Odnosno, promjena u radnom učinku, kojeg Iivari (2005) naziva individualnim utjecajem, podrazumijeva promjenu menadžerske percepcije značajnosti upotrebe kontrolerovih usluga. Ono što je bitno za istaknuti je da Iivari (2005) i Wixom i Todd (2005) istražuju područje informacijskih znanosti te da se navedene mjere kvalitete informacija većinom koriste u području informacijskih istraživanja. Međutim, obzirom na njihovo značenje mogu biti i primjereni u istraživanju razine kvalitete kontrolerovih outputa. Sličan pristup koristili su Caniëls i Bakens (2012) pri potvrđivanju utjecaja kvalitete projektnih informacijskih sustava (PMIS) na kvalitetu donošenja odluka. Kvalitetu sustava mjerili su kroz sljedećih pet dimenzija: dostupnost, pouzdanost, relevantnost, točnost i sveobuhvatnost; dok su kvalitetu donošenja odluka mjerili kroz indikatore koji podrazumijevaju općenito poboljšanje odlučivanja, smanjenja vremena za donošenje odluka, bolje upravljanje aktivnostima i alokacijom resursa te nadziranje aktivnosti.

Nadalje, zanimljiv pristup mjerenja utjecaja konkurentnosti na uspješnost upravljanja (engl. managerial performance), definiranu kao skup aktivnosti planiranja, istraživanja, ocjenjivanja, nadzora, zapošljavanja, pregovaranja, zastupanja i povećanja ukupne uspješnosti poslovanja, primijenili su Ghasemi *et al.* (2016). Kako bi potvrdili pozitivni utjecaj konkurentnosti na

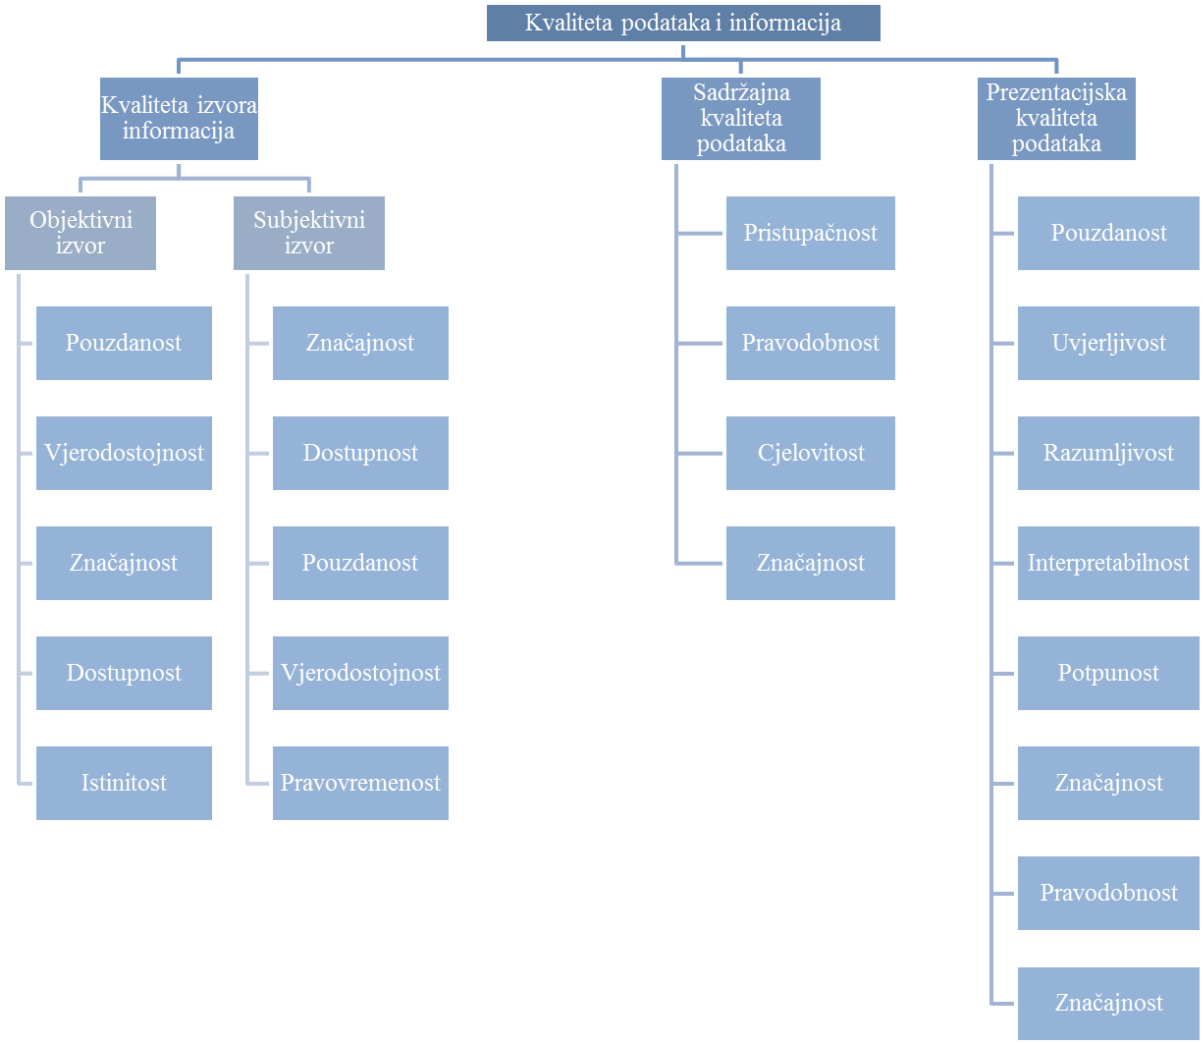
uspješnost upravljanja koristili su tzv. MAS karakteristike – svrha, pravovremenost, integracija i agregacija, prvotno definiranih od strane Chenhall i Morris (1986). MAS karakteristike podrazumijevaju obilježja menadžerskih informacijskih sustava poduzeća. Istraživanjem su potvrdili direktni pozitivni utjecaj konkurentnosti na MAS i MAS-a na uspješnost upravljanja te djelomični indirektni utjecaj konkurentnosti na uspješnost upravljanja kroz medijaciju MAS-a. Sofisticirani MAS sposoban je pružiti ključne informacije menadžerima u donošenju točnih odluka, što dovodi do poboljšanja ukupnog poslovanja. Kontroleri kao glavni korisnici sustava bi pri tome trebali ispitati mogućnosti povećanja kvalitete informacija koje sustav pruža (Ghasemi et al., 2016). Odnosno, kvaliteta kontrolerovih outputa koji zapravo proizlaze iz takvih sustava mogla bi biti mjerena kroz četiri MAS karakteristike. Upravo taj koncept primijenio je Wahdiat *et al.* (2018) pri dokazivanju utjecaja primjene MAS-a na povećanje kvalitete kontrolerovih informacija. Odnosno, u svrhu dokazivanja iste teze Ramadhan (2018) je primijenio navedene MAS karakteristike, izuzev integracije, u kombinaciji sa značajnosti, točnosti i potpunosti. Brojna su druga istraživanja primijenila MAS karakteristike u svrhu dokazivanja utjecaj na uspješnost upravljanja (Agbejule, 2005; Ismail *et al.*, 2020; Pedroso *et al.*, 2020 itd.). Među najnovijim je istraživanje provedeno od strane Pedroso *et al.* (2020). Oni su potvrdili da obuka kontrolera i njegovo zadovoljstvo menadžerskim sustavom imaju direktni utjecaj na kvalitetu MAS-a i posljedično na uspješnost upravljanja i poslovanje poduzeća. Osim toga, potvrđen je i indirektni utjecaj potpore menadžmenta putem varijable obuke.

Dakle, kroz pregled brojnih istraživanja, unutar i izvan područja kontrolinga, može se uvidjeti da postoje različite kombinacije definiranja kvalitete informacija i podataka. Tako je Xu *et al. (*2003) smatrao da kvalitetu podatak koja proizlazi iz računovodstveni informacijskih sustava (engl. Accounting Information Systems - AIS) najviše karakteriziraju sljedeće četiri dimenzije: točnost, pravovremenost, potpunost i dosljednost. Wieder i Ossimitz (2015) potvrdili su da kvaliteta informacija mjerena kroz dimenzije potpunosti, značajnosti, dostupnosti i ažurnosti, imaju značajan utjecaj na donošenje poslovni odluka. Odnosno, Wang i Strong (1996) definirali su kvalitetu podatka kao podatke koji su spremni za upotrebu od strane njihovih korisnik i koji se dijele u četiri područja ovisno o potrebama korisnika podataka - unutarnja, sadržajna, prezentacijska i dostupnost kvalitete podatka. Pri tome se na područje kontrolinga mogu primijeniti sadržajna i prezentacijska kvaliteta podatka koju određuju sljedeće karakteristike:

- Sadržajna kvaliteta podataka - dodana vrijednost, značajnost, pravovremenost, potpunost i prikladnost količine podataka.
- Prezentacijska kvaliteta podataka - sposobnost interpretacije, jednostavnost razumijevanja, dosljednost predstavljanja i sažet prikaz.

Pored navedene dvije vrste, Rogova (2019) smatra da se kvaliteta podataka i informacija može razgraničiti i prema kvaliteti izvora informacija, i to na dvije vrste - objektivni i subjektivni. Pri tome su objektivni podaci oni koje osiguravaju npr. senzori, baze podataka, softverski modeli, dok su subjektivni oni koje osiguravaju npr. eksperti i mediji.

Slika 9: Karakteristike kvalitete podataka i informacija



Izvor: izrada autora prema Rogova (2019)

S gledišta kontrolinga kvaliteta informacija koje pruža menadžmentu u svrhu odlučivanja može se mjeriti temeljem sadržajne i prezentacijske kvalitete te kvalitete subjektivnih izvora. Uvjet za sadržajnu kvalitetu predstavlja dostupnost podatak. Naravno, ako podaci nisu dostupni onda niti ostali atributi koji predstavljaju sadržajnu kvalitetu podataka neće biti značajni. Kod subjektivnih izvora bitno je imati na umu da informacije i podaci mogu biti iskrivljeni, namjerno i nenamjerno, i stoga bi se njihova pouzdanost trebala dodatno potvrđivati kroz npr. razinu osposobljenosti i stručnosti ili reputaciju izvora. Atributi kvalitete prezentacije povezani su s time kada, koje i kako se informacije predstavljaju. Bitni su zbog uloge koju imaju u vidu utjecaja na donositelje odluka, njihove postupke, odluke, prosudbe i mišljenja. Stoga informacije moraju biti pouzdane i moraju se prezentirati na vrijeme i na način koji ih čini razumljivim, cjelovitim i lakim za tumačenje. Pri tome, razumljivost i interpretacija predstavljaju zavisne atribute određene razinom osposobljenosti i stručnosti njihovih stvaralaca (Rogova, 2019). Odnosno, kako navodi Filipčić (2018, str. 31-33):

- „sadržaj i opseg informacija u izvještaju trebaju biti u okviru stvarnih potreba menadžmenta“
- „izvještaj mora služiti menadžmentu kao informativna podloga za osmišljavanje strategije, planiranja, odlučivanja i kontrolu“,
- „izvještaj mora biti prilagođen menadžmentu kako bi ga on mogao razumjeti“,
- „izvještaj mora biti aktualan i isporučen na vrijeme kako bi menadžer mogao poduzeti potrebne aktivnosti“, i
- „informacije iznesene u izvještaju trebaju biti predstavljene na jasan, pregledan i razumljiv način“.

Sukladno teoriji i istraživanjima provedenih unutar, ali i izvan područja kontrolinga vidljiv je značaj utjecaja kvalitete podatak i informacija na poslovno upravljanje tj. donošenje odluka i ostvarenje pozitivnih učinaka za poduzeće. Dakako, brojni su pristupi i načini mjerenja kvalitete. Međutim, ono što se može zaključiti jest da se terminologija informacijskih znanosti, kao glavnog područja definiranja i ispitivanja uloge, značenja i značaja podatak i informacija općenito, može primijeniti i na druga područja kao što je kontroling. Naime, da li se na informaciju gleda kao na produkt nekog sustava, čina ili posljedice ljudskog rada, one moraju odražavati pojedine činjenice koje zadovoljavaju određenu razinu kvalitete. Dakako što je kvaliteta informacija veća to je za pretpostaviti da će njezini korisnici biti zadovoljniji i da će dovesti do dostizanja boljih ishoda. Pretpostavlja se da će informacije koje pružaju

objektivni izvori biti skloniji manjim greškama i bržem generiranju. No, informacije koje pružaju objektivni izvori podataka imaju sposobnost pružanja upravo onih informacija koje su potrebne i značajne u određenom trenutku i koje prikazuju stvarne okolnosti na sveobuhvatan i pravovaljan način. One su posljedica kritičkog, proaktivnog i analitičkog pristupa rješavanju problema koji na prikladan način daju uvid u uzročno-posljedične veze nastanka događaja, načina njihovog rješavanja i vjerojatnosti nastanka budućih događaja. Može se reći da kontroleri u svojem radu koriste podatke i informacije iz objektivnih izvora kako bi menadžmentu na raspolaganje stavili izvještaje koji osiguravaju efikasno poslovno odlučivanje. U smislu digitalizacije, upravo su objektivni izvori oni koji proizlaze iz Big Data. Kontroling je taj koji među njima mora izabrati one podatke koji su značajni i aktualni te ih pravovremeno staviti na raspolaganje (i/ili prezentirati) menadžmentu na jasan način. Naravno, pri tome, podaci i informacije prikazane u izvještajima moraju biti točne, međusobno usklađene i moraju pokrivati sva važna područja poslovnih aktivnosti. Odnosno, sadržaj i korisnost informacija koje pružaju moraju biti na visokoj razini, a to uključuje poštivanje različitih dimenzija kvalitete. Temeljem svih prikazanih dosadašnjih znanstvenih istraživanja sintetizirani su ključni atributi te će se u ovom radu koristiti sljedeće dimenzije kvalitete kontrolerovih outputa: *ažurnost, značajnost, točnost*, *pravodobnost i preglednost.* Ažurnost i značajnost podrazumijevaju da izvještaji menadžmentu pružaju najnovije promjene tj. informacije koje su važne za donošenje određene poslovne odluke. Točnost, da su podaci u izvještajima točni, precizni i međusobno usklađeni. Pravodobnost, da kontroleri osiguravaju menadžeru redovite (dnevne/mjesečne itd.) izvještaje ili izvještaje po zahtjevu. I preglednost, da su informacije u izvještajima prezentirane na jasan i razumljiv način. Iako postoje brojni drugi faktori koji utječu na kontrolerovu razinu utjecaja na donošenje odluka, kvaliteta outputa zasigurno je ta koja bi trebala omogućiti ulazak i trajni ostanak kontrolera u upravljačkoj strukturi kroz uključenost u odlučivanju na strateškoj i operativnoj razini. Odnosno, stvaranje efekta bržeg odlučivanja, donošenja boljih i preciznijih odluka te učinkovitijeg svakodnevnog rada menadžera.

3.2. Utjecajne karakteristike kvalitete kontrolerovog outputa

Brojni su čimbenici koji utječu na kvalitetu outputa kao osnova donošenja ispravnih poslovnih odluka. Naravno, ako se govori o kontroleru kao kreatoru takvih outputa onda će kvaliteta tog produkta prvotno ovisiti o njegovim vještinama i znanju. Odnosno, ovisit će o obilježjima menadžera kao proaktivnog vođe i inicijatora koji prihvaća i cijeni funkciju kontrolinga i značaj njenog sudjelovanja u upravljačkim procesima poduzeća. Pored toga, svakako će ovisiti o kvaliteti internih i eksternih podatka i informacija koje se koriste kao inputi kreiranih izvještaja, o brojnim utjecajima izvan poduzeća te obilježjima koji određuju poduzeće kao cjelinu, o demografskim i kulturološkim čimbenicima, razini implementacije i primjene digitalnih alata i tehnoloških inovacija, te brojnim drugim čimbenicima. Stoga je bitno izučavati i unaprjeđivati utjecajno povezujuća obilježja o kojima ovisi kvaliteta kontrolerovih outputa. Sukladno prethodno navedenoj teoriji, a u svrhu empirijskog testiranja, pored pojedinih kontroling varijabli, odabrane su četiri osnovne karakteristike koje utječu na kvalitetu kontrolerovog outputa: kontroleri, menadžeri, organizacija i okruženje.

3.2.1. Karakteristike kontrolera

Prvi i osnovni čimbenik o kojem ovisi kvaliteta kontrolerovih outputa jest kontrolerova vlastita sposobnost i profesionalnost, a što je istaknuto i Sahte još 1982. godine. Već je tada isticao raznoliku ulogu kontrolera unutar poduzeća i naglašavao da kvalitetne informacije same po sebi nisu dovoljne za donošenje ispravnih poslovnih odluka. Odnosno, kako bi se u potpunosti ostvarila kontrolerova uloga te donosile efikasne odluke, prema mišljenjima menadžera, kontroleri moraju poprimiti karakteristike „jakog“ kontrolera što podrazumijeva aktivnu uključenost u procesu donošenja odluka, ali i objektivnost te nezavisnost. Točnije, kontroleri moraju biti sposobni pružiti adekvatnu preporuku temeljem izvršenih analiza i preispitanih planova i akcija. Iako sukladno izučavanju prakse Sathe predlaže klasifikaciju karakteristika „jakog“ kontrolera kao skup osobnih, tehničkih, poslovnih, komunikacijskih i interpersonalnih vještina (Sathe, 1983), među najbitnijima ističe motiviranost, osobnost i međuljudske odnose s menadžmentom (Sathe, 1982).

Tablica 3: Karakteristike „jakog“ kontrolera

R.	Opis karakteristike	Posebne karakteristike i ponašanje
Osobne kvalitete		
1.	Osobna energija i motivacija	Izvršitelj je. Svjestan je svega što se događa. Preuzima inicijativu.
2.	Osobni integritet i profesionalna predanost	Nepristran izvor informacija. Ima savjest podjele. Ne pokušava blefirati. Nije "da osoba" Iskren je.
Tehnička sposobnost		
3.	Računovodstveno znanje	Ima neupitnu informacijsku sposobnost.
4.	Analitičke vještine	Ne određuje samo što se dogodilo, već zašto se nešto dogodilo. Dobar je u uređivanju i preuređivanju brojevi. Može uočiti trendove prije nego postanu stvarnost. Može "kopati" ispod brojeva.
Poslovna procjena		
5.	Razumijevanje onoga što menadžment treba za učinkovito upravljanje poslovanja	Poslovan je čovjek. Ima dobru poslovnu prosudbu. Poznaje ostale dijelove odjeljenja. Razumije poslovanje odjeljenja. Predviđa buduće poslovne probleme. Preporučuje djelovanje na poslovne probleme u budućnosti. Prati cijelo poslovanje. Nije uvijek zabrinut zbog potrošnje.
Komunikacijske vještine		
6.	Sposobnost prosuđivanja onoga što je važno za upravljanje i preporuku	Ne misli samo na financijsku kontrolu. Može sažeti brzo i točno. Mentalno donosi iste odluke kao i voditelj odjela. Pruža informacije upravi čak i prije nego što shvati potrebu za tim. Razmišlja o načinu na koji voditelj odjela misli. Brzo shvaća informacije od stvarne važnosti za menadžment. Spreman je procijeniti. Može prosuditi potreban stupanj točnosti. Ne naglašava točnost kao cilj sam po sebi. Ne gubi se u raspodjeli troškova. Govori jezik koji koristi menadžment.

		Drži na umu publiku. Može se uhvatiti u koštac s činjenicama i davati preporuke.
Interpersonalne vještine		
7.	Izgradnja odnosa i razvoj utjecaja	Slaže se sa svima. Prihvaćen je u svim funkcionalnim područjima. Dio je upravljačkog tima. Savjetnik povjerenstva uprave. Fleksibilan je u ispunjavanju zahtjeva uprave. Alter ego je glavnog upravitelja. Glas razuma kada se raspravlja o osjetljivim pitanjima. Otvoren je za komunikacije. Poštuje ga uprava. Vjeruje mu uprava. Gradi povjerenje
8.	Sposobnost konstruktivnog osporavanja upravljanja	Postavlja prava pitanja. Razmišlja o utjecaju brojeva. Kontinuirano dovodi u pitanje upravljanje analize i planove. Zna kada se mora boriti i kada popustiti. Uvijek postavlja pitanja. Ne oklijeva ispitati postupak uprave nakon što je poduzet. Ne oklijeva kritizirati planove i akcije upravljanja
Upravljanje dvojnom odgovornošću		
9.	Prepoznavanje važne odgovornosti obje podjele i korporativno upravljanje	Razumije korporativna očekivanja. Prepoznaje odgovornost prema korporaciji kojom se upravljanje. Ima prosudbu koju prepoznaje upravljanje. Može suditi što je važno a što nije. Ima dobar odnos s korporativnim upravljanjem. To su oči, uši i nos upravljanja.

Izvor: izrada autora prema Sathe (1983)

ICV, poznata njemačka Udruga kontrolera, 2012. godine definirala je šest ključnih kompetencija koje moraju imati kontroleri koji kao poslovni partneri žele pružiti menadžmentu sveobuhvatnu potporu (Gänßlen *et al.*, 2012). Odnosno, sukladno Vitezić (2020) svakoj od tih kompetencija mogu se pridati sljedeći atributi:

1. analitičko (logičke) vještine - mogućnost pretvaranja ideja u brojke, razumijevanje složenih planova i analiza odstupanja
2. komunikacijske vještine - sposobnost prenošenja poruke tj. važnog sadržaja

3. znanje iz poslovanja - razumijevanje prirode menadžerskog posla
4. ponašanje (psiho-logičke vještine) tj. bihevioralno znanje - mogućnost prilagodbe kontrolera osobinama menadžmenta
5. znanje iz sustava mjerenja i kontrole - mogućnost upravljanja cjelovitim sustavom kontrola
6. oslonac (potpora upravljanju) - poslovno partnerstvo, nepotkupljivost i neutralnost spram menadžmenta

Nadalje, Vitezić (2020) ističe tri dimenzije kompetencija kontrolera i pripadajuće atribute:

1. osobne kompetencije - biti stručan, imati znanje i vještine, samoinicijativu, samodisciplinu
2. socijalne kompetencije - znati komunicirati, surađivati, konstruktivno rješavati konflikte
3. konceptualne kompetencije - znati planirati zadatke, odrediti prioritete, imati širinu sagledavanja, biti kreativan, fokusiran, razumjeti problem

Slično su istakli i Meter i Pureta (2016), prema kojima kontroleri moraju imati sljedeće grupe te pripadajuće pojedinačne kompetencije:

1. stručne kompetencije - financijsko i menadžersko računovodstvo, znanje o instrumentima operativnog i strategijskog kontrolinga, upravljanje rizicima, troškovno računovodstvo, znanje o poduzeću, poslovno planiranje, interno izvještavanje, itd.
2. osobne kompetencije - samosvijest, samopouzdanje, samomotivacija, samodisciplina, proaktivnost
3. socijalne kompetencije - empatija, asertivnost, suradnja, utjecajnost, konstruktivno rješavanje konflikata
4. konceptualno-kognitivne kompetencije - planiranje radnih zadatka, prioritizacija, sagledavanje šire slike, kreativnost, strukturiranost u izlaganju, razumijevanje problema i donošenje odluka te fokusiranost

Istraživanjem koje su Meter i Pureta (2013, u Meter i Pureta, 2016) proveli 2013. godine na uzorku od 135 hrvatskih poduzeća, potvrdilo se da je među stručnim kompetencijama najbitnije poznavanje operativnih i strateških instrumenta kontrolinga te menadžerskog računovodstva. Među osobnim vještinama najviše su se istakli samopouzdanje i proaktivnost,

među socijalnim utjecajnost i asertivnost, a među konceptualno-kognitivnima strukturiranost izlaganja te razumijevanje problema i donošenja odluka. Iako se kreativnost pokazala kao najmanje značajna u ovom istraživanju, Eiselmayer *et al.* (2015) ga pored holističkog razmišljanja smatraju ključnom osobnom kompetencijom kontrolera u ulozi poslovnog partnera, usmjerenu na oblikovanje budućih odluka te unaprjeđenje rada kontrolinga. Odnosno, prema Eiselmayer *et al.* (2015), ovisno o vrsti poslovnog procesa u koji je uključen, kontroler treba imati određene osobne, socijalno-komunikativne, stručno-metodološke kompetencije i kompetencije usmjerene na aktivnost i primjenu. Kreativnost se stoga pored holističkog razmišljanja i otvorenosti za promjene ističe kao značajna osobna kompetencija u području unaprjeđenja organizacijskih procesa, instrumenata i sustava. Osim toga, holističko razmišljanje se smatra ključnom osobnom kompetencijom kontrolera u području menadžerskog izvještavanja, dok se komunikativnost smatra bitnom u gotovo svim područjima kontrolerovih procesnih zadataka (predviđanja, budžetiranja, strateškog planiranja, itd.). Nadalje, temeljem intervjua kontrolera i menadžera, Preis (2012) je kreirao konceptualni model koji podrazumijeva da kontroler mora imati tehničko-metodološke vještine, znanje o poslovanju te osobne vještine. Među osobnima ističe komunikativnost, timski rad, analitičnost, samostalnost u radu, dok na prvo mjesto tehničko-metodoloških navodi vještinu poznavanja brojeva.

Fenyves i Tarnóczi (2019) istraživanjem prioritetnih karakteristika kontrolera u Rumunjskoj, ustanovili su da je u području profesionalnog znanja najbitnije poznavanje poslovanja tj. poslovnog područja, u metodološkim kontekstualno razmišljanje i analitičke sposobnosti, a u osobnim kontekstualno i logičko razmišljanje. Istraživanje su temeljili na tzv. „first Hungarian controlling competency survey“ kreiranog od strane Solti 2013. godine, koji poput mnogih drugih autora kontrolerove kompetencije dijeli u četiri područja: metodološke, profesionalne, osobne i socijalne vještine. Pri tome navodi sljedeće karakteristike za pojedinu dimenziju kompetencija:

1. metodološke - analitičko razmišljanje, orijentiranost na rješavanje problema, vještine implementiranja, IT vještine
2. profesionalne - znanje iz stručnog područja, razumijevanje poslovanja
3. osobne - ustrajnost, proaktivnost, savjesnost i neutralnost, orijentiranost na uspjeh
4. socijalne vještine - komunikacijske vještine, rad u timu, upravljanje konfliktima, empatija/osjećajnost, orijentiranost prema klijentu/vještine savjetovanja i menadžerske vještine

Gänßlen (2008) je pak potrebne kontrolerove kompetencije svrstao u tri kategorije profesionalne, upravljačke i osobne, te ih dodatno svrstao u potkategorije koje kontroler mora imati (engl. „must have“) i koje bi trebao imati (engl. „should have“). Tako, na primjer, pod upravljačke „must have“ navodi sposobnost komuniciranja i umrežavanja, prezentiranja i moderiranja, a pod osobne predanost poslu, odlučnost, pouzdanost i sposobnost za iskrenim govorom te sposobnost prenošenja vlastitih vjerovanja na druge (argumentirano uvjeravanje). Zanimljivo je da pod „should have“ navodi analitičnost iako upravo tu kompetenciju ističe kao ključnu za kvalifikaciju kontrolera kao poslovnog partnera. Kategoriziranje analitičnosti pod „should have“ umjesto „must have“ može se prepisati godini izrade klasifikacije kompetencija. Odnosno, može se vidjeli da je autor već tada prihvatio smjer razvoja kontrolera ka poslovnom partneru. Da je analitičnost najznačajnija kompetencija kontrolera kao poslovnog partnera potvrdili su i Gleich *et al.* (2013). Točnije, kao najznačajniju profesionalnu vještinu potvrdili su poznavanje poslovanja poduzeća tj. poznavanje strategije, vizije, ciljeva te procesa. Među osobnima su se dokazale proaktivnost i otpornost na stres, a u području socijalnih komunikativnost, orijentiranost na ispunjavanje termina te sposobnost savjetovanja. Osim toga, autori navode da rezultati jasno pokazuju da u ulozi poslovnog partnera socijalne kompetencije postaju kritični faktor uspjeha kontrolinga. Schäffer i Brückner (2019) u svojem istraživanju dolaze do saznanja da je za kontrolera kao partnera pored stručnog znanja (kontrolinga i financija) najbitnije znanje o poduzeću te komunikacijske i osobne vještine, dok su se IT vještine (npr. BI) pokazale kao srednje bitne ili nebitne. Analitičnost i komunikativnost su se također potvrdile kao najznačajnije osobne kompetencije u istraživanju Drerup *et al.* (2016), dok su se razina završenog studija te godine radnog iskustva dokazale kao najbitnije profesionalne vještine. Burns *et al.* (1999, u Pietrzak i Wnuk-Pel, 2015) naglašava da se kontroleri prije svega moraju usmjeriti na razvoj analitičkih vještina, sposobnost interpretacije financijskih i nefinancijskih podatak, komunikacijske vještine te da moraju biti sposobnosti raditi pod pritiskom. Burns i Baldvinsdottir (2005) i Byrne i Pierce (2007) također ističu analitičnost i socijalne vještine, dok Osmanagić Bedenik i Lizzul (2015) svojim istraživanjem potvrđuju da su budući preduvjeti zanimanja kontrolera u Republici Hrvatskoj, prema mišljenju kontrolera, prije svega sposobnost kritičkog propitivanja i otkrivanja slabih točaka, komunikacijske sposobnosti te postojanost i odlučnost. Ghasemaghaei *et al.* (2018) su pak potvrdili da analitičke vještine i znanje o vanjskim čimbenicima te organizacijskim ciljevima, kao dio analitičkih kompetencija, imaju utjecaj na kvalitetu i efikasnost donošenja odluka. Osim toga, jedna od vještina koju pojedini autori

(Maas, 2019; Oesterreich *et al.*, 2019; Sathe, 1982) ističu kao značaju za uspjeh kontrolera je otpornost na stres.

Temeljem Pitcher modela iz 2015. godine koji ističe ulogu interpersonalnih vještina kontrolera pri stvaranju dodane vrijednosti, Zoni (2017) je došla do saznanja da su u Talijanskim oglasima za posao kontrolera najtraženije sljedeće osobne vještine: analitičke i komunikacijske, proaktivnost, cilju usmjereni pristup i timski rad. Kao i Drerup *et al.* (2016), pod tehničkim vještinama ističu stupanj stručne spreme, prethodno radno iskustvo i godine rada u struci, ali i znanje računovodstva i poreza te poznavanje softverskih aplikacija (BI, ERP, itd.). Odnosno, istraživanjem se potvrdilo da kontroleri pored tehničkih vještina moraju raspolagati i određenom razinom osobnih ako žele ispuniti svoju ulogu u potpunom smislu. Uvidom u oglase na web stranici MojPosao mogu se prepoznati sličnosti s navedenim istraživanjima. U Republici Hrvatskoj od kontrolera se tako, na primjer, traži sljedeće (*MojPosao*, 30.1.2019.): analitičke sposobnosti, orijentiranost ka postizanju ciljeva u zadanim rokovima, izražene komunikacijske i prezentacijske vještine, sklonost timskom radu, pouzdanost, preciznost i odgovornost, odlično poznavanje Excela, radno iskustvo, proaktivan pristup poslu, preuzimanje inicijative i odgovornosti za posao, itd. Proaktivnost kao bitnu kontrolerovu karakteristiku ističu i brojni drugi autori (Ramli *et al.*, 2013; Abdul Hamid *et al.*, 2016; Meter i Pureta, 2016; Sejdić, 2017; Fourné *et al.*, 2018; Mäder, 2018; Vitezić, 2018, itd.), a povezuje se prije sveg sa značajem kontrolerove buduće uloge; promjene iz reaktivnog u proaktivni kontroling (Vitezić, 2018). Tako, na primjer, Mäder (2018) navodi proaktivnost, orijentiranost na budućnost i inovativnost kao osnovne značajke kontrolera. Fourné *et al.*, (2018) koji ističu značaj primjene i razvoja mjernih ljestvica u području kontrolinga, navode potrebu za istraživanjem proaktivnosti kao jednu od prioritetnih osobina budućih kontrolera. S promjenom tehnologije, kontrolingu je pružena mogućnost preuzimanja proaktivne uloge kao poslovnog partnera, vođe, komunikatora i rješavalaca problema (Ramli *et al.*, 2013) te se očekuje da kontroleri, ako nisu do sada, postanu punopravni članovi menadžerskog tima (Ruttanaporn, 2001, u Ramli *et al.*, 2013). Odnosno, u pogledu razvoja novih proizvoda, od kontrolera se očekuje da preuzmu kreativniju, proaktivniju i fleksibilniju ulogu (Abdul Hamid *et al.*, 2016). Paterson i Vermaas (2011) su u svojem istraživanju među dvadeset nizozemskih tvrtki došli do saznanja da kontrolerove kompetencije sa stajališta financijskih vrhovnih menadžera imaju značajnu ulogu u donošenju efektivnih odluka. Pri tome navode četiri najbitnije kompetencije, a među kojima se najviše ističe asertivnost. Ostale su spremnost na izazove, nezavisnost, timski rad i potrebno znanje. Značaj asertivnosti za kontrolera potvrdili

su i Meter i Pureta (2013, u Meter i Pureta, 2016), te Oesterreich *et al.* (2019). U istraživanju Meter i Pureta (2013, u Meter i Pureta, 2016) asertivnost se dokazala kao druga najbitnija socijalna kompetencija kontrolera. Oesterreich *et al.* (2019) u svojem konceptualnom modelu zasnovanog na istraživanju postojećih oglasa za radno mjesto kontrolera, osobnih poslovnih profila na društvenim mrežama te postojeće literature, pored profesionalnih vještina ističu sve veći značaj „mekih" vještina - sposobnost timskog rada, komunikacijske vještine, asertivnost, interkulturne kompetencije, osjećaj odgovornosti i pouzdanosti. Sve veći značaj „mekih" vještina u radu kontrolinga ističu i brojni drugi autori (Filipčić, 2019; Heupel i Reinhardt, 2019; Listeš, 2019; Krumwiede 2016, u Oesterreich *et al.*, 2019; Wadan *et al.*, 2019, itd.). Prema Wadan *et al.* (2019) pred kontrolerima postoje tri osnovne promjene, a vezane su uz „meke" vještine, značaj poslovnog partnerstva i razmjene podataka. Stoga navode da je kontrolerima potrebno veće znanje iz područja upravljanja podacima, analitičke sposobnosti te vještine koje će im pomoći u komunikaciji s menadžmentom. Pri tome se nadovezuju i na utjecaj pojave podatkovnog znanstvenika kao sakupljača podataka i s tim povezne sve veće uloge kontrolera kao tumača podataka kojem će u budućnosti biti potrebno značajno unaprjeđenje „mekih" vještina. Krumwiede (2016, u Oesterreich *et al.*, 2019) pak navodi da će s pojavom uloge poslovnog partnera, „meke" vještine postati obvezne vještine svakog financijskog stručnjaka. Odnosno, rastom digitalizacije, automatizacije i tehnologije „tvrde" vještine, koje podrazumijevaju specijalizirana znanja i tehničke sposobnosti proizašle iz znanja stečenog kroz obrazovanje, pohađanje seminara i sl., postaju nedostatan alat za uspjeh poduzeća (Filipčić, 2019); postaju manje relevantne, dok „meke" vještine dobivaju na sve većem značaju (Heupel i Reinhardt, 2019). Nadalje, iako naglašavaju neisključiv značaja tehničkih vještina, Abdul Hamid *et al.* (2016) ističu da kontroleri moraju unaprijediti svoje „meke" vještine kako bi u potpunosti ispunili zadatke pružanja relevantnih i točnih informacija donositeljima odluka. Navedeno potvrđuje i istraživanje koje su proveli Kaštelan Mrak i Sokolić (2017) među menadžerima u Republici Hrvatskoj. Naime, iako istraživanje nije uključivalo kontrolere, potvrdilo je da menadžeri „meke" vještine zaposlenika smatraju značajnijima od psiho-motoričkih. Pri tome, među najvažnijim „mekim" vještinama ističu se odgovornost, prezentacijske vještine i analitičnost.

Tablica 4: „Meke“ vještine potrebne u poslovanju

Osobne vještine	Socijalne vještine	Metodološke vještine
Podnošenje stresa	Komunikacija	Prilagodljivost na promjene
Ravnoteža poslovnog i privatnog	Timski rad	Usmjerenost na korisnika
Kreativnost / inovativnost	Mreža kontakata	Stalni napredak
Vještine učenje	Pregovaranje	Usmjerenost na rezultat
Samosvijest	Upravljanje sukobima	Analitičke vještine
Predanost	Vodstvo	Odlučivanje
Profesionalna etika	Kultura prilagodljivosti	Menadžerske vještine
		Vještine istraživanja i upravljanja informacijama

Izvor: Haselberger (2012, u Filipčić, 2019, str. 69)

Postoje brojne definicije ali i nazivi za „meke“ vještine. Prema Europskom centru za razvoj strukovnog obrazovanja (u Filipčić, 2019, str. 68) „…meke vještine su set netehničkih vještina i znanja koje podupiru uspješno sudjelovanje u poslu. One nisu specifične za određeni posao i usko su povezane s osobnim karakteristikama i stavovima, socijalnim i menadžerskim sposobnostima.“. Ako se uzmu u obzir sva prethodno navedena istraživanja te prikaz razgraničenja „mekih“ vještina danog od strane Haselberger u 2012. godini (tablica 4), kao najznačajnije i najčešće spominjanje mogu se navesti komunikativnost, analitičnost, proaktivnost i asertivnost. Potom slijede kreativnost, timski rad, otpornost na stres tj. rad pod pritiskom, holističko/kontekstualno/logično/kritičko razmišljanje, pouzdanost, odgovornost i predanost poslu.

Opće je poznato da kvaliteta bilo kojeg rada prvenstveno ovisi o vještinama, znanju i motivaciji radnika. Sukladno, kvaliteta kontrolerovog rada ovisit će o njegovim profesionalnim vještinama tj. znanju iz područja kontrolinga te srodnih poslova (npr. računovodstvo, financije, revizija), tržišta i zakonodavstva, a kojeg kontroler usvaja tijekom cijelog svog obrazovnog i poslovnog životnog vijeka. Može se pretpostaviti da su kontroleri koji su postigli ulogu poslovnog partnera menadžmentu, s profesionalnog gledišta, na visokoj razini stručnosti realizirane prije svega dugogodišnjim radnim iskustvom u području kontrolinga i/ili drugim srodnim disciplinama te stupnjem obrazovanja. Takve vještine kontroler će nadograđivati ovisno o npr. djelatnosti u kojoj izvršava ulogu kontrolera, pojavi novih instrumenta upravljanja, praćenjem promjena regulative, poreznih i računovodstvenih standarda itd. Vještine koje značajno utječu na uspjeh obavljanja određenog posla, kojima se u posljednjih nekoliko godina pridaje sve veći značaj i koje zasigurno znatno utječu na rad kontrolera kao poslovnog partnera su određen metodološke, socijalne i osobne vještine.

Poznavanje struke i zakonodavstva svakako predstavlja osnovu izrade kvalitetnih izvještaja i davanja preporuka menadžmentu. Međutim, bez posjedovanja analitičkih vještina, sposobnosti prepoznavanja i logičkog povezivanja brojeva te davanja prijedloga, profesionalne sposobnosti pismene i usmene komunikacije, usmjerenosti na proaktivno unaprjeđenje i ostvarenje ciljeva te kreativnosti u izvršavanju i prije svega rješavanju kompleksnih problema, kontroler ne može biti sposoban u potpunosti ostvariti svoj značaj unutar poduzeća. Stoga će se u modelu koji istražuje ovaj rad u sklopu karakteristika kontrolera ispitivati prije svega uloga „mekih" vještina u izradi kvalitetnih outputa, a koje su se kroz stručnu i znanstvenu literaturu pokazale kao značajne kompetencije kontrolera kao poslovnog partnera. To su: *analitičke vještine, vještine komuniciranja, asertivnost te kreativnost i proaktivnost.*

3.2.1.1. Analitičnost

Sukladno navedenim klasifikacijama kompetencija kontrolera te brojnim istraživanjima uviđa se značaj analitičkih vještina kao osobine kontrolera. Analitičke vještine mogu se definirati kao „sposobnost donošenja zaključaka i prognoziranje budućnosti dobivanjem informacija iz različitih izvora utvrđivanjem uzročno-posljedičnih odnosa" (Haselberger, 2012, u Filipčić, 2019, str. 70). Odnosno, prema Meter i Pureta (2016, str. 120) bitna kognitivno-konceptualna kompetencija kontrolera pod nazivom „razumijevanje problema i donošenje odluka", koja zapravo predstavlja bit analitičnosti, definira se kao „sposobnost analize uzroka problema, sagledavanja mogućih rješenja, analize učinkovitosti svakog od njih i odabir najbolje opcije". Iako se analitičnost u teoriji navodi kao bitna karakteristika te je u empirijskim istraživanjima potvrđena kao značajan za kontroling i poslovnom odlučivanju, rijetko se potvrđuje kroz primjenu složenih konstrukta tj. mjernih ljestvica. Tako je, na primjer, Feeney (2007) u svrhu empirijske analize uloge kontrolinga u pružanju informacija za poslovno odlučivanje ispitao stajališta menadžera o važnosti trinaest vještina, osobina i kompetencija. Prema rezultatima ankete menadžeri kao najznačajnije u smislu poslovnog odlučivanja navode sposobnost rješavanja problema i analitičke sposobnosti. Međutim, pri tome analitičke sposobnosti mjere s jedno-predmetnim mjeritelj (engl. single-item measurement). To podrazumijeva da se je od ispitanika traži da ocjene svoje „analitičke sposobnosti" na određenoj ljestvici (npr. 1-7). Iako se jedno-predmetni mjeritelj koriste u istraživanjima, poznato je da oni pružaju najmanje uvjerenje da je mjera valjan i pouzdan (Boyd *et al.*, 2005, u Fuchs i Diamantopoulos, 2009),

te se zbog toga u recenzentskim postupcima često kategoriziraju kao „fatalnom greškom“ autora (Wanous *et al.*, 1997, u Fuchs i Diamantopoulos, 2009). Više-predmetni mjeritelj podrazumijevaju da se neki konstrukt potvrđuje kroz više čestica (engl. item) koje odražavaju taj konstrukt (npr. neku osobinu).

Analitičke vještine kao bitnu tehničku karakteristiku kontrolera opisao je Sathe (1983). Navodi da kontroler kao analitička osoba mora biti sposoban odrediti zašto se nešto dogodilo, uočiti trendove prije njihovog nastanka, dubinski razumjeti brojeve i mora biti dobar u njihovoj analizi. Sukladno, Fadhilah *et al.* (2015), koji su dokazali da kvaliteta kontrolerovog outputa ima utjecaj na koristi menadžera u donošenju poslovnih odluka, su zapravo prvi postavili analitičke vještine kao više-predmetni mjeritelj kontrolera kao pružatelja usluga, a pod čime se podrazumijeva da su kontroleri usmjereni na budućnost organizacije, da su sposobni objasniti značenje brojeva i da razumiju razloge nastanka problema s kojima se suočavaju. Odnosno, konstrukt analitičkih vještina mjerili su kroz tri čestice. Slične atribute analitičko (logičkog) vještina postavila je i Vitezić (2020) - mogućnost pretvaranja ideja u brojke, razumijevanje složenih planova, te analiza odstupanja. Odnosno, kako navode Fenyves i Tarnóczi (2019), analitičke vještine i razmišljanje predstavljaju ključ uspjeha kontrolinga. Naime, rastom digitalizacije, pojavom sve većeg broj informacija i potrebe za što bržim donošenjem odluka, tjera menadžere na sve veće uključivanje kontrolera. Pri tome, izvještaji koje kontrole izrađuje temelje se na sve kompleksnijim podacima koji zahtijevaju visoku razinu analitičnosti. Stoga se posjedovanje analitičkih vještina smatra jednom od ključnih osobina kontrolera digitalnog doba.

3.2.1.2. Komunikativnost

Komunikacijske vještine su jedne od osnovnih vještina koje osiguravaju kontroleru da izradi kvalitetne izvještaje tj. da iste kvalitetno predstavi menadžmentu i time pozitivno utječe na donošenje poslovnih odluka. Komunikativnost predstavlja sredstvo koje kontroler koristi tijekom cjelokupnog procesa pružanja svojih usluga. Pri pripremi i izradi izvještaja kontroler mora uspostavljati kontakt sa zaposlenicima drugih odjela kako bi osigurao adekvatne podatka te mora biti sposoban iste jasno prikazao u pismenom obliku. Pri prezentaciji i savjetovanju menadžmenta, mora biti sposoban jasno prikazati svoje ideje tj. prenijet poruku i važnost njenog sadržaj. Odnosno, mora biti sposoban slušati sugovornike kako bi dobio

povratne informacije. Stoga, mora posjedovati dobre verbalne i oralne komunikacijske vještine.

Haselberger (2012, u Filipčić, 2019, str. 70), u sklopu socijalnih vještina, definira komunikacije kao „sposobnost prenošenja ideja, informacija i mišljenja jasno i uvjerljivo, kako usmeno tako i pismeno, slušajući i prihvaćajući prijedloge drugih“. Schermerhorn *et al.* (1997, u Smith i Krüger, 2008) ih definiraju kao sposobnost slanja i primanja poruka s određenim značenjem, a Pitan (2015, str. 31) kao „sposobnost prijenosa podataka s jednog entiteta na drugi tj. sposobnost prenošenja ili razmjene misli, mišljenja ili informacija govorom, pisanjem ili znakovima.“. Prema Smith i Krüger (2008) to je vještina koja se koristi tijekom pregovaranja, prezentiranja, davanja instrukcija ili rješavanja konflikata. Kao analitičnost, i komunikativnost se ubraja u „meke“ vještine, a za koje su se tijekom godina razvili brojni drugi nazivi poput: životne vještine, transverzalne vještine, generičke vještine, ključne kompetencije, prenosive vještine, itd. Nazivi su prije svega nastali zbog različitosti njihovih dimenzioniranja i interpretiranja. Sukladno, u istraživanjima dolazi i do primjene brojnih mjeritelja, prvenstveno jedno-predmetnih, i kombinacija komunikacijski kompetencija. Tako, na primjer, Fadhilah *et al.* (2015) komunikacije vještine kontrolera gleda kroz čestice kritičnost u rješavanju problema, uvažavanje tuđih perspektiva i pružanje osjećaja udobnosti, a koje se zapravo mogu pripisati asertivnosti kao interpersonalnoj vještini. Smith i Krüger (2008) ih obilježavaju kroz vještine prezentiranja, pregovaranja i mogućnosti rješavanja konfliktnih situacija. Kavanagh i Drennan (2008) kao kombinaciju oralne i pismene komunikacije te sposobnosti rada u timu. Nicolescu i Nicolescu (2019), koji su izučavali razvoj prijenosnih vještina (engl. transferable skills) u obrazovanju menadžmenta, navode da se one sukladno namjeni i zahtjevima mogu podijeliti na individualne i socijalne. Dok individualne uključuju npr. motivaciju i upravljanje vremenom, socijalne podrazumijevaju komunikativnost i vođenje tj. rad u timu, oralnu i pisanu komunikaciju te sposobnost slušanja, povezivanja ideja i vlastitog izražavanja, prezentacijske sposobnosti i sposobnost prikladnog ponašanja te sposobnosti vođenja i mentoriranja. Odnosno, u istraživanju im se kao pouzdan predstavio mjeritelj prijenosnih socijalnih vještina koji uključuje komunikativnost, prezentiranje te vođenje, mjerenih kroz sljedeće tri čestice: „Mogu slušati i dobro komunicirati s drugim ljudima“, „Znam kako jasno komunicirati svoje ideje usmeno i pismeno“ i „Mogu uvjeriti druge ljude da slijede moje ideje“. S obzirom na ulogu kontrolera i značaj pismenih, oralnih i prezentacijskih vještina u izradi outputa, ali i činjenice da brojni autori oralnu i pismenu komunikaciju smatraju ključnom osobinom

zaposlenika općenito (Nelson *et al.*, 1996; Morgan, 1997; DeLange *et al.*, 2006, itd. u Kavanagh i Drennan, 2008), dio prijenosnih socijalnih vještina koji se odnose na komunikativnost i sposobnost prenošenja poruka te uvjeravanja, smatraju se bitnim čimbenikom od utjecaja na kontrolerovu kvalitetu outputa.

3.2.1.3. Asertivnost

Iako se na asertivnost može gledati kao na vrstu komunikacije, kao ljudska kompetencija svrstava se u interpersonalnu vještinu koja podrazumijeva uvažavanje sebe, ali i drugih. Asertivnost „je oblik ponašanja koji se određuje kao borba za svoja prava i izražavanje mišljenja na izravan način, te odbijanje nerazumnih zahtjeva, bez osjećaja straha i krivnje“ (Zaverski i Mamula, 2009, u Balent, 2018, str. 69). To je sposobnost „jasnog i odlučnog izražavanja vlastitih potreba, interesa, stavova i mišljenja, bez straha od eventualnih negativnih reakcija okoline“ (Meter i Pureta, 2016, str. 18) tj. sposobnost iskrenog izražavanja vlastitih mišljenja, osjećaja i stavova na način koji ne krši prava drugih. Osobe koje su visoko kooperativne i asertivne su sobe koje karakterizira spremnost na suradnju, koje poštuju odnos s ljudima i koje u drugoj strani vide partnera, a ne suparnika (Balent, 2018). Upravo zato asertivnost predstavlja bitnu karakteristiku kontrolera. Naime, kako bi kontroler svoje outpute učinio kvalitetnima i u konačnici imao utjecaj rad menadžera i odlučivanje, mora biti sposoban jasno izražavati i podržavati svoje stavove o dobivenim rezultatima i prijedlozima unaprjeđenja. Mora biti sposoban pružiti menadžmentu konstruktivne kritike, ali istodobno uvažavati tuđa mišljenja.

U znanstvenim istraživanjima, asertivnost se često veže uz stilove vođenja. Tako, na primjer, Hede (2005) za mjerenje asertivnosti primjenjuju tzv. mjeritelj „Conflict Management Style“, koji podrazumijeva da su asertivne osobe one koje se drže vlastitog mišljenja, koje ne popuštaju u nesuglasicama i koje u konfliktima uvijek pokušavaju biti u pravu. Svjetski poznata je i tzv. „Socio Communicative Style Scale (SCS)“ mjerna ljestvica postavljena 1990. tj. 1996. godine od Richmond i McCroskey (2013), a koja mjeri odgovornost i asertivnost na temelju dvadeset čestica. Pri tome se asertivnost mjeri kroz sljedeće čestice: branjenje vlastitih uvjerenja, neovisnost, silovitost, jaka osobnost, asertivnost, dominantnost, zauzimanje stava, djelovanje kao vođa i natjecateljski duh. Nadalje, Mitamura (2018) je razvio tzv. „Functional Assertiveness Scale (FAS)“ mjeritelj koji podrazumijeva da se

funkcijska asertivnost sastoji od dvije komponente: objektivna djelotvornost i pragmatična pristojnost. Objektivnost pri tome podrazumijeva onaj dio asertivnosti izražavanja vlastitih mišljenja i stavova, dok pragmatičnost dio uvažavanja i poštivanja drugih. Navedeno podržava definiciju asertivnosti kao sposobnosti izražavanja onog što želimo, trebamo i mislimo uz poštivanje drugih - čak i kada je to teško (Gaumer Erickson i Noonan, 2018). Instrument koji je također zasnovan na takvom definiranju asertivnosti i koji najbolje odražava mjerenje potrebnog ponašanja kontrolera kreirali su Timmins i McCabe (2005) u području zdravstva. Iako relativno novi instrument i uglavnom primjenjivan u području zdravstva i obrazovanja, potvrdio se kao instrument visoke pouzdanosti. Sukladno navedenom, asertivnost je pored komunikacijskih vještina neizbježiva karakteristika kontrolera. Odnosno, iako ju Sathe (1983) ne predstavlja kao kompetenciju „jakog" kontrolera, pojedina istraživanja i njena sama definicija ukazuje na važnosti njenog uvažavanju i usvajanja od strane kontrolera.

3.2.1.4. Proaktivnost i kreativnost

Ako se gleda današnje digitalno okruženje onda se zasigurno može konstatirati da je proaktivnost i s tim povezana kreativnost jedna od glavnih obilježja kontrolera u procesu poslovnog odlučivanja. Proaktivnost se može nazvati „gledanje unaprijed" ili „neprekidna samoinicijativa" koja je usko povezana sa sposobnošću kreativnog razmišljanja i kreativnom sposobnosti. Proaktivnost se može definirati kao osobno poduzimanje potrebnih aktivnosti u svrhu rješavanja problema (Meter i Pureta, 2016) ili osobnost koja podrazumijeva sklonost pojedinca na aktivnu orijentaciju pokretanja promjena (Bateman i Crant, 1993). Ahmad i Al-Shbiel (2019), koji navode da uspjeh poduzeća znatno ovisi o kvaliteti i uspješnosti kontrolera, naglašavaju sve veću potrebu za proaktivno usmjerenim kontrolerima koji su spremi nositi se s uzbudljivim izazovima budućnosti. Odnosno, kako ističe Listeš (2019, str. 39), „kvalitetna poslovna odluka doći će ako je osoba znatiželjna da detaljno analizira trendove po kategorijama kupaca i po različitim pakiranjima svih proizvoda te ako je dovoljno kreativan da te podatke usporedi s tržišnim podacima, tržišnim udjelima i nekim ekonomskim pokazateljima". Kreativnost označava u kojoj mjeri zaposlenik razvija ideje i pokazuje inovativno ponašanje u izvršavanju dodijeljenih zadataka (Wang i Netemeyer, 2004). Važnost kreativnosti potvrdilo je i istraživanje LinkedIn-a (2019, u Filipčić, 2019) u kojem su menadžeri upravo nju stavili na prvo mjesto po značajnosti pri zapošljavanju osoba.

S obzirom na to da kreativnost podrazumijeva sposobnost generiranja novih ideja, kontroleru kao pružatelju usluga proizašlih iz analiza postojećih podataka, predstavlja bitan faktor uspjeha. Pri tome treba imati na umu da kreativnost, kako mnogi misle, nije „urođena“ kompetencija. Dapače, Balent (2018) navodi kako osobe koje upišu različite tečajeve da vrlo brzo uvide da je kreativnost promjenjivi koncept koji ljudima omogućuje izražavanje vlastitog kreativnog potencijala.

Proaktivna sposobnost jedna je od često ispitivanih pojava, bilo u pogledu uspjeha u karijeri (Seibert *et al.*, 1999), radnog učinka (Gerhardt *et al.*, 2009; Joharia i Subramaniamb, 2018; Joo i Bennett III, 2018), posvećenosti poduzeću (Joo i Bennett III, 2018), itd. Odnosno, kreativnosti i njenoj uskoj povezanosti s proaktivnosti također se pridaje značajna važnost u znanstvenim istraživanjima (Kim *et al.*, 2010; Horng *et al.*, 2016; Joo i Bennett III, 2018; Pan *et al.*, 2018). Uvidom u brojna istraživanja može se uvidjeti da se proaktivnost i kreativnost kao ljudske osobine najčešće istražuje pomoću mjeritelja koje su postavili Bateman i Crant (1993) i Seibert *et al.* (1999) te Zhou i George (2001). Pri tome proaktivnost najčešće uključuje sedamnaest tj. deset čestica kao npr. „Ako uočim nešto što mi se ne sviđa popravim to.“, i „Uvijek tragam za boljim načinima rješavanja problema.“, dok se kreativnost mjeri s trinaest ili pet kao npr. „Dobar je izvor kreativnih ideja“ i „Predlaže nove načine za ostvarenje ciljeva. Značaj primjene takvih mjeritelja u kontrolingu naglasili su Fourné *et al.* (2018), a osobitu pažnju pridaju upravu Bateman i Crant (1993) konstruktu proaktivnosti navodeći da menadžeri sve više očekuju da kontrolori, posebno oni na višim hijerarhijskim razinama, proaktivno s njima dijele i raspravljaju o utemeljenim informacijama. Stoga se proaktivnost, pored kreativnosti, uzima kao jedna od osnovnih karakteristika kontrolera u ostvarenju kvalitetnih outputa i utjecaj na donošenje odluka.

3.2.2. Karakteristike menadžera

Menadžment se može definirati kao „proces planiranja ciljeva, organiziranja resursa i aktivnosti, te upravljanja ljudskim potencijalima i kontroliranja, kojim se kontinuirano postižu efikasne kombinacije ograničenih resursa i ljudskih potencijala za efektivno postizanje organizacijskih ciljeva u promjenjivoj okolini.“ (Zekić, 2007, str. 51). Menadžer je osoba koja je zaduženja za izvršavanje to uloge. Odnosno, prema Mintzbergu menadžment ima tri ključne uloge, odnose se na međuljudske odnose, informiranje i donošenje odluka. Iako se značaj pojedinih ulog kao i potrebnih vještina razlikuje s obzirom na razinu hijerarhijske strukture, poznato je da odlučivanje predstavlja glavni proces menadžmenta koji može rezultirati dobrim poslovnim odlukama jedino uz kvalitetnu informacijsku podlogu. Kao funkcija potpore menadžmentu, tu podlogu osigurava kontroling tj. kontroler. Međutim, da bi kontroler mogao pružiti kvalitetne outputе u svrhu odlučivanja potrebna je prije svega razumijevanje i suradnja menadžera i kontrolera. Razumijevanje podrazumijeva razgraničenje ovlasti i delegiranja zadataka, a suradnja njihov međusobni partnerski odnos. Stoga je bitno da menadžeri posjeduju karakteristike koje omogućavaju kontroleru da postane partnerom menadžeru. Pravilno vođenje, iniciranje i motiviranje te poticanje proaktivnoga i ciljno usmjerenog djelovanja ljudskog potencijala presudni su čimbenici djelotvornog načina rješavanja problema i razvoja poduzeća. Odnosno, kako navodi Zekić (2007) orijentacija na intelektualni kapital tj. poticanje kreativnosti, inovativnog i ciljno usmjerenog djelovanja presudni je čimbenik vitalnosti poduzeća i jedini djelotvoran način rješavanja kompletnih problema s kojima se suočava suvremeni menadžment, a što uključuje i kontroling kao potporu menadžmentu, razvijenu prije svega kao odgovor na povećanu potrebu za koordiniranjem unutar kompleksnog suvremenog poduzeća.

Još od začetaka razvoja menadžerske teorije do danas opće je poznato da menadžeri moraju posjedovati kompetencije u području donošenja odluka. (Boyatzis, 1982, u Carson i Gilmore, 2000). Međutim, kako navode Carson i Gilmore (2000), jedinstveni skup kompetencija primjenjivih na sve menadžerske poslove ne postoji. Iako tvrde da se niti jedan menadžerski posao ne može u potpunosti opisati određenim skupom kompetencija, u svom radu ističu mišljenja Buchanon i Boddy iz 1992, te Smitha i suradnika iz 1989., koji tvrde da su menadžerske tj. upravljačke kompetencije u velikoj mjeri specifične za određenu situaciju i da ih se stoga treba razvijati tako da odgovaraju različitim i promjenjivim okolnostima. Navedeno potvrđuje Ghosh (1999), prema kojem menadžeri moraju imati odgovarajuće

vještine sukladno funkciji koju izvršavaju: 1) Planiranje - vještine donošenje odluka, 2) Usmjeravanje, nadzor i organiziranje - vještine vođenja, 3) Motiviranje - međuljudske vještine, 4) Pregovaranje - komunikacijske vještine i 5) Inoviranje - konceptualne vještine. Stoga je za pretpostaviti da menadžeri kao utjecajni čimbenik kvalitete kontrolerovih outputa posjeduju prikladni set kompetencija u vidu motivacije, vođenja te uvažavanja, kao i budućeg usmjerenja ka ostvarenju postavljenih ciljeva, a kojim potiču kontrolere i osiguravaju njihovo efektivno djelovanje

Brojne su klasifikacije menadžerskih kompetencija. Bahtijarević-Šiber *et al.* (2008), klasificirali su ih u četiri kategorije: osobne, interpersonalne, komunikacijske i grupne vještine. Hersey i Blanchard (1977, u Ghosh, 1999) navodi da postoje najmanje tri područja vještina potrebnih za provođenje procesa upravljanja, a koje i Katz (1974, u Sikavica i Bahtijarević-Šiber, 2004) navodi kao osnovne menadžere vještine kroz čiju kombinaciju menadžeri ostvaruje svoju upravljačku ulogu:

- tehnička i stručna znanja i vještine (specijalizirana znanja određene struke; analitičke sposobnosti određene specijalnosti te znanje specijalnih metoda, modela i tehnika)
- socijalna znanja ili znanja ophođenja s ljudima (sposobnost komuniciranja, motiviranja usmjeravanja i vođenja pojedinaca i grupe; sposobnost izgradnje odnosa suradnje i timskog rada; stvaranje ozračja sigurnosti i podrške)
- konceptualna znanja i vještine tj. znanje oblikovanja ili strategijska znanja (sposobnost stvaranja vizije budućnosti; sagledavanje poduzeća kao cjeline; sposobnost sagledavanja djelovanja promjena u okolini).

Sukladno Katzovoj klasifikaciji, Sikavica i Bahtijarević-Šiber (2004) su u istraživanju među hrvatskim poduzećima došli do saznanja da uspješnost menadžmenta ovisi najviše o sposobnosti, znanju i vještinama menadžera, ali i njihovih suradnika. Odnosno, rezultati istraživanja ukazuju da menadžeri moraju posjedovati karakteristike vođe, kao npr. usmjerenost na budućnost, inspiriranje suradnika, umijeće komuniciranja s ljudima, intuicija za provođenje promjene, poznavanje samog sebe, itd. Međutim, pored navedenih, od menadžera se očekuje da posjeduju i pojedina specifična (npr. timski rad, poznavanje poslovanja, motiviranje zaposlenika, prevođenje primjena, itd.) i individualna znanja (npr. stručnost, brzina odlučivanja, predviđanje, itd.), a kao poželjne osobine ističu se također poštenje, odlučnost, poslovnost, objektivnost, entuzijazam, osobna kultura ponašanja, samostalnost, snalažljivost, kritičnost i hrabrost. Carson i Gilmore (2000) definiraju dvije

vrste menadžerskih kompetencija: tehničke ili one povezane s donošenjem odluka. Pri tome, pod vještine donošenjem odluka podrazumijevaju se „konceptualne kompetencije, opisane kao mentalna sposobnost koordinacije svih interesa i aktivnosti organizacije (Pavett i Lau, 1983; Schein, 1987); ljudska kompetencija, odnosno sposobnost rada s drugim ljudima, njihovo razumijevanje i motiviranje, kako pojedinačno, tako i u skupinama; i politička kompetencija koja može uključivati sposobnost jačanja položaja tvrtke, izgradnje baze moći i uspostavljanja pravih veza (Pavett i Lau, 1983)“ (u Carson i Gilmore, 2000, str. 366). Nadalje, Bhardwaj i Punia (2013) su temeljem detaljnog literaturnog pregleda menadžerskih kompetencija došli do zaključka da su komunikacijske vještine, timski rad, proaktivnost, vizija, samoupravljanje, orijentacija na rezultat, strateška orijentacija, ambicija, ustrajnost, donošenje odluka, preuzimanje rizika i kreativnost, najčešće posjedovane kompetencije uspješnih i učinkovitih menadžera. Odnosno, prema Omarli (2017) proces donošenja odluka pod utjecajem je psiholoških čimbenika poput percepcije, intuicije, motivacije, emocija i međuljudska interakcija.

Musso i Francioni (2012) su u svom modelu utjecaja karakteristika donosioca odluka na strateško odlučivanje unutar malih i srednjih poduzeća uključili četiri vrste čimbenika: osnovne kompetencije (racionalnost, intuicija, iskustvo), osobne karakteristike (potreba za postignućem i stav prema riziku), socio-demografske karakteristike (obrazovanje i poznavanje jezika) i vrstu donosioca odluke (vlasnik ili menadžer). Iako se osobne karakteristike nisu dokazale kao značajni prediktori u ovom slučaju, smatra se da bi kao čimbenici od utjecaja na rad kontrolera mogli biti značajni, a osobito potreba za vlastitim postignućima. Isti model Musso i Francioni (2013) te Francioni *et al.* (2015) istražili su u modificiranom obliku u 2013. i 2015. godini, uz isključenje osnovnih i socio-demografskih kompetencija i uključivanje tzv. „locus of control“ i preferencija za inovacije te vanjskih utjecajnih obilježja. Jedino je istraživanje iz 2015. potvrdilo djelomični utjecaj osobnih kompetencija na odlučivanje. Značaj istraživanja obilježja „locus of control“, potrebe za ostvarenjem i stava prema riziku kod menadžera ističu i druga istraživanja (npr. Papadakis, 2006). Da menadžerska obilježja imaju pozitivni utjecaja na kvalitetu financijskog izvještavanja potvrdila su brojna istraživanja koja u svojem radu prikazuju Habib i Hossain (2013), naglašavajući prekomjerno samopouzdanje, sposobnost predviđanja budućih događaja i ostvarenja pozitivnog financijskog učinka i reputaciju.

Prema istraživanju Sathe (1982), tri glavne kompetencije utječu pozitivno na razinu kontrolerove uključenosti u donošenju odluka. To su, očekivanja koje menadžeri imaju od kontrolinga, financijska pozadina (obrazovanje i/ili dugogodišnje radno iskustvo u kontrolingu) i orijentacija menadžera. Iako dosadašnja istraživanja ne uključuju taj dio Satheovog modela, u teoriji kontrolinga općeprihvaćena je činjenica da uspješnost poslovanja i razina kontrolerove suradnje s menadžmentom ovisi o stavu i karakteristikama menadžera (Osmanagić Bedenik, 1998; Očko i Švigir, 2009; Vitezić, 2016; Meter i Šarčević, 2018). Prema, Šimić (2015) odlučivanje menadžmenta gotovo u jednakoj mjeri ovisi o njihovim vlastitim karakteristikama, situaciji i karakteristikama suradnika. Sukladno najnovijem istraživanju koje su proveli Meter i Šarčević (2018) na području RH, od menadžera se očekuje da bolje razumiju važnost kontrolinga, da imaju veće povjerenje u njega, i da se angažiraju na poboljšanju međusobne komunikacije te stupnja educiranosti međuovisnih znanja. Osim toga, Feeney (2007) je u svojem istraživanju došla do saznanja da menadžeri mogu utjecati na ulogu kontrolera kroz svoja očekivanja, upravljačko usmjerenje (engl. focus), nezavisnost i međusobni odnos spram njega. Rante i Warokka (2016) istraživali su ulogu menadžerskog informacijskog sustava (MAS) kao medijatora između stila vođenja i učinka menadžera. Odnosno, potvrdili su utjecaj stila vođenja na MAS i posljedično na kvalitetu rada menadžera.

Dakle, kao i kod kontrolera, tijekom godina razvile su se brojne klasifikacije menadžerskih kompetencija. Među njima se ističu sljedeće, a koje se ujedno mogu smatrati presudnima za međusobni odnos rada kontrolera i menadžera: sposobnost rada s drugim ljudima, razumijevanje i motiviranje drugih, komunikacijske vještine, timski rad, proaktivnost, vizija, samoupravljanje, orijentacija na rezultat, strateška orijentiranost, racionalnost, intuicija, iskustvo, potreba za postignućem i stav prema riziku (Carson i Gilmore, 2000; Musso i Francioni, 2012; Bhardwaj i Punia, 2013, itd.). Gledano s psihološke strane, može se reći da menadžeri sa svojim osobnim, socijalnim i demografskim karakteristikama utječu na rad zaposlenika općenito, a posebno na one o kojima direktno ovisi njihova realizacija, kao što je kontroling. Osim toga, poznato je i empirijski potvrđeno da motivacija, samomotivacija, osobnost i emocionalna inteligencija utječu na učinkovitost rada zaposlenika (Sujiati *et al.*, 2017; Vijayabanu i Arunkumar, 2018; Jamada i Ainebyona, 2019, itd.). Sukladno, menadžeri s kojima kontroler surađuje imat će zasigurno utjecaj na razinu kvalitete kontrolerovog outputa. Prema dosadašnjim istraživanjima izdvojene su tri osnovne „meke“ karakteristike menadžera: *vođa i inicijator, uvažavanje kontrolera te proaktivan i cilju usmjeren.*

3.2.2.1. Vođa i inicijator

U odnosu kontrolera i menadžera kao poslovnih partnera bitno je da kontroler bude motiviran tj. da menadžer kroz ulogu vođenja i iniciranja utječe na radni učinak kontrolera. Menadžeri moraju biti lideri koji kroz odabrani stil vođenja utječu na način na koji zaposlenici obavljaju svoj posao (Brennan, n.d.). Kako ističu Ali *et al.* (2017, str. 4) pozitivni stil vođenja „motivira zaposlenike da gledaju dalje od vlastitih interesa i razmišljaju izvan okvira u pogledu svojih rutinskih zadataka (Sethibe i Steyn, 2015; Kacem i Harbi, 2014)“ , „potiče pojedince na daljnje razmišljanje, gledanje na probleme iz različitih kutova (Matzler *et al.*, 2008)“, i pomaže zaposlenicima u postizanju postavljenih ciljeva. U literaturi se javljaju mnogi stilovi vođenja: autokratsko, demokratsko, vođenje „odriješenih ruku“, kontingencijsko, situacijsko, e-vođenje, transakcijsko, krizno, autentično, karizmatično, etičko, itd. (Zekić, 2007; Carasco-Saul *et al.*, 2015; Rupčić, 2018). Međutim najčešće korišteni u dokazivanju pozitivnih odnosa između stila vođenja i razine radnog angažmana zaposlenika (Ghadi *et al.*, 2013; Monje Amor *et al.*, 2020), radnog učinka zaposlenika (Wardhani, 2017), kao i u pojedinim istraživanjima u području kontrolinga (Nguyen *et al.*, 2017; Phornlaphatrachakorn, 2019) je tzv. transformacijsko vodstvo (Carasco-Saul *et al.*, 2015). Ono podrazumijeva vođe tj. menadžere koji motiviraju zaposlenike ka postizanju učinaka iznad očekivanja kroz poticanje stavova, uvjerenja i vrijednosti zaposlenika te prepoznavanje i priznanje njihovog rada. Obzirom da učinak kontrolera značajno ovisi o njegovom odnosu spram menadžera tj. pozitivnom odnosu menadžera spram kontrolera, stil vođenja koji podrazumijeva motiviranje i iniciranje uzima se kao bitni faktor od utjecaj na kontrolerove aktivnosti.

3.2.2.2. Uvažavanje kontrolera

Prema tzv. pokazateljima kompetencija upravljanja stresom (engl. Stress Management Competencies Indicator Tool - SMCIT) koje su postavili Yarker i suradnici u 2008 godini, menadžeri moraju biti odgovorni i poštivati druge, biti sposobni upravljati teškim situacijama i komunicirati trenutne i buduće događaje. Koristeći se navedenim instrumentom, Toderi i Balducci (2018) su dokazali pozitivni utjecaj tih karakteristika na dobrobit zaposlenika, a što bi se dalje moglo povezati s rezultatima istraživanja Lee i Ravichandran (2019), koji su dokazali da dobrobit zaposlenika pozitivno utječe na njihov radni učinak. Sukladno navodima Meter i Šarčević (2018), da se od menadžera očekuje da više razumiju i prihvate kontroling, navedena kategorije SMCIT modela koja se odnosi na odgovornost i poštivanje drugih može

se smatrati kao bitan faktor utjecaja na rad kontrolera. Odnosno, efektivno ili učinkovito vođenje može se postići jedino kada su menadžeri i zaposlenici u stanju razviti i održavati visokokvalitetne odnose i shvatiti koristi takvog partnerstva. To se ostvaruje kroz povjerenje, poštivanje i međusobne zadatke koje stvaraju ovisnost između partnera (Graen i Uhl-Bien 1991, 1995, u Hassan i Hatmaker, 2015). Preduvjet za uspješan kontroling je da bude zaista željen od strane menadžera. Treba postojati povjerenje između kontrolera i menadžera (Hirsch *et al.*, 2015) tj. menadžer mora imati povjerenje u kontrolerova rad (Nitzl i Hirsch, 2016). Način za postizanje takvog odnosa je prije svega poštivanje kontrolera kao poslovnog partnera tj. kontroling kao informativnu i savjetodavnu funkciju i profesiju. Takav učinak dokazan je od strane Clarke i Mahadi (2017) tj. Clarke *et al*. (2019), pri čemu tzv. profesionalno/ocjenjeno poštovanje (engl. professional respect/appraisal respect) definiraju kao stupanj do kojeg pojedinac prepoznaje i divi se poslovno povezanim kompetencijama i znanjima drugih osoba. Pri tome pod poslovnim partnerom podrazumijeva se da je kontroling u konstantnom kontaktu s menadžmentom u svrhu donošenja poslovnih odluka (Schäffer, 2017) i da kao proaktivni sunositelj odgovornosti i predlagač promjena kroz dubinsku analizu informacija inicira i vodi promjene unutar poduzeća (Deinert, 2013). Odnosno, da je kontroling kao odnos menadžera i kontrolera orijentiran ka zajedničkom ostvarenju ciljeva pri čemu menadžer nosi potpunu odgovornost za rezulatate ali ima i ulogu motivatora, a kontroler odgovara za integritet podatka te ispravnost i pouzdanost kreiranih outputa (Weber i Schäffer, 2014). Jedino prihvaćanjem kontrolinga kao značajne funkcije i možebitne profesije od strane menadžera može se osigurati najveća razina efektivnosti kontrolera u pogledu ostvarenje uloge poslovnog partnera.

3.2.2.3. Proaktivan i cilju usmjeren

Ross (2014, u Steyn i Van Staden, 2018) navodi da su motivirani menadžeri usmjereni na ciljeve jer ciljevi nude fokus, a postizanje tih ciljeva predstavljaju postignuća koja ujedno doprinose pozitivnom stavu. Točnije autor navodi da svaka karijera i posao određuju osobu na jedan od dva načina: ili je osoba proaktivna i cilju usmjerena ili ima želju zadržavati „status quo“. Odnosno, kako navode Ohly i Fritz (2007), proaktivno ponašanje podrazumijeva unapređenje trenutnog stanja tj. izazivanje „status quo-a“. Ako se na menadžere gleda kao na osobe koje su odgovorne za odlučivanje, koje mogu jedino konstantnim unaprjeđenjem sebe i poticanjem drugih utjecati na ostvarenje pozivnih učinaka za poduzeće, jasno je da se ne

mogu odlučiti za „status quo“ opciju. Menadžeri moraju poprimiti proaktivnu ulogu u svrhu ostvarenja ciljeva. To potvrđuju i Shirazi i Mortazavi (2009) koji su u svojem radu upravo proaktivnost navode tj. dokazuju kao jednu od šest najznačajnijih karakteristika učinkovitog menadžera. Osim toga, usmjerenost cilju ima snažan utjecaj na radnu uspješnost i kreativnost jer određuje načine samoregulacije zaposlenika, uključujući trud, samo-postavljene ciljeva, traženje povratnih informacija, ustrajnost i želju za usavršavanjem, itd. (Brett *et al*., 2016, u Bakker *et al.,* 2020). Preenen *et al.* (2014) potvrdili su da ciljna usmjerenost nadređenih ima utjecaj na zadatke koje odrađuju njihovi zaposlenici. Odnosno zaključili su da ciljna usmjerenost jedne osobe može imati značajan utjecaj na učinke druge ako te dvije osobe imaju izrazito ovisan odnos, što je obično slučaj u odnosima nadređeni-podređeni. Do sličnih zaključaka došli su i drugi autori, a osnova je da ciljna usmjerenost ima pozitivan utjecaj na radni učinak zaposlenika (npr. Sijbom *et al.*, 2015). Jednom riječju proaktivnost i usmjerenost ka ciljevima mogu se nazvati osobnom inicijativom (Frese *et al., 1997).* Obzirom da današnji kontroler mora više nego ikada biti usmjeren na budućnost, za očekivati je da će proaktivna usmjerenost menadžera prema ciljevima imati značajnu povezanost s razinom kvalitete outputa koje im pruža kontroler. Stoga se za efikasno ostvarenje aktivnosti kontrolera, proaktivnost i ciljna usmjerenost smatraju značajnom karakteristikom menadžera.

3.2.3. Karakteristike poduzeća

Prema Eren (2001, u Omarli, 2017) glavni organizacijski faktori nekog poduzeća su tehnologija, organizacijska struktura i interni odnosi te definirani ciljevi, strategije i planovi. Prema Sathe (1982) kritičnost financijskog upravljanja, intenzitet kapitalne imovine i radne imovine predstavljaju glavne utjecajne faktore karakteristika poduzeća kontrolerove uključenosti u donošenju odluka, dok Zoni (2017) glavnim organizacijskim čimbenicima pak smatra kulturu, položaj u organizaciji, povjerenje/vjerodostojnost i interni odnos među zaposlenicima. Haldma i Lääts (2002, u Lindelöf i Löfsten, 2006) navode da su veličina organizacije, tehnologija i strategija poduzeća najčešći interni faktori povezani s dosadašnjim istraživanjima u području kontrolinga. Prema Rosenzweig (1981) na odjel kontrolinga kao funkcije unutar organizacijske strukture, utječe kompleksnost poduzeća i razina administrativnog mehanizma (tj. razina propisanih procedura, propisa, itd.). Ghasemi, *et al.* (2015), koji su istraživali utjecaj strategije na kontroling, ističu da se svi organizacijski elementi kao što su npr. struktura, strategija, ljudi i kultura moraju razvijati i mijenjati jednako kroz vrijeme kako bi se osigurala efektivnost ukupne organizacije a time i kontrolinga. Cadez u Guilding (2012) tvrde da formalne strategije (engl. deliberate) rezultiraju u većoj uključenosti kontrolinga u strateškom odlučivanju. Odnosno, Erhart *et al.* (2017) tvrde da snažno uključeni odjel kontrolinga može utjecati na proces formiranja organizacijske strategije. Prema Chen i Huang (2007) organizacijska struktura, kultura, zajednička uvjerenja i sustavi vrijednosti koje slijedi organizacija imaju značajan utjecaj na uspješnost upravljanja. Prema Melnyk *et al.* (2013, u Yigitbasioglu, 2017) kontroling se smatra efektivnim kada se uklapa u okruženje i postavljenu strategiju. Luft i Shields (2003, u Erhart *et al., 2017*) ističu da strategija utječe na razinu korištenja kontrolerovih informacija, dok su Jermias *et al.* (2018) otkrili da je neusklađenost među poslovnom strategijom, stilom vođenja, organizacijske kulture i menadžerskog informacijskog sustava negativno povezane s financijskim i nefinancijskim učinkom poduzeća. Prema Omarli (2017) menadžerski proces donošenja odluka pored psiholoških i osobnih te faktora iz okruženja, ovisi i o menadžerskom informacijskom sustava, kojeg definira kao jednu vrstu tehnološkog sredstva u donošenju odluka. Navedeno podržavaju i brojna druga istraživanja. Sejdić (2019) kao i Vitezić i Lebefromm (2019) te mnogi drugi autori sve više ističu ulogu digitalizacije tj. digitalne transformacije u području kontrolinga. Sjedić (2019) naglašava da se kontroling jedino uz prilagodbu i primjenu digitalnih tehnologija može prilagoditi aktualnim i budućim trendovima i tako osigurati efektivnost izvršavanja svoje uloge poslovnog partnera.

Postoje brojni stavovi o tome koje karakteristike poduzeća su najbitnije u pogledu uključenost zaposlenika, njihovog radnog učinka, utjecaja na uspješnost poslovanja, itd. Međutim, ako se uzme u obzir kontrolerova uloga u donošenju poslovnih odluka koja se realizira kroz izradu kvalitetnih izvještaja, analiza, prezentacija i savjetovanja, a sukladno istraživanjima, onda se mogu izdvojiti sljedeće četiri karakteristike: *strateška orijentiranost, organizacijska formalizacija, kvaliteta informacijskog sustava i digitalna transformacija*.

3.2.3.1. Strateška orijentiranost

Strateška orijentiranost može se definirati kao opcija koja može dinamički stvarati mogućnosti u poslovnom okruženju koje se stalno mijenja, a koje omogućuje tvrtkama da brzo odgovore na te promjene. Da strateška orijentiranost ima utjecaj na kontroling potvrdila su pojedina istraživanja. Tako su Löfsten i Lindelöf (2005) potvrdili da strateška orijentiranost ima značajan učinak na važnost kontrolinga, odnosno Pasch (2019) je potvrdio da razlike u strategiji poduzeća u pogledu važnosti pojedinih stavki naspram konkurenta imaju pozitiv utjecaj na ulogu kontrolera kao poslovnog partnera. Zoni (2017) je dokazala da formalizacija strateških planova i procesa budžetiranja ima utjecaj na kontrolerovu uključenost na strateškoj razini odlučivanja, dok su Ghasemi *et al.* (2015) dokazali da strategija poduzeća ima pozitivni utjecaj na menadžerski informacijskog sustav (MAS) i da on posljedično pozitivno utječe na uspjeh poduzeća. Ako se uzmu u obzir rezultati istraživanja Otache (2019), provedenog temeljem definiranog koncepta strateške orijentiranosti postavljenog od strane Weinzimmer *et al.* (2012), u kojem je potvrđen utjecaj strateške orijentiranosti na uspješnost poslovanja direktno i preko varijable timskog rada, može se pretpostaviti da će strateška orijentiranost imati pozitivni učinak na kvalitetu kontrolerovog rada obzirom da je ona ovisna djelomično i o suradnji kontrolera i menadžera. Kada su u pitanju strateški pravci razvoja onda kod većine poduzeća utjecaj ima vlasnika koji je određuje, karakteristike osobnosti pri tome nisu važne koliko suradnja. Kroz godine, razvili su se brojne definicije i mjeritelji strateške orijentirati poduzeća (vidi Weinzimmer *et al.*, 2012), međutim među najnovijima može se istaknuti mjeritelj kreiran od strane Weinzimmer *et al.* (2012), koji se konceptualno razlikuje od ostalih, ali koji na sveobuhvatan način objedinjuje bitne elemente strateške orijentiranosti poduzeća. Odnosno, ne definira se kao vrsta strategije (npr. agresivna, defenzivna) već kao skup postavljenih ciljeva, planova i strategija poduzeća,

koji kao takvi u praksi zasigurno usmjeravaju kontroling pri izradi outputa tj. analiza i izvještaja.

3.2.3.2. Organizacijska formalizacija

Iako se organizacijska struktura ističe kao značajan faktor efektivne prakse kontrolinga u literaturi se još uvijek naglašava oskudnost istraživanja njenog utjecaja na organizacijsku uspješnost (Elnihewi *et al.,* 2015). Odnosno, Shahzad *et al.* (2018) potvrdili su da organizacijska struktura ima direktni pozitivni utjecaj na psihološko osnaživanje zaposlenika, koje se prema Conger i Kanungo (1988, u Shahzad *et al*., 2018) može definirati kao odnos zaposlenika prema poslu i ulozi u organizaciji. Osim toga, istraživanja u području psihologije potvrdila su da psihološko osnaživanje ima pozitivan učinak na stav prema poslu koje posljedično dovodi do ponašanja koji su ključni za organizacijski uspjeh. Navedenu teoriju primijenili su i Wolf *et al.* (2015) istražujući utjecaj ponašanja kontrolora, tj. stava i subjektivne norme, na doprinos odjela kontrolinga i poboljšanje interne efikasnosti i procesa. Dakle, ako se zna da organizacijska struktura ima utjecaj na osnaživanje zaposlenika, da se osnaživanje može promatrati kao stav kontrolera, da stav prema poslu dovodi do ponašanja koje utječe na organizacijski uspjeh direktno ili kroz doprinos kontrolera, za pretpostaviti je i da postoji izravan učinak organizacijske strukture na doprinos kontrolinga tj. kvalitetu njegovih outputa. Navedeno se može povezati i s istraživanjem Hammad *et al. (*2013) koje je potvrdilo da decentralizacija ima pozitivan utjecaj na MAS i posljedično menadžerski učinak. Nadalje, Ahmetoglu *et al.* (2019) potvrdili su pozitivnu vezu između organizacijske strukture, u vidu formalizacije i veličine, te radnog učinka tj. negativnu vezu centralizacije kao organizacijske karakteristike i radnog učinka. Chen i Huang (2007) potvrdili su da su interakcije među članovima pojedine organizacije bolje kada je organizacijska struktura manje formaliziran, manje centralizirana, a više integrirana. Nitzl i Hirsch (2016) su pak potvrdili da formalizacija organizacijske strukture ima pozitivan utjecaj na povjerenje menadžera u kontrolere, dok je Rosenzweig (1981) potvrdio vezu između veličine poduzeća i razine obrazovanja menadžmenta s dva organizacijska faktora - razinom kompleksnosti i razinom administrativnog mehanizma (razina propisanih procedura, propisa, itd.). Prema Kaštelan Mrak (2005) u tradicionalnom postupku izgradnje organizacijskih hijerarhija, temeljne odrednice ocjenjivanja i uspoređivanja predstavljaju stupanj složenosti, formalizacije i centralizacije. Kroz pregled istraživanja može se uočiti različitost klasificiranja i mjerenja

organizacijske strukture: centralizacija i formalizacija (Pugh *et al.*, 1968), centralizacija, formalizacija i integracija (Chen i Huang, 2007; Pleshko, 2007), centralizacija, formalizacija, specijalizacija (Sathe, 1978), decentralizacija (Hammad *et al.*, 2013; Rante i Warokka, 2016; Rouwelaar *et al.*, 2018), formalizacija (Mahlendorf *et al.*, 2012). Međutim, u pogledu kvalitete kontrolerovog outputa kao najznačajnija se može istaknuti formalizacija obzirom da definira pravila i procedure, sistematizaciju radnih mjesta, hijerarhijske razine autorizacije te nadzor na svakodnevnim operacijama, a što kontroleru prije svega osigurava dostupnost točnih i pravovremenih internih podataka.

3.2.3.3. Kvaliteta informacijskog sustava

Da informacijski sustavi imaju utjecaj na kontroling potvrdili su Weißenberger i Angelkort (2011). Istraživanje je potvrdilo da razina integriranosti menadžerskog informacijskog sustava (MAS) ima indirektni značajan utjecaj na kvalitetu kontrolerovih outputa i posljedično na njegov utjecaj na donošenje odluka. Pangaribuan (2016), Astuty (2015) i Anggadini (2014) su također dokazali da MAS utječe na kvalitetu kontrolerovih informacija tj. outputa, mjerenih kroz faktore sadržaja, vremena i oblika tj. značajnosti, točnosti, potpunosti, integracije, agregiranosti i širine sadržaja. Osim toga, brojna istraživanja potvrđuju značajnost uloge Enterprise Resource Planning systems (ERPS ili ERP) u poslovnom odlučivanju (npr. Lin, 2010) i veze s kontrolingom (Chou, Tripuramallu i Chou, 2005; Goretzki *et al.*, 2013; Gullkvist, 2013; Abbasi *et al.*, 2014; Gürtner i Krichbaum, 2014, itd.). Yigitbasioglu (2017) potvrđuje da fleksibilnost informacijskog sustava (IS) utječe pozitivno na prilagodljivost kontrolinga i posljedično na njegovu efektivnost. Da integriranost IS ima pozitivan utjecaj na kontroling u Hrvatskoj, dokazali su Pervan i Dropulić (2019); potvrdili su da kvaliteta implementacije IS-a značajno utječe na promjene povezane s prikupljanjem podataka i internim izvještavanjem. Sukladno razvoju različitih informacijskih sistema i terminologija (MIS, ERP, MAS, AIS, itd.) razvile su se i brojne definicije i mjeritelji za pojedine od njih. Međutim, u pogledu ukupne kvalitete nekog informacijskog sustava može se istaknuti primjena mjeritelja „kvaliteta sustava“ (pouzdanost, dostupnost, vrijeme obrade, fleksibilnost, integriranost i ukupna razina kvalitete) postavljenog od strane Nelson *et al.* (2005) tj. Wixom i Todd (2005). Naime u informatičkoj znanosti kroz brojna istraživanja potvrdila se pozitivna veza kvalitete sustava i kvalitete informacija, a čiju primjenu u području kontrolinga ističu Fourné *et al.* (2018).

3.2.3.4. Digitalna transformacija

Empirijska istraživanja koja uključuju digitalnu transformaciju i nove koncepte koji iz nje proizlaze (npr. Big Data, aplikacije, platforme, informacijski sustavi), a koji su usko povezani s utjecajem kvalitete informacijskog sustava na efikasnost rada zaposlenika i utjecaja na uspješnost poduzeća, uglavnom su ostvarene u području informatike, dok su u kontrolingu još uvijek zastupljeni u teorijskim modelima (Appelbaum *et al.,* 2017) i preporukama za istraživanje (Rikhardsson i Yigitbasioglu, 2018). Međutim, zbog sve većeg značaja koji se pridaje digitalnoj transformaciji kontrolinga (Sejdić, 2019; Vitezić i Lebefromm, 2019; Vitezić *et al.,* 2019) neophodno je usmjerenje istraživanja ka analizi utjecaja koncepata digitalne transformacije, prije svega zbog prednosti koje daju kontroleru u vidu realizacije svojih aktivnosti. Odnosno, istraživanja koja se mogu primijeniti kao podloga za provedbu istraživanja digitalne transformacije u području kontrolinga su ona provedena od strane Nwankpa i Roumani (2016) i El Hilali *et al.* (2020). Nwankpa i Roumani (2016) su u svojem radu dokazali da digitalna transformacija ima značajni pozitivni utjecaj na inovativnost i uspješnost poslovanja poduzeća, pri čemu digitalnu transformaciju definiraju kroz razinu primjene digitalnih tehnologija od strane poduzeća. Pod digitalnih tehnologijama podrazumijevaju društvene mreže, big data, poslovnu analitiku, „oblak“ (engl. cloud) i mobilnu tehnologiju. El Hilali *et al. (*2020) su potvrdili pozitivnu povezanost između upotrebe Big data i održivosti mjerene kroz utjecaj digitalne transformacije na pojedine elemente poduzeća kao na primjer, tržišne udjele, ekonomsku korist, imidž poduzeća, itd.. U pogledu kontrolinga, važnost digitalizacije ogleda se kroz dostupnost i mogućnost generiranja i analize raznovrsnih podatka koji mogu značajno pomoći u predviđanju i prognoziranju budućih događaja. Naime, podaci koji su dostupni unutar poduzeća danas nisu dostatni za ostvarenje i zadržavanje konkurentske prednosti poduzeća. Stoga je bitno da kontroling ima organizacijsku mogućnost pristupa navedenim digitalnim tehnologijama i da se u skladu s njima i razvija. Osim toga, raspoloživost velikim podacima također potencira potrebu za isticanjem pojedinih kontrolerovih karakteristika kao što su analitičnost, kreativnost i proaktivnost.

3.2.4. Karakteristike okruženja

Globalizacija i brze tehnološke promjene te otvorenost globalnom tržištu dovele su do sve veće potrebe za prilagođavanjem poduzeća vlastitom okruženju. Uvidom u brojna istraživanja može se zaključiti da se utjecaj karakteristika okruženja uglavnom svodi na analizu obilježja globalizacije i s tim poveznih tehnoloških promjena. Odnosno, pojavljuju se različite kombinacije faktora vanjskog okruženja, a koje se odnose na dinamičnost tržišta, neprijateljsko okruženje (engl. hostility), neizvjesnost promjena, konkurentnost, stopu promjene okruženja, složenost i razinu tehnoloških promjena. Tako, na primjer, Haldma i Lääts (2002, u Lindelöf i Löfsten, 2006) kao najčešće istraživane faktore vanjskog okruženja ističu nepredvidljivost i neprijateljsko okruženje, dok drugi smatraju da su bitnija kompleksnost i dinamičnost okruženja. Odnosno, ako se uzmu u obzir sva istraživanja koje je proveo Miller 70-ih i 80-ih godinama, samostalno i u koautorstvu mogu se istaknuti sljedeće osnovne okolišne varijable: dinamičnost, heterogenost i neprijateljsko okruženje te neizvjesnost. Pri tome, Miller i Friesen (1983) tržišnu dinamičnost definiraju kao razinu i nepredvidljivost promjene u pogledu potreba kupaca, proizvoda ili tehnoloških usluga i konkurentnosti unutar industrije. Jaworski i Kohli (1993) su pak promjene okruženja definirali i mjerili kroz tržišnu turbulenciju, tehnološku turbulenciju i intenzitet konkurentnosti, a koje se sukladno Miller i Friesen (1983) mogu smatrati potkategorijama tržišne turbulentnosti. Međutim, ako se uzme obzir istraživanje Jayachandran *et al.* (2005) i Asare *et al.* (2013) tržišna i tehnološka turbulencija smatraju se sastavnicama ukupne dinamičnosti okruženja tj. dinamičnosti industrije. Prema Kafetzopoulos *et al.* (2019) neizvjesnost okruženja ogleda se u tržišnim i tehnološkim promjenama, dok se prema Ahmad i Zabri (2015) tržišna konkurentnost smatra supkategorijom nepredvidljivosti okruženja. Mitchell *et al.* (2011), iako ističu značaj neprijateljskog i dinamičnosti okruženja, u istraživanju su dokazali da je jedino neprijateljsko okruženje povezano s višom razinom odlučivanja.

Da globalizacija tj. dinamičnost i neizvjesnost tržišta imaju značajan utjecaj na kontroling naglasili su brojni autori (Sathe, 1982; Haldma i Lääts, 2002; Zoni i Merchant, 2007; Mäder, 2018, itd.). Dok Haldma i Lääts (2002) ističu neizvjesnost i neprijateljsko okruženje, Sathe (1982) smatra da su dva osnova faktora koja utječu na kontroling tj. njegovu uključenost u odlučivanju: 1) stopa promjene okruženja i 2) operativna nezavisnost poduzeća. Odnosno, kroz provedeno istraživanje dokazao se kao značajan samo indeks promjene okruženja.

Promjene u okruženju utječu na menadžersku potrebu za kontrolerovim informacijama te njegovu uključenost u donošenje odluka. U okruženju karakteristično po brzim promjenama, za pretpostaviti je da će menadžeri imati potrebu za donošenjem brzih odluka, tražeći od kontrolera dostupnost pravovremenih i točnih analiza, a ujedno i njegovu uključenost na višoj razini. Za razliku od Sathe (1983), Zoni i March (2007) nisu dokazali značaj stupnja promjenjivosti okruženja na kontrolerovu uključenost u odlučivanju. Nadalje, Krishnan i Ramasamy (2011) ističu vezu percipirane neizvjesnosti okruženja (PEU) i karakteristika kontrolerovih informacija te potrebu za njihovim daljnjim istraživanjem. Chenhall i Morris (1986), kao i Sathe, ističu da povećana neizvjesnost ima pozitivan utjecaj na upotrebu kontrolerovih informacija tj. da neizvjesnost povećava potrebu za pravovremenim podacima. Odnosno, Pangaribuan (2016) je potvrdio da PEU ima utjecaj na kvalitetu kontrolerovih informacija u vidu pravovremenosti, sadržajnosti i oblika njihovog iznošenja. Slično je dokazano od strane Astuty (2015) tj. potvrđena je indirektna pozitivna veza između poslovnog okruženja i kvalitete kontrolerovih informacija (značajnost točnost, potpunost, pravovremenost, širina sadržaja i agregiranost) preko varijable implementacije MAS sustava. Rachmawati i Saudi (2019) nisu potvrdili indirektni utjecaj PEU na kvalitetu kontrolerovih informacija, već samo direktni utjecaj kvalitete sustava na kvalitetu informacija. Gledano kroz istraživanja u drugim povezanim područjima, npr. Prihantari i Astika (2019) potvrdili su da PEU ima negativni utjecaj na radni učinak zaposlenika, dok su Gul i Chia (1994), potvrdili pozitivni utjecaj argumentirajući da će neizvjesnost potaknuti zaposlenike da pronađu dodatne informacije značajne za napredovanje poduzeća. Brojna druga istraživanja potvrdila su da PEU ima značajan pozitivan (Gul, Glen i Huang, 1993; Ritonga i Zainuddin, 2002; Chiou, 2011), a pojedini i negativan (Lal i Hassel, 1998; Hammad *et al.*, 2013) utjecaj na menadžerski informacijski sustav (MAS) tj. korisnost njegove upotrebe, a većinom kroz primjenu svih ili pojedinih MAS karakteristika - sadržajnost, pravovremenost, agregiranost i integriranost.

Nadalje, Fuadah *et al.* (2014) potvrdili su da je promjena u praksi kontrolinga povezana s tržišnom konkurencijom. Da konkurentnost ima značajna utjecaj na MAS dokazala su brojna istraživanja. Tako su Mia i Clarke (1999) potvrdili direktnu, a Ismail *et al.* (2018) indirektnu pozitivnu vezu između tržišne konkurentnosti i razine upotrebe kontrolerovih informacija kao i posljedični utjecaj na uspješnost poduzeća. Ismail *et al.* (2018) navode da MAS informacije mogu pružiti pravovremene, točne i relevantne informacije koje se mogu koristiti u uvjetima vrlo intenzivne tržišne konkurencije u svrhu učinkovitijeg donošenja odluka. Baines i

Langfield-Smith (2003) su pak potvrdili pozitivnu vezu između promjene razine konkurentnosti i primjene strateških alata kontrolinga kao i povjerenja menadžera u kvalitetu nefinancijskih informacija. Ghasemi *et al.* (2015) su potvrdili da tržišna konkurentnost ima značajan pozitivan utjecaj na MAS u vidu njegovog značaja, pravovremenosti, integriranosti i agregiranosti, a što se može tretirati kao razina kvalitete MAS-a. Nasuprot navedenom, Tuan Mat i Smith (2014) su potvrdili da promjena razine konkurentnosti nema značajan utjecaj na praksu kontrolinga, tj. Löfsten i Lindelöf (2005) potvrdili su značajnu negativnu vezu između općenitog značaj kontrolinga i tržišne konkurentnosti.

Kako je već navedeno, Jaworski i Kohli (1993) definiraju okruženje kroz tri razine - tržišnu turbulenciju, tehnološku turbulenciju i intenzitet konkurentnosti, a koje se sukladno Miller i Friesen (1983) mogu smatrati potkategorijama tržišne turbulentnosti. Odnosno, sukladno Jayachandran *et al.* (2005) i Asare *et al.* (2013) mogu se podrazumijevati sastavnicama ukupne dinamičnosti okruženja. Iako se turbulentnost tehnologije kao sastavnica ne pojavljuje u dosadašnjim istraživanjima u području kontrolinga, kao pojava koja mjeri koliko primjena novih tehnologija određuje mogućnost rasta poduzeća, kreiranja novih ideja, unaprjeđenja poslovnih procesa i efikasniju upotrebu dostupnih podataka i informacija, zasigurno predstavlja značaj element okruženja.

Sukladno svemu navedenom kao glavne utjecajne karakteristike okruženja u istraživanju će biti primijenjene: *intenzitet konkurentnosti, turbulentnost tehnologije i rizičnost okruženja*. Pri tome će se intenzitet konkurentnosti, kao najčešće istraživan vanjski utjecajni faktor kontrolinga, te turbulentnost tehnologije, kao najmanje tj. neistražen, potvrdili kroz primjenu postavljenog koncepta tj. mjeritelja Jaworski i Kohli (1993) i Asare *et al.* (2013). Značaj primjene istih potvrđuje i činjenica njihovog navođenja, u za sada prvom izdanom priručniku mjeritelja u području kontrolinga (Schäffer, 2007). Iako se rizičnost u većini istraživanja mjeri kroz neizvjesnost okruženja, njezin utjecaj mjerljiv je i kroz razinu neprijateljskog okruženja definiranog kao skupa razine neuspjeha unutar neke grane, razine rizičnosti, niskih profitnih marži, odanosti kupaca i neprilagodljivosti okruženja (Mitchell *et al*., 2011).

3.2.5. Poslovna inteligencija, radno iskustvo i organizacijska obilježja

Empirijska istraživanja koja uključuju nove koncepte kao što su poslovna inteligencija, poslovna analitika i Big Data, uglavnom su ostvarena u području informatike, dok su u kontrolingu još uvijek uglavnom zastupljeni teorijski modeli (Appelbaum et al., 2017) i preporuke za istraživanja (Rikhardsson i Yigitbasioglu, 2018). Istraživanje koje je za istaknuti je ono koje je provela Gullkvist (2013). Iako je koristila poslovnu inteligenciju kao kontrolnu varijablu i kao preteču kvalitete podataka i informacija te zadataka kontrolera, potvrdila je njezin pozitivni utjecaj na kvalitetu podataka i zadatke kontrolera, te posljedični pozitivni utjecaj na efektivnost i promjenu prakse kontrolera. Odnosno, istraživanje je potvrdilo da primjena BI-a utječe na efektivnost koju je prema Nicolaou (2000, u Gullkvist, 2013) definirala kao percepciju donositelja odluka o tome da li informacije koje su im stavljene na raspolaganje putem obrade transakcija, izvještavanja i sustava budžetiranja, zadovoljavaju njihove zahtjeve za upravljanje poduzećem. Osim toga, kao kontrolnu varijablu koristila je prisutnost revizije tj. vrstu revizorske kuće. Signifikantnost te varijable nije potvrđena, međutim Gullkvist ističe njezinu značajnost u pogledu dosadašnjih i budućih istraživanja. Premda Gullkvist u svojem istraživanju u obzir uzima utjecaj vanjske revizije, značajnost unutarnje revizije ističe Xu (2015), ali i brojna druga istraživanja koja izučavaju utjecajne varijable kvalitete podataka informacijskih sustavan. Odnosno, Xu (2015) unutarnju reviziju smatra jednom od najznačajnijih faktora kvalitete računovodstvenih informacija kojima se osigurava kvaliteta podataka informacijskog sustava. Ako se uzme u obzir značaj ispravnosti podataka informacijskog sustava u izvršavanju zadataka kontrolera, a prije sve izrade kvalitetnih outputa, onda interna revizija kao osiguravatelj ispravnosti tih podataka predstavlja i značajan čimbenik kontrolerovog utjecaja na donošenje poslovnih odluka.

Nadalje, značajna kontrolna varijabla u području kontrolinga, ali i drugim istraživanjima koja izučavaju efektivnost radne snage, predstavlja dužina radnog iskustva zaposlenika. Navedenu varijablu u svojem istraživanju primijenili su Rouwelaar *et al.* (2018). Pored toga, obilježje poduzeća koje dolazi do izražaja je i organizacijska struktura poduzeća tj. način organizacije kontrolinga - centralizirani ili decentralizirani. Dok su npr. Rouwelaar *et al.* (2018) način organizacije kontrolinga (decentralizacija) koristili kao latentnu varijablu karakteristike poduzeća, Pasch (2019) način organizacije kontrolinga kroz stupanj centralizacije koristi kao kontrolnu varijablu. Istraživanjem je potvrdio da kontroler kao poslovni partner utječe na donošenje poslovnih odluka te posljedično na inovacije kontrolirane razinom centralizacije

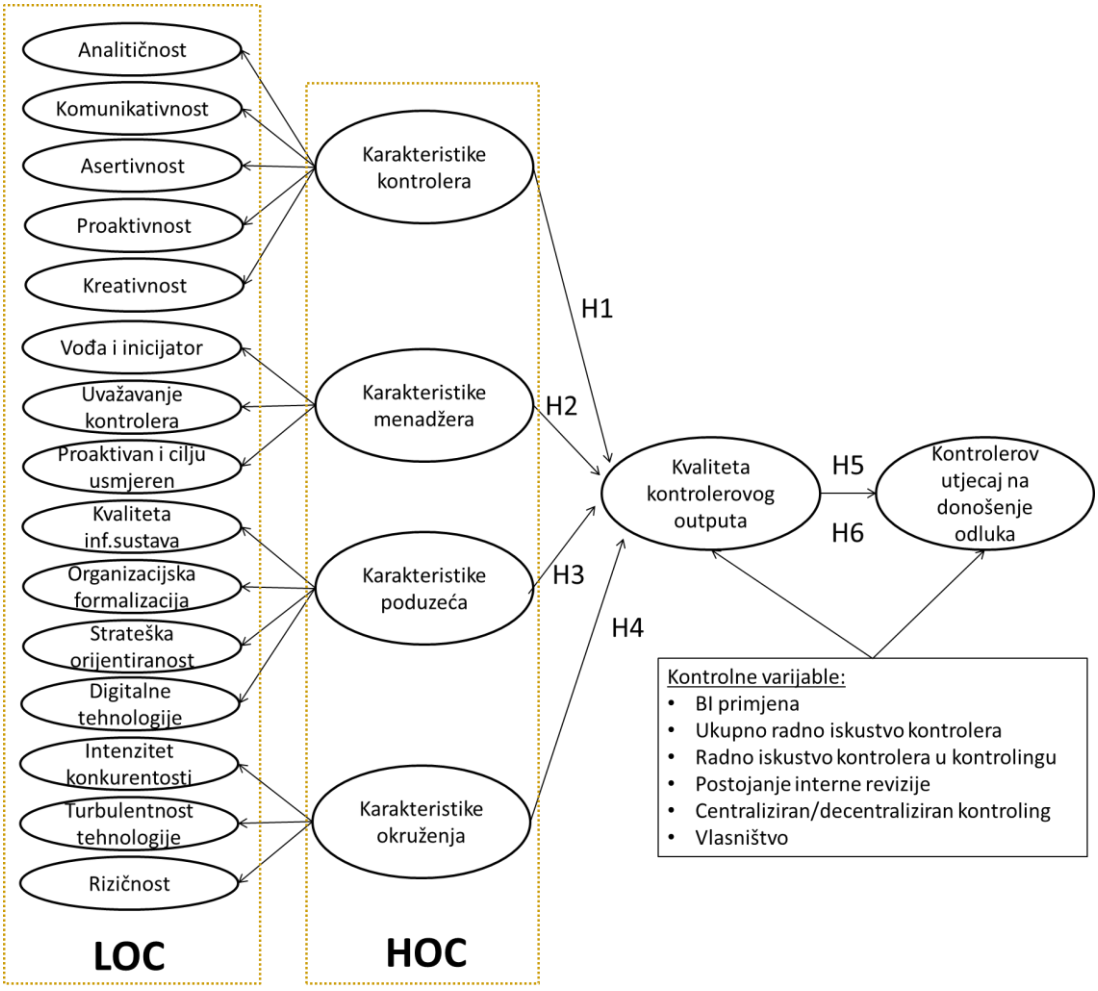
kontrolinga. Drugo organizacijsko obilježje koje ima značajni kontrolni učinak na kontrolerov utjecaj na donošenje poslovnih odluka je vlasništvo poduzeća, a kojeg su Albu i Albu (2012) povezali s usvajanjem i uporabom kontrolerskih instrumenta u Rumunjskoj. Odnosno, u svojem istraživanju potvrdili su da vrsta kapitala kao kontrolna varijabla poveća složenost kontrolinga u vidu razine primjene instrumenata kontrolinga.

Iako se kao kontrolne varijable općenito često koriste demografska obilježja ispitanika kao npr. djelatnost poduzeća, veličina i starost poduzeća itd.; po uzoru na prethodno navedena istraživanja kao najznačajnije kontrolne varijable kvalitete kontrolerovih outputa i utjecaja na donošenje poslovnih odluka u ovoj disertaciji izabrane su: *primjena poslovne inteligencije* (Gullkvist, 2013), *radno iskustvo kontrolera* (Rouwelaar *et al.*, 2018), *postojanje revizije* (Gullkvist, 2013; Xu, 2015), *centralizacija tj. decentralizacija kontrolinga* (Rouwelaar *et al.*, 2018; Pasch, 2019) i *vlasništvo poduzeća* (Albu i Albu, 2012).

4. KONCEPTUALNI MODEL UTJECAJA KVALITETE KONTROLINGA NA POSLOVNO ODLUČIVANJE

Temeljem predočenih teorijskih spoznaja i pregleda dosadašnjih istraživanja postavljen je konačni konceptualni model kojim će se, kroz empirijsko istraživanje temeljem odabranog uzorka kontrolera i menadžera u Republici Hrvatskoj, potvrditi povezanost karakteristika kontrolera, menadžera, poduzeća i okruženja s kvalitetom kontrolerovog outputa. Odnosno potvrdit će se da u uvjetima digitalizacije kvaliteta kontrolerovog outputa ima značajnu povezanost s kontrolerovim utjecajem na donošenje poslovnih odluka.

Slika 10: Konceptualni model istraživanja



Izvor: izrada autora

Konceptualni model (slika 10), pored kontrolnih varijabli, uključuje šest hipoteza koje će biti potvrđene temeljem empirijskog istraživanja:

- **H1:** Karakteristike kontrolera su statistički značajno i pozitivno povezane s kvalitetom njegovog outputa.
- **H2:** Karakteristike menadžera su statistički značajno i pozitivno povezane s kvalitetom kontrolerovog outputa.
- **H3:** Karakteristike poduzeća su statistički značajno i pozitivno povezane s kvalitetom kontrolerovog outputa.
- **H4:** Karakteristike okruženja su statistički značajno i pozitivno povezane s kvalitetom kontrolerovog outputa.
- **H5:** Postoji statistički značajna i pozitivna povezanost između kvalitete kontrolerovog outputa i njegovog utjecaja na donošenje odluka.
- **H6:** Menadžerska percepcija utjecaja kvalitete kontrolerovog outputa na donošenje poslovnih odluka, razlikuje se od kontrolerove percepcije.

Model obuhvaća sljedeće nezavisne (egzogene) i zavisne (endogene) latentne varijable tj. konstrukte:

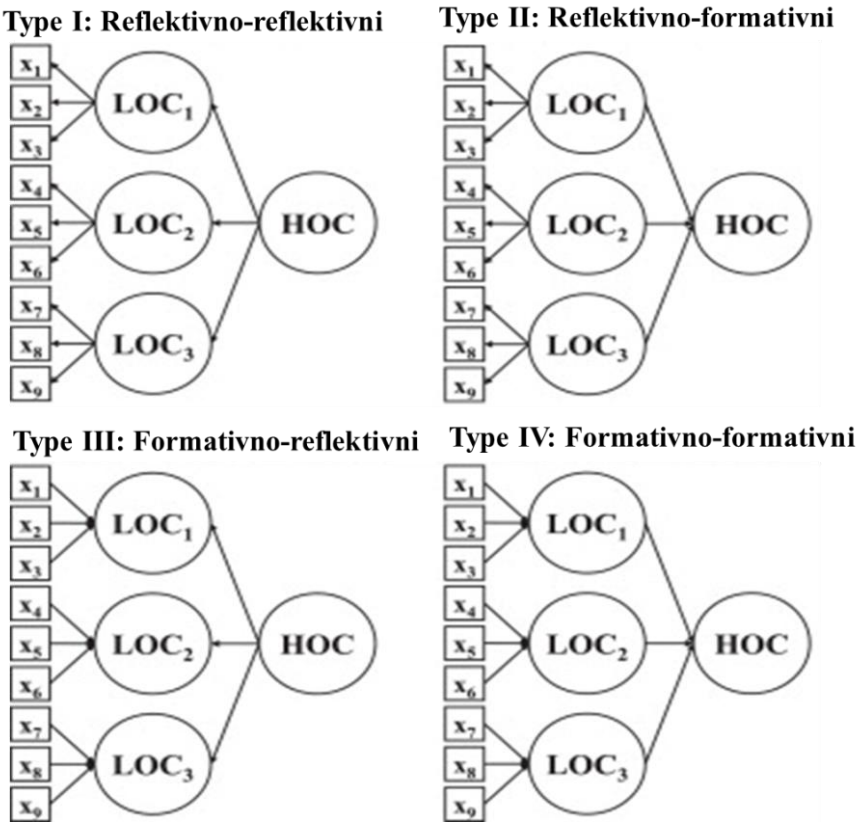
- karakteristike kontrolera, menadžera, poduzeća i karakteristike okruženja - egzogene varijable
- kvaliteta kontrolerovog outputa - egzogena i endogena varijabla
- kontrolerov utjecaj na donošenje odluka - endogena varijabla

S obzirom na kompleksnost modela tj. postavljenih latentnih varijabli, a sukladno prethodnim istraživanjima, model je postavljen kao hijerarhijsko komponentni model (engl. Hierarchical component model - HCM). HCM modeli su eksplicitni prikazi višedimenzionalnih konstrukata koji postoje na višoj razini i koji su povezani s drugim konstruktima na sličnoj razini apstrakcije, a koji u potpunosti posreduju (engl. mediating) utjecaj od ili do njihove krajnje dimenzije (Chin, 1998, u Becker *et al.*, 2012). To su modeli koji istraživačima omogućavaju modeliranje konstrukata na apstraktnijim dimenzijama i njihovim konkretnijim poddimenzijama (Sarstedt *et al.*, 2019). Nekoliko je razloga tj. prednosti primjene HCM modela, a najviše se ističu (npr. Edwards, 2001, Johnson *et al.*, 2011, Polites *et al.*, 2012 u Hair *et al.*, 2017): 1) smanjenje broja veza unutar modela tj. kompleksnosti modela i 2) prevladavanje tzv. „bandwidth-fidelity“ dileme tj. ideje da su širi konstrukti bolji prediktori kriterija koji obuhvaćaju više domena (npr. ako je cilj predikcija široko definiranih ponašanja,

tada se visoko-redni višedimenzionalni konstrukti mogu pokazati vrijednima). Navedeno se očituje i u sve većoj popularnosti njihove primjene (Becker *et al.*, 2012; Sarstedt *et al.*, 2019).

Kako navode Becker *et al.* (2012), HCM karakteriziraju dvije stvari: 1) broj razina u modelu i 2) broj veza između konstrukata. Iako se modeli mogu formirati kao tro-redni, četvero-redni, itd., u istraživanjima se većinom primjenjuju drugo-redni modeli (Hair *et al.*, 2017). To podrazumijeva da model, koji je napravljen kao drugo-redni model, sadrži jedan ili više visoko-rednih (drugo-rednih) konstrukata (engl. high-order construct tj. second-order - HOC) s pripadajućim nisko-rednim (prvo-rednim) konstruktima (engl. low-order constructs i.e. first-order - LOC). Pri tome, HOC su sastavljeni (engl. formative) ili određeni s (engl. reflective) odgovarajućim LOC-ovima, a LOC-ovi s odgovarajućim manifestnim varijablama (engl. manifest variables) tj. česticama (engl. items). Točnije, postoje četiri vrste (engl. type) drugo-rednih HCM modela (slika 11).

Slika 11: Vrste drugo-rednih HCM modela

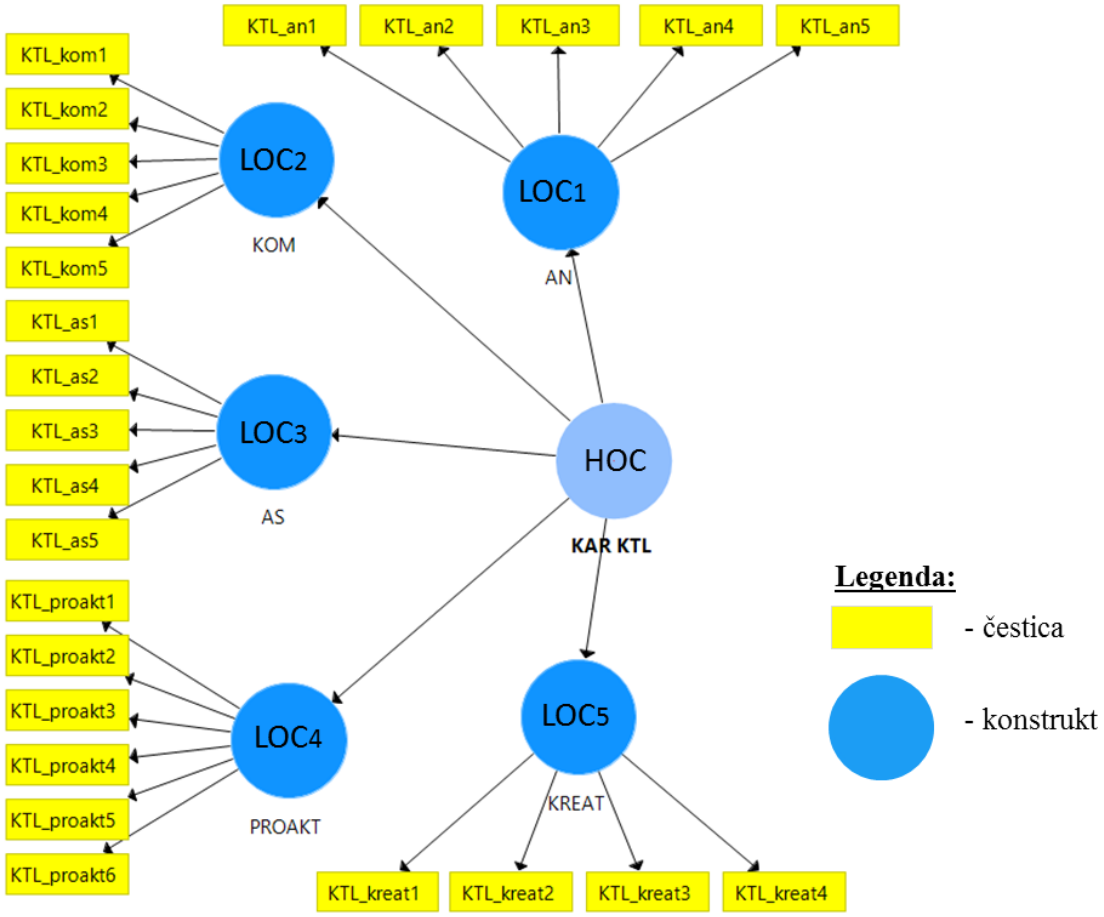


Legenda: HOC = visoko-redni konstrukt; LOC = nisko-redni konstrukt; x1-x9 = manifestne varijable tj. čestice

Izvor: izrada autora prema Sarstedt *et al.* (2019)

Sukladno prethodnim istraživanjima HCM model istraživanja ove doktorske disertacije postavljen je kao reflektivno-reflektivni Type I model (Fadhilah *et al.*, 2015; Rahman *et al.*, 2015; Padukkage *et al.*, 2016; Arshad i Arshad, 2018; Farhat *et al.*, 2020; Ngah *et al.*, 2021, itd.), što znači da je svaki HOC manifestiran u pripadajućim LOC-ovima, odnosno da su LOC-ovi reflektivno mjereni konstrukti koji se razlikuju jedan od drugog ali koji su međusobno povezani.

Slika 12: Primjer reflektivno-reflektivnog HOC-a konceptualnog modela istraživanja



Izvor: izrada autora prema SmartPLS (v. 3.3.3)

Konceptualni model sadrži četiri visoko-redna konstrukta: karakteristike kontrolera (KAR KTL), menadžera (KAR MEN), poduzeća (KAR POD) i okruženja (KAR OKR). Svaki od njih ima pripadajuće nisko-redne konstrukte koji su mjereni određenim brojem čestica. Tako je na primjer visoko-redni konstrukt KAR KTL reflektiran kroz pet nisko-redna konstrukta (LOC_1-LOC_5) pojedinačno mjerenih pripadajućim brojem čestica (npr. KTL_as1) (slika 12). Odnosno, model sadrži četiri HOC-a sastavljenih od ukupno petnaest LOC-a i sedamdesettri čestice (tablica 5).

Tablica 5: Pregled HOC konstrukata, pripadajućih LOC-ova i broja čestica konceptualnog modela

HOC	LOC	Broj čestica	Primjer čestice
KAR KTL	Analitičnost (AN)	5	KTL_an1
	Komunikativnost (KOM)	5	KTL_kom1
	Asertivnost (AS)	5	KTL_as1
	Proaktivnost (PROAKT)	6	KTL_proakt1
	Kreativnost (KREAT)	4	KTL_kreat1
KAR MEN	Vođa i inicijator (VOD&INC)	5	MEN_vod&inc1
	Uvažavanje kontrolera (UVAZKTL)	5	MEN_uvazktl1
	Proaktivan i cilju usmjeren (PROCILJ)	5	MEN_procilj1
KAR POD	Kvaliteta informacijskog sustava (KVINFS)	5	POD_kvinfs1
	Organizacijska formalizacija (FORM)	5	POD_form1
	Strateška orijentiranost (STROR)	4	POD_stror1
	Digitalne tehnologije (DIGTEH)	3	POD_digteh1
KAR OKR	Intenzitet konkurentnosti (INTKON)	6	OKR_intkon1
	Turbulentnost tehnologije (TURBTEH)	5	OKR_turbteh1
	Rizičnost (RIZIK)	5	OKR_rizik1

Izvor: izrada autora

Pored navedenih četiri visoko-redna konstrukta konceptualni HCM model sadrži i jednodimenzionalne reflektivne konstrukte koji predstavljaju zavisne varijable modela i koji su također mjereni kroz pripadajući broj čestica. To su:

- Kvaliteta kontrolerovog outputa - deset čestica (npr. kvout_1)
- Kontrolerov utjecaj na donošenje odluka - šest čestica (npr. utjklt_1).

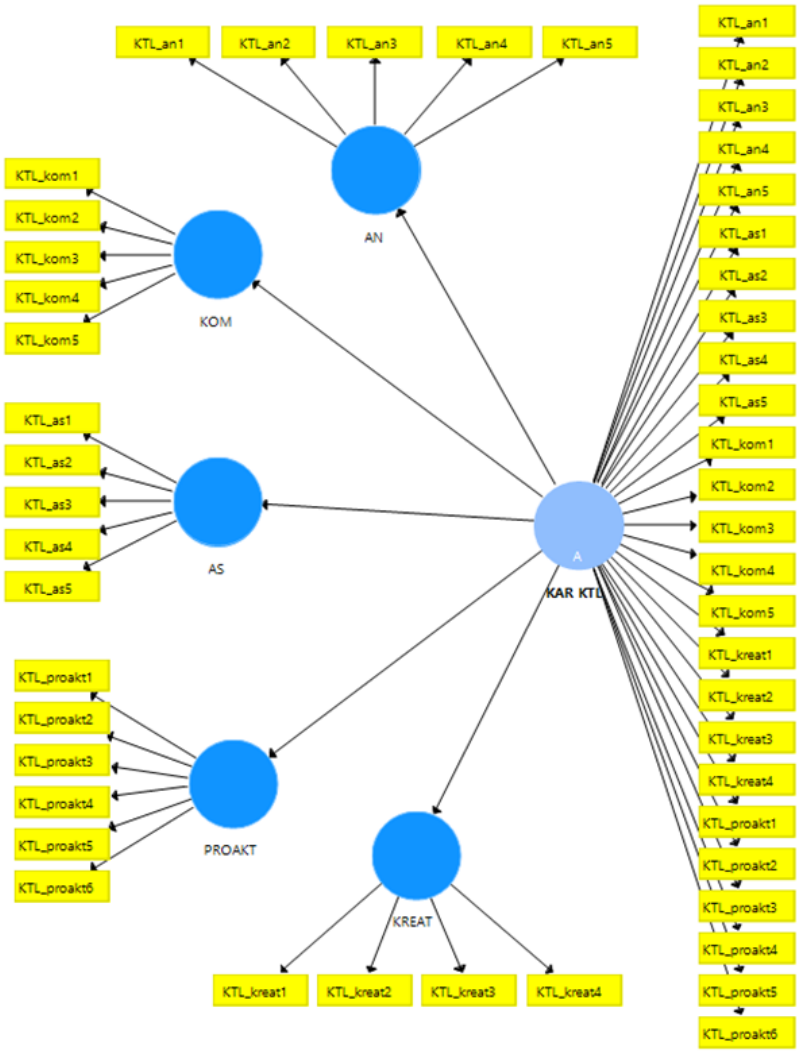
Odnosno, model sadrži i šest kontrolnih varijabli postavljenih kao konstrukti s jednom česticom (engl. single-item measurement). Ukupno, konceptualni model sastavljen je od četiri HOC-a, petnaest LOC-a, dva jednodimenzionalna reflektivna konstrukta i šest kontrolnih varijabli tj. devedesetpet čestica.

Pri postavljanju i analizi HCM modela bitno je odrediti dvije stvari (Sarstedt *et al.*, 2019):

1) način specifikacije HOC-a i
2) način procjene HOC-a.

Postoje dva istaknuta pristupa specifikacije HOC-a. TO su tzv. pristup ponovljenog indikatora tj. čestica (engl. repeted indicator approach) i dvo-stupanjski pristup (engl. two-stage approach). Iako se oba koriste u različitim istraživanjima te bi trebala davati približno jednake rezultate pri dovoljno velikom uzorku, sukladno istraživanju Becker *et al.* (2012) te preporuci Becker *et al.* (2019) u ovom istraživanju biti će primijenjen pristup ponovljenog indikatora. Pristup ponovljenog indikatora podrazumijeva da se svi indikatori nisko-rednih konstrukata dodijele pripadajućem visoko-rednom konstruktu. Niti jedan model ne može se testirati dok postoje konstrukti bez minimalno jednog indikatora. Tako se na primjer HOC-u karakteristike kontrolera dodjeljuju indikatori svih njegovih LOC-ova, odnosno HOC KAR KTL sadrži 20 čestica pripadajućih LOC konstrukata (slika 13). Isto se radi i za sva ostala tri HOC-a u modelu.

Slika 13: Primjer primjene pristupa ponovljenog indikatora na HOC-u Karakteristike kontrolera



Izvor: izrada autora prema SmartPLS (v. 3.3.3)

Pri procijeni HOC-a u PLS-SEM metodi (za opis metode vidi poglavlje 5.1.3.) posebnu pažnju treba pridati postavkama algoritma. PLS-SEM algoritam koristi dva načina za procjenu mjernog modela - Model A i Model B. Sukladno Sarstedt *et al.* (2019) Model A bi se trebao koristi kod reflektivno formiranih HOC-ova (tj. reflektivno-reflektivni i formativno-reflektivni modeli), a Model B kod formativnih (tj. reflektivno-formativni i formativno-formativni modeli). Obzirom da je model ovog istraživanja postavljen kao reflektivno-reflektivni model, u svrhu empirijskog istraživanja biti će primijenjen Model A, uz specifikaciju modela putem pristupa ponovljenog indikatora. Odabir modela vidljiv je i u shemi modela (slika 13) tj. na samom HOC konstruktu (kružiću).

5. EMPIRIJSKO ISTRAŽIVANJE UTJECAJA KONTROLINGA NA DONOŠENJE ODLUKA

Empirijskim istraživanjem, postavljeni konceptualni model (slika 10; poglavlje 4) testiran je na uzorku kontrolera i menadžera u Republici Hrvatskoj. Analiza je provedena temeljem dva modela čiji su rezultati prikazani u nastavku ovog poglavlja. Osim toga, detaljno je razrađena metodologija istraživanja u vidu postupka izrade instrumenta istraživanja, odabira uzorka i primjene statističkih metoda. Na kraju poglavlja, uz zaključna razmatranja i dane prijedloge budućeg usmjerenja kontrolinga, navedena su ograničenja istraživanja, implikacije budućih istraživanja i znanstveni i aplikativni doprinos rada.

5.1. Metodologija empirijskog istraživanja

Metodologija empirijskog istraživanja podrazumijeva detaljnu razradu operacionalizacije latentnih varijabli postavljenog konceptualnog modela te postupak testiranja i formiranja anketnog upitnika. Odnosno, uključuje način odabira ciljane populacije, provedbe prikupljanja podataka, potvrdu reprezentativnosti uzorka i njegovu deskriptivnu analizu, te razradu primijenjenih statističkih metoda.

5.1.1. Operacionalizacija varijabli i dizajn upitnika

Za potrebe empirijskog istraživanja i testiranja postavljenih hipoteza kreiran je anketni upitnik. Pri tome su se koristile validne mjerne ljestvice dosadašnjih istraživanja, uz pojedine modifikacije, te dopunska pitanja u svrhu dobivanja dubljih saznanja o rezultatima istraživanja (npr. upotreba poslovne analitike, vrste i učestalosti obavljanja pojedinih zadataka kontrolera, itd.). Odnosno, za mjerenje konstrukata postavljenog konceptualnog modela upotrjebljene su čestice zatvorenog tipa, dok su se za dopunska pitanja koristila i pojedina pitanja otvorenog tipa.

Za mjerenje konstrukata konceptualnog modela korištena je Likertova ljestvica od sedam stupnjeva, obzirom da se smatra točnijom i mjerom boljeg odraza istinske procjene ispitanika od ljestvica s većim i manjim brojem stupnjeva (Finstad, 2010). Pri tome su upotrijebljene sljedeće vrijednosti:

1 - u potpunosti se ne slažem;
2 - ne slažem se
3 - donekle se ne slažem
4 - niti se slažem niti se ne slažem
5 - donekle se slažem
6 - slažem se
7 - u potpunosti se slažem

Za mjerenje kontrolnih varijabli, socio-demografskih obilježja ispitanika (dob, spol, obrazovanje, itd.) i poduzeća u kojima rade (djelatnost poduzeća, veličina poduzeća, financijski podaci, itd.) te prikupljanje odgovora na dopunska pitanja korištene su različite nominalne i ordinarne ljestvice.

Kako su mjerne ljestvice preuzete iz postojećih inozemnih istraživanja te su stoga originalno razvijene na engleskome ili njemačkom jeziku, u svrhu pravilnog prijevoda na hrvatski jezik sve čestice su prevedene u suradnji sa za to kvalificiranom osobom. Prva verzija ankete (na hrvatskom jeziku) detaljno je analizirana od strane četiri kontrolera, kako bi se provjerila valjanost sadržaja upitnika tj. osiguralo razumijevanje i primjerenost postavljenih čestica te vremena potrebnog za njeno ispunjavanje. Analizom se ustanovila potreba za izbacivanjem i izmjenom pojedinih pitanja, te oblikovanjem anketnog upitnika za kontrolere u dva dijela; prvi dio koji sadrži pitanja vezana uz postavljeni konceptualni model i drugi dio koji sadrži pitanja za prikupljanje dubljih saznanja o rezultatima istraživanja. Ispravljena verzija ankete zatim je testirana na pilot uzorku od 21 ispitanika tj. kontrolera (članova Udruge hrvatskih kontrolera). Menadžeri nisu bili predmet pilot testiranja. Pilot testiranje provedeno je od početka rujna 2020 do sredine listopada 2020. godine. Pilot testiranje potvrdilo je pouzdanost, valjanost i značajnost modela. Odnosno, temeljem pilot testiranja ustanovljeno je koji konstrukti primjereno mjere postavljene karakteristike, koje čestice ne zadovoljavaju potrebne uvjete valjanosti i koja dopunska pitanja opterećuju ukupni opseg anketnog upitnika. Sukladno rezultatima kreiran je konačni anketni upitnik empirijskog istraživanja.

Konačni anketni upitnik kreiran je u dvije verzije, jedna za kontrolere (privitak 1) i druga za menadžere (privitak 2). Odnosno, kako je prethodno već navedeno, zbog opsega pitanja anketni upitnik kontrolera kreiran je u dva dijela. Na taj način osigurana je veća točnost danih odgovora obzirom da se kontrolerima dala mogućnost ispunjavanja svakog dijela upitnika vremenski neovisno jedan od drugog. U prvom dijelu upitnika sva pitanja bila su postavljena

kao obavezna polja dok su u drugom dijelu većina njih bila neobavezna. Anketa za menadžere (privitak 3) sadržavala je ista pitanja kao prvi dio ankete za kontrolere, ali u manjem opsegu. Odnosno, menadžerima su postavljena pitanja koja određuju tri konstrukta modela: karakteristike kontrolera, kvaliteta kontrolerovog outputa i kontrolerov utjecaj na donošenje odluka. Dakle, ukupni model prvotno je testiran temeljem odgovora kontrolera, a potom kombinacijom odgovora menadžera i kontrolera. Anketni upitnici kreirani su putem besplatne opcije Google Form.

U metodološkom smislu, u istraživanju je primijenjena je tzv. „dyadic" metoda istraživanja, koja podrazumijeva da anketu ispunjava kontroler i njegov menadžer pod određenom lozinkom koja omogućuje uparivanje odgovora tj. tretiranje odgovora kontrolera i njegovog menadžera kao jedno opažanje. Točnije, kontrolerima je poslan e-mail koji je sadržavao poveznice na anketu kontrolera i poveznicu na anketu menadžera. Kontroler je u svrhu ispunjavanja svoje ankete morao kreirati tzv. „zajedničku oznaku" (koja je mogla biti bilo koje duljine i sadržavati bilo koju kombinaciju slova, brojki i simbola), koju je morao proslijedite svom menadžeru (tj. osobi kojoj dostavlja izvještaje i pomažete u poslovnom odlučivanju) skupa s poveznicom za anketu za menadžere. Na taj način, osigurano je uparivanje odgovora uz istodobnu anonimnost kontrolera i menadžera.

U nastavku (tablica 6 - 10) je prikazan detaljni pregled svih reflektivnih mjernih konstrukata konceptualnog modela s izvorom literature i korištenim česticama. Kako je već navedeno, svi konstrukti osim kontrolnih varijabli, mjereni su pomoću Likertove ljestvice od sedam stupnjeva.

Tablica 6: Operacionalizacija HOC konstrukta *Karakteristike kontrolera*

Naziv LOC konstrukta	**Čestice** (za kontrolere / za menadžere)	**Izvor**
Analitičnost	1. Sposoban sam objasniti značenje brojeva. / Sposoban je objasniti značenje brojeva. 2. Fokusiran sam i razumijem izvore problema. / Fokusiran je i razumije izvore problema. 3. Usmjeren sam ka budućnosti. / Usmjeren je ka budućnosti. *4. Sposoban sam uočiti trendove prije nego postanu stvarnost. / Sposoban je uočiti trendove prije nego postanu stvarnost.* 5. *Dobar sam u korištenju, strukturiranju i obradi brojeva. / Dobar je u korištenju, strukturiranju i obradi brojeva.*	Fadhilah *et al.* (2015) + *Sathe (1983)*

Komunikativnost	1. Lako uspostavljam kontakt s drugima i slušam sugovornike. / Lako uspostavlja kontakt s drugima i sluša sugovornike. 2. Jasno komuniciram svoje ideje usmenim putem. / Jasno komunicira svoje ideje usmenim putem. 3. Jasno komuniciram svoje ideje pismenim putem. / Jasno komunicira svoje ideje pismenim putem. 4. Mogu uvjeriti druge ljude da slijede moje ideje. / Može uvjeriti druge ljude da slijede njegove ideje. *5. Sposoban sam prenijeti poruku, tj. važni sadržaj. / Sposoban je prenijeti poruku, tj. važni sadržaj.*	Nicolescu i Nicolescu (2019) + *Gänßlen et al., (2012) i Vitezić (2020)*
Asertivnost	1. Jasno izražavam svoje mišljenje, osjećaje i stavove. / Jasno izražava svoje mišljenje, osjećaje i stavove. 2. Izražavam svoje neslaganje sa mišljenjima drugih. / Izražava svoje neslaganje sa mišljenjima drugih. 3. Dajem konstruktivne kritike. / Daje konstruktivne kritike. 4. Nije mi problem reći NE drugima. / Nije mu problem reći NE drugima. 5. Dopuštam drugima da izraze svoje mišljenje. / Dopušta drugima da izraze svoje mišljenje.	Timmins i McCabe (2005)
Proaktivnost	1. Prilika i izazov mi je vidjeti da se moje ideje pretvaraju u stvarnost. / Prilika i izazov mu je vidjeti da mu se ideje pretvaraju u stvarnost. 2. Samoinicijativno popravljam uočene greške, probleme i nedostatke. / Samoinicijativno popravlja uočene greške, probleme i nedostatke. 3. Uvijek tragam za boljim načinima rada i načinima rješavanja problema. / Uvijek traga za boljim načinima rada i načinima rješavanja problema. 4. Prepreke me ne sprječavaju u ostvarenju ciljeva i ideja u koje vjerujem. / Prepreke ga ne sprječavaju u ostvarenju ciljeva i ideja u koje vjeruje. 5. Izravno se suočavam s problemima. / Izravno se suočava s problemima. 6. Probleme pretvaram u prilike. / Probleme pretvara u prilike.	Bateman i Crant (1993)
Kreativnost	1. Predlažem kreativna rješenja problema i pri tome se ne bojim preuzeti rizik. / Predlaže kreativna rješenja problema i pri tome se ne boji preuzeti rizik. 2. Promičem i zagovaram vlastite kreativne ideje i ideje drugih. / Promiče i zagovara vlastite kreativne ideje i ideje drugih. 3. Moja kreativnost dolazi do izražaja prilikom rješavanja složenih problem. / Njegova kreativnost dolazi do izražaja prilikom rješavanja složenih problem. 4. Predlažem nove načine postizanja ciljeva i ciljanih	Zhou i George (2001) tj. Alge *et al.* (2004)

	vrijednosti. / Predlaže nove načine postizanja ciljeva i ciljanih vrijednosti.	

Napomena: sadržaj u kurzivu predstavlja modifikacije mjernih ljestvica napravljenih od strane autora ove disertacije

Izvor: izrada autora

U svrhu mjerenja nisko-rednog konstrukta *Analitičnost* korištena je mjerna ljestvica razvijena od strane Fadhilah *et al.* (2015) temeljem postavljenih obilježja „jakog kontrolera" od strane Sathe (1983). U svrhu ovog istraživanja ljestvica je proširena s dvije dodatne čestice također temeljem dane klasifikacije Sathe (1983). *Komunikativnost* je mjerena pomoću modificirane mjerne ljestvice „socijalne prijenosne vještine" koje su razvili Nicolescu i Nicolescu (2019), a koja podrazumijeva komunikativnost tj. rad u timu, sposobnost slušanja, povezivanja ideja i vlastitog izražavanja, oralnu i pisanu komunikaciju, prezentacijske sposobnosti i sposobnost prikladnog ponašanja. Originalna ljestvica uključivala je tri čestice. U svrhu ovog istraživanja, jedna čestica koja je podrazumijevala sposobnost komuniciranja usmenim i pismenim putem, podijeljena je u dvije zasebne (čestica usmene i čestica pismene sposobnosti komuniciranja). Osim toga, temeljem Gänßlen *et al.*, (2012) i Vitezić (2020) dodana jedna nova koja podrazumijeva kontrolerovu sposobnost prijenosa određene poruke tj. važnog sadržaja. Za mjerenje *Asertivnosti* primijenjena je originalna mjerna ljestvica Timmins i McCabe (2005). Iako relativno nova ljestvica i uglavnom primjenjivan u području zdravstva i obrazovanja, potvrdila se kao mjera visoke pouzdanosti (Hauck *et al.*, 2016). Osim toga, sadržajno odgovara željenom mjerenju kontrolerove razine asertivnosti. Kontrolerova karakteristika *Proaktivnost* mjerena je pomoću poznate mjerne ljestvice Bateman i Crant (1993). Tijekom godina pojavile su se brojne modifikacije njihove originalne ljestvice od sedamnaest čestica. Tako su na primjer, prijedlog primjene verzije od pet čestica u području kontrolinga dali Fourné *et al.*, (2018). Konačna verzija primijenjena u ovom istraživanju sastoji se od četiri predloženih čestica Fourné *et al.*, (2018) te dvije iz originalne ljestvice koje odražavaju ulogu kontrolera. Za mjerenje *Kreativnosti* primijenjena je ljestvica Alge *et al.* (2006), izuzev jedne čestice, a koja predstavlja skraćenu verziju originalne trinaest-čestične ljestvice kreirane od Zhou i George (2001).

Tablica 7: Operacionalizacija HOC konstrukta *Karakteristike menadžera*

Naziv LOC konstrukta	**Čestice**	**Izvor**
Vođa i inicijator	1. Iskazuje povjerenje i etičnost. 2. Naglašava kolektivnu misiju. 3. Govori pozitivno o budućnosti. 4. Ima poštovanje kontrolera i ostalih zaposlenika. 5. Potiče svijest kontrolera i ostalih zaposlenika o onome što je doista važno.	Nguyen *et al.* (2017)
Uvažavanje kontrolera	1. Cijeni znanje kontrolera. 2. Poštuje kontrolerove vještine i kompetencije. *3. Pouzdaje se u kontrolerove zaključke i prijedloge.* *4. Smatra kontrolera svojim poslovnim partnerom.* 5. *Posao kontrolera smatra izuzetno važnom profesijom.*	Liden i Malisn (1998) tj. Clarke *et al*. (2019) + *Oesterreich et al. (2019), Schäffer i Brückner, (2019), itd.*
Proaktivan i cilju usmjeren	1. Uočava i rješava probleme na vrijeme. 2. Preuzima inicijativu za rješavanje problema. 3. Ne zazire od rješavanja problema. 4. Učinkovito koristi prilike kako bi postigao svoje ciljeve. 5. Aktivno se uključuje u rješavanje nastalih problema. 6. Ističe se u realizaciji problema.	Frese *et al.* (1997)

Napomena: sadržaj u kurzivu predstavlja modifikacije mjernih ljestvica napravljenih od strane autora ove disertacije

Izvor: izrada autora

Konstrukt *Vođa i inicijator* mjeren je kroz pet od osam čestica originalne ljestvice koju su kreirali Nguyen *et al.* (2017) temeljem opće poznate mjerne ljestvice transformacijskog vodstva od Avolio, Bass i Jung iz 1999. godine. *Uvažavanje kontrolera* mjereno je pomoću modificirane tj. nadopunjene mjerne ljestvice „profesionalno poštovanje“ korištene od strane Clarke *et al*. (2019) i dr., a preuzete iz tzv. LMX (engl. leader-member exchange leadership) mjerne ljestvice koja ukupno sadrži dvanaest čestica i koja je kreirana od strane Liden i Maslyn (1998). U svrhu ovog istraživanja preuzete su dvije čestice iz originalne ljestvice te su dodane tri nove temeljem znanstvene i stručne literature u području kontrolinga (Oesterreich *et al.,* 2019; Schäffer i Brückner, 2019;, itd.), a koje odražavaju mjere poštivanja kontrolera kao poslovnog partnera menadžmentu. Osim toga, originalna mjerna ljestvica podrazumijevala je ocjenu nadređenih od strane zaposlenika. Za istraživanje ove disertacije navedena ljestvica korištena je za samoprocjenu kontrolera te ocjenu kontrolera od strane nadređenog tj. menadžera. Treća karakteristika menadžera, *Proaktivan i cilju usmjeren,*

mjeren je originalnom ljestvicom „osobna inicijativa“ od Frese *et al.* (1997). Odnosno, jedna čestica je izostavljena.

Tablica 8: Operacionalizacija HOC konstrukta *Karakteristike poduzeća*

Naziv LOC konstrukta	**Čestice**	**Izvor**
Kvaliteta informacijskog sustava (IS)	1. IS ima zadovoljavajuće vrijeme obrade podataka. 2. IS čini informacije lako dostupnima. 3. IS učinkovito integrira podatke različitih područja, tj. odjela poduzeća. 4. IS omogućava učinkovitu analizu i obradu prikupljenih podataka. 5. IS je prilagodljiv potrebama poduzeća, tj. izvršavanju poslovnih zadataka.	Lin (2010)
Organizacijska formalizacija	1. Poduzeće ima veliki broj propisanih pravila i procedura. *2. Postoji jasno definirana sistematizacija radnih mjesta - zadaci, odgovornosti i ovlasti.* *3. Postoje jasno definirane hijerarhijske razine autorizacije i/ili odlučivanja.* 4. Zaposlenici, uključujući kontroler, se pridržavaju jasno definiranih procedura. 5. Poduzeće vrši nadzor svakodnevnih operacija.	Chen i Huang (2007) + *Nitzl i Hirsch (2016) i Pugh et al (1968)*
Strateška orijentiranost	1. Strateški smjer je transparentan. 2. Postoji kolektivna vizija o tome kakvo će biti poduzeće u budućnosti. 3. Postavljeni ciljevi i ciljane vrijednosti poduzeća povezane su s misijom, vizijom i strategijom. 4. Postoji učinkovit strateški plan.	Weinzimmer *et al.* (2012)
Digitalne tehnologije	1. Poduzeće pokreće nove poslovne procese zasnovane na digitalnim tehnologijama. 2. Poduzeće potiče korištenje digitalnih tehnologija u svakodnevnim poslovnim operacijama. 3. Poduzeće integrira digitalne tehnologije kako bi potaknulo promjene i napredak.	Nwankpa i Roumani (2016)

Napomena: sadržaj u kurzivu predstavlja modifikacije mjernih ljestvica napravljenih od strane autora ove disertacije

Izvor: izrada autora

Kako bi se izmjerio nisko-redni konstrukt *Kvaliteta informacijskog sustava,* korištena je mjerna ljestvica kreirana od strane Lin (2010) temeljem postavki Nelson *et al.* (2005) te DeLone modela. Odnosno, preuzete su četiri čestice iz dimenzije kvaliteta sustava i jedna modificirana čestica iz domene procijenjena korisnost koja se odnosi na ulogu IS u efikasnom obavljanju posla, a što za kontrolera podrazumijeva mogućnost učinkovite analize i obrade prikupljenih podataka. *Organizacijska formalizacija*, mjerena je pomoću tri čestice

postavljene od Chen i Huang (2007) te dvije čestice postavljenje temeljem Nitzl i Hirsch (2016) i Pugh *et al*. (1968). Za mjerenje *Strateške orijentiranosti* primijenjena je skraćena verzija Weinzimmer *et al*. (2012) ljestvice (četiri od šest čestica), dok je za mjerenje *Digitalne tehnologije* korišten novo-razvijeni, ali validni (kompozitna pouzdanost=0,89) konstrukt od Nwankpa i Roumani (2016).

Tablica 9: Operacionalizacija HOC konstrukta *Karakteristike okruženja*

Naziv LOC konstrukta	**Čestice**	**Izvor**
Intenzitet konkurentnosti	1. Poslujemo u okruženju vrlo agresivnih konkurenata. 2. Konkurencija je velika. 3. Proizvodi, usluge i interni procesi koje imaju poduzeća lako se kopiraju. 4. Poduzeća usmjeravaju velike napore k ostvarenju i zadržavanju tržišnog udjela. 5. Informacije o konkurentima i njihovim tržišnim potezima su svakodnevne. 6. Cjenovna konkurencija je jaka.	Jaworski i Kohli (1993) i Asare *et al.* (2013)
Turbulentnost tehnologije	1. Tehnološke promjene vrlo su česte. 2. Tehnološke promjene pružaju velike mogućnosti rasta. 3. Tehnološka otkrića prilika su za kreiranje novih ideja - proizvoda i usluga. 4. Tehnološka otkrića omogućavaju kreiranje boljih poslovnih procesa unutar poduzeća. 5. Tehnološka otkrića i inovacije omogućuju efikasniju upotrebu podataka u analizi i poslovnom odlučivanju.	Jaworski i Kohli (1993) tj. Asare *et al.* (2013); Eker i Eker (2019)
Rizičnost	1. Stopa neuspjeha poduzeća unutar grane je visoka. 2. Zbog velike rizičnosti, jedna loša poslovna odluka može ugroziti održivost cijele poslovne jedinice. *3. Poslovno okruženje je nedovoljno prilagodljivo.* 4. Prevladavaju niske profitne marže. 5. Odanost kupaca je niska.	Mitchell *et al.* (2011)

Napomena: sadržaj u kurzivu predstavlja modifikacije mjernih ljestvica napravljenih od strane autora ove disertacije

Izvor: izrada autora

Čestice za mjerenje *Intenziteta konkurentnosti* i *Turbulentnosti tehnologije* preuzete su iz originalne ljestvice Jaworski i Kohli (1993) s pojedinim modifikacijama napravljenih temeljen Asare *et al.* (2013) tj. Eker i Eker (2019), a koji su pored brojnih drugih autora koristili modificirane verzije Jaworski i Kohli (1993) ljestvice u vlastitim istraživanjima. Za mjerenje *Rizičnosti* korištena je modificirana mjerna ljestvica neprijateljskog okruženja od Mitchell *et al.* (2011). Točnije, preuzete su četiri od šest čestica te je dodana jedna vlastita

temeljem istog istraživanja. Sva tri konstrukta okruženja također se navode u priručniku mjeritelja u području kontrolinga (Schäffer, 2007).

Tablica 10: Operacionalizacija konstrukta *Kvaliteta kontrolerovog outputa* i *Kontrolerov utjecaj na donošenje odluka*

Naziv konstrukta	**Čestice** (za kontrolere / za menadžere)	**Izvor**
Kvaliteta kontrolerovog outputa	U kojoj se mjeri slažete sa sljedećim tvrdnjama u vezi s kvalitetom outputa (informacije u obliku izvještaja, prezentacija, dashboardova,usmenog savjetovanja itd.) koje dajete menadžeru/ koje Vam daje kontroler? " Informacije koje pružam / koje pruža kontroler… ": 1. pokrivaju sva važna područja poslovnih aktivnosti. 2. odražavaju stvarne okolnosti na sveobuhvatan i pravovaljan način. 3. odražavaju visoku razinu korisnosti i sadržajnosti. 4. vrlo su precizne. 5. uvijek su ažurne. 6. sadrže točne podatke. 7. su jasno prikazane. 8. su međusobno usklađene. 9. sadrže najrelevantnije informacije. 10. osigurane su kroz redovite izvještaje (dnevno/mjesečno itd. ili po zahtjevu).	Weißenberger i Angelkort (2011) i Wixom i Todd (2005)
Kontrolerov utjecaj na donošenje odluka	U kojoj se mjeri slažete sa sljedećim tvrdnjama (1-u potpunosti se ne slažem; 7-u potpunosti se slažem): 1. Igram vrlo važnu ulogu u procesu odlučivanja poduzeća. / Kontroler igra vrlo važnu ulogu u procesu odlučivanja poduzeća. 2. Menadžment daje visoku vrijednost mojem mišljenju pri donošenju odluka. / Dajem visoku vrijednost kontrolerovom mišljenju pri donošenju odluka. 3. Imam snažan utjecaj pri odabiru ispravne poslovne odluke (odabiru između alternativa). / Kontroler ima snažan utjecaj pri odabiru ispravne poslovne odluke (odabiru između alternativa). 4. Prije donošenja važnih odluka, menadžment se uvijek konzultira sa mnom. / Prije donošenja važnih odluka, uvijek se konzultiram sa kontrolerom. 5. Sudjelujem u donošenju odluka menadžera. / Kontroler sudjeluje u donošenju odluka. *6. Smatram da sam suodgovoran u donošenju odluka. / Smatram da je kontroler suodgovoran u donošenju odluka.*	Weissenberger i Angelkort (2011), Nitzl i Hirsch (2016) i Wolf *et al.* (2015) + *Vitezić (2020)*

Napomena: sadržaj u kurzivu predstavlja modifikacije mjernih ljestvica napravljenih od strane autora ove disertacije

Izvor: izrada autora

Za mjerenje konstrukta *Kvaliteta kontrolerovog outputa* (tj. informacija, analiza, izvještaja, prijedloga, zaključaka, itd.) korištena je modificirana mjerna ljestvica Weißenberger i Angelkort (2011, modificirana prema Bauer, 2002). Točnije, iz ljestvice Weißenberger i Angelkort (2011) izbačena je jedna čestica te je dodano pet novih iz mjerne ljestvice Wixom i Todd (2005), koju su u vlastitom obliku primijenili i Fadhilah *et al.* (2015) u području kontrolinga. Pojedine čestice koje su već bile sadržane u Weißenberger i Angelkort (2011) također su dio Wixom i Todd (2005) ljestvice. Sukladno odabranim česticama mjerna ljestvica postavljenog istraživanja doktorske disertacije mjeri točnost, ažurnost, značajnost, oblik, pravovremenost i obuhvatnost kontrolerovih outputa. U svrhu mjerenja konstrukta *Kontrolerov utjecaj na donošenje odluka* korištena je također mjerna ljestvica Weissenberger i Angelkort (2011, prilagođena prema Spillecke, 2006) nadopunjena s dvije nove čestice prema istraživanju Nitzl i Hirsch (2016) i Wolf *et al.* (2015) i jednom vlastitom temeljem Vitezić (2020), koja podrazumijeva da je kontroler suodgovoran u donošenju odluka.

Po uzoru na prethodna istraživanja uključene su sljedeće kontrolne varijable: primjena poslovne inteligencije tj. BI-a (Gullkvist, 2013), postojanje interne revizije (Gullkvist, 2013; Xu, 2015), radno iskustvo kontrolera (Rouwelaar *et al.,* 2018), organizacijski položaj odjela kontrolinga tj. centraliziran i/ili decentraliziran kontroling (Rouwelaar *et al.,* 2018; Pasch, 2019) te vlasništvo poduzeća (Albu i Albu, 2012). Sve su mjerene kroz odgovarajuću nominalnu ljestvicu. Pitanje da/ne korišteno je za primjenu BI i postojanje interne revizije, dok su unaprijed ponuđeni odgovori korišteni za ostale kontrolne varijable.

Dopunska pitanja, koja su pretežito sastavni dio drugog dijela ankete kontrolera također su uključivala pojedine mjerne ljestvice prethodnih istraživanja (Zoni i Merchant, 2007; Fadhilah *et al*., 2015; Kulkarni *et al.*, 2017; Ghasemaghaei *et al.*, 2018; Eker i Eker, 2019), ali i novokreirana pitanja temeljem postojeće literature (Ghasemi *et al.*, 2016; Appelbaum *et al.*, 2017; El Hilali *et al.*, 2020; Vitezić, 2020), a odnosila su se na kontrolerov utjecaj na rad menadžera i procjenu sudjelovanja na operativnoj i strateškoj razini, procjenu sposobnosti poslovne inteligencije, njene korisnosti i potrebe za učestalijim korištenjem, razinu upotrebe metoda poslovne analitike i Big data, aktivnosti kontrolera, vrstu pruženih informacija, predvidljivost okruženja i poslovnog rezultata, itd.

5.1.2. Uzorak istraživanja

Ciljanu populaciju istraživanja činili su kontroleri i njihovi menadžeri na području Republike Hrvatske (RH). S obzirom na to da u RH ne postoji registar kontrolera niti poduzeća koja imaju kontroling funkciju unutar svoje organizacije, kreirana je vlastita baza temeljem baze Udruge hrvatskih kontrolera, osobne provjere i analize (telefonski pozivi) 150 najvećih poduzeća prema Lider izvješću za 2019. godinu te dostupnih LinkedIn profila. Anketni upitnik poslan je ukupno 663 kontrolera (uključujući kontrolere iz pilot uzorka), koje je uključivalo oko 390 poduzeća. Preciznije, kontrolerima iz pilot uzorka je proslijeđena samo anketa za menadžere, dok je svim ostalim ispitanicima poslana cjelokupna anketa. Napravljene izmjene ankete kontrolera pilot istraživanja i konačnog istraživanja nisu utjecale na valjanost dobivenih odgovora pilot uzorka te su stoga isti uzeti u konačni uzorak istraživanja. Istraživanje je provedeno od početka studenog 2020. godine do kraja siječnja 2021. Podsjetnici su slani u nekoliko navrata putem e-maila odnosno ispitanici su dodatno kontaktirani putem LinkedIn-a i telefonskog poziva.

Ukupno je dobiveno 155 ispunjenih upitnika od strane kontrolera tj. 71 uparena odgovora kontrolera i menadžera. Prilikom ispitivanja i provjere podataka iz uzorka je isključeno 7 anketa kontrolera i menadžera, zbog analize nedostajućih i netipičnih vrijednosti te nekonzistentnosti odgovora tj. identifikacije velikog broja ekstremnih vrijednosti. Konačni uzorak činilo je 148 kontrolera i 64 menadžera, što predstavlja stopu odgovora od 22,3% i 9,7% (tj. 43,2% od ukupnih dobivenih odgovora kontrolera) tj. može se smatrati reprezentativnim uzorkom istraživanja (Weissenberg i Angelkort, 2011). Kako je već prethodno navedeno, istraživanje uključuje testiranje konceptualnog modela kroz dva uzorka. Model 1 tj. 1a podrazumijeva testiranje modela isključivo na odgovorima kontrolera (n=148), a Model 2 i 2a na uparenim odgovorima menadžera i kontrolera (n=64).

Pod kontrolerom su se podrazumijevale osobe koje rade u odijelu kontrolinga tj. čiji naziv radnog mjesta ukazuje na tu funkciju (npr. voditelj kontrolinga, specijalist za kontroling), ali i osobe koje vrše funkciju kontrolinga unutar drugih odjela (npr. plan i analiza, odjel financija tj. voditelj financija i računovodstva, itd.), a što se utvrdilo telefonskim razgovorom prije slanja upitnika te kroz opis radnog mjesta i kontaktom s ispitanikom putem LinkedIn-a.

Sukladno rezultatima istraživanja najčešći nazivi radnih mjesta kontrolera bili su: voditelj/direktor/rukovoditelj kontrolinga i/ili financija i računovodstva, voditelj financija,

specijalist/stručnjak za kontroling, referent/asistent u kontrolingu, financijski kontroler, poslovni kontroler, analitičar za kontroling tj. planer. Također se pojavljuju i sljedeći nazivi: poslovni kontroler, poslovni partner, mlađi kontroler, voditelj prodajnog kontrolinga, voditelj kontrolinga i računovodstva itd. Najčešći nazivi odjela u kojem rade kontroleri su: odjel/služba kontrolinga, kontroling i financije, financije, financije i računovodstvo; a javljaju se i: odjel podrške, plana, analize i kontrolinga, sektor plana i analize, služba operativnog planiranja, planiranje i menadžersko izvještavanje, odjel kontrolinga i interne revizije, itd. Uzorak menadžera tj. osoba kojima kontroleri pomažu u poslovnom odlučivanju uključivao je članove uprave (42,2%), direktore društva, sektora i odjela (32,8%) te voditelje financijskih odjela (25%).

Tablica 11: Socio-demografska obilježja uzorka kontrolera (n=148)

Varijabla	Kategorija	n	Udio (%)
Obilježja kontrolera			
Dob (u god)	25-34	46	31,1
	35-44	58	39,2
	45-54	31	20,9
	55-64	13	8,8
Spol	Žensko	89	60,1
	Muško	58	39,2
	Ostalo	1	0,7
Obrazovanje	SSS ili SŠS	3	2,0
	VŠS (npr. bacc. oec.)	7	4,7
	VSS (npr. mag.oec.)	93	62,8
	Sveučilišni specijalist struke (npr. univ.spec.oec, MBA)	30	20,3
	Magistar znanosti (mr.sc.)	15	10,1
Ukupno radno iskustvo (u god)	1-10	50	33,8
	11-20	58	39,2
	21-30	27	18,2
	31-40	13	8,8
Ukupno radno iskustvo u kontrolingu (u god)	1-10	101	68,0
	11-20	41	28,0
	21-30	5	3,0
	31-40	1	1,0
Obilježja poduzeća			
Veličina	malo	12	8,0
	srednje	34	23,0
	veliko	102	69,0
Djelatnost (NKD2007)	A-Poljoprivreda, šumarstvo i ribarstvo	3	2,0
	C-Prerađivačka industrija	53	35,8
	D-Opskrba električnom energijom, plinom, parom i klimatizacija	1	0,7

	E-Opskrba vodom; uklanjanje otpadnih voda, gospodarenje otpadom te djelatnosti sanacije okoliša	1	0,7
	F-Građevinarstvo	5	3,4
	G-Trgovina na veliko i na malo; popravak motornih vozila i motocikala	31	20,9
	H-Prijevoz i skladištenje	5	3,4
	I-Djelatnosti pružanja smještaja te pripreme i usluživanja hrane	11	7,4
	J-Informacije i komunikacije	11	7,4
	K-Financijske djelatnosti i djelatnosti osiguranja	12	8,1
	L-Poslovanje nekretninama	1	0,7
	M-Stručne, znanstvene i tehničke djelatnosti	7	4,7
	P-Obrazovanje	1	0,7
	Q-Djelatnosti zdravstvene zaštite i socijalne skrbi	3	2,0
	S-Ostale uslužne djelatnosti	3	2,0
Vlasništvo	hrvatsko	67	45
	strano	47	32
	većinsko hrvatsko	14	9
	većinsko strano	20	14

Napomena: u velika poduzeća uključene su i banke, osiguravajuća društva i holding društva.

Izvor: izrada autora

Prema deskriptivnim podacima socio-demografskih obilježja (tablica 11 i 12) vidljivo je da u najvećem dijelu prvog i drugog (n=148 / n=64) uzorka istraživanja čine kontroleri i menadžeri velikih poduzeća uključujući financijske institucije (102 / 44), praćeni srednjim (34 / 16) i pojedinim malim (12 / 4) poduzećima za koje se utvrdilo da zaista vrše ulogu kontrolinga. Financijske institucije nisu isključene iz uzorka s obzirom na to da model ne uključuje pojave (npr. računovodstvene politike, utjecaj na financijske pokazatelje, itd.) koje bi mogle davati iskrivljene rezultate. Oba uzorka u najvećem dijelu čine poduzeća prerađivačke djelatnosti (35,8% / 42,1%) i djelatnosti trgovina na veliko i na malo; popravak motornih vozila i motocikala (20,9% / 20,3%). Pored njih se također ističu djelatnosti pružanja smještaja te pripreme i usluživanja hrane (7,4% / 7,8%), informacije i komunikacije (7,4% / 6,2%) te financijske djelatnosti i djelatnosti osiguranja (8,1% / 7,8%), dok sve ostale djelatnosti sudjeluju sa manje do 5% posto. Najveći udio poduzeća je u hrvatskom vlasništvu (45% / 53,1%).

Tablica 12: Socio-demografska obilježja „dyadic“ uzorka menadžera i kontrolera (n=64)

Varijabla	Kategorija	n	Udio (%)	n	Udio (%)
Obilježja kontrolera i menadžera		***Kontroler***		***Menadžer***	
Dob (u god)	28-37	22	34,4	13	20,3
	38-47	27	42,1	32	50,0
	48-57	12	18,8	13	20,3
	58-68	3	4,7	6	9,4
Spol	Žensko	39	60,9	28	43,8
	Muško	25	39,1	36	56,2
Obrazovanje	SSS ili SŠS	2	3,1	1	1,6
	VŠS (npr. bacc. oec.)	1	1,6	1	1,6
	VSS (npr. mag.oec.)	39	60,9	37	57,8
	Sveučilišni specijalist struke (npr. univ.spec.oec, MBA)	12	18,8	10	15,6
	Magistar znanosti (mr.sc.)	10	15,6	10	15,6
	Doktor znanosti (dr.sc.)			5	7,8
Ukupno radno iskustvo kontrolera (u god)	3-12	18	28,1		
	13-22	26	40,6		
	23-32	16	25,0		
	33-42	4	6,3		
Ukupno radno iskustvo kontrolera u kontrolingu (u god)	2-11	38	59,4		
	12-21	24	37,5		
	22-31	2	3,1		
Ukupno radno iskustvo menadžera na rukovodećim mjestima (u god)	3-12			26	40,6
	13-22			31	48,4
	23-32			6	9,4
	33-42			1	1,6
Ukupno radno iskustvo suradnje menadžera s odjelom kontrolinga (u god)	1-10			37	57,8
	11-20			19	29,7
	21-30			7	10,9
	31-40			1	1,6

Obilježja poduzeća		n	Udio (%)
Veličina	malo	4	6,3
	srednje	16	25,0
	veliko	44	68,7
Djelatnost (NKD2007)	A-Poljoprivreda, šumarstvo i ribarstvo	1	1,6
	C-Prerađivačka industrija	27	42,1
	D-Opskrba električnom energijom, plinom, parom i klimatizacija	1	1,6
	F-Građevinarstvo	1	1,6
	G-Trgovina na veliko i na malo; popravak motornih vozila i motocikala	13	20,3
	H-Prijevoz i skladištenje	2	3,1
	I-Djelatnosti pružanja smještaja te pripreme i usluživanja hrane	5	7,8
	J-Informacije i komunikacije	4	6,2
	K-Financijske djelatnosti i djelatnosti osiguranja	5	7,8
	L-Poslovanje nekretninama	1	1,6
	M-Stručne, znanstvene i tehničke djelatnosti	2	3,1
	Q-Djelatnosti zdravstvene zaštite i socijalne skrbi	1	1,6
	S-Ostale uslužne djelatnosti	1	1,6
Vlasništvo	hrvatsko	34	53,1
	strano	22	34,4
	većinsko hrvatsko	2	3,1
	većinsko strano	6	9,4

Napomena: u velika poduzeća uključene su i banke, osiguravajuća društva i holding društva.

Izvor: izrada autora

Nadalje, prema obilježjima kontrolera i menadžera (tablica 11 i 12) može se zaključiti da posao kontrolera u većem dijelu obavljaju žene (60,1% / 60,9%), a posao menadžera muškarci (56,2%); da najveći broj kontrolera i menadžera ima od 35 do 44 tj. 38 do 47 godina; da je najvećem broju menadžera najviši stupanj završenog obrazovanja visoka stručna sprema (57,8%), kao i kontrolerima (62,8% / 60,9%) praćena specijalističkim obrazovanjima (20,3% / 18,8%). Među menadžerima također je 5 osoba sa završenim doktoratom znanosti, ali i 10 sa specijalističkim obrazovanjem što se može pripisati činjenici uključenosti financijskih direktora u uzorku menadžera. Analizom prvog uzroka (n=148) može se uvidjeti da kontroleri u prosjeku imaju 9 godina radnog iskustva u kontrolingu, odnosno 11 godina ako se u obzir uzme drugi uzorak istraživanja (n=64). Najduže radno iskustvo u kontrolingu u prvom uzorku iznosi 32 godine, a u drugom 24 godine. Najkraće iskustvo je 1 godina, odnosno 2 godine u manjem uzorku, uz minimalno trogodišnje radno iskustvo u sličnim poslovima (npr. računovodstvo, financije, revizija, razvoj itd.). Menadžeri u prosjeku imaju 14 godina radnog iskustva na rukovodećim pozicijama te 11 godina iskustva suradnje s odjelom kontrolinga. Najveći broj menadžera ima 3 do 22 godine iskustva na rukovodećim mjestima, a 1 do 10 godina suradnje s kontrolingom. Točnije, 40 menadžera ima iskustva u radu s kontrolingom u trajanju od 5 do 16 godina, 12 u dužem i 12 u kraćem trajanju. Od toga čak 2 menadžera imaju jednu tj. dvije godine iskustva rada s kontrolerom, odnosno od 37 menadžera koji surađuju s kontrolingom 1 do 10 godina, njih 13 je u dobi od 29-40 godina. Može se zaključiti da je suradnja kontrolera i menadžera u godinama trajanja relativno mlada, ali i da je vidljiv rast te suradnje kroz mlađe generacije menadžera, što ukazuje na sve veći budući značaj kontrolinga i potrebe za njegovim istraživanjem.

Iako je prema prethodnim istraživanjima uzorak potvrđen kao reprezentativan (Weissenberg i Angelkort, 2011), te pojedini autori navode da PLS-SEM metoda podržava analize s uzorkom od 100 opažanja, pa i niže (Reinartz *et al.* 2009; Kock i Hadaya, 2018; Nitzl, 2018), potrebno je odrediti minimalno dopuštenu veličinu uzorka. Prema Barclay *et al.* (1995, u Hair *et al.*, 2017) tj. primjeni multivarijatne statističke analize (PLS-SEM) koja se koristi u ovo istraživanju, gruba procjena minimalne veličine uzorka prema tzv. „10 times“ pravilu podrazumijeva da uzorak mora biti deset puta veći od najvećeg broja strukturnih puteva usmjerenih prema jednom konstruktu unutar modela. U istraživanju ovog rada, maksimalan broj veza (strelica) koje su usmjerene na jedan konstrukt iznosi sedam (Model 1 i 1a) odnosno četiri (Model 2 i 2a). Primjenjujući navedeno pravilo, minimalna veličina uzorka mora iznositi 70 odnosno 40, a prikupljeno je 148 odnosno 64 važećih anketa.

Iako je prema navedenom pravilu, koje se često koristi u istraživanjima, zadovoljen minimalan broj uzorka u istraživanju, Hair *et al.* (2017) naglašavaju da bi se on trebao odrediti i pomoću analize snage (engl. power analyses) temeljem dijela modela s najvećim brojem prediktora. Pri tome predlaže korištenje pravila postavljenih od Cohen 1992. godine i/ili tzv. G*Power aplikaciju.

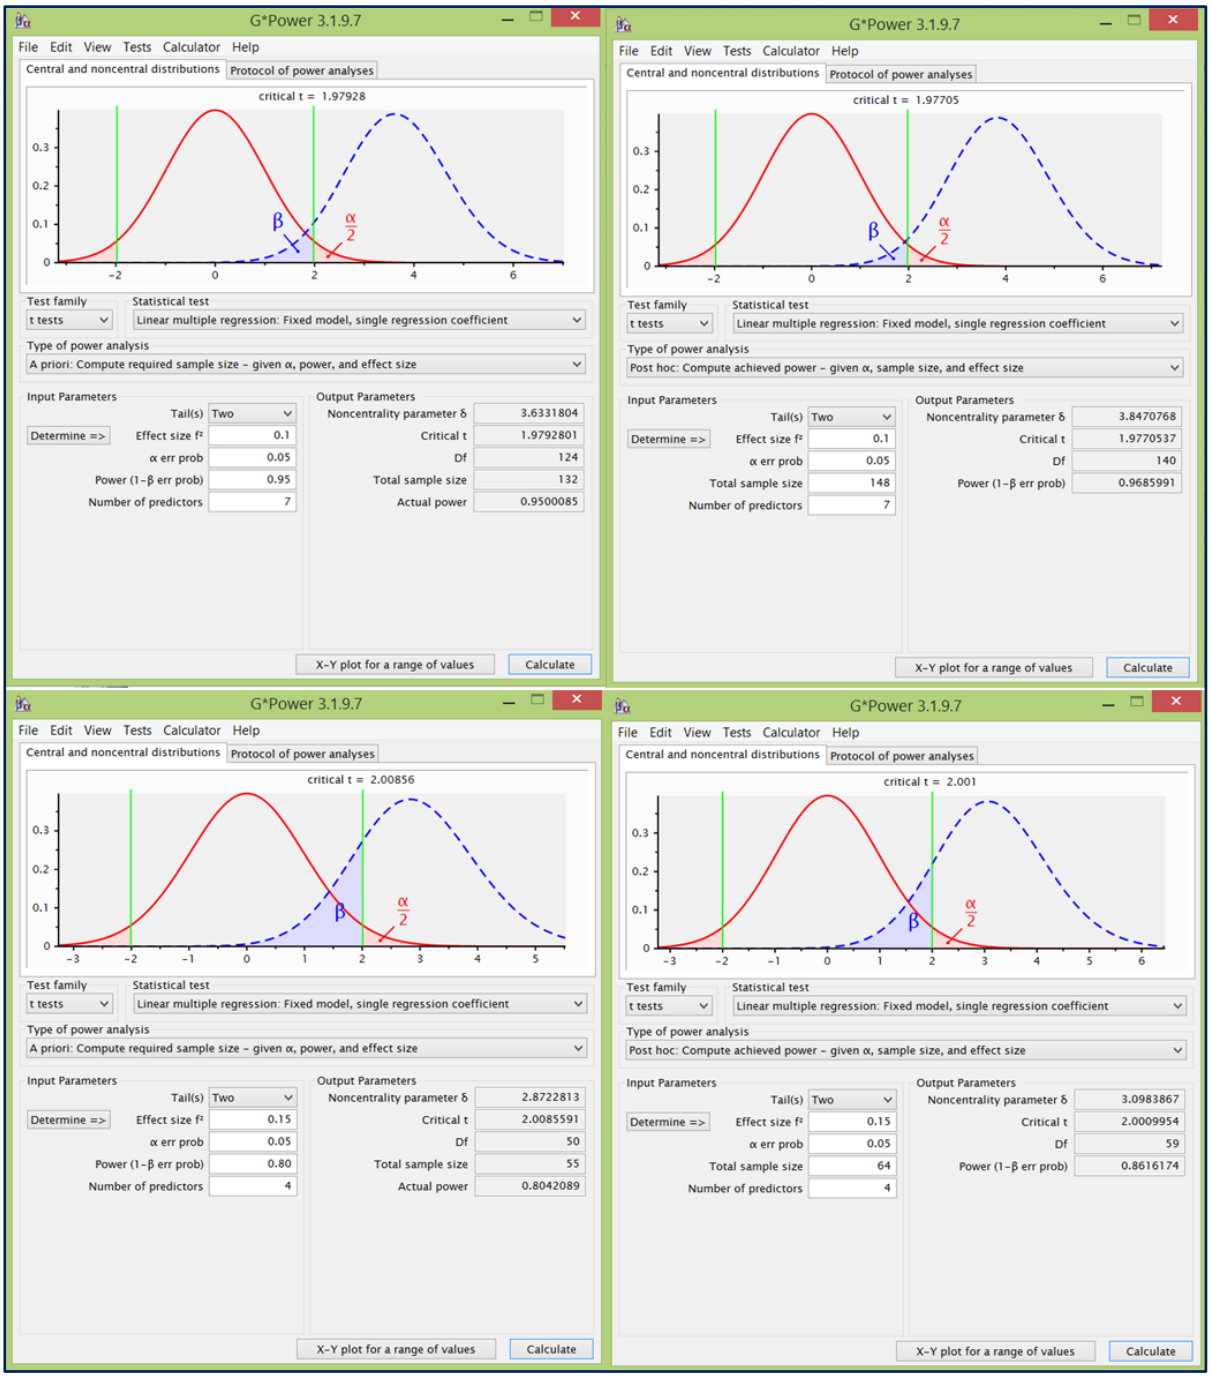
Tablica 13: Preporuka minimalne veličina uzorka pri statističkoj snazi od 80%

Maksimalan broj strukturnih puteva usmjerenih prema jednom konstruktu	Razina značajnosti											
	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: Cohen (1992, u Hair *et al.*, 2017)

Uzorak istraživanja zadovoljava minimalnu veličinu i prema pravilima koje je postavio Cohen (tablica 13). Uzorak od 148 kontrolera s maksimalno 7 strelica prema određenom konstruktu i maksimalnom veličinom koeficijenta determinacije (R^2) endogenog konstrukta od 0,112 zadovoljava postavljenu granicu od 137 ispitanika uz 5% vjerojatnost nastanka greške za ostvarenje 80% statističke snage. Odnosno, uzorak od 64 kontrolera i menadžera s maksimalno 4 strelice prema određenom konstruktu i maksimalnom veličinom R^2 endogenog konstrukta od 0,464 zadovoljava postavljenu granicu od 41 ispitanika uz 5% vjerojatnost nastanka greške za ostvarenje 80% statističke snage tj. 58 ispitanika uz 1% vjerojatnost nastanka greške za ostvarenje 80% statističke snage.

Slika 14: G*Power rezultati



Izvor: aplikacija G*Power (3.1.9.7.) aplikacije

Rezultati dobiveni kroz G*Power aplikaciju (slika 14), koja u obzir uzima veličinu učinka i statističku snagu, također potvrđuju prikladnost veličine uzorka. Odnosno, uz veličinu učinka 0.1 tj. 0.15 uzorak od 168 tj. 64 ispitanika ostvaruje jačinu snage od 97% tj. 86%. Dakle, prikupljene ankete zadovoljavaju uvjete minimalne veličine uzorka i mogu se primijeniti za analizu postavljenog konceptualnog modela.

5.1.3. Metode statističke analize

U svrhu pripreme podataka i za analizu socio-demografskih obilježja uzorka korišten je Microsoft Excel tj. opcija PivotTable i PowerQuery. Za deskriptivnu statistiku varijabli, čišćenje podataka, određivanje ekstrema i izračuna normalnosti podataka korišten je softverski alat Stata14, dok je u svrhu dokazivanja postavljenih hipoteza modela i njegove predikacijske moći korišten softverski alat SmartPLS (v. 3.3.3).

SmartPLS tj. metoda parcijalnih najmanjih kvadrata modeliranja strukturalnim jednadžbama (engl. Partial least squares Structural equation modeling - PLS-SEM) predstavlja multivarijatnu statističku metodu zasnovanu na običnoj linearnoj regresiji (engl. ordinary least squares - OLS) i standardiziranim podacima, koja u posljednjih nekoliko godina dobiva na sve većem značaju. Tijekom godina razvile su se brojne multivarijatne metode koje se prvenstveno koriste u društvenim znanostima, a koje se dijele na metode prve i druge generacije (tablica 14, Hair *et al*., 2017). PLS-SEM predstavlja jednu od metoda druge generacije.

Tablica 14: Multivarijatne statističke metode

Generacija	**Vrsta metode**	
	Prvenstveno eksploratorna	**Prvenstveno konfirmatorna**
Prva	• klaster analiza • eksploratorna faktorska analiza • višedimenzionalno skaliranje	• analiza varijance • logistička i višestruka regresija • konfirmatorna faktorska analiza
Druga	Metoda parcijalnih najmanjih kvadrata modeliranja strukturalnim jednadžbama (PLS-SEM)	Modeliranje strukturnih jednadžbi temeljeno na kovarijanci (engl. Covariance-based structural equation model ing - CB-SEM)

Izvor: Hair *et al.* (2017)

Upotreba tehnika prve generacije multivarijatnih metoda dominirala je tijekom 1980-ih godina. Međutim, tijekom ranih 90-ih godina istraživači su značajno počeli primjenjivati metode druge generacije. Odnosno, u posljednjih 20-30 godina došlo je do njihove povećane primjene prvenstveno zbog slabosti tehnika prve generacije. Dvije su osnovne vrste tehnika druge generacije tj. metoda strukturalnog modeliranja (engl. Structural equation modeling - SEM). To su PLS-SEM i CB-SEM. Dok se CB-SEM primarno koristi u konfirmatornim istraživanjima, PLS-SEM prvenstveno se primjenjuje za razvoj teorija u eksploratornim istraživanja. Odnosno, PLS-SEM minimizira greške tj. rezidualne varijance endogenih varijabli i procjenjuje koeficijente koji maksimiziraju vrijednosti R^2 ciljanog endogenog

konstrukta. Stoga se smatra metodom temeljenoj na varijanci (engl. variance-based), dok se CB-SEM smatra kovarijantnom metodom (Hair *et al.*, 2017).

Iako PLS-SEM kao i svaka druga metoda ima određena ograničenja (npr. nemogućnost analize kauzalnih veza) u ovom istraživanju je korištena i više razloga, a koje Hair *et al.* (2017) prikazuju kao glavne prednosti te metode:

1) radi se o eksplanatornom istraživanju,
2) istraživanje uključuje manji uzorak,
3) model istraživanja je kompleksan (sadrži puno konstrukata i indikatora),
4) model je postavljen kao hijerarhijsko komponentni model,
5) prisutna je ne-normalnost distribucije podataka,
6) cilj je predvidjeti ključni konstrukt tj. želi se ispitati prediktivna moć modela i
7) namjera je da se latentne varijable primjene u naknadnim analizama.

Osim toga, od 2010. godine sve je veća primjena PLS-SEM metode u odnosu na CB-SEM metodu u različitim područjima menadžmenta (Hair *et al.*, 2019), a sve se više naglašava potreba za njegovom primjenom i u kontrolingu (Nitzl, 2016, 2018).

5.2. Rezultati empirijskog istraživanja

Rezultati empirijskog istraživanja sadrže tri podpoglavlja. U prvom je prikazan kratak pregled aktivnosti i razine informacijske uloge kontrolera. U drugom su prikazani rezultati deskriptivne statističke analize tj. analize čestica svih konstrukata testiranog modela. Treći dio uključuje rezultate i interpretacije provedene PLS-SEM analize, a kojom je potvrđena glavna i pomoćne hipoteze doktorske disertacije.

5.2.1. Aktivnosti i razina informacijske uloge kontrolera

Prije prikaza deskriptivne statističke analize varijabli i rezultata analize konceptualnog modela, napravljena je analiza razine aktivnosti i uloge kontrolera s osnove informacijske opskrbe menadžmenta. Odnosno, provedena je analiza učestalosti (frekvencije) kontrolerovih aktivnosti i vrste informacija koje pružaju menadžerima te razine koristi primjene velike količine podataka (Big Data) od strane kontrolera. Analiza ne uključuje cijeli uzorak od 148

kontrolera već 131. Razlog tomu je što su podaci za izvršenje analize bili dio drugog dijela ankete kontrolera koji nije bio obavezan. Međutim, navedeni rezultati pored rezultata analize modela te analize primjene poslovne inteligencije i analitike (prikazani u poglavlju 5.2.3.) predstavljaju osnovu za prijedlog budućeg razvoja kontrolinga koji je dio empirijskog istraživanja ove disertacije (poglavlje 5.3).

Tablica 15: Analiza vrsta i učestalosti kontrolerovih aktivnosti - analiza i informacija (n = 131; Likert 1-nikada; 2-gotovo nikada; 3-rijetko; 4-ponekad; 5-često; 6-vrlo često; 7-redovito)

Naziv aktivnosti	**Prosječna vrijednost**	**Frekvencija (u broju ispitanika)**						
		1	**2**	**3**	**4**	**5**	**6**	**7**
Analiza odstupanja (kontrola planirano/izvršeno)	6.420	2	0	3	4	10	20	92
Analiza i planiranje prihoda i troškova	6.244	4	0	5	7	7	20	88
Operativno planiranje i budžetiranje	6.145	2	1	10	5	13	14	86
Razvoj i praćenje ključnih pokazatelja poslovanja (KPI)	5.824	5	1	3	9	22	36	55
Prognoziranje i predviđanje	5.603	9	1	9	9	18	25	60
Analiza uspješnosti (rentabilnost, produktivnost, ekonomičnost,obrtaji imovine)	5.504	4	5	8	15	22	26	51
Analiza proizvoda i usluga, profitabilnost kupca, podružnica i dr.	5.198	10	5	13	13	17	26	47
Usporedna analiza i benchmarking	4.977	10	3	19	15	19	31	34
Praćenje likvidnost	4.756	12	11	13	18	20	21	36
Razvoj i vrednovanje investicija i projekata (stupanj isplativosti i dovršenosti)	4.542	17	11	13	15	23	22	30
Rolling planiranje	4.397	28	7	12	12	18	18	36
Analiza efikasnosti procesa nabave (npr. narudžbe, dobavljači, optimizacija troškova) i/ili proizvodnje (npr. količina proizvodnje i škarta, vrijeme izrade)	4.153	17	13	16	29	19	17	20
Analiza rizika i ostalih neizvjesnosti	3.863	23	15	18	25	19	13	18
Analiza snaga, slabosti, prilika i prijetnji (SWOT)	3.847	19	22	18	20	23	11	18
Uravnoteženo mjerenje uspješnosti poslovanja (Balanced scorecarda)	3.771	28	16	14	17	26	16	14
Analiza boniteta kupaca i dobavljača	3.756	25	20	18	19	17	12	20
Analiza učinkovitosti djelatnika	3.733	24	17	22	17	23	14	14
Ispomoć u procesu reinženjeringa i inovacija.	3.290	31	20	29	15	13	13	10
Analiza ostalih vrsta ulaganja (ulaganja u vrijednosne papire, nekretnine, oročavanje sredstava…)	3.008	37	25	22	21	9	7	10

Izvor: izrada autora

Iz rezultata (tablica 15) vidljivo je da su u prosjeku najčešće aktivnosti kontrolera analiza odstupanja, analiza i planiranje prihoda i troškova te operativno planiranje i budžetiranje. Međutim, značajni dio aktivnosti predstavljaju i prognoziranje i predviđanje. Točnije, za 46% ispitanika navedena aktivnost predstavlja redovitu poslovnu obvezu, što se može povezati i s razinom aktivnosti razvoja i praćenja ključnih pokazatelja poslovanja i primjenom rolling

planiranja. Navedeno ukazuje na značaj proaktivnosti i buduće orijentiranosti kontrolera. U prosjeku, kontroleri najmanje sudjeluju u analizi ulaganja kao npr. nekretnina i vrijednosnih papira, što se može pripisati vrsti uzorka istraživanja. Samo jedno poduzeće ukupnog uzorka je iz područja djelatnosti poslovanja nekretninama, dok je jedanaest iz područja financijskih djelatnosti i djelatnosti osiguranja. Za pretpostaviti je da su upravo ta poduzeća ona koja aktivnost analize ulaganja koriste kao redovitu poslovnu aktivnost. Pored toga, iz rezultata vidljivo je da kontroleri najmanje sudjeluju u analizi učinkovitosti djelatnika, analizi ocjene boniteta kupaca i dobavljača te kao ispomoć u procesu reinženjeringa i inovacija. To se može povezati s razinom uključenosti funkcijskih odjela kontrolinga. Naime, u uzorku istraživanja uključena su sveg četiri odjela kontrolinga prodaje i tri odjela kontrolinga proizvodnje, a nije uključen niti jedan odjel kontrolinga nabave. Također, uzorak ne uključuje novije koncepte odjela kontrolinga kao što su kontroling ljudskih potencijala te projektni i inovacijski kontroling.

Tablica 16: Analiza vrsta nefinancijskih informacija i učestalosti njihova pružanja menadžmentu u svrhu poslovnog odlučivanja (n = 131; Likert 1-nikada; 2-gotovo nikada; 3-rijetko; 4-ponekad; 5-često; 6-vrlo često; 7-redovito)

Vrste informacija	**Prosječna vrijednost**	**Frekvencija (u broju ispitanika)**						
		1	**2**	**3**	**4**	**5**	**6**	**7**
A - Informacije koje se odnose buduće događaje.	5.145	3	6	7	24	30	35	26
B - Eksterne informacije kao npr. preferencije i zadovoljstvo kupaca, zadovoljstvo postojećih i dostupnost novih dobavljača, konkurentske prijetnje, odluke državnih i lokalnih tijela itd.	3.611	18	19	21	39	14	12	8
C - Interne informacije kao npr. zadovoljstvo, motiviranost i stavovi zaposlenika, kvaliteta upravljanja i organizacije internih procesa, radna okolina itd.	3.794	14	18	21	35	21	15	7
D - Informacije o brojnim čimbenicima koji su izvan vaše poduzeća (poput ekonomskih uvjeta, rasta stanovništva, dostupnosti ljudskih resursa, tehnološkog razvoja, ekoloških rizika, BDP, rasta cijena, troškova života itd.)	3.649	17	23	15	36	21	12	7
E - Nefinancijske informacije koje doprinose većoj efikasnosti kao npr. stopa rasta proizvodnje i/ili prodaje, smanjenje škarta i nesukladnih proizvoda, ušteda vremena pružanja usluge, unaprjeđenje efikasnosti procesa nabave, fluktuacija i izostanci učinkovitosti zaposlenika, pokazatelji odnosa prema ekologiji i društvenim aspektima poslovanja (zaštita na radu, zdravstvena zaštita, diskriminacija, korupcija), itd.	4.069	10	22	14	32	24	14	15

Izvor: izrada autora

Da kontroleri kao partneri menadžmentu imaju značajnu ulogu u planiranju i predviđanju budućih događaja, potvrđuju i rezultati analize učestalosti pružanja pojedinih vrsta informacija (tablica 16). Čak 69% ispitanika često, vrlo često ili redovito pruža menadžmentu informacije koje se odnose na buduće događaje. U manjoj mjeri im podnose nefinancijske informacije koje doprinose efikasnosti poslovanja kao npr. efikasnost rada i procesa te analiza odnosa prema društvenim aspektima poslovanja. ali i informacije koje se odnose na zadovoljstvo i motiviranost zaposlenika, kvalitetu upravljanja i organizacije internih procesa te radne okoline. Informacije o vanjskim čimbenicima poput ekonomskih uvjeta, dostupnosti ljudskih resursa i tehnološkog razvoja, preferencija i zadovoljstva kupaca i dobavljača, konkurentskih prijetnji te odluka državnih i lokalnih tijela, u prosjeku su najmanje zastupljene.

Tablica 17: Analiza korisnosti primjene Big Data (n = 131)

Vrsta koristi	**Prosječna vrijednost**	**Frekvencija (u broju ispitanika)**						
		1	**2**	**3**	**4**	**5**	**6**	**7**
Big Data omogućava izradu učinkovitih (operativnih i strateških) analiza i efikasnije poslovno odlučivanje.	6.053	0	0	0	8	17	66	40
Big Data koristi kontrolingu za generiranje i obradu aktualnih internih i eksternih podataka u svrhu poslovnog odlučivanja.	5.969	0	0	0	11	18	66	36
Big Data omogućava kontrolingu uštedu vremena pronalaženja potrebnih podatka za obradu i time pridodaje vrijednosti analizama.	5.969	0	0	0	9	23	62	37
Big Data se koristi za razumijevanje i mjerenje utjecaja okruženja na poslovanje poduzeća (npr. ekološki rizici, gospodarski uvjeti, dostupnost ljudskih resursa itd.)	5.557	0	0	7	13	34	54	23

Izvor: izrada autora

U današnjem digitalnom dobu, neizostavna je analiza značaja i koristi Big Data, a osobito u poslovima koji se prvenstveno bave prikupljanjem i analizom podataka u svrhu efikasnog odlučivanja, kao što je primarna uloga kontrolinga. Big Data se definira kao velika količina raznolikih, strukturiranih, nestrukturiranih i polustrukturiranih podataka koji poduzeću stoje na raspolaganju unutar i izvan poduzeća (npr. interni dokumenti, arhiva i serveri strojeva, svi podaci dostupni na Internetu, podaci s mobilnih aplikacija, društvenih mreža, javnih baza podataka, medija itd.). Prema analizi dobivenih odgovora kontrolera (tablica 17) može se zaključiti da Big Data ima značajnu korist za kontroling. U prosjeku najveću korist od Big Data kontroleri vide pri izradi operativnih i strateških analiza tj. njihovog korištenja u svrhu poslovnog odlučivanja. Odnosno, korist se očituje kroz lakše generiranje i obradu podataka te uštedu vremena za pronalaženje istih. U neznatno manjoj mjeri Big Data se koristi i za

razumijevanje i mjerenje utjecaja poslovnog okruženja poduzeća. Dobiveni rezultati ukazuju na direktnu povezanost s dobivenim rezultatima analize vrste i učestalosti pružanja kontrolerovih aktivnosti i informacija. Naime, danas se Big Data smatra osnovnim sredstvom izvora podataka i informacija za poslovno planiranje i predviđanje, koje se je u ovom istraživanju dokazalo kao jedno od četiri osnovne aktivnosti kontrolera. Jedino pružanjem informacija koje ukazuju na buduća događanja kontroler može ostvariti svoju ulogu poslovnog partnera menadžmentu.

5.2.2. Deskriptivna statistička analiza latentnih varijabli modela

Deskriptivnom statističkom analizom se na sažet način opisuju podaci (varijable) neke analizirane pojave. Osnovni parametri deskriptivne analize podrazumijevaju izračun aritmetičke sredine, standardne devijacije, najveće i najmanje vrijednosti, koeficijenta zaobljenosti i koeficijenta asimetričnosti. U nastavku će biti prikazani izračuni navedenih parametara za sve čestice korištene u svrhu analize konceptualnog modela oba uzorka (n=148 i n=64).

Tablica 18: Deskriptivna statistička analiza HOC, LOC i endogenih jednodimenzionalnih čestica prvog uzorka (n=148)

HOC	LOC	Kratica čestice	Čestica	Aritmetička sredina	Min	Max	Standardna devijacija	Skewness	Kurtosis
KAR KTL	AN	KTL_an1	Sposoban sam objasniti značenje brojeva.	6.581	5.000	7.000	0.581	-1.04	3.080
		KTL_an2	Fokusiran sam i razumijem izvore problema.	6.446	5.000	7.000	0.618	-0.652	2.466
		KTL_an3	Usmjeren sam ka budućnosti.	6.426	5.000	7.000	0.638	-0.658	2.441
		KTL_an4	Sposoban sam uočiti trendove prije nego postanu stvarnost.	5.791	4.000	7.000	0.832	-0.155	2.347
		KTL_an5	Dobar sam u korištenju, strukturiranju i obradi brojeva.	6.446	5.000	7.000	0.640	-0.727	2.505
	KOM	KTL_kom1	Lako uspostavljam kontakt s drugima i slušam sugovornike.	6.291	5.000	7.000	0.607	-0.246	2.381
		KTL_kom2	Jasno komuniciram svoje ideje usmenim putem.	6.176	5.000	7.000	0.644	-0.181	2.334
		KTL_kom3	Jasno komuniciram svoje ideje pismenim putem.	6.318	5.000	7.000	0.637	-0.391	2.303
		KTL_kom4	Mogu uvjeriti druge ljude da slijede moje ideje.	5.622	4.000	7.000	0.783	-0.238	2.681
		KTL_kom5	Sposoban sam prenijeti poruku, tj. važni sadržaj.	6.257	5.000	7.000	0.659	-0.331	2.235
	AS	KTL_as1	Jasno izražavam svoje mišljenje, osjećaje i stavove.	6.020	4.000	7.000	0.792	-0.443	2.663
		KTL_as2	Izražavam svoje neslaganje sa mišljenjima drugih.	5.865	4.000	7.000	0.827	-0.460	2.769
		KTL_as3	Dajem konstruktivne kritike.	6.061	4.000	7.000	0.719	-0.527	3.301
		KTL_as4	Nije mi problem reći NE drugima.	5.520	3.000	7.000	1.030	-0.574	3.199
		KTL_as5	Dopuštam drugima da izraze svoje mišljenje.	6.507	5.000	7.000	0.575	-0.665	2.450
	PROAKT	KTL_proakt1	Prilika i izazov mi je vidjeti da se moje ideje pretvaraju u stvarnost.	6.466	5.000	7.000	0.641	-0.797	2.585
		KTL_proakt2	Samoinicijativno popravljam uočene greške, probleme i nedostatke.	6.514	5.000	7.000	0.642	-0.970	2.836
		KTL_proakt3	Uvijek tragam za boljim načinima rada i načinima rješavanja problema.	6.466	5.000	7.000	0.630	-0.762	2.567
		KTL_proakt4	Prepreke me ne sprječavaju u ostvarenju ciljeva i ideja u koje vjerujem.	6.122	4.000	7.000	0.813	-0.754	3.163
		KTL_proakt5	Izravno se suočavam s problemima.	6.270	5.000	7.000	0.694	-0.418	2.112
		KTL_proakt6	Probleme pretvaram u prilike.	5.770	4.000	7.000	0.871	-0.214	2.315
	KREAT	KTL_kreat1	Predlažem kreativna rješenja problema i pri tome se ne bojim preuzeti rizik.	5.986	4.000	7.000	0.797	-0.457	2.749
		KTL_kreat2	Promičem i zagovaram vlastite kreativne ideje i ideje drugih.	5.926	4.000	7.000	0.772	-0.489	3.049
		KTL_kreat3	Moja kreativnost dolazi do izražaja prilikom rješavanja složenih problem.	5.899	4.000	7.000	0.898	-0.582	2.657
		KTL_kreat4	Predlažem nove načine postizanja ciljeva i ciljanih vrijednosti.	5.845	4.000	7.000	0.868	-0.377	2.480
KAR MEN	VOD&INC	MEN_vod&inic1	Iskazuje povjerenje i etičnost.	6.149	3.000	7.000	0.996	-1.368	4.684
		MEN_vod&inic2	Naglašava kolektivnu misiju.	6.074	4.000	7.000	0.894	-0.941	3.313
		MEN_vod&inic3	Govori pozitivno o budućnosti.	6.135	4.000	7.000	0.827	-0.685	2.825
		MEN_vod&inic4	Ima poštovanje kontrolera i ostalih zaposlenika.	6.135	4.000	7.000	0.890	-0.957	3.282
		MEN_vod&inic5	Potiče svijest kontrolera i ostalih zaposlenika o onome što je doista važno.	5.966	3.000	7.000	1.093	-1.206	3.920
	UVAZKTL	MEN_uvazktl1	Cijeni znanje kontrolera.	6.203	4.000	7.000	0.893	-1.035	3.353
		MEN_uvazktl2	Poštuje kontrolerove vještine i kompetencije.	6.236	4.000	7.000	0.825	-0.896	3.168
		MEN_uvazktl3	Pouzdaje se u kontrolerove zaključke i prijedloge.	6.135	4.000	7.000	0.802	-0.641	2.836
		MEN_uvazktl4	Smatra kontrolera svojim poslovnim partnerom.	6.034	3.000	7.000	1.068	-1.132	3.632

		MEN_uvazktl5	Posao kontrolera smatra izuzetno važnom profesijom.	6.027	3.000	7.000	1.000	-1.028	3.544
	PROCILJ	MEN_procilj1	Uočava i rješava probleme na vrijeme.	6.014	4.000	7.000	0.838	-0.645	2.942
		MEN_procilj2	Preuzima inicijativu za rješavanje problema.	6.088	4.000	7.000	0.892	-0.857	3.081
		MEN_procilj3	Ne zazire od rješavanja problema.	6.270	4.000	7.000	0.875	-1.159	3.669
		MEN_procilj4	Učinkovito koristi prilike kako bi postigao svoje ciljeve.	6.122	4.000	7.000	0.877	-0.900	3.217
		MEN_procilj5	Aktivno se uključuje u rješavanje nastalih problema.	6.142	4.000	7.000	0.830	-0.695	2.816
		MEN_procilj6	Ističe se u realizaciji problema.	6.068	3.000	7.000	0.977	-0.961	3.512
KAR POD	KVINFS	POD_kvinfs1	IS ima zadovoljavajuće vrijeme obrade podataka.	5.588	2.000	7.000	1.278	-1.079	3.720
		POD_kvinfs2	IS čini informacije lako dostupnima.	5.426	2.000	7.000	1.376	-0.934	3.256
		POD_kvinfs3	IS učinkovito integrira podatke različitih područja, tj. odjela poduzeća.	5.155	1.000	7.000	1.558	-0.784	2.800
		POD_kvinfs4	IS omogućava učinkovitu analizu i obradu prikupljenih podataka.	5.270	2.000	7.000	1.450	-0.836	2.868
		POD_kvinfs5	IS je prilagodljiv potrebama poduzeća, tj. izvršavanju poslovnih zadataka.	5.291	1.000	7.000	1.503	-0.955	3.194
	FORM	POD_form1	Poduzeće ima veliki broj propisanih pravila i procedura.	5.750	2.000	7.000	1.394	-1.283	4.007
		POD_form2	Postoji jasno definirana sistematizacija radnih mjesta - zadaci, odgovornosti i ovlasti.	5.595	2.000	7.000	1.394	-1.182	3.926
		POD_form3	Postoje jasno definirane hijerarhijske razine autorizacije i/ili odlučivanja.	5.757	2.000	7.000	1.334	-1.173	3.958
		POD_form4	Zaposlenici, uključujući kontroler, se pridržavaju jasno definiranih procedura.	5.655	3.000	7.000	1.113	-0.790	3.070
		POD_form5	Poduzeće vrši nadzor svakodnevnih operacija.	5.405	2.000	7.000	1.202	-0.723	3.541
	STROR	POD_stror1	Strateški smjer je transparentan.	5.791	3.000	7.000	0.995	-0.683	3.108
		POD_stror2	Postoji kolektivna vizija o tome kakvo će biti poduzeće u budućnosti.	5.574	3.000	7.000	1.040	-0.450	2.909
		POD_stror3	Postavljeni ciljevi i ciljane vrijednosti poduzeća povezane su s misijom, vizijom i strategijom.	5.696	3.000	7.000	1.044	-0.544	2.643
		POD_stror4	Postoji učinkovit strateški plan.	5.432	2.000	7.000	1.192	-0.498	2.719
	DIGTEH	POD_digteh1	Poduzeće pokreće nove poslovne procese zasnovane na digitalnim tehnologijama.	5.786	3.000	7.000	1.133	-0.781	2.949
		POD_digteh2	Poduzeće potiče korištenje digitalnih tehnologija u svakodnevnim poslovnim operacijama.	5.916	3.000	7.000	1.034	-0.961	3.627
		POD_digteh3	Poduzeće integrira digitalne tehnologije kako bi potaknulo promjene i napredak.	5.802	3.000	7.000	1.073	-0.832	3.247
KAR OKR	INTKON	OKR_intkon1	Poslujemo u okruženju vrlo agresivnih konkurenata.	5.885	2.000	7.000	1.308	-1.582	5.118
		OKR_intkon2	Konkurencija je velika.	5.905	2.000	7.000	1.322	-1.458	4.666
		OKR_intkon3	Proizvodi, usluge i interni procesi koje imaju poduzeća lako se kopiraju.	4.905	1.000	7.000	1.552	-0.818	3.015
		OKR_intkon4	Poduzeća usmjeravaju velike napore k ostvarenju i zadržavanju tržišnog udjela.	6.142	4.000	7.000	0.862	-0.973	3.473
		OKR_intkon5	Informacije o konkurentima i njihovim tržišnim potezima su svakodnevne.	5.135	1.000	7.000	1.446	-0.706	3.163
		OKR_intkon6	Cjenovna konkurencija je jaka.	5.831	2.000	7.000	1.377	-1.386	4.203
	TURBTEH	OKR_turbteh1	Tehnološke promjene vrlo su česte.	5.020	1.000	7.000	1.557	-0.796	2.948
		OKR_turbteh2	Tehnološke promjene pružaju velike mogućnosti rasta.	5.736	3.000	7.000	1.099	-0.779	3.061
		OKR_turbteh3	Tehnološka otkrića prilika su za kreiranje novih ideja - proizvoda i usluga.	5.743	3.000	7.000	1.079	-0.736	3.037
		OKR_turbteh4	Tehnološka otkrića omogućavaju kreiranje boljih poslovnih procesa unutar poduzeća.	5.851	3.000	7.000	1.016	-0.899	3.609
		OKR_turbteh5	Tehnološka otkrića i inovacije omogućuju efikasniju upotrebu podataka u analizi	6.014	4.000	7.000	0.870	-0.765	3.068

			i poslovnom odlučivanju.						
	RIZIK	OKR_rizik1	Stopa neuspjeha poduzeća unutar grane je visoka.	3.541	1.000	7.000	1.574	0.201	1.950
		OKR_rizik2	Zbog velike rizičnosti, jedna loša poslovna odluka može ugroziti održivost cijele poslovne jedinice.	3.541	1.000	7.000	1.612	0.140	2.037
		OKR_rizik3	Poslovno okruženje je nedovoljno prilagodljivo.	3.851	1.000	7.000	1.449	0.020	2.376
		OKR_rizik4	Prevladavaju niske profitne marže.	3.932	1.000	7.000	1.699	0.056	1.864
		OKR_rizik5	Odanost kupaca je niska.	3.324	1.000	7.000	1.591	0.518	2.335
Endogeni jednodimenzionalni konstrukti									
KVALITETA OUTPUTA		Informacije koje pružam… :							
		kvout_1	pokrivaju sva važna područja poslovnih aktivnosti.	5.973	5.000	7.000	0.687	0.035	2.117
		kvout_2	odražavaju stvarne okolnosti na sveobuhvatan i pravovaljan način.	6.000	4.000	7.000	0.707	-0.344	2.973
		kvout_3	odražavaju visoku razinu korisnosti i sadržajnosti.	6.014	4.000	7.000	0.716	-0.351	2.896
		kvout_4	vrlo su precizne.	6.081	4.000	7.000	0.712	-0.455	3.074
		kvout_5	uvijek su ažurne.	6.142	4.000	7.000	0.780	-0.595	2.808
		kvout_6	sadrže točne podatke.	6.291	5.000	7.000	0.639	-0.346	2.298
		kvout_7	su jasno prikazane.	6.250	5.000	7.000	0.635	-0.267	2.327
		kvout_8	su međusobno usklađene.	6.196	5.000	7.000	0.644	-0.207	2.324
		kvout_9	sadrže najrelevantnije informacije.	6.236	5.000	7.000	0.630	-0.233	2.360
		kvout_10	osigurane su kroz redovite izvještaje (dnevno/mjesečno itd. ili po zahtjevu).	6.412	5.000	7.000	0.636	-0.614	2.406
UTJECAJ NA ODLUKE		utjktl_1	Igram vrlo važnu ulogu u procesu odlučivanja poduzeća.	5.439	2.000	7.000	1.116	-0.751	3.452
		utjktl_2	Menadžment daje visoku vrijednost mojem mišljenju pri donošenju odluka.	5.324	2.000	7.000	1.152	-0.575	3.234
		utjktl_3	Imam snažan utjecaj pri odabiru ispravne poslovne odluke (odabiru između alternativa).	4.993	2.000	7.000	1.216	-0.460	3.073
		utjktl_4	Prije donošenja važnih odluka, menadžment se uvijek konzultira sa mnom.	4.696	1.000	7.000	1.514	-0.610	2.728
		utjktl_5	Sudjelujem u donošenju odluka menadžera.	4.743	1.000	7.000	1.534	-0.553	2.563
		utjktl_6	Smatram da sam suodgovoran u donošenju odluka.	4.662	1.000	7.000	1.680	-0.466	2.233

Izvor: izrada autora

Obzirom da drugi uzorak (n=64) umjesto odgovora kontrolera uključuje odgovore menadžera za pojedine konstrukte (karakteristike kontrolera, kvaliteta kontrolerovog outputa i kontrolerov utjecaj na donošenje odluka), u svrhu prepoznavanja čestica, napravljene su izmjene kratica tih čestica. Svim česticama navedena tri konstrukta dodana je oznaka „men“. Tako je, na primjer, čestica KTL_an1 zamijenjena sa KTLmen_an1; kvout_1 s kvoutmen_1; utjktl1 sa utjktlmen_1, itd.

Tablica 19: Deskriptivna statistička analiza HOC, LOC i endogenih jednodimenzionalnih čestica drugog uzorka (n=64)

HOC	LOC	Kratica čestice	Čestica	Aritmetička sredina	Min	Max	Standardna devijacija	Skewness	Kurtosis
KAR KTL	AN	KTLmen_an1	Sposoban je objasniti značenje brojeva.	6.525	5.000	7.000	0.531	-0.437	1.973
		KTLmen_an2	Fokusiran je i razumije izvore problema.	6.344	3.000	7.000	0.807	-1.677	7.050
		KTLmen_an3	Usmjeren je ka budućnosti.	5.836	2.000	7.000	1.074	-1.615	6.910
		KTLmen_an4	Sposoban je uočiti trendove prije nego postanu stvarnost.	5.672	2.000	7.000	1.036	-1.110	5.092
		KTLmen_an5	Dobar je u korištenju, strukturiranju i obradi brojeva.	6.459	5.000	7.000	0.589	-0.578	2.497
	KOM	KTLmen_kom1	Lako uspostavlja kontakt s drugima i sluša sugovornike.	6.067	4.000	7.000	0.704	-0.689	4.121
		KTLmen_kom2	Jasno komunicira svoje ideje usmenim putem.	6.117	5.000	7.000	0.661	-0.135	2.418
		KTLmen_kom3	Jasno komunicira svoje ideje pismenim putem.	6.233	5.000	7.000	0.667	-0.317	2.346
		KTLmen_kom4	Može uvjeriti druge ljude da slijede njegove ideje.	5.667	3.000	7.000	0.810	-0.469	3.962
		KTLmen_kom5	Sposoban je prenijeti poruku, tj. važni sadržaj.	6.100	3.000	7.000	0.790	-1.024	5.466
	AS	KTLmen_as1	Jasno izražava svoje mišljenje, osjećaje i stavove.	5.966	4.000	7.000	0.736	-0.477	3.410
		KTLmen_as2	Izražava svoje neslaganje sa mišljenjima drugih.	5.814	4.000	7.000	0.791	-0.497	3.226
		KTLmen_as3	Daje konstruktivne kritike.	5.983	4.000	7.000	0.725	-0.252	2.839
		KTLmen_as4	Nije mu problem reći NE drugima.	5.475	2.000	7.000	0.998	-0.994	4.675
		KTLmen_as5	Dopušta drugima da izraze svoje mišljenje.	6.288	5.000	7.000	0.690	-0.467	2.320
	PROAKT	KTLmen_proakt1	Prilika i izazov mu je vidjeti da mu se ideje pretvaraju u stvarnost.	5.833	4.000	7.000	0.898	-0.370	2.507
		KTLmen_proakt2	Samoinicijativno popravlja uočene greške, probleme i nedostatke.	6.183	4.000	7.000	0.719	-0.576	3.186
		KTLmen_proakt3	Uvijek traga za boljim načinima rada i načinima rješavanja problema.	6.067	4.000	7.000	0.750	-0.848	4.198
		KTLmen_proakt4	Prepreke ga ne sprječavaju u ostvarenju ciljeva i ideja u koje vjeruje.	6.033	4.000	7.000	0.752	-0.299	2.599
		KTLmen_proakt5	Izravno se suočava s problemima.	6.153	4.000	7.000	0.633	-0.559	4.421
		KTLmen_proakt6	Probleme pretvara u prilike.	5.763	4.000	7.000	0.908	-0.343	2.527
	KREAT	KTLmen_kreat1	Predlaže kreativna rješenja problema i pri tome se ne boji preuzeti rizik.	5.917	2.000	7.000	0.936	-1.339	6.794
		KTLmen_kreat2	Promiče i zagovara vlastite kreativne ideje i ideje drugih.	5.950	4.000	7.000	0.717	-0.484	3.528
		KTLmen_kreat3	Njegova kreativnost dolazi do izražaja prilikom rješavanja složenih problem.	5.867	3.000	7.000	0.826	-0.840	4.544
		KTLmen_kreat4	Predlaže nove načine postizanja ciljeva i ciljanih vrijednosti.	5.881	2.000	7.000	0.993	-1.482	6.640
KAR MEN	VOD&INC	MEN_vod&inic1	Iskazuje povjerenje i etičnost.	6.188	3.000	7.000	1.044	-1.369	4.262
		MEN_vod&inic2	Naglašava kolektivnu misiju.	6.109	4.000	7.000	0.937	-1.016	3.246
		MEN_vod&inic3	Govori pozitivno o budućnosti.	6.219	4.000	7.000	0.760	-0.603	2.629
		MEN_vod&inic4	Ima poštovanje kontrolera i ostalih zaposlenika.	6.203	4.000	7.000	0.887	-1.080	3.523
		MEN_vod&inic5	Potiče svijest kontrolera i ostalih zaposlenika o onome što je doista važno.	5.875	3.000	7.000	1.152	-1.164	3.694
	UVAZKTL	MEN_uvazktl1	Cijeni znanje kontrolera.	6.266	4.000	7.000	0.906	-1.179	3.578
		MEN_uvazktl2	Poštuje kontrolerove vještine i kompetencije.	6.250	4.000	7.000	0.810	-0.838	2.993
		MEN_uvazktl3	Pouzdaje se u kontrolerove zaključke i prijedloge.	6.156	4.000	7.000	0.755	-0.703	3.312
		MEN_uvazktl4	Smatra kontrolera svojim poslovnim partnerom.	5.984	3.000	7.000	1.152	-1.072	3.246

		MEN_uvazktl5	Posao kontrolera smatra izuzetno važnom profesijom.	5.891	3.000	7.000	1.062	-0.719	2.596
	PROCILJ	MEN_procilj1	Uočava i rješava probleme na vrijeme.	6.109	4.000	7.000	0.793	-0.573	2.772
		MEN_procilj2	Preuzima inicijativu za rješavanje problema.	6.172	4.000	7.000	0.894	-1.000	3.315
		MEN_procilj3	Ne zazire od rješavanja problema.	6.328	4.000	7.000	0.885	-1.231	3.658
		MEN_procilj4	Učinkovito koristi prilike kako bi postigao svoje ciljeve.	6.172	4.000	7.000	0.876	-1.038	3.528
		MEN_procilj5	Aktivno se uključuje u rješavanje nastalih problema.	6.141	4.000	7.000	0.882	-0.825	2.934
		MEN_procilj6	Ističe se u realizaciji problema.	6.141	3.000	7.000	0.982	-1.274	4.485
KAR POD	KVINFS	POD_kvinfs1	IS ima zadovoljavajuće vrijeme obrade podataka.	5.812	2.000	7.000	1.102	-1.305	4.866
		POD_kvinfs2	IS čini informacije lako dostupnima.	5.656	2.000	7.000	1.189	-1.322	5.114
		POD_kvinfs3	IS učinkovito integrira podatke različitih područja, tj. odjela poduzeća.	5.469	2.000	7.000	1.287	-0.921	3.676
		POD_kvinfs4	IS omogućava učinkovitu analizu i obradu prikupljenih podataka.	5.531	2.000	7.000	1.131	-0.757	3.520
		POD_kvinfs5	IS je prilagodljiv potrebama poduzeća, tj. izvršavanju poslovnih zadataka.	5.562	2.000	7.000	1.273	-1.003	3.797
	FORM	POD_form1	Poduzeće ima veliki broj propisanih pravila i procedura.	5.953	2.000	7.000	1.386	-1.573	4.830
		POD_form2	Postoji jasno definirana sistematizacija radnih mjesta - zadaci, odgovornosti i ovlasti.	5.578	2.000	7.000	1.344	-1.055	3.855
		POD_form3	Postoje jasno definirane hijerarhijske razine autorizacije i/ili odlučivanja.	5.703	2.000	7.000	1.377	-1.108	3.591
		POD_form4	Zaposlenici, uključujući kontroler, se pridržavaju jasno definiranih procedura.	5.656	3.000	7.000	1.093	-0.797	3.126
		POD_form5	Poduzeće vrši nadzor svakodnevnih operacija.	5.266	2.000	7.000	1.189	-0.746	3.359
	STROR	POD_stror1	Strateški smjer je transparentan.	5.719	3.000	7.000	1.125	-0.816	3.044
		POD_stror2	Postoji kolektivna vizija o tome kakvo će biti poduzeće u budućnosti.	5.500	3.000	7.000	1.075	-0.415	2.863
		POD_stror3	Postavljeni ciljevi i ciljane vrijednosti poduzeća povezane su s misijom, vizijom i strategijom.	5.641	3.000	7.000	1.095	-0.396	2.354
		POD_stror4	Postoji učinkovit strateški plan.	5.453	3.000	7.000	1.131	-0.370	2.459
	DIGTEH	POD_digteh1	Poduzeće pokreće nove poslovne procese zasnovane na digitalnim tehnologijama.	5.967	3.000	7.000	1.201	-1.100	3.382
		POD_digteh2	Poduzeće potiče korištenje digitalnih tehnologija u svakodnevnim poslovnim operacijama.	6.082	3.000	7.000	1.045	-1.316	4.642
		POD_digteh3	Poduzeće integrira digitalne tehnologije kako bi potaknulo promjene i napredak.	5.918	3.000	7.000	1.091	-0.998	3.605
KAR OKR	INTKON	OKR_intkon1	Poslujemo u okruženju vrlo agresivnih konkurenata.	5.781	2.000	7.000	1.340	-1.506	4.718
		OKR_intkon2	Konkurencija je velika.	5.844	2.000	7.000	1.337	-1.360	4.306
		OKR_intkon3	Proizvodi, usluge i interni procesi koje imaju poduzeća lako se kopiraju.	4.766	1.000	7.000	1.455	-0.867	3.200
		OKR_intkon4	Poduzeća usmjeravaju velike napore k ostvarenju i zadržavanju tržišnog udjela.	6.078	4.000	7.000	0.889	-0.820	3.015
		OKR_intkon5	Informacije o konkurentima i njihovim tržišnim potezima su svakodnevne.	5.172	1.000	7.000	1.409	-0.842	3.780
		OKR_intkon6	Cjenovna konkurencija je jaka.	5.797	2.000	7.000	1.427	-1.349	3.995
	TURBTEH	OKR_turbteh1	Tehnološke promjene vrlo su česte.	4.719	1.000	7.000	1.596	-0.527	2.478
		OKR_turbteh2	Tehnološke promjene pružaju velike mogućnosti rasta.	5.625	3.000	7.000	1.083	-0.545	2.743
		OKR_turbteh3	Tehnološka otkrića prilika su za kreiranje novih ideja - proizvoda i usluga.	5.578	3.000	7.000	1.087	-0.493	2.641
		OKR_turbteh4	Tehnološka otkrića omogućavaju kreiranje boljih poslovnih procesa unutar poduzeća.	5.781	3.000	7.000	1.007	-0.745	3.196

		OKR_turbteh5	Tehnološka otkrića i inovacije omogućuju efikasniju upotrebu podataka u analizi i poslovnom odlučivanju.	5.969	4.000	7.000	0.901	-0.708	2.837
	RIZIK	OKR_rizik1	Stopa neuspjeha poduzeća unutar grane je visoka.	3.500	1.000	6.000	1.436	0.127	1.873
		OKR_rizik2	Zbog velike rizičnosti, jedna loša poslovna odluka može ugroziti održivost cijele poslovne jedinice.	3.516	1.000	7.000	1.510	0.256	2.130
		OKR_rizik3	Poslovno okruženje je nedovoljno prilagodljivo.	3.750	1.000	6.000	1.323	-0.182	2.320
		OKR_rizik4	Prevladavaju niske profitne marže.	4.125	1.000	7.000	1.596	-0.066	2.056
		OKR_rizik5	Odanost kupaca je niska.	3.297	1.000	7.000	1.528	0.466	2.230
Endogeni jednodimenzionalni konstrukti									
KVALITETA OUTPUTA		Informacije koje pruža kontroler… :							
		kvoutmen_1	pokrivaju sva važna područja poslovnih aktivnosti.	5.953	4.000	7.000	0.694	-0.217	2.804
		kvoutmen_2	odražavaju stvarne okolnosti na sveobuhvatan i pravovaljan način.	6.016	4.000	7.000	0.820	-0.540	2.775
		kvoutmen_3	odražavaju visoku razinu korisnosti i sadržajnosti.	6.062	3.000	7.000	0.808	-0.826	4.405
		kvoutmen_4	vrlo su precizne.	6.312	5.000	7.000	0.658	-0.436	2.252
		kvoutmen_5	uvijek su ažurne.	6.250	5.000	7.000	0.685	-0.365	2.133
		kvoutmen_6	sadrže točne podatke.	6.406	4.000	7.000	0.655	-0.987	4.242
		kvoutmen_7	su jasno prikazane.	6.250	5.000	7.000	0.612	-0.204	2.417
		kvoutmen_8	su međusobno usklađene.	6.219	5.000	7.000	0.717	-0.351	1.985
		kvoutmen_9	sadrže najrelevantnije informacije.	6.031	5.000	7.000	0.706	-0.044	2.004
		kvoutmen_10	osigurane su kroz redovite izvještaje (dnevno/mjesečno itd. ili po zahtjevu).	6.375	2.000	7.000	0.839	-1.272	6.491
UTJECAJ NA ODLUKE		utjktlmen_1	Kontroler igra vrlo važnu ulogu u procesu odlučivanja poduzeća.	6.047	3.000	7.000	0.991	-0.961	3.716
		utjktlmen_2	Dajem visoku vrijednost kontrolerovom mišljenju pri donošenju odluka.	6.000	3.000	7.000	0.984	-0.885	3.630
		utjktlmen_3	Kontroler ima snažan utjecaj pri odabiru ispravne poslovne odluke (odabiru između alternativa).	5.609	3.000	7.000	1.040	-0.251	2.536
		utjktlmen_4	Prije donošenja važnih odluka, uvijek se konzultiram sa kontrolerom.	5.453	3.000	7.000	1.103	-0.405	2.612
		utjktlmen_5	Kontroler sudjeluje u donošenju odluka.	5.281	3.000	7.000	1.111	-0.228	2.308
		utjktlmen_6	Smatram da je kontroler suodgovoran u donošenju odluka.	5.000	2.000	7.000	1.358	-0.487	2.583

Izvor: izrada autora

Rezultati deskriptivne statističke analize (tablica 18 i 19) svih čestica ukazuju na prisutnost odstupanja od normalne distribucije. Navedeno je vidljivo iz vrijednosti koeficijenta asimetrije (Skewness) i koeficijenta zaobljenosti (Kurtosis). Naime, prema Hair *et al.* (2017) kad oba koeficijenta imaju vrijednost blizu nule, radi se o normalnoj distribuciji podataka. Odnosno, opće pravilo asimetrije i zaobljenosti podrazumijeva da ako je vrijednost koeficijenta veća od +1 ili manja od -1 da podaci imaju iskrivljenu distribuciju tj. da je distribucija prezaobljena ili preizdužena (Hari *et al.,* 2017). Iz analize prvog (n=148) i drugog (n=64) uzorka vidljivo je da određene čestice imaju vrijednosti oba koeficijenta veće ili manje od +1 ili -1. Koeficijent asimetrije u oba uzorka ima najvišu vrijednosti od -1.677, dok koeficijent zaobljenosti ima najvišu vrijednost od 5.115 tj. 7.050. Rezultati ukazuju na opravdanost upotrebe PLS-SEM metode, koja kao neparametrijska metoda ne zahtjeva normalnu distribuciju podataka. Naravno pri tome treba uzeti u obzir da nije prisutna ekstremna ne-normalnost distribucije podatka (Hari *et al.,* 2017). Obzirom da pojedini izvori prihvaćaju i veće vrijednosti koeficijenta zaobljenosti i asimetrije, može se zaključiti da u analiziranim uzorcima nije prisutna ekstremna ne-normalnost distribucije podataka te da se isti mogu koristiti za procjenu postavljenog konceptualnog modela. Osim toga, deskriptivna analiza pokazuje da je u prosjeku najniže ocjenjena čestica OKR_rizik5 („Odanost kupaca je niska.“), a najviše KTL_an1 tj. KTLmen_an1 („Sposoban sam objasniti značenje brojeva.“). U prosjeku najvišu ocjenu imaju konstrukti analitičnost ($\bar{x}$=6.338), proaktivnost ($\bar{x}$=6.268), kvaliteta outputa ($\bar{x}$=6.160) i uvažavanje kontrolera ($\bar{x}$=6.127) u prvom uzorku, te kvaliteta outputa ($\bar{x}$=6.187), analitičnost ($\bar{x}$=6.167) i tri karakteristike menadžera ($\bar{x}$=6.177, $\bar{x}$=6.119 i $\bar{x}$=6.109) u drugom uzorku. U prosjeku, veću ocjenu za dva endogena konstrukta, kvaliteta outputa i utjecaj kontrolera na donošenje odluka, dali su menadžeri ($\bar{x}$=6.187 i $\bar{x}$=5.565) u odnosu na kontrolere ($\bar{x}$=6.160 i $\bar{x}$=4.976). Odnosno, u prosjeku kontroleri su vlastite karakteristike ocijenili s neznatno višim ocjenama nego što su ih procijenili njihovi menadžeri. Prema podacima izračunatih standardnih devijacija može se zaključiti da u prosjeku ne postoje značajna odstupanja od prosječnih vrijednosti unutar uzorka.

5.2.3. Rezultati PLS-SEM analize

Nakon što je specificiran konceptualni tj. strukturni model te su zadovoljeni kriteriji veličine, distribucije i statističke snage uzorka, slijedi procjena PLS-SEM rezultata. PLS-SEM analiza podrazumijeva:

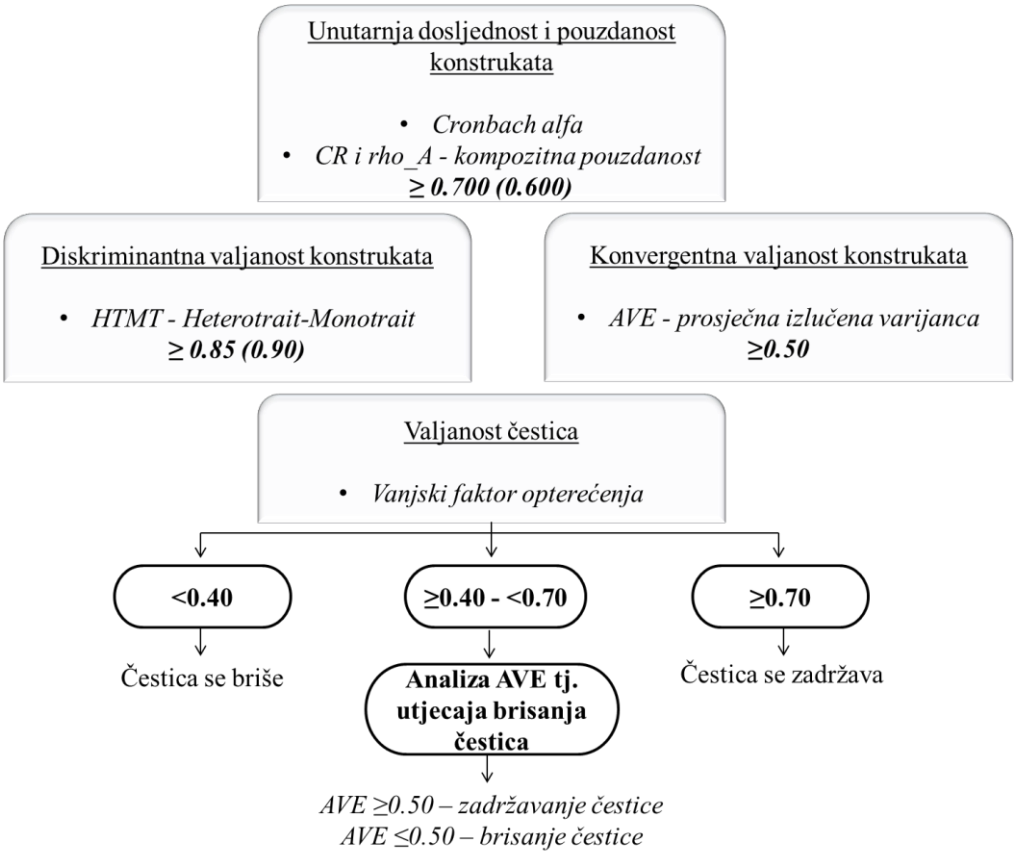
1) procjenu mjernog modela i
2) procjenu strukturnog modela.

Procjenom mjernog modela određuje se pouzdanost i valjanost teorijski definiranih konstrukata. Procjena ovisi o vrsti modela tj. vrsti postavljenih čestica i konstrukata modela. Obzirom da je model ovog istraživanja postavljen kao reflektivno-reflektivni hijerarhijsko komponentni model (HCM) koji se analizira pomoću pristupa ponovljenog indikatora, ocjena mjernog modela uključuje pojedinačnu analizu LOC konstrukata, jednodimenzionalnih endogenih konstrukata i kontrolnih varijabli te analizu HOC konstrukata. Pri tome se podrazumijeva ocjena (Hair *et al.*, 2017):

1) unutarnje dosljednosti i pouzdanosti konstrukata (engl. internal consistency reliability),
2) valjanosti čestica (engl. indicator reliabiliy),
3) konvergentne valjanosti konstrukata (engl. convergent validity) i
4) diskriminantne valjanosti konstrukata (engl. discriminant validiy),

sukladno postavljenim pravilima tj. pragovima (slika 15).

Slika 15: Kriteriji procjene reflektivnog mjernog modela



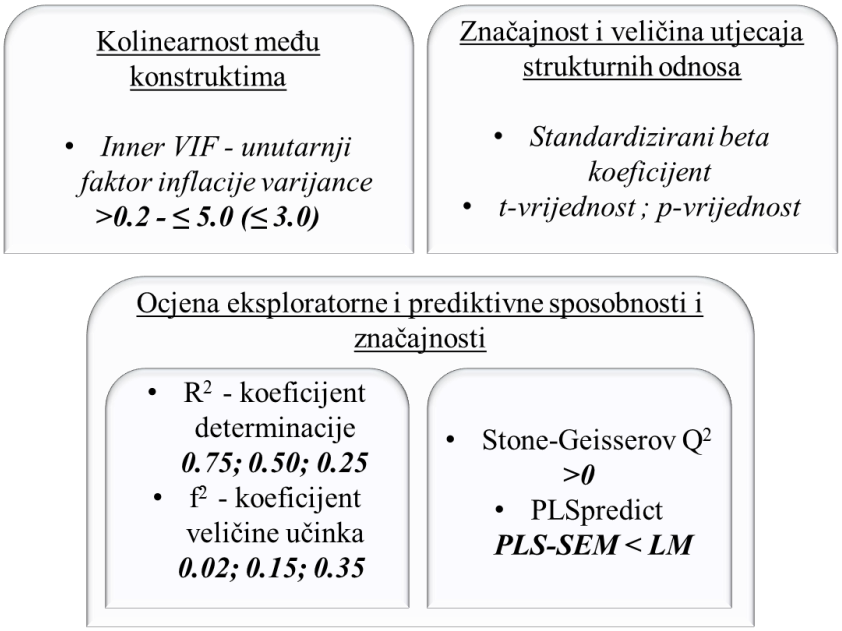
Izvore: izrada autora prema Hair *et al*. (2017)

Nakon što je potvrđena kvaliteta mjernog modela slijedi procjena strukturnog modela. Ona uključuje (Hair *et al*., 2017):

1) provjeru postojanja kolinearnosti unutar strukturnog modela,
2) testiranje značajnosti i veličine utjecaja strukturnih odnosa među konstruktima i
3) ocjenu eksploratorne i prediktivne sposobnosti i značajnosti,

te vrši sukladno postavljenim kriterijima (slika 16).

Slika 16: Postupak i kriteriji procjene strukturnog modela



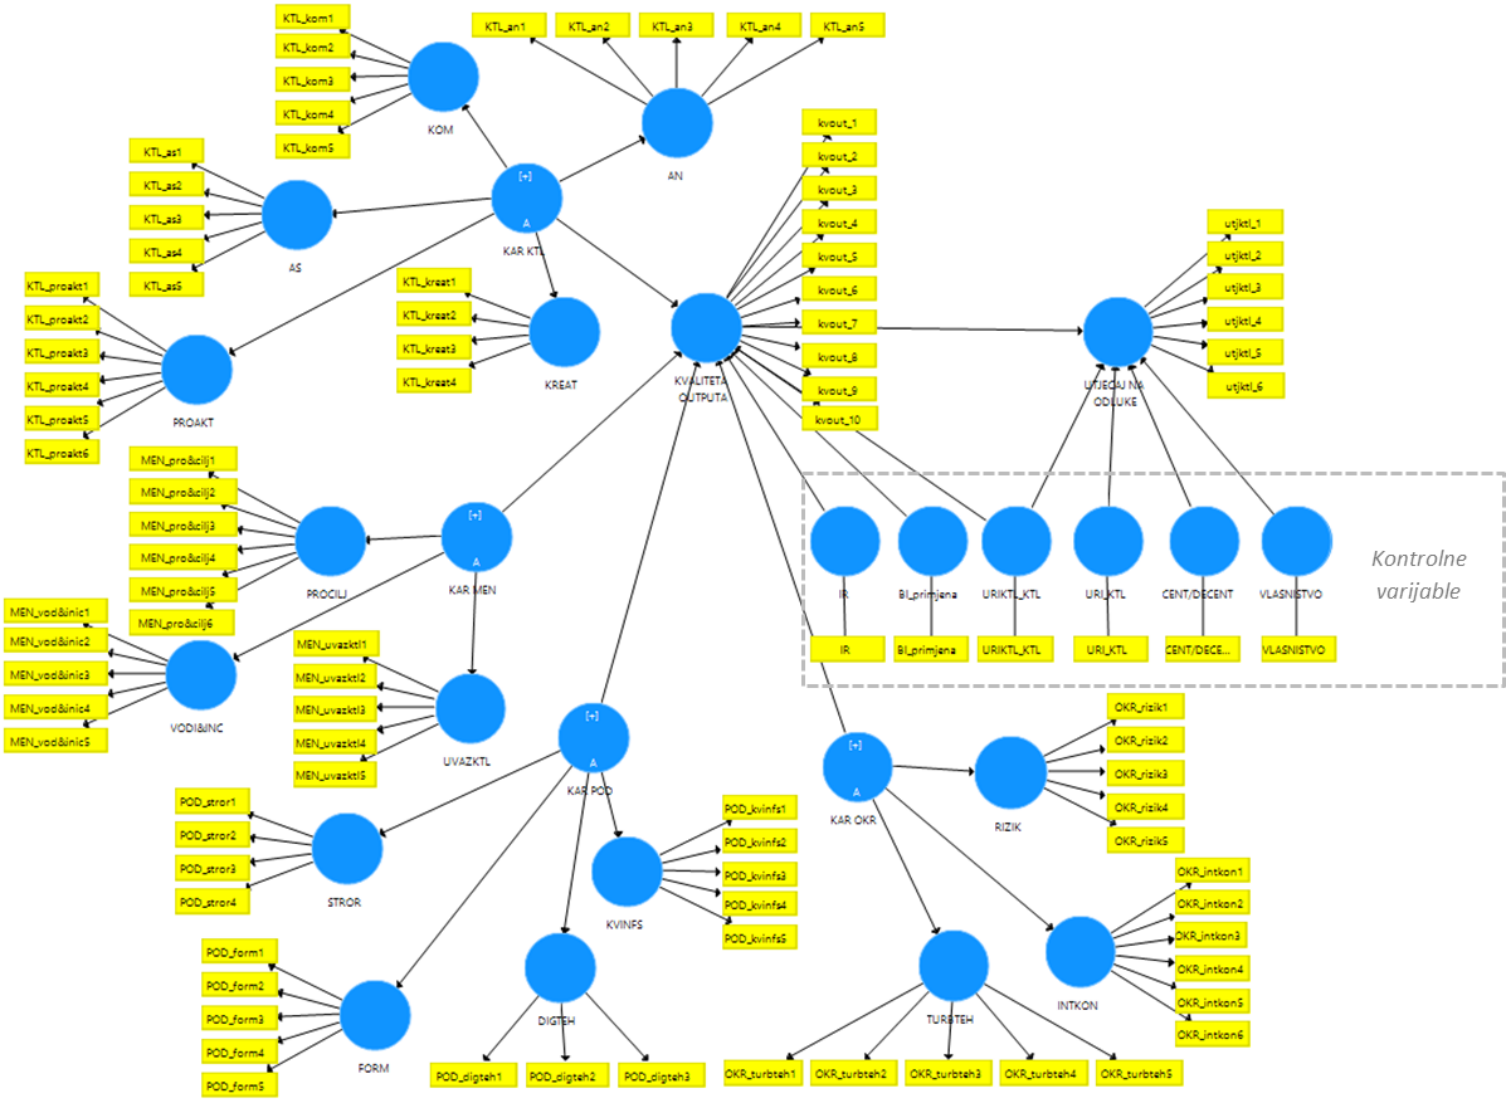
Izvore: izrada autora prema Haire *et al.* (2017)

Rezultati dobiveni PLS-SEM analizom uključuju procjenu dva modela. Model 1 predstavlja analizu postavljenog konceptualnog modela sa stajališta kontrolera, dok Model 2 podrazumijeva uključivanje stajališta menadžera u pogledu ocjene karakteristika kontrolera, kvalitete njegovog outputa i utjecaja na donošenje poslovnih odluka.

5.2.3.1. Rezultati analize konceptualnog modela sa stajališta kontrolera - Model 1

Model 1 temelji se isključivo na odgovorima prikupljenim od strane kontrolera. Naime, sve čestice konceptualnog modela mjerene su kroz odgovore 148 kontrolera. Modelom 1 žele se potvrditi hipoteze H1-H5. Ukupni konceptualni model istraživanja postavljen u softveru SmartPLS (v.3.3.3) vidljiv je na slici 17. Analiza modela uključuje procjenu mjernog i strukturnog modela prikazanih u sljedećim podpoglavljima.

Slika 17: Konceptualni model istraživanja postavljen u softveru SmartPLS (v. 3.3.3)



Izvor: SmartPLS (v. 3.3.3)

5.2.3.1.1. Procjena mjernog modela - Model 1

Prvi korak procjene mjernog modela uključuje ocjenu svih LOC komponenti HOC konstrukata te ostalih jednodimenzionalnih konstrukata tj. kvalitete outputa i utjecaj na odluke. Konstrukti koji sadrže samo jednu česticu (engl. single-item measurement), što su u ovom slučaju kontrolne varijable, poprimaju uvijek vrijednost 1.000 (tablica 20).

Tablica 20: Rezultati LOC konstrukata mjernog modela (Model 1)

Konstrukti	Čestice	Vanjska faktorska opterećenja	Cronbach alfa	rho_A	CR	AVE
ANALITIČNOST (AN)	KTL_an1	0.771	0.776	0.780	0.849	0.530
	KTL_an2	0.796				
	KTL_an3	0.637				
	KTL_an4	0.730				
	KTL_an5	0.696				
ASERTIVNOST (AS)	KTL_as1	0.760	0.770	0.795	0.845	0.524
	KTL_as2	0.763				
	KTL_as3	0.824				
	KTL_as4	0.648				
	KTL_as5	0.601				
KOMUNIKATIVNOST (KOM)	KTL_kom1	0.606	0.803	0.819	0.863	0.561
	KTL_kom2	0.812				
	KTL_kom3	0.776				
	KTL_kom4	0.704				
	KTL_kom5	0.825				
PROAKTIVNOST (PROAKT)	KTL_proakt1	0.708	0.831	0.835	0.876	0.542
	KTL_proakt2	0.762				
	KTL_proakt3	0.686				
	KTL_proakt4	0.799				
	KTL_proakt5	0.760				
	KTL_proakt6	0.696				
KREATIVNOST (KREAT)	KTL_kreat1	0.878	0.872	0.876	0.912	0.723
	KTL_kreat2	0.835				
	KTL_kreat3	0.848				
	KTL_kreat4	0.839				
PROAKTIVAN I CILJU USMJEREN (PROCILJ)	MEN_procilj1	0.873	0.931	0.934	0.948	0.786
	MEN_procilj2	0.923				
	MEN_procilj3	0.905				
	MEN_procilj4	0.823				
	MEN_procilj5	0.905				
VOĐA I INICIJATOR (VOD&INC)	MEN_vod&inic1	0.879	0.898	0.908	0.925	0.712
	MEN_vod&inic2	0.844				
	MEN_vod&inic3	0.742				
	MEN_vod&inic4	0.884				
	MEN_vod&inic5	0.863				
UVAŽAVANJE KONTROLERA (UVAZKTL)	MEN_uvazktl2	0.924	0.932	0.934	0.951	0.830
	MEN_uvazktl3	0.904				
	MEN_uvazktl4	0.929				
	MEN_uvazktl5	0.887				

STRATEŠKA ORIJENTIRANOST (STROR)	POD_stror1	0.868	0.902	0.904	0.932	0.773
	POD_stror2	0.879				
	POD_stror3	0.894				
	POD_stror4	0.877				
ORGANIZACIJSKA FORMALIZACIJA (FORM)	POD_form1	0.768	0.875	0.879	0.909	0.668
	POD_form2	0.838				
	POD_form3	0.853				
	POD_form4	0.864				
	POD_form5	0.756				
DIGITALNE TEHNOLOGIJE (DIGTEH)	POD_digteh1	0.934	0.931	0.934	0.956	0.879
	POD_digteh2	0.935				
	POD_digteh3	0.943				
KVALITETA INFORMACIJSKOG SUSTAVA (KVINFS)	POD_kvinfs1	0.843	0.945	0.946	0.958	0.821
	POD_kvinfs2	0.901				
	POD_kvinfs3	0.884				
	POD_kvinfs4	0.950				
	POD_kvinfs5	0.946				
TURBULENTNOST TEHNOLOGIJE (TURBTEH)	OKR_turbteh2	0.840	0.895	0.897	0.927	0.761
	OKR_turbteh3	0.873				
	OKR_turbteh4	0.896				
	OKR_turbteh5	0.879				
INTENZITET KONKURENTNOSTI (INTKON)	OKR_intkon1	0.889	0.878	0.882	0.912	0.675
	OKR_intkon2	0.869				
	OKR_intkon4	0.785				
	OKR_intkon5	0.728				
	OKR_intkon6	0.826				
KVALITETA OUTPUTA	kvout_1	0.696	0.927	0.929	0.938	0.605
	kvout_2	0.817				
	kvout_3	0.822				
	kvout_4	0.806				
	kvout_5	0.772				
	kvout_6	0.738				
	kvout_7	0.813				
	kvout_8	0.798				
	kvout_9	0.781				
	kvout_10	0.723				
UTJECAJ NA ODLUKE	utjktl_1	0.871	0.937	0.941	0.952	0.799
	utjktl_2	0.920				
	utjktl_3	0.899				
	utjktl_4	0.903				
	utjktl_5	0.875				
Primjena poslovne inteligencije (BI_primjena)*			1.000	1.000	1.000	1.000
Centraliziran/decentraliziran (CENT/DECENT)*			1.000	1.000	1.000	1.000
Postojanje interne revizije (IR)*			1.000	1.000	1.000	1.000
Ukupno radno iskustvo kontrolera u kontrolingu (URIKTL_KTL)*			1.000	1.000	1.000	1.000
Ukupno radno iskustvo kontrolera (URI_KTL)*			1.000	1.000	1.000	1.000

Vlasništvo poduzeća (VLASNISTVO)*			1.000	1.000	1.000	1.000

*Napomena: faktorska opterećenja svih čestice imaju t-vrijednost>1.96 tj. p<0.05; *kontrolne varijable*
Izvor: izrada autora prema SmartPLS (v. 3.3.3)

Unutarnja dosljednost i pouzdanost konstrukata ocijenjena je temeljem Cronbach alfa koeficijenta pouzdanosti i mjere kompozitne pouzdanosti (engl. Composite reliability - CR). Sukladno Hair *et al.* (2017) prihvatljiv prag Cronbach-ovog koeficijenta i CR-a iznosi 0.7. Odnosno, u eksplanatornim istraživanjima prihvaća se i prag CR-a od 0.6. Sukladno rezultatima (tablica 20) vidljivo je da svi konstrukti zadovoljavaju postavljene pragove pouzdanosti jer su sve vrijednosti veće od postavljenog praga. Prema navodima Hair *et al.* (2017, 2019) Cronbach alfa se smatra previše konzervativnom, a CR previše liberalnom mjerom, dok se stvarna pouzdanost određenog konstrukta zapravo nalazi između te dvije vrijednosti. Stoga su Dijkstra i Henseler (2015) predložili dodatnu mjeru kompozitne pouzdanosti tzv. pA (ili rho_A) koja se nalazi između vrijednosti Cronbach alfe i CR-a. Prema rezultatima može se zaključiti da svi LOC konstrukti zadovoljavaju uvjete pouzdanosti.

Nadalje, konvergentna valjanost konstrukta utvrđuje se s tzv. AVE (engl. Average Variance Extracted) mjerom tj. prosječnom izlučenom varijancom, čiji općeprihvaćeni prag iznosi 0.5 (Hair *et al.*, 2017). Svi LOC konstrukti zadovoljavaju postavljeni prag. AVE je usko povezan s utvrđivanjem valjanosti čestica modela. Naime, predloženi prag faktorskih opterećenja čestica iznosi 0.708, što podrazumijeva da konstrukt objašnjava više od 50% varijance čestice. Međutim, pojava faktorskih opterećenja manjih od 0.708 (ili 0.700) ne podrazumijeva njihovo automatsko isključenje iz modela. Točnije, čestice s faktorskim opterećenjem manjim od 0.40 potrebno je isključiti iz modela, dok isključivanje čestica s faktorskim opterećenjem 0.40 - 0.70 ovisi o AVE vrijednosti. Ako čestice pojedinog konstrukta imaju vrijednost faktorskih opterećenja 0.40-0.70, a AVE vrijednost je veća ili jednaka 0.50 onda se čestice zadržavaju u modelu. Tako npr. vrijednost čestice KTL_an3 iznosi 0.637, ali s obzirom na to da AVE konstrukta AN iznosi 0.530 navedenu česticu zadržavamo u modelu. Isto vrijedi i za čestice: KTL_an5, KTL_as4, KTL_as5, KTL_kom1, KTL_kom4, KTL_proakt3, KTL_proakt6 i kvout_1. Međutim, tri su čestice isključene zbog negativnog utjecaja na rho_A tj. vrijednost kompozitne pouzdanosti. Prva se odnosi na tehnološku turbulentnost okruženja (OKR_turbteh1), druga na intenzitet konkurentnosti okruženja (OKR_inkont3), a treća na utjecaj kontrolera na donošenje odluka (utjktl_6). Osim toga, jedna čestica menadžerske

karakteristike uvažavanje kontrolera isključena je zbog utjecaja na unakrsna standardizirana faktorska opterećenja (engl. cross-loadings) tj. vrijednost HTMT kriterija (MEN_uvazktl1). Iz modela je u potpunosti izbačen jedan LOC (RIZIČNOST) konstrukt karakteristika okruženja obzirom da je imao nezadovoljavajuća faktorska opterećenja dviju od pet varijabli, kao i AVE vrijednosti ukupnog konstrukta. Sukladno rezultatima može se zaključiti da svi ostali LOC konstrukti zadovoljavaju uvjete konvergentne valjanosti.

Značajan dio analize reflektivnih konstrukata uključuje i analizu diskriminantne valjanosti. Unutar PLS-SEM-a ona se procjenjuje pomoću tzv. kriterija Heterotrait-Monotrait (HTMT) (Henseler *et al.*, 2015; Hair *et al.*, 2017). Prema Henseler *et al.* (2015) HTMT vrijednosti iznad 0.85 (ili 0.90) upućuju na to da diskriminantna valjanost nije uspostavljena. Sukladno rezultatima (tablica 21) vidljivo je da model zadovoljava uvjet diskriminantne valjanosti. Odnosno, svi konstrukti imaju međusobne vrijednosti manje od 0.85 osim pojedinih odnosa HOC i pripadajućih LOC konstrukta (npr. KAR KTL i AN = 0.901), što je i za očekivati obzirom da se HOC konstruktima pripisuju čestice pripadajućih LOC konstrukata (Hari *et al.*, 2018).

Tablica 21: HTMT vrijednosti modela (Model 1)

	AN	AS	BI_primjena	CENT /DECENT	DIGTEH	FORM	INTKON	IR	KAR KTL	KAR MEN	KAR OKR	KAR POD	KOM	KREAT	KVALITETA OUTPUTA	KVINFS	PROAKT	PROCILJ	STROR	TURBTEH	URIKTL_KTL	URI_KTL	UTJECAJ NA ODLUKE	UVAZKTL	VLASNISTVO	VOD&INC
AN																										
AS	0.473																									
BI_primjena	0.064	0.107																								
CENT/DECENT	0.146	0.070	0.013																							
DIGTEH	0.217	0.215	0.262	0.100																						
FORM	0.216	0.172	0.167	0.028	0.420																					
INTKON	0.228	0.232	0.293	0.116	0.230	0.186																				
IR	0.060	0.137	0.265	0.034	0.146	0.312	0.091																			
KAR KTL	0.901	0.869	0.127	0.112	0.294	0.225	0.240	0.112																		
KAR MEN	0.228	0.218	0.064	0.120	0.313	0.325	0.109	0.065	0.283																	
KAR OKR	0.301	0.301	0.273	0.107	0.361	0.232	0.977	0.112	0.336	0.158																
KAR POD	0.291	0.273	0.264	0.088	0.765	0.830	0.281	0.218	0.351	0.429	0.354															
KOM	0.622	0.612	0.143	0.067	0.190	0.305	0.215	0.067	0.813	0.154	0.224	0.350														
KREAT	0.598	0.547	0.097	0.087	0.168	0.084	0.150	0.134	0.874	0.266	0.233	0.164	0.423													
KVALITETA OUTPUTA	0.552	0.410	0.142	0.055	0.255	0.296	0.368	0.072	0.550	0.164	0.391	0.450	0.513	0.359												
KVINFS	0.205	0.218	0.252	0.051	0.359	0.257	0.229	0.064	0.249	0.194	0.239	0.743	0.264	0.109	0.446											
PROAKT	0.655	0.593	0.099	0.083	0.360	0.134	0.150	0.062	0.931	0.265	0.287	0.319	0.398	0.787	0.383	0.202										
PROCILJ	0.179	0.204	0.046	0.042	0.309	0.349	0.087	0.057	0.275	0.944	0.157	0.421	0.168	0.243	0.137	0.203	0.294									
STROR	0.202	0.182	0.078	0.089	0.531	0.571	0.164	0.111	0.257	0.441	0.216	0.845	0.228	0.130	0.251	0.310	0.272	0.379								
TURBTEH	0.265	0.260	0.138	0.054	0.366	0.192	0.394	0.091	0.312	0.151	0.896	0.295	0.145	0.236	0.260	0.155	0.330	0.174	0.189							
URIKTL_KTL	0.207	0.074	0.168	0.059	0.052	0.059	0.098	0.020	0.117	0.096	0.120	0.073	0.039	0.051	0.065	0.036	0.098	0.090	0.069	0.097						
URI_KTL	0.137	0.065	0.062	0.086	0.079	0.182	0.069	0.014	0.105	0.127	0.110	0.190	0.077	0.022	0.083	0.120	0.114	0.113	0.154	0.113	0.647					
UTJECAJ NA ODLUKE	0.365	0.240	0.163	0.151	0.381	0.105	0.253	0.100	0.390	0.261	0.242	0.308	0.181	0.437	0.230	0.149	0.344	0.182	0.324	0.131	0.199	0.087				
UVAZKTL	0.278	0.188	0.072	0.193	0.268	0.265	0.122	0.056	0.268	0.944	0.177	0.359	0.129	0.234	0.195	0.169	0.245	0.722	0.363	0.170	0.045	0.140	0.316			
VLASNISTVO	0.125	0.091	0.115	0.038	0.212	0.173	0.245	0.119	0.128	0.133	0.307	0.193	0.032	0.114	0.089	0.100	0.144	0.121	0.094	0.255	0.043	0.075	0.037	0.163		
VOD&INC	0.178	0.202	0.059	0.110	0.276	0.267	0.092	0.067	0.231	0.984	0.101	0.389	0.120	0.250	0.124	0.157	0.182	0.757	0.460	0.070	0.123	0.099	0.230	0.823	0.084	

Izvor: izrada autora prema SmartPLS (v. 3.3.3)

Drugi korak procjene mjernog modela kod HCM-a podrazumijeva analizu valjanosti i pouzdanosti HOC konstrukata (tablica 22). Pri tome se LOC konstrukti interpretiraju kao čestice pripadajućeg HOC konstrukta tj. dobivene veze (privitak 4) se interpretiraju kao faktorska opterećenja iako su prikazane kao koeficijenti puta ili veze (engl. path coefficient - β) tj. standardni beta koeficijenti. Vrijednosti Crnobach alfe, CR i AVE potrebno je izračunati ručno putem sljedećih formula (Hair *et al.*, 2018; Sarstedt *et al.*, 2019):

$$AVE = \frac{(\sum_{i=1}^{M} l_i^2)}{M} \qquad (1)$$

pri čemu l_i predstavlja faktorsko opterećenje nisko-redne komponente i određenog visoko-rednog konstrukta mjerenog sa M nisko-rednih komponenti ($i = 1, \dots M$).

$$CR = \frac{(\sum_{i=1}^{M} l_i)^2}{(\sum_{i=1}^{M} l_i)^2 + \sum_{i=1}^{M} var(e_i)} \qquad (2)$$

pri čemu je e_i pogreška mjerenja nisko-redne komponente, a $var(e_i)$ označava varijancu pogreške mjerenja, koja je definirana kao $1 - l_i^2$.

$$Cronbach\ alfa = \frac{M \cdot \bar{r}}{(1 + (M-1) \cdot \bar{r}} \qquad (3)$$

pri čemu $\bar{r}$ predstavlja prosječnu korelaciju između nisko-rednih komponenti.

Tablica 22: Rezultati HOC konstrukata mjernog modela (Model 1)

Konstrukti	Čestice	Faktorska opterećenja	Cronbach alfa	CR	AVE
KARAKTERISTIKE KONTROLERA (KAR KTL)	AN	0.762	0.819	0.874	0.581
	AS	0.726			
	KOM	0.686			
	PROAKT	0.825			
	KREAT	0.805			
KARAKTERISTIKE MENADŽERA (KAR MEN)	PROCILJ	0.889	0.882	0.927	0.808
	VOD&INC	0.912			
	UVAZKTL	0.896			
KARAKTERISTIKE PODUZEĆA (KAR POD)	STROR	0.785	0.705	0.818	0.531
	FORM	0.737			
	DIGTEH	0.720			
	KVINFS	0.667			
KARAKTERISTIKE OKRUŽENJA (KAR OKR)	TURBTEH	0.787	0.523	0.806	0.675
	INTKON	0.855			

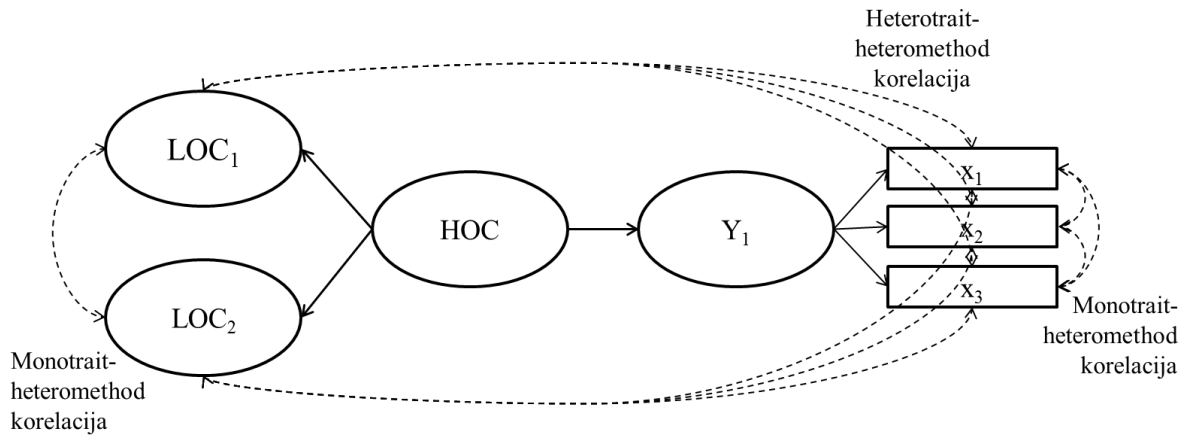
Napomena: Cronbach alfa, CR i AVE izračunati su ručno (privitak 5 i 6)

Izvor: izrada i izračuna autora prema SmartPLS (v. 3.3.3)

Iako su faktorska opterećenja HOC čestica komunikativnost (KOM) i kvaliteta informacijskog sustava (KVINFS) manja od postavljenog praga 0.7, sukladno pravilima primijenjenih i za ocjenu LOC konstrukata, iste se ne isključuju iz modela obzirom da izračunate AVE vrijednost zadovoljavaju postavljeni prag 0.5. Vidljivo je da Cronbach alfa konstrukta KAR OKR ima vrijednost manju 0.7. Međutim, obzirom da prema Hari *et al.* (2017) CR predstavlja pouzdaniju mjeru i da prema Hinton, McMurray i Brownlow (2014) alfa od 0.5 do 0.7 pokazuje umjerenu pouzdanost, navedeni konstrukt ne isključuje se iz modela.

Pored rezultata prikazanih u tablici 22 izračunate su i HTMT vrijednosti HOC konstrukata. HTMT vrijednosti za HOC konstrukte također je potrebno izračunati ručno.

Slika 18: Heterotrait-Monotrait - HTMT



Izvor: Hair *et al.* (2019)

Prema Henseler *et al.* (2015, u Sarstedt *et al.,* 2019) HTMT predstavlja omjer prosječne vrijednosti korelacije čestica među svim konstruktima (tj. heterotrait-heteromethod korelacije) i geometrijske sredine prosječnih korelacija čestica koje mjere isti konstrukt (tj. monotrait-heteromethod korelacije). Heterotrait-heteromethod korelaciju nekog visoko-rednog konstrukta predstavljaju unakrsna faktorska opterećenja drugih konstrukata u modelu tj. njihovih čestica sa nisko-rednim komponentama toga visoko-rednog konstrukta. Monotrait-heteromethod korelacija visoko-rednog konstrukta jednaka je korelaciji njegovih nisko-rednih konstrukata i korelacije među česticama drugih konstrukata (slika 18). Sukladno navedenom izračunate su HTMT vrijednosti svih HOC konstrukata u modelu (privitak 7). Izračuni potvrđuju njihovu valjanost obzirom na to da vrijednosti odnosa HOC konstrukata s ostalim egzogenim, endogenim i kontrolnim varijablama ne prelaze prag +/-0.85.

5.2.3.1.2. Procjena strukturnog modela - Model 1

Nakon utvrđivanja kvalitete mjernog modela slijedi procjena strukturnog modela. Ona uključuje provjeru postojanja kolinearnosti unutar strukturnog modela, testiranje značajnosti i veličine utjecaja strukturnih odnosa među konstruktima te ocjenu prediktivne sposobnosti i značajnosti.

Prvi korak podrazumijeva uklanjanje pristranosti u koeficijentima puta. Stoga se strukturni model testira na kolinearnost ispitivanjem svakog skupa prediktorskih konstrukata odvojeno za svaki pod-dio strukturnog modela (Hair *et al.*, 2017). Za to se primjenjuje tzv. unutarnji faktor inflacije varijance (engl. inner Variance Inflation Factor - inner VIF) čija bi vrijednost trebala biti veća od 0.2 i niža od 5.0 (Hair *et al.*, 2017), a idealno je da bude blizu ili ispod 3.0 (Hair *et al.*, 2019). Obzirom da su sve unutarnje VIF vrijednosti postavljenog modela manje od 3.0 (tablica 23) može se zaključiti da model ispunjava kriterij kolinearnosti i da nije prisutna pristranost metode (engl. common method bias) (Kock, 2015).

Tablica 23: Unutarnji faktori inflacije varijance (Model 1)

	KVALITETA OUTPUTA	UTJECAJ NA ODLUKE
KAR KTL	1.208	
KAR MEN	1.253	
KAR POD	1.435	
KAR OKR	1.213	
BI_primjena	1.216	
IR	1.127	
URIKTL_KTL	1.051	1.724
CENT/DECENT		1.010
URI_KTL		1.747
VLASNISTVO		1.012
KVALITETA OUTPUTA		1.012

Izvor: izrada autora prema SmartPLS (v. 3.3.3)

Drugi korak u ocjeni strukturnog modela podrazumijeva testiranje hipoteza tj. ocjenu značajnosti i jačine odnosa unutar modela. Kako bi se potvrdila ili opovrgnula značajnost odnosa među konstruktima proveden je tzv. „bootstrapping“ (5000 pod-uzoraka; dvostrani test $p \leq 0.05$; Bias-Corrected and Accelerated Bootstrap). Bootstrapping je neparametrijska metoda na kojoj se zasniva SmartPLS, a koja radi na principu stvaranja pod-uzoraka nasumičnim odabirom iz izvornog skupa podataka. Na primjer, ovo istraživanje ima 148 valjanih zapažanja, što znači da će svaki bootstrap uzorak imati 148 zapažanja. Obzirom da se preporučuje primjena 5000 bootstrap pod-uzoraka to znači da se značajnost modela procjenjuje s ukupno 740.000 zapažanja (Hair *et al.*, 2017). Koeficijenti puta predstavljaju

jačinu odnosa između konstrukata odnosno standardizirane vrijednosti koje mogu poprimiti vrijednost od +1 do -1. Što su bliže nuli to su slabiji u predviđanju zavisne varijable tj. što su bliže jedan su bolji (Hair *et al.*, 2019). Rezultati PLS-SEM-a određuju prihvaćanje ili neprihvaćanje postavljenih hipoteza (H) i utjecaja kontrolnih varijabli (k.v.) temeljem statističke značajnosti. Odnosno, rezultati p-vrijednosti i t-vrijednosti određuju značajnost postavljenih veza unutar modela (tablica 24 i slika 19).

Tablica 24: Rezultati značajnosti i jačine koeficijenata puta strukturnog modela (Model 1)

H	Veza	Koef. puta	Stand. Dev.	T-vrijed.	p-vrijed.	Hipoteza?
H1	KAR KTL -> KVALITETA OUTPUTA	0.395	0.059	6.735	0.000*	Prihvaćena
H2	KAR MEN -> KVALITETA OUTPUTA	-0.103	0.073	1.411	0.158	Odbačena
H3	KAR POD -> KVALITETA OUTPUTA	0.279	0.089	3.127	0.002*	Prihvaćena
H4	KAR OKR -> KVALITETA OUTPUTA	0.164	0.077	2.120	0.034*	Prihvaćena
H5	KVALITETA OUTPUTA -> UTJECAJ NA ODLUKE	0.211	0.075	2.817	0.005*	Prihvaćena
k.v.	URIKTL_KTL -> UTJECAJ NA ODLUKE	0.261	0.077	3.379	0.001*	Prihvaćena
	CENT/DECENT -> UTJECAJ NA ODLUKE	0.137	0.066	2.065	0.039*	Prihvaćena
	IR -> KVALITETA OUTPUTA	-0.083	0.073	1.134	0.257	Odbačena
	URI_KTL -> UTJECAJ NA ODLUKE	-0.109	0.098	1.111	0.266	Odbačena
	URIKTL_KTL -> KVALITETA OUTPUTA	-0.033	0.074	0.441	0.659	Odbačena
	BI_primjena -> KVALITETA OUTPUTA	0.030	0.071	0.421	0.674	Odbačena
	VLASNISTVO -> UTJECAJ NA ODLUKE	0.019	0.079	0.246	0.805	Odbačena

Napomena: $p<0.05$*

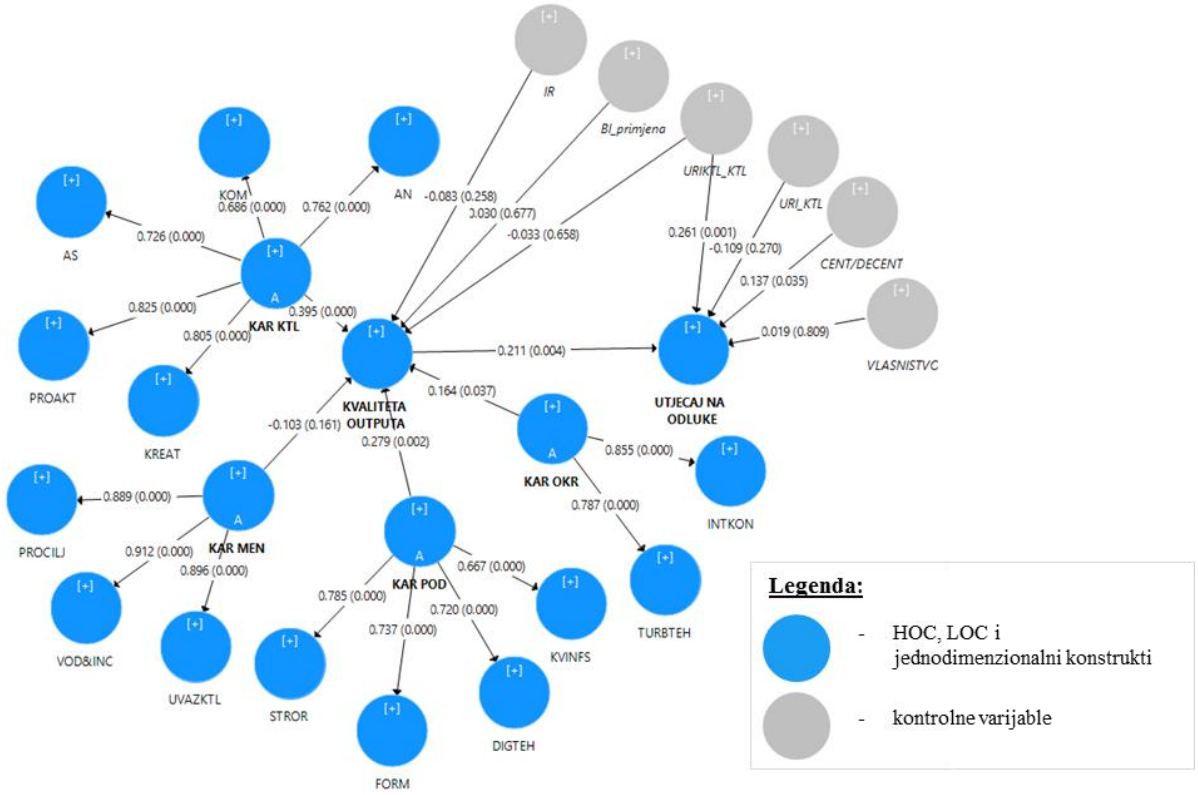
Izvor: izrada autora prema SmartPLS (v. 3.3.3)

Rezultati direktnih utjecaja (tablica 24) pokazuju da su svi odnosi tj. postavljene hipoteze statistički značajne osim jedne. Točnije, sve postavljene HOC karakteristike, osim karakteristika menadžera, imaju pozitivan i značajan utjecaj na kvalitetu kontrolerovog outputa, te posljedično kvaliteta kontrolerovog outputa ima pozitivan i značajan utjecaj na kontrolerov utjecaj na donošenje odluka. Dakle, rezultati KAR KTL ($\beta=0.395$, $p<0.05$), KAR POD ($\beta=0.279$, $p<0.05$) i KAR OKR ($\beta=0.164$, $p<0.05$) spram KVALITETA OUTPUTA potvrđuju hipoteze H1, H3 i H4, dok rezultati KVALITETE OUTPUTA ($\beta=0.211$, $p<0.05$) spram UTJECAJA NA ODLUKE potvrđuju hipotezu H5. Vidljivo je da od tri postavljene i potvrđene utjecajne karakteristike, KAR KTL imaju najveći utjecaj na kvalitetu outputa, zatim KAR POD, a najmanji KAR OKR. Odnosno, prema faktorskim opterećenjima LOC konstrukata (slika 19) može se utvrditi da najveću težinu KAR KTL ima proaktivnost, kod KAR POD strateška orijentiranost poduzeća, dok kod KAR OKR intenzitet konkurentnosti.

Istraživanjem se jedino nije potvrdila hipoteza H5 da karakteristike menadžera imaju pozitivan i značajna utjecaj na kvalitetu kontrolerovog outputa.

Uvidom u dodane rezultate analize anketnih upitnika (n=148) vidljivo je da u prosjeku kontroleri smatraju da imaju veću ulogu u donošenju operativnih ($\bar{x} = 3.0$; Likert 1-uopće se ne odnosi na mene; 2-uglavnom se ne odnosi na mene; 3-uglavnom se odnosi na mene; 4-u potpunosti se odnosi na mene) nego strateških odluka ($\bar{x} = 2.6$; Likert 1-4) u vidu prezentiranja informacija i analiza, preporučivanju akcija koje treba poduzeti i preispitivanju postavljenih planova i akcija. Odnosno, sukladno rezultatima kontroleri trenutno imaju najmanju ulogu u preporučivanju strateških akcija ($\bar{x} = 2.4$; Likert 1-4) te preispitivanju već postavljenih strateških planova i akcija ($\bar{x} = 2.5$; Likert 1-4), a najveću u prezentiranju informacija i analiza ($\bar{x} = 3.3$; Likert 1-4) te preispitivanju planova i akcija ($\bar{x} = 3.0$; Likert 1-4) u svrhu donošenja operativnih odluka. Pri tome operativne odluke podrazumijevaju odluke do 1 godine, a strateške 2 ili više godina. Bez obzira na nižu razinu uključenosti u strateškom odlučivanju, kontroleri smatraju ($\bar{x} = 6.1$; Likert 1-u potpunosti se ne slažem; 7-u potpunosti se slažem) da kroz pružanje kvalitetnih outputa značajno pridonose „neto koristi“ menadžera koja se manifestira kroz učinkovitiji svakodnevni rad menadžera, brže odlučivanje i donošenje boljih i preciznijih odluka. Isto potvrđuju i sami menadžeri uključeni u ovo istraživanje (n=64) koji u prosjeku „neto korist“ koju imaju od kontrolera ocjenjuju sa neznatno nižom ocjenom od samih kontrolera ($\bar{x} = 6.0$; Likert 1-7), a pri čemu najveći značaj pridaju utjecaju na donošenje boljih i preciznijih odluka ($\bar{x} = 6.2$).

Slika 19: Rezultati značajnosti (p-vrijednosti) i jačine koeficijenata puta strukturnog modela (Model 1)



Izvor: izrada autora prema SmartPLS (v. 3.3.3)

Od postavljenih kontrolnih varijabli statistički značajne za UTJECAJ NA ODLUKE potvrdile su se URIKTL_KTL i CENT/DECENT, dok se za KVALITETU OUTPUTA, iznenađujuće, nije potvrdila niti jedna kontrolna varijabla, iako se očekivalo da će razina primjene BI alata (srednja vrijednost=0.628; 93/148 ispitanika primjenjuje) pokazati kao značajna varijabla izrade kontrolerovih outputa. Međutim, sukladno mišljenjima ispitanika o korisnosti primjene BI u kontrolingu (Likert 1-7; srednja vrijednost=6.264) i potrebe za uvećanjem njegove primjene (Likert 1-7; srednja vrijednost=6.216) za pretpostaviti je da će u budućnosti taj utjecaj rasti i postati statistički značajan u obavljanju uloge kontrolera Osim toga, od 93 kontrolera koji primjenjuju BI alate u svojem svakodnevnom radu njih 80 ocijenilo je i osnovne značajke korištenih BI-sustava (Likert: 1-u potpunosti se ne slažem; 7-u potpunosti se slažem), a koje se odnose na mogućnost jednostavnijeg izvršenja poslovnih aktivnosti, mogućnost istraživanja alternativnih scenarija, prilagodljivost sustava i ukupnu sadržajnost i funkcionalnost sustava (grafikon 1-4).

Grafikon 1 - 4: Ocjena značajki korištenih BI sustava



Izvor: izrada autora

Sukladno analizi vidljivo je da većina kontrolera koji koriste BI sustave daju visoke ocjene njihovim značajkama. Pri tome, kao najčešće primjenjivane BI sustave ispitanici navode: Excel Power BI, SAP BI, Oracle BI, IBM Cognos Analytics., a također se koriste i Qlik Sense, Tableau Software, MicroStrategy BI, Infor Birst, itd. Navedeno u velikoj mjeri podržava i rezultate Gartner istraživanja koje se provodi svake godine (slika 20), a koje već nekoliko godina za redom potvrđuje da je Microsoft tj. Excel lider u području poslovne analitike i inteligencije. Stoga bi kontroleri trebali unaprjeđivati svoje znanje Excela, a kojeg Microsoft konstantno unaprjeđuje kroz nove funkcije (npr. Power Query, Power BI), a čije znanje su ispitanici ovog istraživanja u prosjeku ocijenili sa 5.57 (Likert: 1-neprihvatljivo poznavanje; 7-odlično poznavanje; n=148), odnosno sa 5.63 (Likert 1-7; n=93 tj. ispitanici

koji primjenjuju BI). Osim toga, dio ispitanika tj. kontrolera navode i korištenje pojedinih metoda poslovne analitike (engl. business analytics - BA). Od 131 kontroleri koji su ispunili drugi dio ankete u najvećem dijelu koriste različite prediktivne modele, manji dio linearnu i vremensku regresiju te metodu analitički hijerarhijski procesa, dok jedan dio ponekad koristi Monte Carlo simulacije i metodu modeliranja strukturnih jednadžbi. Odnosno, čak 15 kontrolera navodi da u svojem radu redovito koristi prediktivne modele. Pri tome koriste već navedene softvere primjene BI aplikacija tj. njihove napredne module.

Slika 20: Gartnerov magični kvadrant primjene BI sustava



Izvor: Richardson *et al.* (2020)

Treći korak procjene strukturnog modela podrazumijeva ocjenu prediktivne značajnosti modela. Ona uključuje analizu sposobnosti predviđanja unutar originalnog uzorka (engl. in-sample prediction) i izvan njega (engl. out-of-sample prediction). Analiza in-sample predviđanja, koja ocjenjuje eksplanatornu moć modela, podrazumijeva interpretaciju koeficijenta determinacije (R^2) i koeficijent veličine učinka (f^2). Za analizu prediktivne snage tj. analizu prediktivne sposobnosti modela na novim, budućim uzorcima koristi se tzv. blinfolding zasnovan na Stone-Geisserov Q^2 funkciji te PLSpredict funkciji koju je razvio Shmueli *et al.* (2016). Odnosno, dok je Q^2 zapravo kombinacija in i out-of-sample sposobnosti modela, PLSpredict služi isključivo za potvrdu prediktivne snage modela (Sarstedt *et al.*, 2017).

Koeficijent determinacije R^2 mjeri varijancu koja je objašnjena u endogenom konstruktu strukturnog modela. Može poprimiti vrijednost od 0 do 1, pri čemu viša vrijednost upućuje na veću eksplanatornu moć. Kao smjernice tj. grubo pravilo praga, R^2 od 0.75, 0.50 i 0.25 smatra se znatnim, umjerenim i slabim vrijednostima (Hair *et al.,* 2019). Postavljeni model ovog istraživanja ima dvije endogene varijable čiji R^2 iznose 0.366 (KVALITETA OUTPUTA) i 0.112 (UTJECAJ NA ODLUKE). Navedene vrijednosti vidljive su i u rezultatima PLS algoritma (privitak 4), tj. unutar kružica dva navedena konstrukta. Sukladno pravilu praga KVALITETA OUTPUTA ima slabi do umjereni, dok UTJECAJ NA ODLUKE izuzetno slabi koeficijent determinacije. Međutim, kako navode Hair *et al.* (2019) njegova prihvatljiva vrijednost ovisi o kontekstu i području istraživanja. Točnije, navode da je i vrijednost od 0.10 prihvatljiva u određenim istraživanjima. To potvrđuju i drugi izvori. Tako npr. Falk i Miller (1992, u Streukens i Leroi-Werelds, 2016) navode da bi R^2 trebao biti jedan ili veći od 0.10, a Cohen (1988) R^2 od 0.13 smatra umjerenim. Osim toga, R^2 je funkcija broja prediktorskih konstrukata, što je njihov broj veći to će R^2 biti veći. U postavljenom modelu, pored kontroling varijabli UTJECAJ NA ODLUKE ima samo jedan prediktorski konstrukt. Sukladno navedenom te činjenicom da su dva endogena konstrukta modela mjerena s postojećim validnim mjernim skalama, uz minimalne modifikacije, dobiveni R^2 smatraju se zadovoljavajućima za daljnju procjenu modela.

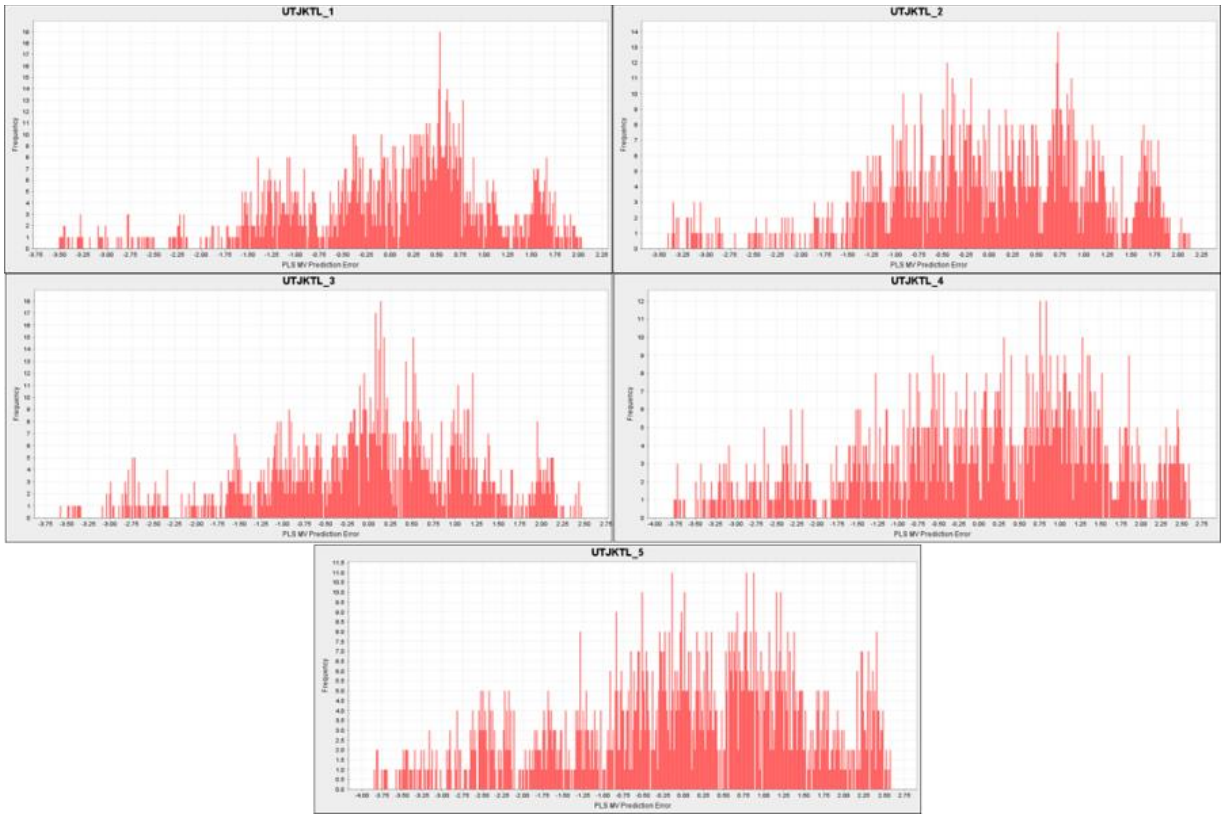
Rezultati vrijednosti f^2, koje ocjenjuju koliko jako jedan egzogeni konstrukt pridonosi objašnjenju pojedinog endogenog konstrukta u pogledu R^2 (Hair *et al.,* 2019) zapravo podržavaju rezultate značajnosti veza strukturnog modela. U pravilu, vrijednosti više od 0.02, 0.15 i 0.35 označavaju slabu, umjerenu i jaku veličinu učinka (Cohen, 1988). Sukladno rezultatima KAR KTL ima umjereni učinak (f^2=0.204) na KVALITETU OUTPUTA, dok KAR POD (f^2=0.086) i KAR OKR (f^2=0.035) imaju slabi. Odnosno, KVALITETA OUTPUTA (f^2=0.050) te kontrolne varijable URIKTL_KTL (f^2=0.045) i CENT/DECENT (f^2=0.021) imaju slabi učinak na UTJECAJ NA ODLUKE. Za KAR MEN i ostale kontrolne varijable učinak je manji od 0.02.

Nadalje, ocijenjen je Stone-Geisserov Q^2 indikator prediktivne značajnosti endogenih konstrukata tj. postavljenih veza unutar modela. Rezultati su dobiveni blindfolding procesom uz udaljenost propusta (engl. omission distance) D=7. Blindfolding je iterativni postupak koji se temelji na tehnici ponovne upotrebe uzorka koja izostavlja dio matrice podataka (tj. zamjenjuje ih s nedostajućim vrijednostima), te procjenjuje model dok god se svaki podatak

ne izostavi i model nanovo procijeni. Vrijednost Q^2 veća od nula upućuje da model ima prediktivni značaj endogenih konstrukata (Hair *et al.*, 2017). Sukladno rezultatima koeficijenta unakrsno-validirane redundancije (engl. cross-validated redundancy), Q^2 vrijednost oba endogene konstrukta veći je od nule (KVALITETU OUTPUTA=0.207; UTJECAJ NA ODLUKE=0.081), što ukazuje da model ima prediktivni značaj endogenih konstrukta.

Upotreba R^2 za tumačenje prediktivne snage modela može davati krive zaključke (Singh, Sood i Bala, 2021). Stoga Hari *et al*. (2017) predlažu primjenu PLSpredict postupka određivanja out-of-sample prediktivne moć modela, koji se zasniva na procjeni modela kroz kreiranje testnih uzoraka nasumičnim dijeljenjem uzorka na pod-skupove (tzv. folds) podataka. Sukladno preporuci Hair *et al*. (2017), primijenjeno je 10 pod-skupova (k) s 10 ponavljanja (r). Prvotni korak u provedbi PLSpredict postupka podrazumijeva ocjenu PLS-SEM $Q^2_{predict}$ vrijednosti. Ako su njegove vrijednosti svih čestica endogenih konstrukata veće od nula, prelazi se na korak usporedbe s dobivenim naivnim benchmarkom tj. linearnom regresijom modela (engl. Linear regression Model - LM). Ovisno o normalnosti distribucije čestica ključnog konstrukta modela (engl. key endogenous construct) primjenjuje se usporedba srednjih apsolutnih pogrešaka (engl. mean absolute error - MAE) ili korijenskih srednjih kvadratnih pogreška (engl. root mean squared error - RMSE) (Shmueli *et al.*, 2019).

Grafikon 5 - 9: PLS manifestni rezidualni histogrami (Model 1)



Izvor: SmartPLS (v. 3.3.3)

Iz histograma čestica ključnog konstrukta UTJECAJ NA ODLUKE (grafikon 5 - 9), vidljiva je prisutnost ne-normalne distribucije, a što podržavaju i rezultati Shapiro-Wilk testa (utjktl_1:z = 3.528, p<0.01; utjktl_2:z = 2.670, p<0.01; utjktl_3:z = 1.050, p>0.01; utjktl_4:z = 2.511, p<0.01; utjktl_5:z = 2.352, p<0.01). Stoga se u konačnom koraku PLSpredict postupka primjenjuje usporedba MAE vrijednosti PLS-SEM i LM rezultata.

Tablica 25: PLSpredict rezultati (Model 1)

Čestica	**PLS-SEM**			**LM**		**PLS-SEM - LM**
	MAE	RMSE	$Q^2_{predict}$	**MAE**	RMSE	**MAE**
utjktl_1	**0.858**	1.086	0.066	**1.197**	1.514	**-0.339**
utjktl_2	**0.897**	1.112	0.080	**1.117**	1.439	**-0.220**
utjktl_3	**0.919**	1.178	0.073	**1.287**	1.653	**-0.368**
utjktl_4	**1.206**	1.470	0.069	**1.616**	2.069	**-0.410**
utjktl_5	**1.198**	1.477	0.087	**1.589**	1.983	**-0.391**

Izvor: SmartPLS (v. 3.3.3)

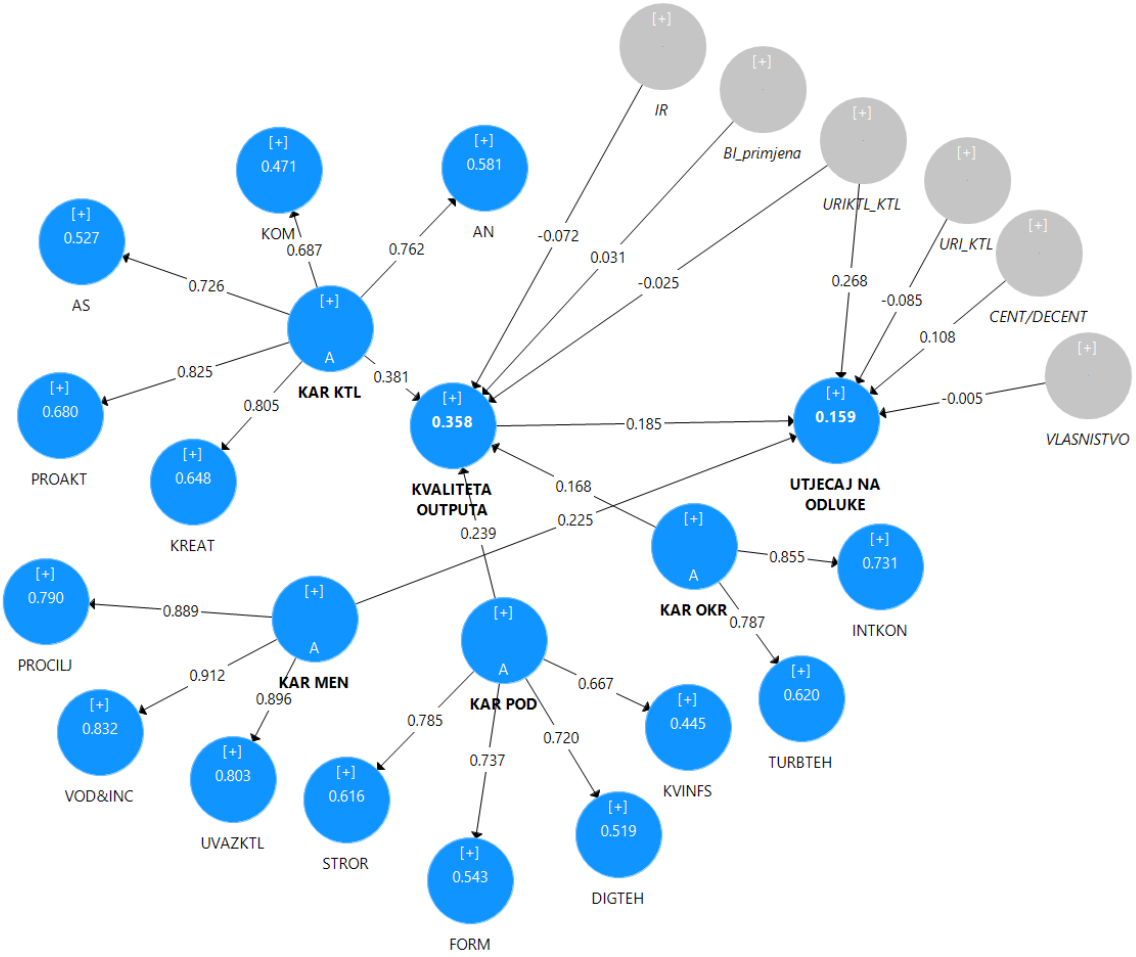
Analiza pokazuje da sve čestice endogenog konstrukta imaju nižu vrijednosti MAE za PLS-SEM model od referentne vrijednosti LM (tablica 25), što ukazuje na visoku prediktivnu moć

modela (Hair *et al.,* 2017; Shmueli *et al.,* 2019). Osim toga, $Q^2_{predict}$ svih čestica PLS-SEM analize veći su od nula što upućuje na prediktivnu moć modela.

Sukladno svim rezultatima ocjene prediktivne značajnosti modela može se zaključiti da model ima slabu do umjerenu eksplanatornu, međutim jaku prediktivnu moć. Shmueli *et al.* (2019), navedeno da takvi rezultati mogu upućivati na potrebu za proširenjem postojeće teorije ili razvojem nove. S obzirom na jaku out-of-sample moć predviđanja prvotni prijedlog daljnjih istraživanja uključivao bi testiranje modela na novim, većim uzorcima, a prije svega u zemljama koje kontroling smatraju gotovo pa neizostavnom funkcijom, kao što su Njemačka i Austrija, ali i drugim zemljama (npr. Italija, Švicarska, Rumunjska, Slovenija, Nizozemska, itd.). Odnosno, daljnja istraživanja trebala bi se usmjeriti na provjeru utjecaja i kreiranje HOC konstrukata s drugim karakteristikama, kao npr. "tvrdim" vještinama kontrolera (npr. sposobnost primjene različitih softverskih rješenja, sposobnost izrade uravnotežene matrice uspješnosti, itd.) ili uključivanjem drugih utjecajnih karakteristika menadžera (npr. usmjerenost na rast rezultata).

S obzirom na neočekivani neznačajni utjecaj specificiranih karakteristika menadžer na kvalitetu kontrolerovog outputa, a sukladno navodu Nguyen *et al.* (2017) da transformacijsko vodstvo (jedna od karakteristika menadžera u modelu ove disertacije), koje podrazumijeva vođenje, motiviranje i iniciranje zaposlenika, utječe na primjenu kontrolerovih outputa od strane menadžera u poslovnom odlučivanju, napravljena je i testirana modifikacija postavljenog modela (Model 1a) ovog istraživanja (slika 21). Odnosno, postavljena hipoteza H2 koja tvrdi da su karakteristike menadžera statistički značajno i pozitivno povezane s kvalitetom kontrolerovog outputa, trebala bi glasiti: karakteristike menadžera su statistički značajno i pozitivno povezane s kontrolerovim utjecajem na donošenje poslovnih odluka.

Slika 21: Modificirani strukturni model (Model 1a)



Izvor: SmartPLS (v. 3.3.3)

Ocjena mjernog modela modificirane verzije rezultirala je neznatnim promjenama u faktorskim opterećenjima čestica konstrukata KVALITETE OUTPUTA I UJTECAJA NA ODLUKE. Vrijednost opterećenja se maksimalno promijenila za 0,004. Na primjer, čestica utjktl_2 nema više vrijednost 0.920 već 0.924, dok npr. čestica kvout_1 više ne iznosi 0.696 već 0.697. Odnosno, došlo je do smanjenja CR (sa 0.927 na 0.838) i AVE (sa 0.808 na 0.531) vrijednosti HOC konstrukta KAR MEN te neznatnog povećanja AVE (sa 0.581 na 0.582) vrijednosti HOC konstrukta KAR KTL, ali unutar dozvoljenog praga. Svi LOC i HOC konstrukti i dalje zadovoljavaju sve uvjete pouzdanosti i valjanosti mjernog modela.

U procjeni strukturnog modela dolazi do pojedinih izmjena. Iako su se vrijednosti unutarnjih faktora inflacije varijance (VIF) promijenile, rezultati potvrđuju ispunjavanje kriterija kolinearnosti jer su sve vrijednosti ispod 3.0 (tablica 26).

Tablica 26: Unutarnji faktori inflacije varijance (Model 1a)

	KVALITETA OUTPUTA	**UTJECAJ NA ODLUKE**
KAR KTL	1.185	
KAR POD	1.242	
KAR OKR	1.211	
BI_primjena	1.216	
IR	1.112	
URIKTL_KTL	1.043	1.725
CENT/DECENT		1.026
URI_KTL		1.758
VLASNISTVO		1.024
KAR MEN		1.064
KVALITETA OUTPUTA		1.027

Izvor: izrada autora prema SmartPLS (v. 3.3.3)

Značajna promjena vidljiva je u rezultatima značajnosti i jačine koeficijenata puta (tablica 27). Pozitivni utjecaji KAR KTL, KAR POD i KAR OKR na KVALITETU OUTPUTA neznatno su se promijenili, te su i dalje značajni ($p<0.05$). Međutim, KAR MEN dokazale su se kao značajna stavka koja ima pozitivni efekt na kontrolerov UTJECAJ NA ODLUKE ($\beta=0.225$, $p<0.05$). Dok se kontrolna varijabla URIKTL_KTL ponovo potvrdila kao statistički značajna za UTJECAJ NA ODLUKE, CENT/DECENT u ovom modelu je odbačena kao utjecajna varijabla. Dobiveni neznačajni utjecaj organizacijske pozicije odjela kontrolinga može se opravdati intervalnim odnosima iste varijable u Modelu 1. Iako se prema p-vrijednosti ($p=0,039$) organizacijska pozicija kontroling funkcije dokazala kao statistički značajna varijabla, prema intervalnim vrijednostima [-0.002; 0.265], koje daju dodani uvid stabilnosti koeficijenta (Hair *et al.*, 2017), mogla bi se zaključiti upitnost značaja k.v. CENT/DECENT već u Modelu 1. Dobiveni rezultati se mogu opravdati činjenicom da pojmovi centralizacija i decentralizacija u praksi još uvijek nisu dovoljno razgraničeni. Npr. dok pojedini smatraju da imaju decentralizirani odjel obzirom da odgovaraju matičnom uredu van zemlje, drugi mogu smatrati svoj odjel decentraliziranim jer odgovaraju voditelju financijskog odjela.

Tablica 27: Rezultati značajnosti i jačine koeficijenata puta strukturnog modela (Model 1a)

H	Veza	Koef. puta	Stand. Dev.	T-vrijed.	p-vrijed.	Hipoteza?
H1	KAR KTL -> KVALITETA OUTPUTA	0.381	0.059	6.481	0.000*	Prihvaćena
H2	KAR MEN -> UTJECAJ NA ODLUKE	0.225	0.068	3.306	0.001*	Prihvaćena
H3	KAR POD -> KVALITETA OUTPUTA	0.239	0.077	3.101	0.002*	Prihvaćena
H4	KAR OKR -> KVALITETA OUTPUTA	0.168	0.077	2.189	0.029*	Prihvaćena
H5	KVALITETA OUTPUTA -> UTJECAJ NA ODLUKE	0.185	0.074	2.499	0.012*	Prihvaćena
k.v.	URIKTL_KTL -> UTJECAJ NA ODLUKE	0.268	0.079	3.377	0.001*	Prihvaćena
	CENT/DECENT -> UTJECAJ NA ODLUKE	0.108	0.069	1.563	0.118	Odbačena
	IR -> KVALITETA OUTPUTA	-0.072	0.071	1.010	0.312	Odbačena
	URI_KTL -> UTJECAJ NA ODLUKE	-0.085	0.093	0.916	0.359	Odbačena
	URIKTL_KTL -> KVALITETA OUTPUTA	-0.025	0.076	0.333	0.740	Odbačena
	BI_primjena -> KVALITETA OUTPUTA	0.031	0.073	0.423	0.672	Odbačena
	VLASNISTVO -> UTJECAJ NA ODLUKE	-0.005	0.076	0.071	0.944	Odbačena

Napomena: $p<0.05$*

Izvor: izrada autora prema SmartPLS (v. 3.3.3)

U pogledu prediktivne moći modela također dolazi do promjena, ali model i dalje zadržava slabu do umjerenu eksplanatornu te jaku prediktivnu moć. R^2 endogene varijable KVALITETA OUTPUTA se smanjila (0.358) dok se za UTJECAJ NA ODLUKE povećao (0.159). f^2 većine varijabli se neznatno smanjio, ali je razina učinka ostala ista. Odnosno, jačina učinka kontrolne varijable CENT/DECENT na UTJECAJ NA ODLUKE je postala neznačajna (f^2=0.013) dok se je KAR MEN dokazao kao konstrukt slabog učinka (f^2=0.056).

Tablica 28: PLSpredict rezultati (Model 1a)

Čestica	PLS-SEM			LM		PLS-SEM - LM
	MAE	RMSE	$Q^2_{predict}$	MAE	RMSE	MAE
utjktl_1	**0.836**	1.079	0.080	**1.179**	1.501	**-0,343**
utjktl_2	**0.857**	1.085	0.127	**1.092**	1.409	**-0,235**
utjktl_3	**0.909**	1.163	0.102	**1.274**	1.636	**-0,365**
utjktl_4	**1.216**	1.466	0.076	**1.617**	2.063	**-0,401**
utjktl_5	**1.195**	1.448	0.121	**1.591**	2.002	**-0,396**

Izvor: SmartPLS (v. 3.3.3)

Q^2 indikator svih endogenih konstrukata i dalje je veći od nule, kao i $Q^2_{predict}$ koji se povećao za sve čestice ključnog konstrukta. Osim toga, MAE vrijednosti za PLS-SEM model niže su u odnosu na LM vrijednosti za sve čestice ključnog konstrukta (tablica 28).

5.2.3.2. Rezultati analize konceptualnog modela sa stajališta menadžera i kontrolera - Model 2

U svrhu potvrde hipoteze H6, da se menadžerska percepcija utjecaja kvalitete kontrolerovog outputa na donošenje poslovnih odluka razlikuje od kontrolerove percepcije, drugi model istraživanja uključio je ocjenu tri varijable modela od strane menadžera tj. svih razina menadžera kojima kontroleri pomažu u donošenju odluka. Drugim riječima, menadžeri su ocjenjivali kontrolerove karakteristike, kvalitetu kontrolerovog outputa i kontrolerov utjecaj na donošenje odluka, dok su se za ocjenu karakteristika menadžera, poduzeća i okruženja primijenili rezultati ankete ispunjenje od strane kontrolera (onih korištenih u Modelu 1 i 1a). Tako se osigurala veća objektivnost obzirom da kontroleri ocjenjuju karakteristike menadžera i obrnuto; tj. dodatno je smanjena mogućnost pristranosti metode (Podsakoff *et al.*, 2003). Model 2 temelji se na modelu 1a tj. modelu koji podrazumijeva da karakteristike menadžera utječu na kontrolerov utjecaj na donošenje odluka. Analiza modela također se provodi kroz procjenu mjernog i strukturnog modela.

5.2.3.2.1. Procjena mjernog modela - Model 2

Sukladno prvom koraku rezultatima analize mjernog modela (tablica 29) može se zaključiti da svi LOC konstrukti zadovoljavaju uvjete konvergentne valjanosti i pouzdanosti. Odnosno, u odnosu na Model 1a, a zbog utjecaja na unakrsna standardizirana faktorska opterećenja, pet dodatnih čestica isključeno je iz modela, a odnose se na analitičnost (KTLmen_an5), asertivnost (KTLmen_as4), komunikativnost (KTLmen_kom1) i proaktivnost kontrolera (KTLmen_proakt1), te menadžersku karakteristiku vođa i inicijator (MEN_vod&inic3). Ukupno radno iskustvo kontrolera u kontrolingu (URIKTL_KTL) jedina je kontrolna varijabla uključena u ovaj model s obzirom da se je u Modelu 1 i 1a dokazala kao jedina signifikantna kontrolna varijabla.

Tablica 29: Rezultati LOC konstrukata mjernog modela (Model 2)

Konstrukti	Čestice	Vanjska faktorska opterećenja	Cronbach alfa	rho_A	CR	AVE
AN	KTLmen_an1	0.816	0.848	0.852	0.898	0.688
	KTLmen_an2	0.857				
	KTLmen_an3	0.777				
	KTLmen_an4	0.864				

AS	KTLmen_as1	0.825	0.761	0.814	0.844	0.578
	KTLmen_as2	0.725				
	KTLmen_as3	0.830				
	KTLmen_as5	0.646				
KOM	KTLmen_kom2	0.741	0.842	0.859	0.895	0.681
	KTLmen_kom3	0.806				
	KTLmen_kom4	0.836				
	KTLmen_kom5	0.908				
PROAKT	KTLmen_proakt2	0.795	0.884	0.886	0.915	0.684
	KTLmen_proakt3	0.850				
	KTLmen_proakt4	0.826				
	KTLmen_proakt5	0.831				
	KTLmen_proakt6	0.831				
KREAT	KTLmen_kreat1	0.875	0.878	0.879	0.917	0.733
	KTLmen_kreat2	0.809				
	KTLmen_kreat3	0.868				
	KTLmen_kreat4	0.872				
PROCILJ	MEN_procilj1	0.825	0.923	0.930	0.943	0.769
	MEN_procilj2	0.932				
	MEN_procilj3	0.930				
	MEN_procilj4	0.764				
	MEN_procilj5	0.921				
VOD&INC	MEN_vod&inic1	0.944	0.916	0.922	0.941	0.800
	MEN_vod&inic2	0.825				
	MEN_vod&inic4	0.913				
	MEN_vod&inic5	0.893				
UVAZKTL	MEN_uvazktl2	0.897	0.920	0.922	0.943	0.806
	MEN_uvazktl3	0.875				
	MEN_uvazktl4	0.913				
	MEN_uvazktl5	0.906				
STROR	POD_stror1	0.871	0.906	0.908	0.934	0.780
	POD_stror2	0.878				
	POD_stror3	0.873				
	POD_stror4	0.909				
FORM	POD_form1	0.823	0.849	0.852	0.894	0.628
	POD_form2	0.786				
	POD_form3	0.852				
	POD_form4	0.832				
	POD_form5	0.655				
DIGTEH	POD_digteh1	0.937	0.912	0.925	0.944	0.849
	POD_digteh2	0.900				
	POD_digteh3	0.928				
KVINFS	POD_kvinfs1	0.719	0.889	0.902	0.919	0.697
	POD_kvinfs2	0.836				
	POD_kvinfs3	0.757				
	POD_kvinfs4	0.918				
	POD_kvinfs5	0.925				
TURBTEH	OKR_turbteh2	0.792	0.868	0.872	0.910	0.718
	OKR_turbteh3	0.838				
	OKR_turbteh4	0.908				
	OKR_turbteh5	0.847				
INTKON	OKR_intkon1	0.857	0.878	0.879	0.912	0.676
	OKR_intkon2	0.878				

	OKR_intkon4	0.774				
	OKR_intkon5	0.722				
	OKR_intkon6	0.868				
KVALITETA OUTPUTA	kvoutmen_1	0.675	0.907	0.912	0.923	0.548
	kvoutmen_2	0.723				
	kvoutmen_3	0.781				
	kvoutmen_4	0.823				
	kvoutmen_5	0.700				
	kvoutmen_6	0.770				
	kvoutmen_7	0.752				
	kvoutmen_8	0.785				
	kvoutmen_9	0.772				
	kvoutmen_10	0.591				
UTJECAJ NA ODLUKE	utjktlmen_1	0.855	0.924	0.930	0.943	0.767
	utjktlmen_2	0.917				
	utjktlmen_3	0.915				
	utjktlmen_4	0.842				
	utjktlmen_5	0.848				
URIKTL_KTL*			1.000	1.000	1.000	1.000

*Napomena: faktorska opterećenja svih čestice imaju t-vrijednost>1.96 tj. p<0.05; *kontrolna varijabla*

Izvor: izrada autora prema SmartPLS (v. 3.3.3)

Vrijednost HTMT analize potvrđuju da i Model 2 zadovoljava uvjet diskriminantne valjanosti. Sve vrijednosti su ispod dozvoljenog praga. Odnosno, jedino odnos varijable UVAZKTL i VOD&INC ima malo višu vrijednost (0.855), ali unutar dozvoljenog praga 0.90 (tablica 30).

Tablica 30: HTMT vrijednosti modela (Model 2)

	AN	AS	DIGTEH	FORM	INTKON	KAR KTL	KAR MEN	KAR OKR	KAR POD	KOM	KREAT	KVALITETA OUTPUTA	KVINFS	PROAKT	PROCILJ	STROR	TURBTEH	URIKTL_KTL	UTJECAJ NA ODLUKE	UVAZKTL	VOD&INC
AN																					
AS	0.532																				
DIGTEH	0.068	0.216																			
FORM	0.124	0.186	0.382																		
INTKON	0.146	0.298	0.141	0.219																	
KAR KTL	0.945	0.841	0.136	0.165	0.185																
KAR MEN	0.159	0.162	0.530	0.304	0.145	0.216															
KAR OKR	0.177	0.318	0.328	0.370	0.967	0.233	0.201														
KAR POD	0.174	0.277	0.735	0.817	0.263	0.224	0.608	0.411													
KOM	0.803	0.751	0.131	0.124	0.149	0.955	0.116	0.171	0.171												
KREAT	0.767	0.601	0.121	0.149	0.123	0.924	0.178	0.164	0.210	0.719											
KVALITETA OUTPUTA	0.634	0.542	0.149	0.171	0.190	0.643	0.261	0.257	0.313	0.612	0.422										
KVINFS	0.128	0.180	0.273	0.255	0.226	0.174	0.448	0.283	0.767	0.143	0.192	0.330									
PROAKT	0.808	0.588	0.082	0.143	0.122	0.950	0.295	0.204	0.163	0.731	0.770	0.590	0.125								
PROCILJ	0.136	0.107	0.517	0.342	0.108	0.164	0.944	0.204	0.613	0.089	0.096	0.272	0.492	0.256							
STROR	0.162	0.212	0.509	0.463	0.142	0.152	0.471	0.188	0.860	0.085	0.119	0.209	0.390	0.101	0.402						
TURBTEH	0.122	0.173	0.382	0.358	0.245	0.168	0.162	0.859	0.373	0.108	0.126	0.202	0.203	0.196	0.213	0.144					
URIKTL_KTL	0.118	0.154	0.175	0.118	0.039	0.117	0.181	0.087	0.186	0.053	0.143	0.092	0.094	0.059	0.172	0.156	0.098				
UTJECAJ NA ODLUKE	0.597	0.414	0.176	0.195	0.109	0.635	0.422	0.190	0.254	0.412	0.619	0.662	0.136	0.669	0.386	0.218	0.188	0.128			
UVAZKTL	0.174	0.206	0.483	0.255	0.154	0.260	0.962	0.197	0.511	0.134	0.245	0.289	0.313	0.339	0.718	0.439	0.146	0.167	0.442		
VOD&INC	0.126	0.139	0.437	0.218	0.139	0.173	0.965	0.141	0.522	0.098	0.160	0.144	0.399	0.212	0.723	0.449	0.069	0.154	0.323	0.855	

Izvor: izrada autora prema SmartPLS (v. 3.3.3)

Tablica 31: Rezultati HOC konstrukata mjernog modela (Model 2)

Konstrukti	Čestice	Vanjska faktorska opterećenja	Cronbach alfa	CR	AVE
KAR KTL	AN	0.857	0.890	0.919	0.695
	AS	0.726			
	KOM	0.857			
	PROAKT	0.876			
	KREAT	0.845			
KAR MEN	PROCILJ	0.878	0.879	0.925	0.805
	VOD&INC	0.906			
	UVAZKTL	0.908			
KAR POD	STROR	0.811	0.675	0.804	0.508
	FORM	0.688			
	DIGTEH	0.689			
	KVINFS	0.652			
KAR OKR	TURBTEH	0.710	0.357	0.754	0.607
	INTKON	0.842			

Napomena: Cronbach alfa, CR i AVE izračunati su ručno (vidi privitak 8 i 9)

Izvor: izrada i izračuna autora prema SmartPLS (v. 3.3.3)

Sukladno analizi HOC konstrukata (tablica 31), tj. drugom koraku analize, vidljivo je da svi konstrukti zadovoljavaju uvjete valjanosti i pouzdanosti. Odnosno, jedino KAR OKR imaju izrazito nisku vrijednost Cronbach alfe, međutim CR i AVE pokazuju zadovoljavajuće vrijednosti te se stoga ostavlja u modelu za daljnju analizu. Izračunate HTMT vrijednosti (privitak 10) potvrđuju i da HOC konstrukti zadovoljavaju uvjet diskriminantne valjanosti. Za razliku od Modela 1a, u kojem su se kao najznačajnije karakteristike kontrolera isticale proaktivnost, kreativnost i analitičnost, u ovom modelu (sa stajališta menadžera) se kao najznačajnije dokazuju proaktivnost, analitičnost i komunikativnost.

5.2.3.2.2. Procjena strukturnog modela - Model 2

Ocjena strukturnog modela podrazumijeva prvotnu analizu kolinearnosti. Obzirom da su sve unutarnje VIF vrijednosti postavljenog modela manje od 3.0 (tablica 32) model ispunjava kriterij kolinearnosti i može se smatrati da nije prisutna pristranost metode.

Tablica 32: Unutarnji faktori inflacije varijance (Model 2)

	KVALITETA OUTPUTA	UTJECAJ NA ODLUKE
KAR KTL	1.005	
KAR POD	1.095	
KAR OKR	1.067	
URIKTL_KTL	1.032	1.048
KAR MEN		1.097
KVALITETA OUTPUTA		1.069

Izvor: izrada autora prema SmartPLS (v. 3.3.3)

Drugi korak u ocjeni strukturnog modela podrazumijeva testiranje hipoteza.

Tablica 33: Rezultati značajnosti i jačine koeficijenata puta strukturnog modela (Model 2)

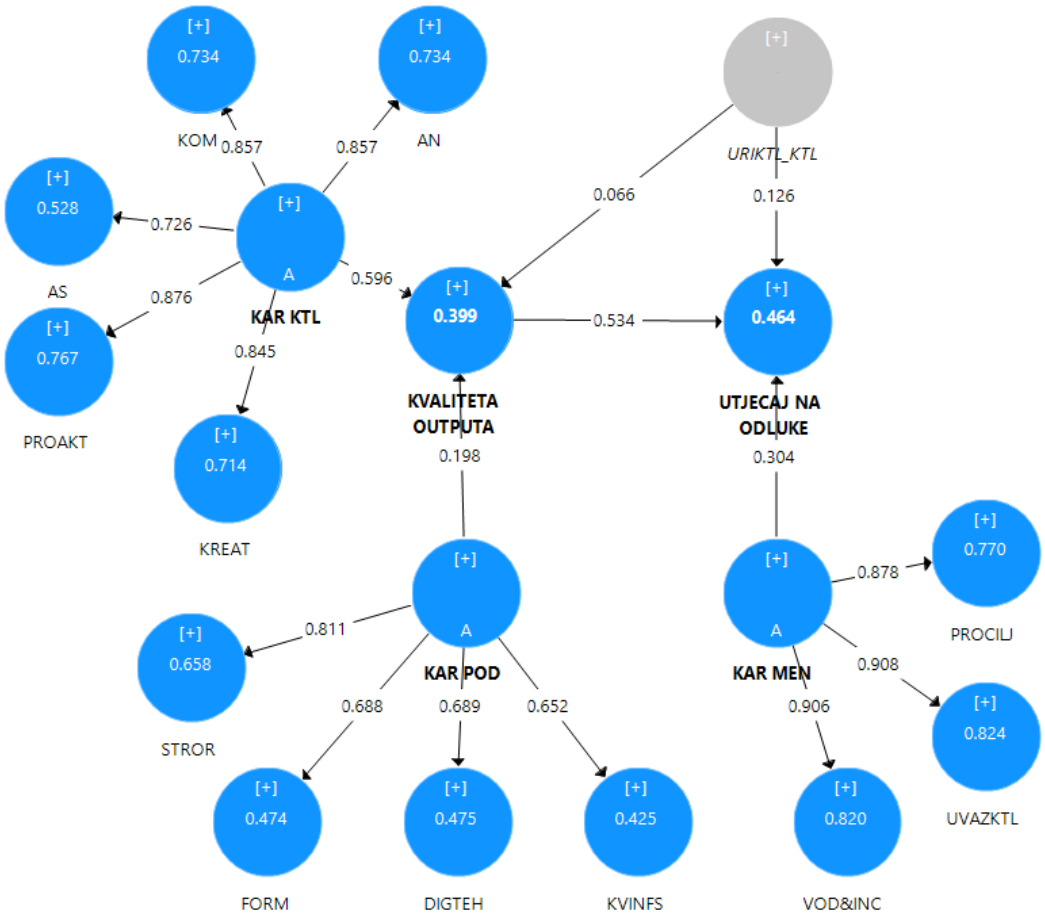
H	Veza	Koef. puta	Stand. Dev.	T-vrijed.	p-vrijed.	Hipoteza?
H1	KAR KTL -> KVALITETA OUTPUTA	0.596	0.081	7.406	0.000*	Prihvaćena
H2	KAR MEN -> UTJECAJ NA ODLUKE	0.304	0.121	2.511	0.012*	Prihvaćena
H3	KAR POD -> KVALITETA OUTPUTA	0.192	0.111	1.734	0.083**	Prihvaćena
H4	KAR OKR -> KVALITETA OUTPUTA	0.028	0.097	0.284	0.777	Odbačena
H5/ H6	KVALITETA OUTPUTA -> UTJECAJ NA ODLUKE	0.534	0.087	6.168	0.000*	Prihvaćena
k.v.	URIKTL_KTL -> UTJECAJ NA ODLUKE	0.126	0.087	1.456	0.145	Odbačena
	URIKTL_KTL -> KVALITETA OUTPUTA	0.065	0.098	0.667	0.505	Odbačena

*Napomena: *p<0,05; **p<0,10*

Izvor: izrada autora prema SmartPLS (v. 3.3.3)

Sukladno rezultatima (tablica 33) vidljivo je da pri razini signifikantnosti od α=5% KAR POD i KAR OKR, kao i kontrolna varijabla URIKTL_KTL nisu značajne za postavljeni model. Obzirom na značajan utjecaj KAR POD u Modelu 1 i 1a, a sukladno opravdanosti primjene veće razine značajnosti u društvenim i eksplanatornim istraživanjima (Hair *et al.,* 2017), model je testiran s razinom značajnosti od α=10% (5000 pod-uzoraka; dvostrani test $p \leq 0.10$; Bias-Corrected and Accelerated Bootstrap). Rezultati potvrđuju značajnost konstrukta KAR POD, dok KAR OKR i URIKTL_KTL ostaju neznačajni. Navedeno se može opravdati veličinom uzorka koji značajno utječe na razinu p-vrijednosti. Međutim, obzirom da je konstrukt KAR OKR imao i izrazito nisku vrijednost Cronbach alfe kao HOC konstrukta te f^2=0.001, navedeni konstrukt se izbacuje iz Modela 2, dok se kontrolna varijabla zadržava obzirom da f^2=0.028 ukazuje na utjecaj na ključni konstrukt.

Slika 22: Strukturni Model 2a



Izvor: SmartPLS (v. 3.3.3)

Valjanost i pouzdanost novog mjernog modela (bez konstrukta KAR OKR) tj. Modela 2a (slika 22) u odnosu na Model 2 ostaje nepromjenjiva, kao i prihvatljivost unutarnjih faktora inflacije varijance te hipoteza uz pojedine promjene vrijednosti standardne devijacije te β, p i t-vrijednosti (tablica 34).

Tablica 34: Rezultati značajnosti i jačine koeficijenata puta strukturnog modela (Model 2a)

H	Veza	Koef. puta	Stand. Dev.	T-vrijed.	p-vrijed.	Hipoteza?
H1	KAR KTL -> KVALITETA OUTPUTA	0.596	0.079	7.520	0.000*	Prihvaćena
H2	KAR MEN -> UTJECAJ NA ODLUKE	0.304	0.125	2.430	0.015*	Prihvaćena
H3	KAR POD -> KVALITETA OUTPUTA	0.198	0.110	1.798	0.072**	Prihvaćena
H5/ H6	KVALITETA OUTPUTA -> UTJECAJ NA ODLUKE	0.534	0.088	6.104	0.000*	Prihvaćena
k.v.	URIKTL_KTL -> UTJECAJ NA ODLUKE	0.126	0.087	1.447	0.148	Odbačena
	URIKTL_KTL -> KVALITETA OUTPUTA	0.066	0.097	0.682	0.495	Odbačena

*Napomena: *p<0,05; **p<0,10*

Izvor: izrada autora prema SmartPLS (v. 3.3.3)

Sukladno dobivenim rezultatima potvrđuje se postavljena hipoteza H6, da se menadžerska percepcija utjecaja kvalitete kontrolerovog outputa na donošenje poslovnih odluka razlikuje od kontrolerove percepcije. Odnosno, uzimajući u obzir razliku u veličini uzorka Modela 1 tj. 1a i Modela 2 te razlike u načinu mjerenja konstrukata modela, može se zaključiti da je utjecaj kvalitete kontrolerovog outputa na donošenje odluka značajno bolje percipiran od strane menadžera (Model 2 β=0.534) nego samih kontrolera (Model 1 β=0.211; Model 1a β=0,185). Iako se rezultati ne podudaraju s istraživanjem Weißenberger *et al.,* (2012) u pogledu jačine značajnog pozitivnog utjecaja kvalitete outputa na uključenost u donošenju odluka, navedeno se može pripisati uzorku ispitivanja (1500 najboljih njemačkih poduzeća; ukupno 149 dyadic anketa); odnosno za pretpostaviti je da su u svrhu istraživanja koje se prikazuje u ovoj disertaciji, a koje uključuje samo 64 dyadic ispitanika, anketu ispunili uglavnom oni menadžeri koji uvažavaju kontrolere i smatraju funkciju kontrolinga značajnom. Osim toga, u istraživanju Weißenberger *et al.* (2012) navodi se da je uzorak uključivao generalne menadžere (tj. članove uprave, direktore poduzeća-CEO i direktore odjela), međutim, nije specificirano što se podrazumijeva pod direktorima odjela tj. da li to uključuje i direktore/voditelje financijskog odijela koji u ovom istraživanju pored članova uprave i direktora poduzeća zauzimaju veliki udio u uzorku. To ujedno ukazuje na činjenicu da se kontroling u Hrvatskoj u velikoj mjeri smatra dijelom financijskog odjela, ali se temeljem veličine uzorka ne može u potpunosti i potvrditi već isto zahtjeva daljnja istraživanja koja bi se bavila isključivo navedenom problematikom organizacijske strukture kontrolinga. Nadalje, razlog nepodudarnosti istraživanja može biti u primjeni različitih mjernih modela (Likert 1-5 u odnosu na 1-7), broju i vrsti nezavisnih varijabli te broju čestica endogenih varijabli, odnosno razlike u dobivenim rezultatima dva endogena konstrukta. Dok su u istraživanju Weißenberger *et al.,* (2012), koje uključuje manji broj čestica, menadžeri dali bolje prosječne ocjene za sve čestice utjecaja na odluke, a kontroleri bolje za sve čestice kvalitete kontrolerovog outputa, u ovom istraživanju menadžeri su dali bolje prosječne ocjene za sve čestice utjecaja na odluke dok su prosječne vrijednosti čestica kvalitete kontrolerovog outputa pomiješane tj. razlika prosječnih središnjih vrijednosti svih čestica konstrukta je znatno manja od usporednog istraživanja (0,06 u odnosu na 0,90).

U konačnici potvrđena je i prediktivna moć Modela 2a. U odnosu na Model 1 i 1a, pokazuje znatno bolju in-sample prediktivnu moć. R^2 endogene varijable KVALITETA OUTPUTA (R^2=0.399), a osobito UTJECAJA NA ODLUKE (R^2=0.464), pokazuju veću objašnjenost varijance u endogenom konstruktu. Navedeno potvrđuje opravdanosti primjene subjektivnijeg

načina ispitivanja sudionika tj. uključivanja kontrolera i menadžera u ocjeni međusobnih karakteristika. Vrijednosti f^2 ukazuju na jaku veličinu učinka KAR KTL na KVALITETU OUTPUTA (f^2=0.589) te KVALITETE OUTPUTA na UTJECAJ NA ODLUKE (f^2=0.498), umjereni učinak KAR MEN na UTJECAJ NA ODLUKE (f^2=0.157) i slabi učinak KAR POD na KVALITETU OUTPUTA (f^2=0.064), te URIKTL_KTL na UTJECAJ NA ODLUKE (f^2=0.058). Ocijenjen Stone-Geisserov Q^2 indikatora unakrsno-validirane redundancije (D=7) ukazuje da model ima prediktivni značaj endogenih konstrukta (KVALITETA OUTPUTA=0.195; UTJECAJ NA ODLUKE=0.341).

Tablica 35: PLSpredict rezultati (Model 2a)

Čestica	**PLS-SEM**			**LM**		**PLS-SEM - LM**
	MAE	**RMSE**	**$Q^2_{predict}$**	**MAE**	**RMSE**	**MAE**
utjktlmen_1	**0.656**	0.878	0.241	**2.064**	2.824	**-1.408**
utjktlmen_2	**0.641**	0.831	0.309	**1.834**	2.473	**-1.193**
utjktlmen_3	**0.703**	0.870	0.327	**2.643**	3.584	**-1.940**
utjktlmen_4	**0.705**	0.967	0.259	**2.165**	2.992	**-1.460**
utjktlmen_5	**0.757**	0.960	0.276	**2.464**	3.412	**-1.707**

Izvor: SmartPLS (v. 3.3.3)

Rezultati PLSpredict (tablica 35) analize (k=10, r=10), kao i kod Modela 1 i 1a, potvrđuju veliku out-of-sample prediktivnu moć. $Q^2_{predict}$ svih čestica PLS-SEM analize veći su od jedan tj. MAE vrijednosti PLS-SEM rezultata su niži od LM vrijednosti svih čestica ključnog konstrukta. Kao i kod analize prediktivne moći Modela 1, korištena je usporedba MAE vrijednosti obzirom na ne-normalnu distribuciju tri od pet čestice ključnog konstrukta potvrđene Shapiro-Wilk testom (utjktlmen_1:z = 4.413, p<0.00; utjktlmen_2:z = 4.413, p<0.00; utjktlmen_3:z = 1.6944, p<0.04). Sukladno svim rezultatima ocjene prediktivne značajnosti modela može se zaključiti da Model 2a ima znatno bolju ukupnu prediktivnu moć od Modela 1 tj. 1a.

Ako se usporede dobiveni rezultati svih PLSpredict analiza empirijskog istraživanja (Shmueli *et al.*, 2019) može se zaključiti da je najpouzdaniji model Model 2a, obzirom da ima najnižu MAE vrijednosti ključnog konstrukta utjecaj na odluke (MAE Model 1=0.783; MAE Model 1a=0.770; MAE Model 2a=0.624), a što podržavaju i rezultati ocjene strukturnog modela (npr. znatno više R^2 i f^2).

5.3. Zaključna razmatranja i prijedlog budućeg razvoja kontrolinga s osnova digitalizacije

Prikazanim istraživanjem potvrđena je temeljna hipoteza da karakteristike kontrolera i menadžera te poduzeća i okruženja u uvjetima digitalizacije imaju značajan utjecaj na učinke kontrolerovih aktivnosti i doprinos u donošenju poslovnih odluka. Točnije, nije potvrđena teza da karakteristike menadžera doprinose kvaliteti kontrolerovih outputa, ali je zato potvrđena njihova povezanost s kontrolerovim utjecajem na donošenje poslovnih odluka. U skladu s prethodnim istraživanjima (Spillecke, 2006; Weißenberger i Angelkort, 2011; Weißenberger *et al.*, 2012) potvrđen je pozitivan odnos kvalitete kontrolerovog outputa i kontrolerovog utjecaja na donošenje odluka. Odnosno, potvrđeno je da su postavljene utjecajne karakteristike tj. karakteristike kontrolera, poduzeća i okruženja pozitivno povezne s kvalitetom kontrolerovih outputa. Model 1, koji podrazumijeva testiranje postavljenog konceptualnog modela sa sastajališta kontrolera. potvrdio je da karakteristike kontrolera u vidu proaktivnosti, analitičnosti, komunikativnosti, kreativnosti i asertivnosti imaju značajnu pozitivnu povezanost s kvalitetom analiza i izvještaja koje kontroler izrađuje u svrhu donošenja odluka od strane menadžera, a što potvrđuju u svojim istraživanjima i modelima Sathe (1982), Haluk *et al.* (2016) i Rouwelaar *et al.* (2018). Dokazana povezanost kvalitete informacijskog sustava, primjene digitalnih tehnologija, strateške orijentiranosti i formalizacije organizacijske strukture, kao odrednica karakteristika poduzeća, s kvalitetom kontrolerovih outputa također je potvrdilo prethodna istraživanja u području kontrolinga (Weißenberger i Angelkort, 2011; Anggadini, 2014; Astuty, 2015; Ghasemi *et al.*, 2015, 2016; Pangaribuan, 2016; Ahmetoglu *et al.*, 2019). Intenzitet konkretnosti i turbulentnost tehnologije potvrdile su se kao značajne karakteristike okruženja. Iako je utjecaj konkurentnosti na kontroling potvrđen kroz brojna istraživanja (Mia i Clarke, 1999; Ghasemi *et al.*, 2015; Ismail, Isa i Mia, 2018, itd.) utjecaj tehnološke turbulentnosti nije evidentan. S obzirom na veliki utjecaj digitalizacije naglašava se potrebna za daljnjim istraživanjima kako bi se utvrdila korist primjene različitih oblika tehnoloških inovacija u poduzećima općenito, ali i u radu kontrolinga. Pri tome bi se, u vidu kontrolinga, istraživanja trebala prvenstveno usmjereniti na pitanja poboljšanja poslovnih procesa te alata koji omogućuju efikasniju analizu i poslovno odlučivanje. Modelom 1 jedino nije potvrđena povezanost kvalitete kontrolerovog outputa i karakteristika menadžera definiranih kroz osobine vođe i inicijatora, uvažavanja kontrolera te proaktivnosti i usmjerenosti cilju. Međutim, u skladu s istraživanjem Nguyen *et al.* (2017) Modelom 1a potvrđena je pozitivna povezanost tih karakteristika s

kontrolerovim utjecajem na donošenje odluka. Model 1a, kao i Model 1, podrazumijevao je testiranje modela sa stajališta kontrolera. Model 2, uzimajući u obzir percepciju menadžera po pitanju karakteristika kontrolera, kvalitete njihovih outputa i utjecaja na donošenje odluka, potvrđuje sve veze Modela 1a, izuzev povezanosti karakteristika okruženja s kvalitetom kontrolerovog outputa. Sukladno, Model 2a podrazumijeva isključenje visoko-rednog konstrukta karakteristika okruženja, odnosno potvrdu povezanosti karakteristika kontrolera i poduzeća s kvalitetom kontrolerovog outputa i karakteristika menadžera s kontrolerovim utjecajem na donošenje odluka. U prvom modelu tj. Modelu 1 i 1a, kao značajna kontrolna varijabla kontrolerovog utjecaja na odlučivanje, dokazala se varijabla godine radnog iskustava kontrolera u kontrolingu. Način organizacije kontrolinga jedino se potvrdio kao značajna kontrolna varijabla u Modelu 1. Osim toga, Model 1 i 1a te Model 2a potvrdili su jaku out-of-sample predikcijsku moć što upućuje na mogućnost i adekvatnost njegovog testiranja na drugim uzorcima, a temeljem usporedbe PLSpredict analiza zaključeno je da je najpouzdaniji model Model 2a koji pored kontrolera uključe i menadžere kao grupu ispitanika.

Dakle, provedenim empirijskim istraživanjem potvrđeno je da kontroler kao proaktivan, analitičan, komunikativan, kreativan i asertivan poslovni partner utječe na donošenje poslovnih odluka kroz izradu i prezentaciju kvalitetnih analiza i izvještaja. Pri tome, stupanj utjecaja tj. uključenosti u procesu odlučivanja ovisi o razini menadžerskog uvažavanja kontrolera kao profesionalne i kvalificirane osobe, menadžerske volje za vođenjem i iniciranjem zaposlenika te usmjerenosti ka ciljevima i proaktivno upravljanju. Odnosno, razina kvalitete kontrolerovog outputa povezana je sa strateškom orijentiranosti poduzeća koja podrazumijeva postojanje misije, vizije, strateških planova i njihove transparentnosti. Povezana je s razinom formalizacije organizacijske strukture u vidu propisanih pravila, procedura, hijerarhijskih razina autorizacije te nadzora operacija, kao i kvalitetom informacijskog sustava (vremenom obrade podataka, dostupnosti i razine integriranosti podataka, prilagodljivosti i korisnosti) te primjeni digitalnih tehnologija tj. različitih uređaja i sredstava koji omogućavaju pokretanje novih poslovnih procesa, poboljšanje svakodnevnih operacija i ukupni napredak poduzeća. U pojedinom dijelu kvaliteta outputa također ovisi o uvjetima okruženja tj. intenzitetu konkurentnosti i razini tehnološke turbulentnosti koja omogućuje poboljšanje poslovnih procesa, kreiranje novih ideja, rast poduzeća te efikasniju upotrebu podataka u analizi i poslovnom odlučivanju. U svemu tome, najveću ulogu prije svega ima kontroler. Stoga je bitno da on bude sposoban objasniti značenje brojeva, razumjeti izvore problema i da je usmjeren na budućnost; da zna komunicirati ideje usmenim i

pismenim putem te da bude sposoban uspostaviti kontakt s drugim sugovornicima te prenijeti važnu poruku; da zna dati konstruktivne kritike, jasno izraziti vlastita mišljenja uz istodobno prihvaćanje tuđih; da na poslovanje poduzeća gleda kroz proaktivni pristup tj. da se izravno suočava s problemima, da traga za boljim načinima rješavanja problema i da bude samoinicijativan u pretvaranju problema u poslovne prilike. Također, da kroz svoj rad zagovara i promiče vlastite kreativne ideje i ideje drugih i da pri tome pronalazi nove načine postizanja postavljenih ciljeva i ciljanih vrijednosti poduzeća. Pri tome, važno je i da prihvati značaj i ulogu poslovne inteligencije i analitike te da se tijekom radnog vijeka konstanto usavršava i time dodatno pridonosi značaju povezanosti razine radnog iskustva i sudjelovanja u poslovnom odlučivanju.

Sukladno rezultatima empirijskog istraživanja te saznanjima dobivenih uvidom kroz dubinsku analizu stručne i znanstvene literature u području kontrolinga i šire, proizlaze sljedeće preporuke za budući razvoj kontrolinga kao funkcije i profesije tj. kontrolera kao nositelja zadatka:

1. *Usmjeriti kontrolera ka razvoju „mekih" vještina.*
   Digitalizacija sve veći naglasak stavlja na „meke" vještine zaposlenika. Naravno, isto ne umanjuje značaj „tvrdih" vještina bez kojih zaposlenici u raznim područjima, uključujući kontrolingu, ne bi mogli izvršavati svakodnevne aktivnosti. Međutim, u digitalnom i automatiziranom svijetu, znatno se smanjuje potreba za usvajanjem određenih tehničkih vještina, što predstavlja sve manji izazov novim generacijama. Stoga se u doba u kojem strojevi mogu odrađivati sve veću razinu ljudskih poslova naglasak stavlja na osobne, socijalne i metodološke kompetencije koje omogućavaju razradu i razumijevanje podataka i informacija na način moguć jedino ljudskom biću. S aspekta uloge kontrolera kao sunositelja odgovornosti i poslovnog partnera menadžmentu, a u skladu s dobivenim rezultatima empirijskog istraživanja, kontroleri razvoj svojih budućih kompetencija moraju prvotno usmjeriti na sposobnost analitičkog razmišljanja, socijalne vještine komunikacije i asertivnosti, te vještine proaktivnog i kreativnog razmišljanja. Iako se dugo vremena smatralo da su navedene kompetencije „prirođene" osobine pojedinca, u današnje doba postoje brojne efikasne metode i edukacije koje omogućavaju otkrivanje ili poboljšanje tih osobina. Stoga bi se kontroleri pored uobičajenih edukacija usvajanja tehničkih vještina, kroz koje se naravno razvijaju i navedene „meke" vještine (npr. najviše analitičke, a najmanje

komunikacijske), u budućnosti trebali prigrliti edukacije usmjerene na razvoj osobnih i socijalnih vještina.

2. *Poticati i/ili održavati učinkovitu suradnju s menadžmentom*

   Suradnja kontrolera i menadžera, a time i razina kontrolerove uključenosti u poslovno odlučivanje, prvotno ovisi o želji i prihvaćenosti kontrolinga od strane menadžmenta. Ako ta prihvaćenost ne postoji, za pretpostaviti je da će kontroler imati izrazito malu ili nikakvu ulogu u procesu odlučivanja. Istraživanjem ove disertacije potvrđeno je da menadžeri koji prihvaćaju kontroling kao funkciju uključuju kontrolere u proces odlučivanja i time ostvaruju koristi za sebe i poslovanje kroz donošenje efikasnijih i bržih odluka temeljem dobivenih kvalitetnih outputa. Odnosno, potvrđeno je da menadžer kao vođa i inicijator utječe i na kontrolerovu razinu utjecaja na donošenje poslovnih odluka. Kako bi se održala tj. proširila potvrđena uloga kontrolera kao poslovnog partnera, preporuka budućeg razvoja ogleda se u uključivanju menadžera u svijet kontrolinga. Odnosno, kontroleri koji imaju dobar poslovni odnos i koji dobivaju povratne informacije od menadžera, ali i oni koji smatraju da se taj odnos zbog prisutnosti želje druge strane može nadograditi i poboljšati, trebali bi svoje menadžere uključivati tj. upoznavati s trendovima u kontrolingu, kroz edukaciju, stručnu literaturu, usporedbu s drugim poduzećima, konferencije, itd.

3. *Aktivno uključiti kontrolere u strateško orijentaciju poduzeća, implementaciju i način unaprjeđenja organizacijske strukture te postojećih informacijskih sustava i drugih digitalnih tehnologija.*

   Karakteristike poduzeća u vidu poslovne strategije, razine formalizacije, kvalitete informacijskog sustava i spremnosti primjene digitalnih tehnologija dokazale su se kao značajni faktori kvalitete kontrolerovih outputa. Sukladno tome, kontroleri bi trebali biti aktivno uključeni u određivanje strateške orijentiranosti poduzeća, njene misije, vizije, ciljeva i strategije poduzeća, ali i u razradi administrativnih mehanizama formalizacije kao što su pravila i procedure, razine autorizacije, zadaci i odgovornosti. Njihova uloga bi bila uspješnija da su uključeni u ocjenjivanje i davanje prijedloga za unaprjeđivanje postojećih informacijskih sustava kao i prijedloga implementacije novih sustava zasnovanih na digitalnoj tehnologiji koji omogućuju pokretanje novih i unaprjeđenje postojećih poslovnih procesa. Tako na primjer, ako postoji pravilo toka informacija koje na neadekvatan način prikuplja i strukturira podatke, kontroler će kao

glavni korisnik svih internih podataka kroz upotrebu informacijskog sustava, biti najpouzdanija osoba za određivanje razloga neadekvatnosti i davanja prijedloga za njegovo rješavanje. Naravno, u suradnji s drugim odjelima na koje se promjene odnose i informatičara kao tehničke potpore.

4. *Veću pažnju posvetiti praćenju promjena u okruženju, s naglaskom na konkurente i promjene tehničkih mogućnosti.*

   Iako se istraživanjem došlo do saznanja da kontroleri menadžerima kroz izvještaje dostavljaju različite nefinancijske podatke i podatke koji se odnose na buduće događaje, kao najmanje zastupljene potvrdile su se informacije o čimbenicima izvan poduzeća. S obzirom na to da je kroz konceptualni model potvrđena značajnost okruženja tj. konkurentnosti i tehnološke turbulentnosti, kontroleri bi u budućnosti sukladno potrebama prediktivne i preskriptivne analitike, trebali veću pažnju posvetiti vanjskim čimbenicima poslovanja. Vanjski čimbenici u današnjem brzorastućem okruženju predstavljaju ključ opstanka i ostvarenja konkurentske prednosti. Stoga se kontroleri prije svega trebaju usmjeriti na analizu konkurenata kroz npr. češću primjenu benchmarking analize, ali i praćenje razine promjena i utjecaja tehnoloških inovacija na poduzeće, granu u kojoj posluje i samu funkciju kontrolinga u vidu mogućnosti koje tehnologije pružaju u području efikasnije upotrebe podataka u analizi i odlučivanju.

5. *Kontinuiranim usavršavanjem osposobljavati kontrolere u području poslovne inteligencije.*

   Iako se u istraživanju ove disertacije poslovna inteligencija nije potvrdila kao značajan faktor efektivnosti rada kontrolinga, sukladno dobivenim mišljenjima kontrolera o njenoj korisnosti i potrebi šire primjene, može se zaključiti da će primjena takvih alata biti neizostavna u obavljanju kontrolerskih poslova, ako već i nije. Isto podržavaju i mišljenja brojnih stručnjaka koji se mogu pronaći u stručnoj literaturi u području kontrolinga, ali i trenutni trendovi koji su vidljivi kroz sve veću tržišnu ponudu edukacija poslovne inteligencije. Stoga se kontroleri moraju konstantno usavršavati kroz primjene alata poslovne inteligencije te poticati vlastito poduzeće na njihovu implementaciju i nadogradnju.

6. *Poticati daljnja istraživanja uloge i značaja kontrolinga u poslovnom odlučivanju*. Opće je prihvaćeno da kontroling u današnjem vremenu brzih promjena i generiranja velike količine podataka i informacija predstavlja jednu od najznačajnijih funkcija poslovnog odlučivanja. Iako postoje znanstvena istraživanja u području kontrolinga tj. njegovog značaja u procesu odlučivanja, ona su još uvijek oskudna, a osobitu na području RH. Naravno, stručna literatura može pružiti uvid u trenutne trendove i stanja pojedinih poduzeća tj. odjela kontrolinga i očekivanja koja se stavljaju pred kontrolere. Međutim, jedini pravi način potvrđivanja i generaliziranja utjecajnih povezanosti među pojavama određene populacije ostvariva je kroz empirijska istraživanja tj. uključivanje većeg broj ispitanika te analizu prikupljenih podataka putem adekvatnih statističkih metoda. Stoga se kao preporuka budućeg razvoja kontrolinga naglasak stavlja i na povećanje broja empirijskih istraživanja u području rada i uloge kontrolinga kao poslovnog partnera menadžmentu.

Uzimanjem u obzir svih navedenih preporuka, njihovom provedbom i proširenjem u smislu aplikacije kroz npr. razvoj edukativnih programa namijenjenih kontrolerima i menadžerima, kontroling će zasigurno osigurati svoj budući razvoj kao funkcija i profesija. Odnosno, prihvaćanjem proaktivne uloge savjetnika odlučivanja osigurat će se neupitnost kontrolerske uloge u upravljačkoj strukturi poduzeća i njegovog opstanka bez obzira na pojavu novih radnih mjesta poput podatkovnog znanstvenika. Da bi se to ostvarilo, kontroleri moraju neprekidno ulagati u razvoj svojih „mekih“, ali i „tvrdih“ vještina koje ima u današnjem digitalnom dobu predstavljaju jedino osiguranje značaja i održivosti kontrolinga u poslovanju poduzeću, ali i šire.

5.4. Doprinos empirijskog istraživanja

Iako je Sathe (1982) postavio karakteristike kontrolera kao jedan od osnovnih faktora koji utječu na kontrolerovu uključenost u poslovnom odlučivanju istu nije primijenio u vlastitom istraživanju. Osim toga, za karakteristike menadžera te karakteristike poduzeća i okruženja koristio je druga obilježja u odnosu na ona koja su korištena u modelu ove doktorske disertacije. Weißenberger i Angelkort (2011) tj. Weißenberger *et al.*, (2012), od kojih je preuzet dio modela utjecaja kvalitete kontrolerovog outputa na kontrolerov utjecaj na donošenje odluka, istraživali su utjecaj samo jedne odrednice karakteristike poduzeća na kvalitetu kontrolerovih outputa, a to je integriranost informacijskog sustava (MAS). Osim

toga, navedeno istraživanje mjeri kvalitetu kontrolerovih outputa kroz modificirani mjeritelj postavljen od strane Bauer (2002) dok se u modelu ove disertacije navedeni mjeritelj proširuje s pojedinim česticama mjerne ljestvice Wixom i Todd (2005). Odnosno, dok se utjecaj kontrolinga na odlučivanje u istraživanju Weißenberger i Angelkort (2011) mjeri pomoću tri čestice Spillecke (2006), u ovom istraživanju navedeni mjeritelj modificiran je kroz dvije dodatne čestice prema Nitzl i Hirsch (2016) te Wolf *et al.* (2015). Dakle, iako postoji od prije postavljen koncept utjecajnih karakteristika uključenosti kontrolinga u poslovnom odlučivanju te je kroz istraživanja dokazan utjecaj pojedinih odrednica tih karakteristika na kvalitetu outputa i kontrolerov utjecaj na donošenje odluka, do sada nije istražen i ispitan ovakav model koji uzima u obzir pojedine karakteristike kao visoko-redne konstrukte kroz postavljenu kombinaciju pojedinih karakteristika mjerenih validnim prethodno korištenim mjernim ljestvicama. Osim toga, izuzev istraživanja koje su proveli Fadhilah *et al.* (2015), istraživanja koja su dokazala povezanost „mekih" vještina kontrolera s njegovim aktivnostima u vidu poslovnog partnera menadžmentu također nisu pronađena. Odnosno, za razliku od istraživanja ove disertacije istraživanje Fadhilah *et al.* (2015) potvrdilo je utjecaj kontrolerovih karakteristika na zadovoljstvo korisnika outputa te posljedično utjecaja na neto korist samih korisnika (tj. menadžera) u vidu učinkovitijeg svakodnevnog rada, donošenja boljih i preciznijih odluka te bržeg odlučivanja.

U metodološkom smislu doprinos je ostvaren kroz razvoj novog modela povezanosti karakteristika kontrolera, menadžera, poduzeća i okruženja, s kvalitetom kontrolerovog outputa i njihovog utjecaja na donošenje odluka. Odnosno, potvrdom valjanosti i pouzdanosti modela doprinijelo se razvoju znanstvene misli o postojanju značajne veze između povezujućih karakteristika i kvalitete kontrolerovog outputa na donošenje poslovnih odluka u brzo rastućem digitalnom okruženju. Osim toga, doprinos se ogleda u rijetko korištenoj, a sve zastupljenijoj, multivarijatnoj statističkoj metodi PLS-SEM, čija primjena u području kontrolinga značajno zaostaje, ali i sve više naglašava (Nitzl, 2016, 2018). Odnosno, čija primjena u području istraživanjima kontrolinga u RH nije utvrđena.

U aplikativnom smislu, doprinos ove disertacije jest u činjenici da model nije samo potvrdio značajnu povezanost postavljenih karakteristika i utjecaj na efektivnost kontrolinga, koja se ogleda u povezanosti kvalitete kontrolerovog outputa i njegov utjecaj na donošenje odluka, već je potvrdio i njegovu out-of-sample predikcijsku moć. Stoga se navedeni model može testirati i na drugim uzorcima, a prije svega na državama Europske Unije koje primjenjuju

europski sustav kontrolinga (npr. Njemačka i Austrija, Slovenija, itd.). Daljnja testiranja modela također mogu biti provedena sukladno nekim drugim kriterijima kao npr. veličini poduzeća, industriji, vlasništvu poduzeća, načinu organizacije kontrolinga, itd. Pri tome se kao kriterij načina organizacije može razmatrati da li poduzeće ima centralizirani kontroling unutar iste države ili van nje. Nadalje, model bi se mogao primijeniti unutar organizacija u svrhu ocjene efektivnosti rada odjela kontrolinga, odnosno za ocjenu odnosa i suradnje te razine potrebnih vještina kontrolera i menadžera. U jednom dijelu, primjena se može ostvariti i kao evaluacijski instrument pri zapošljavanju kadrova u odjelu kontrolinga ili može biti podloga za kreiranje i unapređenje studijskog programa kontroling. U aplikativnom smislu, istraživanje je potvrdilo potrebu kontrolinga u procesu donošenja poslovnih odluka, kroz povezanost uzajamno utjecajnih karakteristika kontrolera i menadžera te poduzeća i okruženja na kvalitetu kontrolerovog outputa. Odnosno, potvrdilo je potrebu za jačanjem veza između kontrolera i menadžera. Iako istraživanjem nije dokazano, uvidom u dopunske analize empirijskog istraživanja uviđa se potreba za većom primjenom digitalnih tehnologiju, a posebno primljene poslovne inteligencije. Istraživanje je također potvrdilo da radno iskustvo kontrolera u području kontrolinga utječe na efektivnost kontrolinga, što ukazuje na značaj i specifičnost tog zanimanja i buduću mogućnost njegovog postavljanja kao profesije. Stoga se u aplikativnom smislu, doprinos ovog rada ogleda i u preporukama za budući razvoj kontrolinga kao funkcije i profesije te kontrolera kao nositelja zadatka.

U teorijskom smislu doprinos se ogleda u primjeni PLS-SEM metode, tj. doprinosu istraživanja koje primjenjuje i procjenjuje hijerarhijsko komponentni model, čija primjena kao naprednog PLS-SEM modela je još uvijek nedovoljno zastupljena u znanstvenoj literaturu. Sukladno Sathe (1982) te Weißenberger i Angelkort (2011) i ovo istraživanje također doprinosi razvoju tri teorije:

- psihološkoj teoriji (engl. psychological theory) za karakteristike kontrolera i menadžera,
- teoriji kontingencije (engl. contingency theory) za karakteristike poduzeća i okruženja,
- teoriji racionalnog izbora (engl. rational choice theory) za odnos kvalitete kontrolerovog outputa i njegovog utjecaja na donošenje odluka.

Doprinos ekonomskoj znanosti u teorijskom smislu ogleda se u razvoju spoznaje o važnosti utjecaja kontrolinga na upravljanje i poslovno odlučivanje te potrebu za njenim daljnjim istraživanjem.

5.5. Ograničenja i implikacije budućih empirijskih istraživanja

Premda se na najbolji način nastojala osigurati kvaliteta empirijskog istraživanja ove doktorske disertacije, kao i sva druga istraživanja, i ovo ima ograničenja koja treba uzeti u obzir pri generalizaciji rezultata tj. budućim istraživanjima zasnovanih na konceptualnom modelu prikazane disertacije.

Iako se ovo istraživanje bavi važnim pitanjima koja imaju praktične implikacije i značajnu vrijednost za područje kontrolinga i menadžmenta, činjenica jest da je istraživanje ograničeno na uzorak jedne države. Odnosno, iako je uzorak potvrđen kao reprezentativan te je zadovoljio uvjete minimalne veličine PLS-SEM metode kroz tri vrste testa, testiranje modela, osobito u pogledu drugog modela istraživanja temeljenog na „dyadic" metodi, zasigurno bi bilo vjerodostojnije kroz primjenu većeg uzorka. Prvotno kroz povećanje uzorka iste države tj. RH, a potom uključivanjem ispitanika drugih zemalja koje kontroling smatraju bitnom funkcijom poduzeća (npr. Njemačka i Austrija, te Italija, Švicarska, Rumunjska, Slovenija, Nizozemska, itd.). Buduće studije u različitim poslovnim i kulturnim okruženjima potrebne su kako bi se poboljšali teorijski i praktični doprinosi rezultata i zaključaka ove studije.

Nadalje, istraživanje je obuhvatilo samo kontrolere i menadžere koji su dobrovoljno sudjelovati u istraživanju te se stoga može pretpostaviti da su anketu ispunili oni kontroleri i menadžeri koji zaista izvršavaju i shvaćaju ulogu te značaj kontrolera unutar poduzeća. Osim toga, u istraživanju su sudjelovali kontroleri i menadžeri različitih organizacijskih razina. Kao preporuka budućim istraživanjima, ako to dopušta veličina uzorka, predlaže se uključivanje isključivo voditelja odjela kontrolinga i njihovih nadređenih. Nadalje, iako se ne može navesti kao nedostatak, u istraživanju su sudjelovali ispitanici iz poduzeća različitih veličina i grana. Konceptualni model bilo bi korisno testirati na uzorcima zasebnih djelatnosti i/ili s obzirom na različitu organizaciju kontrolinga - centraliziranu ili decentraliziranu.

Kao nedostatak istraživanja može se navesti i dužina anketnog upitnika. Iako se prilikom izrade ankete pokušalo minimizirati broj pitanja te je smanjena mogućnost prikupljanja iskrivljenih podataka kroz podjelu kontrolerove ankete u dva dijela, preporuka za buduća istraživanje jest dodano smanjenje opsega upitnika. Odnosno, predlaže se izbacivanje ili zamjena konstrukta rizik kao dijela karakteristika okruženja te se predlaže testiranje modele uz uvjet ocjene karakteristika kruženja od strane menadžmenta. Osim toga, iako se tretira kao metodološki pristup, način specifikacije visoko-rednih konstrukata može se smatrati i

nedostatkom ovog istraživanja. Naime, pojedini elementi četiri visoko-redna konstrukta proizašli su iz dubinske analize stručne i znanstvene literature. Buduća istraživanja mogla bi se usmjeriti na ispitivanje adekvatnosti postavljenih karakteristika i potrebe za modifikacijom i/ili nadogradnjom kroz isti pristup, ali i kroz dodatna istraživanja pomoću metode rangiranja ili predlaganja karakteristika od strane samih kontrolera i menadžera. Odnosno, buduća istraživanja bi trebala razmotriti mogućnosti postojanja dodatnih utjecaja kao na primjer moderatorskog ili medijatorskog utjecaja stresa na vezu karakteristika kontrolera i kvalitete outputa ili povratne informacije (engl. feedback) na vezu kvalitete outputa i kontrolerovog utjecaja na donošenje poslovnih odluka. Također, bi mogla uzeti u obzir kvalitetu kontrolerovih outputa kao visoko-rednog konstrukta mjerenog kroz Wixom i Todd (2005) instrument ili mjeritelje MAS karakteristika koje su često primjenjivane u dosadašnjim istraživanjima u području kontrolinga.

Nadalje, u vidu testiranja pojedinih utjecaja tj. povezanosti latentnih varijabli, kao nedostatka se ističe način mjerenja utjecaja poslovne inteligencije. Naime, utjecaj BI-a na kvalitetu kontrolerovog outputa u modelu proveo je kroz postavljanje BI-a kao kontrolne varijable. Buduća istraživanja trebala bi proširiti taj dio modela kroz primjenu adekvatnog višedimenzionalnog konstrukta koji će mjeriti razinu njegove primjene na višoj dimenziji tj. kroz konkretne čestice njegove korisnosti za područje kontrolinga. Osim toga, buduća istraživanja bi se trebala usmjeriti na detaljniju analizu karakteristika pojedinih BI sustava kako bi se u vidu potreba kontrolinga mogle odrediti i unaprijediti one koje će omogućiti unaprjeđenje kvalitete kontrolerovih outputa.

Sukladno istaknutom nedostatku same PLS-SEM metode, kao dodatni nedostatak ovog istraživanja može se istaknuti nemogućnost testiranja kauzalnih, povratnih veza, kao na primjer, povratne veze kontrolerove uključenosti u odnošenju poslovnih odluka na kvalitetu kontrolerovih outputa.

Prikazana ograničenja ne umanjuju kvalitetu i značaj dobivenih rezultata i zaključaka, već bi trebala biti uzeta kao usmjerenja za daljnja izučavanja i unaprjeđenja postavljenog i testiranog konceptualnog modela.

6. ZAKLJUČAK

Današnje digitalno okruženje omogućuje tvrtkama da koriste velike količine podataka, ali ih također prisiljava da pronalaze metode, tehnologije i znanja koja omogućuju da se ti podaci prikupe, strukturiraju i analiziraju na način prikladan i koristan za efikasno i efektivno poslovno odlučivanje. Zbog velikog broja raznolikih podataka, konkurentska prednost i uspjeh tvrtki više nego ikad ovisi o kvaliteti podataka i informacija koje se koriste u donošenju poslovnih odluka. Stoga su onima koji donose odluke potrebne metode i vještine koje omogućuju pretvaranje podataka i informacija u znanje i koje je temelj uspješnog poslovanja. Kontroling, kao jedna od priznatih funkcija koja doprinosi ne samo učinkovitom donošenju odluka, već i ukupnom radu poduzeća, upravo je ona koja pomaže u rastu i razvoju poduzeću u brzo mijenjajućem okruženju. Kao informacijska i savjetodavna funkcija prvenstveno je usmjeren na analitičku obradu podataka i informacija za donošenje poslovnih odluka, kroz koje pomaže menadžmentu u ostvarenju postavljenih ciljeva i prilagođavanju poduzeća unutarnjim i vanjskim utjecajima. Kontroler, kao nositelj aktivnosti kontrolinga, danas predstavlja polovnog partnera menadžmentu, koji svojim vještinama, znanjem i iskustvom pridonosi efikasnosti i efektivnosti poslovnog odlučivanja. Kako bi isto mogao realizirati, kontroler mora prvotno biti sposoban donositeljima odluka pružati kvalitetne informacije, analize, izvještaje, prijedloge, zaključke tj. outpute, bilo usmenim ili pismenim putem. Odnosno, kontroler mora posjedovati vještine koje će omogućiti izradu kvalitetnih outputa, ali mora biti svjestan i karakteristika poduzeća i okruženja te drugih digitalnih i socio-demografskih obilježja koja pridonose učinkovitom radu kontrolinga. Naravno, pri tome ključnu ulogu ima i kontrolerova povezanost s menadžmentom tj. prihvaćenost kontrolera kao poslovnog partnera te spoznaji korisnosti kontrolinga.

Sukladno navedenom, fokus ovog istraživanja bila je analiza i mogući razvoj kontrolinga kao potpore funkcije upravljanju, odnosno kontrolera kao njenog nositelja. Osnovna svrha bila je definirati i potvrditi utjecajne karakteristike koje u digitalnim uvjetima određuju efikasnost rada kontrolera i njegov utjecaj na donošenje odluka, te ujedno dokazati važnost kontrolinga kao potpore menadžmentu. Iz toga je proizašao i osnovni cilj rada, a to je razvoj modela za potvrdu povezanosti karakteristika kontrolera, menadžera, poduzeća i okruženja s kvalitetom kontrolerovog outputa. Odnosno, potvrda činjenice da u uvjetima digitalizacije kvaliteta kontrolerovog outputa ima značajnu povezanost s kontrolerovim utjecajem na donošenje poslovnih odluka.

Kako bi se ostvario osnovni cilj rada, dubinskom analizom stručne i znanstvene literature te postojećim saznanjima iz prakse kontrolinga, postavljen je konceptualni model utjecaja kvalitete kontrolinga na poslovno odlučivanje. Znanstveno utemeljeno, određeno je pet karakteristika kontrolera (analitičnost, komunikativnost, asertivnost, proaktivnost i kreativnost), tri karakteristike menadžera (vođa i inicijator, uvažavanje kontrolera i proaktivan i cilju usmjeren), četiri karakteristike poduzeća (kvaliteta informacijskog sustava, organizacijska formalizacija, strateška orijentiranost i digitalne tehnologije) i tri karakteristike okruženja (intenzitet konkurentnosti, turbulentnost tehnologije i rizičnost). Sve navedene karakteristike teorijski su istražene da predstavljaju najznačajnije utjecajne čimbenike kvalitete kontrolerovih outputa. Pri tome se digitalizacija ogleda u vanjskim utjecajima dinamičnog rasta tehnologije i internih faktora kvalitete informacijskog sustava te usmjerenosti poduzeća ka digitalnoj transformaciji, ali i kroz analizu učinka primjene poslovne inteligencije kao kontrolne varijable. Kvaliteta kontrolerovog outputa definirana je kroz dimenzije ažurnosti, značajnosti, točnosti, pravodobnosti i preglednosti, dok je kontrolerov utjecaj na donošenje odluka određen razinom njegove uloge i uključenosti u poslovnom odlučivanju tj. utjecaju koji ima pri odabiru ispravne poslovne odluke te vrijednosti koju menadžeri daju kontrolerovim izvještajima i mišljenjima. Povezanost kvalitete kontrolerovog outputa i utjecaja na donošenja odluka testirana je i na kontrolne učinke ukupne dužine i dužine radnog iskustva kontrolera u praksi kontrolinga, postojanja interne revizije kao osiguravatelja točnosti internih podataka, organizacijskog oblika kontrolinga i vlasništva poduzeća u kojem rade. Dakle, modelom se htjelo potvrditi da u uvjetima digitalizacije postavljene karakteristike kontrolera, karakteristike menadžera, poduzeća i okruženja imaju značajan utjecaj na učinke kontrolerovih aktivnosti i doprinos u donošenju poslovnih odluka.

Radi testiranja modela kreiran je anketni upitnik. Pri tome su se koristile validne mjerne ljestvice dosadašnjih istraživanja, uz pojedine modifikacije. U izradi upitnike, sa svrhom provjere valjanosti sadržaja, razumijevanja i vremenskog trajanja, sudjelovala su četiri stručnjaka-kontrolera, odnosno sudjelovala je jedna osoba kvalificirana za osiguranje pravilnog prijevoda mjernih ljestvica sa stranih jezika. Po izradi prve verzije upitnika provedeno je pilot testiranje na manjem uzorku kontrolera, koje je potvrdilo pouzdanost, valjanost i značajnost modela te su ustanovljene potrebne manje modifikacije upitnika. Po izradi konačne verzije upitnika provedeno je empirijsko istraživanje na uzorku kontrolera i menadžera u Republici Hrvatskoj. S obzirom na to da je cilj rada bilo testiranje cjelokupnog

modela, prvotno sa stajališta kontrolera, a potom i uključivanjem mišljenja menadžera po pitanjima karakteristika kontrolera, kvalitete njegovog outputa i utjecaja na donošenje poslovnih odluka, istraživanje je uključilo dvije ankete - jednu za kontrolere i jednu za menadžere, s time da je zbog dužine ispunjavanja, anketa za kontrolere podijeljena u dva vremenski neovisna dijela. Sukladno tome, empirijsko istraživanje uključivalo je testiranje dva osnovna modela. Prvi model se temeljio na odgovorima kontrolera, a drugi na kombinaciji odgovora kontrolera i menadžera.

Empirijsko istraživanje potvrdilo je povezanost karakteristika kontrolera, poduzeća i okruženja s kvalitetom kontrolerovih outputa te povezanost kvalitete outputa s kontrolerovim utjecajem na donošenje poslovnih odluka. Iz modela, tj. visoko-rednog konstrukta okruženja, izbačena je karakteristika rizičnosti s obzirom na to da procjenom mjernog modela nije potvrđena valjanost i pouzdanost tog konstrukta. Valjanost i pouzdanost svih ostalih postavljenih karakteristika su potvrđene. Premda je bila postavljena u konceptualnom modelu, veza karakteristika menadžera s kvalitetom kontrolerovih outputa nije potvrđena. Međutim, potvrđeno je da su karakteristike menadžera značajno povezane s kontrolerovim utjecajem na donošenje poslovnih odluka. Točnije, potvrđen je da menadžer kao cilju usmjereni vođa i inicijator koji prihvaća kontrolera kao stručnu osobu ima pozitivan utjecaj na njegovu uključenost u odlučivanju. Uključenost podrazumijeva da se menadžer prije donošenja važni odluka konzultira sa kontrolerom, da mu kontroler pomaže u odabiru ispravne odluke i da menadžer pridaje visoku vrijednost mišljenju kontrolera. Navedeno je potvrđeno ispitivanjem modela sa stajališta samih kontrolera, ali i kroz uključivanje menadžera kroz ocjenjivanje karakteristika kontrolera, kvalitete njegovog outputa i utjecaja na donošenje odluka. Točnije, pri uključivanju menadžera tj. primjenom tzv. „dyadic“ istraživanja, nije jedino potvrđena veza između karakteristika okruženja i kontrolerovog utjecaja na donošenje odluka. Navedeno se može pripisati činjenici da su u oba modela kontroleri ocjenjivali karakteristike okruženju, a da bi se prikladniji podaci možda dobili uključivanjem stajališta menadžera, a što je navedeno i kao prijedlog budućim istraživanjima. U oba modela, kao najznačajnija karakteristika kontrolera pokazala se proaktivnost, a kod menadžera vođa i inicijator. Strateška orijentiranost potvrđena je kao najznačajnija karakteristika poduzeća, dok se u okruženju dokazao intenzitet konkurentnosti. Sa stajališta samih kontrolera, tj. prvim modelom, također je potvrđeno da dužina radnog iskustva kontrolera u području kontrolinga pridonosi kvaliteti kontrolerovih outputa i ulozi u poslovnom odlučivanju. Iako se primjena poslovne inteligencije, kao bitnog digitalnog alata današnjeg kontrolinga, nije dokazala kao

značajni kontrolni čimbenik kvalitete kontrolerovog outputa, sukladno dobivenim mišljenjima kontrolera o njenoj korisnosti i potrebi šire primjene, može se zaključiti da će primjena takvih alata u obavljanju kontrolerskih aktivnosti u budućnosti biti neizostavna. Osim toga, istraživanje je pokazalo da je kontroling danas, pored najčešćih aktivnosti kao što su npr. različite analize odstupanja, analize prihoda i troškova te planiranja, u većoj mjeri usmjeren na izvještavanje budućih događaja tj. prognoziranje i predviđanje. Pri tome, veliki značaj pridaje se Big Data koji omogućuje izradu učinkovitijih analiza, uštedu vremena za pronalaženje potrebnih podatka i njihove obrade te generiranje i analizu internih i eksternih podataka u svrhu poslovnog odlučivanja. Sukladno tome, pojedini kontroleri u svom svakodnevnom radu primjenjuju i alate poslovne analitike, kao što su prediktivni modeli i različite vrste regresije. Ostale kontrolne varijable, postojanje interne revizije, ukupno radno iskustvo kontrolera i vlasništvo poduzeća nisu se dokazale kao značajne. Odnosno, način organizacije kontrolinga (centraliziran/decentraliziran/kombiniran), potvrdio se kao značajan čimbenik utjecaja kontrolera na poslovno odlučivanje jedino u prvom modelu ispitivanja. Osim toga, iako su oba modela potvrdila nisku i umjerenu razinu eksploratorne moći, oba modela potvrđuju veliku prediktivnu moć tj. mogućnost testiranja na drugim uzorcima.

Sukladno rezultatima empirijskog istraživanja te saznanjima dobivenim uvidom u stručnu i znanstvenu literaturu u području kontrolinga i šire, proizašle su preporuke za budući razvoj kontrolinga kao funkcije i profesije tj. kontrolera kao nositelja zadatka. Postavljeno je sljedećih šest preporuka, čijom provedbom i aplikacijom kontroleri mogu napraviti prvi korak ka budućem razvoju kao profesije:

1. Usmjeriti kontrolera ka razvoju „mekih“ vještina.
2. Poticati i/ili održavati učinkovitu suradnju s menadžmentom
3. Aktivno uključiti kontrolere u stratešku orijentaciju poduzeća, implementaciju i način unaprjeđenja organizacijske strukture te postojećih informacijskih sustava i drugih digitalnih tehnologija.
4. Veću pažnju posvetiti praćenju promjena u okruženju, s naglaskom na konkurente i promjene tehničkih mogućnosti.
5. Kontinuiranim usavršavanjem osposobljavati kontrolere u području poslovne inteligencije.
6. Poticati daljnja istraživanja uloge i značaja kontrolinga u poslovnom odlučivanju.

Iako u literaturi postoji od prije postavljen koncept utjecajnih karakteristika uključenosti kontrolinga u poslovnom odlučivanju te je kroz više istraživanja dokazan utjecaj pojedinih odrednica tih karakteristika na kvalitetu kontrolinga i njegovog utjecaja na donošenje odluka, prema saznanjima iz relevantne literature, model kakav je postavljen u ovoj disertaciji do sada nije objavljen niti istražen, te može predstavljati osnovu za buduća istraživanja. Osnovi doprinos ove disertacije u metodološkom smislu ostvaren je kroz razvoj i potvrdu modela povezanosti karakteristika kontrolera, menadžera, poduzeća i okruženja s kvalitetom kontrolerovog outputa i njihovog utjecaja na donošenje odluka. Doprinos se također ogleda u primjeni multivarijatne statističke metode PLS-SEM, koja dobiva na sve većem značaju u znanstvenoj literaturi. U aplikativnom smislu, doprinos je ostvaren kroz potvrdu značajnosti samog modela tj. postavljenih veza modela. Odnosno, istraživanje je potvrdilo potrebu kontrolinga u procesu donošenja poslovnih odluka te potrebu za jačanjem veza između kontrolera i menadžera. Osim toga, empirijski rezultati potvrdili su out-of-sample predikcijsku moć postavljenog modela, što upućuje na mogućnost njegovog testiranja na drugim uzorcima tj. državama, ali i mogućnost primijeniti unutar organizacija u npr. svrhu ocjene efektivnosti rada odjela kontrolinga, tj. ocjene odnosa i suradnje te razine potrebnih vještina kontrolera i menadžera. Model, također, može biti podloga za kreiranje i unapređenje studijskog programa kontroling, a u jednom dijelu se može primijeniti i kao evaluacijski instrument pri zapošljavanju kadrova u odjelu kontrolinga. Iako istraživanjem nije dokazano, uvidom u dopunsku analizu, utvrđena je potreba za većom primjenom digitalnih tehnologija, a posebno primjene poslovne inteligencije, te značaja uloge Big data i poslovne analitike. Nadalje, istraživanje je potvrdilo da radno iskustvo kontrolera u području kontrolinga utječe na efektivnost rada kontrolera, što ukazuje na značaj i specifičnost tog zanimanja i buduću mogućnost njegovog postavljanja kao profesije. Stoga se u aplikativnom smislu doprinos ovog rada ogleda i u danim preporukama za budući razvoj kontrolinga kao funkcije i profesije. Doprinos ekonomskoj znanosti u teorijskom smislu ogleda se u razvoju spoznaje o važnosti utjecaja kontrolinga na upravljanje i poslovno odlučivanje te potrebu za njenim daljnjim istraživanjem. U teorijskom smislu doprinos predstavlja primjenu tj. kreiranje rada temeljenog na hijerarhijsko komponentnom modelu, koji predstavlja napredni oblik PLS-SEM analize te još nije dovoljno zastupljen u literaturi. Odnosno, model pridonosi razvoju tri teorije: psihološkoj teoriji, teoriji kontingencije i teoriji racionalnog izbora. Psihološkoj teoriji se pridonosi kroz potvrdu učinka „mekih“ tj. osobnih vještina kontrolera i menadžera, kontingencijskoj kroz potvrdu značaja karakteristika poduzeća i okruženja u poslovnom

odlučivanju, a teoriji racionalnog izbora kroz potvrdu povezanosti kvalitete kontrolerovog outputa i kontrolerovog utjecaja na donošenje odluka.

Ograničenja provedenog istraživanja prvenstveno se odnose na uzorak istraživanja. Naime, istraživanje je provedeno na uzorku jedne države tj. Republike Hrvatske te je obuhvatilo samo kontrolere i menadžere koji su dobrovoljno sudjelovati u istraživanju. Stoga se može pretpostaviti da su anketu ispunili oni kontroleri i menadžeri koji u Hrvatskoj zaista izvršavaju i shvaćaju ulogu te značaj kontrolera unutar poduzeća. Odnosno, uzorak se sastojao od poduzeća različitih veličina, djelatnosti, organizacijskih oblika i razina kontrolinga tj. kontrolera. Kao nedostatak istraživanja može se navesti i dužina anketnog upitnika, način mjerenja uloge poslovne inteligencije te nemogućnost testiranja povratnih veza među varijablama modela. Sukladno tome, daljnja istraživanja trebala bi prvenstveno testirati model na drugim uzorcima tj. državama. Pri tome, valjalo bi primijeniti pojedine kriterije odabira uzorka kao što su npr. veličini poduzeća, industrija, organizacija kontrolinga ili pozicija kontrolera (npr. voditelj kontrolinga). Dakle, za buduća istraživanja predlaže se primjena dodatnih varijabli za testiranje uloge i značaj digitalnih tehnologija, a osobito poslovne inteligencije, ali i proširenje modela kroz dopunu ili zamjenu definiranih karakteristika kontrolera, menadžera, poduzeća i okruženja. Time bi se dobio uvid u valjanost i pouzdanost modela u različitim poslovnim i kulturnim okruženjima, ali bi se možda došlo i do spoznaja načina njegovog poboljšanja.

Jedino posjedovanjem i primjenom potrebnih kompetencija kontrolera, kontroling može postati neizostavna profesija unutar poduzeća. Jedino poznavanjem karakteristika poduzeća i okruženja koje mogu utjecati na efikasnost i efektivnost kontrolinga, kontroleri mogu pridonijeti razvoju istih te unaprijediti svoje aktivnosti u cilju potpore menadžmentu u procesu donošenja odluka. Kontroling koji bude sposoban odgovoriti na sve zahtjeve koje pred njega stavlja digitalizacija i globalizacija, moći će pridonijeti uspješnom upravljanju poduzećem i postati adekvatan partner donosiocima odluka. Samo kontroleri koji budu usavršavali svoja znanja i vještine sukladno izazovima koje donosi digitalno doba, osigurat će svoju budućnost i nemogućnost da ih jednog dana zamijeni neki novi „superjob“ kao što se danas vidi posao podatkovnog znanstvenika. Naravno, pri tome značajnu ulogu imat će različite karakteristike menadžera, a prvenstveno njegovo prihvaćanje kontrolinga kao funkcije. Stoga je bitno izučavati i unaprjeđivati utjecajne karakteristike o kojima ovisi kvaliteta kontrolerovih outputa i njegova uključenost u poslovno odlučivanje, što je i bila svrha ove doktorske disertacije.

LITERATURA

[1] Abbasi, S., Zamani, M., Valmohammadi, C. (2014). The effects of ERP systems implementation on management accounting in iranian organizations. *Education, Business and Society: Contemporary Middle Eastern Issues*, *7*(4), 245–256. doi: https://doi.org/10.1108/EBS-03-2014-0020

[2] Abdul Hamid, S. F., Zainuddin, Z. N., Sulaiman, S. (2016). Competences level and its perceived importance: a case study in malaysian companies. *Asia-Pacific Management Accounting Journal*, *11*(2), 223–246. Dostupno na: http://ir.uitm.edu.my/id/eprint/29981/1/29981.pdf

[3] Agbejule, A. (2005). The relationship between management accounting systems and perceived environmental uncertainty on managerial performance: a research note. *Accounting and Business Research ISSN:*, *35*(4), 295–305. doi: https://doi.org/10.1080/00014788.2005.9729996

[4] Ahmad, K., Zabri, S. M. (2015). Factors explaining the use of management accounting practices in Malaysian medium-sized firms. *Journal of Small Business and Enterprise Development*, *22*(4), 762–781. doi: https://doi.org/10.1108/JSBED-04-2012-0057

[5] Ahmad, M. A., Al-Shbiel, S. O. (2019). The effect of ethical leadership on management accountants ' performance: The mediating role of psychological well-being. *Problems and Perspectives in Management*, *17*(2), 228–241. doi: https://doi.org/10.21511/ppm.17(2).2019.17

[6] Ahmetoglu, G., Scarlett, L., Codreanu, S. C., Chamorro-Premuzic, T. (2019). The impact of organizational structure and work autonomy in fostering entrepreneurial tendencies and job performance. *Evidence-Based HRM*, *8*(1), 128–143. doi: https://doi.org/10.1108/EBHRM-11-2018-0070

[7] Al-Htaybat, K., Alberti-Alhtaybat, L. Von. (2017). Big Data and corporate reporting: impacts and paradoxes. *Accounting, Auditing & Accountability Journal*, *30*(4), 850–873. doi: https://doi.org/10.1108/AAAJ-07-2015-2139

[8] Albu, N., Albu, C. N. (2012). Factors Associated with the Adoption and Use of Management Accounting Techniques in Developing Countries: The Case of Romania. *Journal of International Financial Management & Accounting*, *23:3*(July), 14–17. doi: https://doi.org/10.1111/jifm.12002

[9] Alexander, S., Haisermann, A., Schabicki, T., Frank, S. (2018). Robotic Process Automation (RPA) im Rechnungswesen und Controlling - welche Chancen ergeben sich? *Controlling*, *3*, 11–19. doi: https://doi.org/10.15358/0935-0381-2018-3-11

[10] Alge, B., Ballinger, G., Tangirala, S., Oakley, J. (2006). Information privacy in organizations: empowering creative and extrarole performance. *Journal of Applied Psychology*, *9*(1), 221–321. doi: https://doi.org/10.1037/0021-9010.91.1.221

[11] Ali, Z., Sun, H., Ali, M. (2017). The impact of managerial and adaptive capabilities to stimulate organizational innovation in SMEs: A complementary PLS-SEM approach. *Sustainability (Switzerland)*, *9*(12), 1–23. doi: https://doi.org/10.3390/su9122157

[12] Anggadini, S. D. (2014). The Effect of Top Management Support and Internal Control of the Accounting Information Systems Quality and Its Implications on the Accounting Information Quality. *Proceedings of 2nd International Conference on Economics and*

Social Sceinces (str. 22–29). Bangkok, Thailand: International Foundation for Research and Development (IFRD).

[13] Appelbaum, D., Kogan, A., Vasarhelyi, M., Yan, Z. (2017). Impact of business analytics and enterprise systems on managerial accounting. *International Journal of Accounting Information Systems*, *25*(March), 29–44. doi: https://doi.org/10.1016/j.accinf.2017.03.003

[14] Arockia Panimalar, S., Varnekha Shree, S., Veneshia Kathrine, A. (2017). The 17 V ' s Of Big Data. *International Research Journal of Engineering and Technology*, *4*(9), 329–333.

[15] Arshad, M. Z., Arshad, D. (2018). Intellectual Capital and SMEs Performance in Pakistan: The Role of Environmental Turbulence. *International Journal of Entrepreneurship*, *22*(1S).

[16] Asare, A. K., Brashear, T. G., Yang, J., Kang, J. (2013). The relationship between supplier development and firm performance: The mediating role of marketing process improvement. *Journal of Business and Industrial Marketing*, *28*(6), 523–532. doi: https://doi.org/10.1108/JBIM-04-2013-0100

[17] Astuty, W. (2015). An Analysis of the Effects on Application of Management Accounting Information Systems and Quality Management Accounting Information. *Information Management and Business Review*, *7*(3), 80–92. doi: https://doi.org/10.22610/imbr.v7i3.1156

[18] Bahtijarević-Šiber, F., Sikavica, P., Pološki Vokić, N. (2008). *Suvremeni menadžment*. Zagreb: Školska knjiga d.d.

[19] Baier, L., Bange, C., Bloemen, J., Derwisch, S., Engel, A., Fuchs, C., et al. (2020). *BARC Research Study: BI Trend Monitor 2020, The world's largest survey of BI trends*.

[20] Baines, A., Langfield-Smith, K. (2003). Antecedents to management accounting change: A structural equation approach. *Accounting, Organizations and Society*, *28*(7–8), 675–698. doi: https://doi.org/10.1016/S0361-3682(02)00102-2

[21] Bakker, A. B., Petrou, P., Op den Kamp, E. M., Tims, M. (2020). Proactive Vitality Management, Work Engagement, and Creativity: The Role of Goal Orientation. *Applied Psychology*, *69*(2), 351–378. doi: https://doi.org/10.1111/apps.12173

[22] Balent, B. (2018). Kako upravljati konfliktima? *Kontroling, Financije i Menadžment*, 5, 67–71.

[23] Bateman, T. S., Crant, J. M. (1993). The Proactive Component of Organizational Behavior: A Measure and Correlates. *Journal of Organizational Behavior*, *14*, 103–118.

[24] Bauer, M. (2002). *Controllership in Deutschland: zur erfolgreichen Zusammenarbeit von Controllern und Managern* (1. izdanje). Wiesbaden: Deutscher Universitäts-Verlag GmbH. doi: https://doi.org/10.1007/978-3-322-90394-5

[25] Becker, J.-M., Klein, K., Wetzels, M. (2012). Hierarchical Latent Variable Models in PLS-SEM: Guidelines for Using Reflective-Formative Type Models. *Long Range Planning*, *45*(5–6), 359–394. doi: https://doi.org/10.1016/j.lrp.2012.10.001

[26] Becker, J.-M., Ringle, C. M., Sarstedt, M. (2019). PLS-SEM Using SmartPLS 3: Foundations and Advaned Issues; Workshop materials, Comprehensive Partial Least Squares Strucutral Ecquation Modeling (PLS-SEM) Seminar using SmartPLS3, Hamburg, November 20-23, 2019. Hamburg: Northern Institute of Technology Management & SmartPLS.

[27] Bhardwaj, A., Punia, B. K. (2013). Managerial competencies and their influence on

managerial performance: A literature review introduction. *International Journal of Advanced Research in Management and Social Sciences*, *2*(5), 70–84. Dostupno na: http://garph.co.uk/IJARMSS/May2013/6.pdf

[28] Bhimani, A., Willcocks, L. (2014). Digitisation , 'Big Data' and the transformation of accounting information. *Accounting and Business Research*, *44*(4), 469–490. doi: https://doi.org/10.1080/00014788.2014.910051

[29] Bilandžić, M., Lucić, D. (2018). BUSINESS INTELLIGENCE U HRVATSKOM GOSPODARSTVU – REZULTATI ISTRAŽIVANJA 2017. *Poslovna Izvrsnost Zagreb*, *7*(1), 9–31. doi: https://doi.org/10.22598/pi-be/2018.12.1. 9

[30] Brennan, D. (n.d.). Does the style of management affect the way staff members carry out their work ?

[31] Breuer, A., Frumuşanu, M. L., Manciu, A. (2013). The role of management accounting in the decision making process: Case study Caraş Severin county. *Annales Universitatis Apulensis Series Oeconomica*, *15*(2), 355–366. Dostupno na: http://www.oeconomica.uab.ro/upload/lucrari/1520132/01.pdf

[32] Brewer, T., Knight, D., Noiray, G., Naik, H. (2019). Digital Twin Technology in the Field Reclaims Offshore Resources. *Offshore Technology Conference*. Houston, Texas, USA, 6-9 May.

[33] Brynjolfsson, E., McAfee, A. (2012). Big data: The management revolution. *Harvard Business Review*, *90*(October 2012), 60–68.

[34] Bulog, I. (2016). The influence of top management demographic characteristics on decision making approaches. *Ekonomski Vjesnik*, *2*, 393–403.

[35] Burns, J., Baldvinsdottir, G. (2005). An institutional perspective of accountants' new roles–the interplay of contradictions and praxis. *European Accounting Review*, *14*(4), 725–757. doi: https://doi.org/10.1080/09638180500194171

[36] Burns, J., Warren, L., Oliveira, J., Burns, J. (2014). Business Partnering: Is It All That Good ? *Controlling & Management Review*, *58*, 36–41. doi: https://doi.org/https://doi.org/10.1365/s12176-014-0907-6

[37] Butterfield, E. (2016). *Managerial Decision-making and Management Accounting Information*. Helsinki Metropolia University of Applied Sciences. Dostupno na: http://www.theseus.fi/bitstream/handle/10024/106190/Butterfield_Emma.pdf?sequence=1&isAllowed=y

[38] Byrne, S., Pierce, B. (2007). Towards a more comprehensive understanding of the roles of management accountants. *European Accounting Review*, *16*(3), 469–498. doi: https://doi.org/10.1080/09638180701507114

[39] Cadez, S., Guilding, C. (2012). Strategy, strategic management accounting and performance: A configurational analysis. *Industrial Management and Data Systems*, *112*(3), 484–501. doi: https://doi.org/10.1108/02635571211210086

[40] Caniëls, M. C. J., Bakens, R. J. J. M. (2012). The effects of Project Management Information Systems on decision making in a multi project environment. *International Journal of Project Management*, *30*(2), 162–175. doi: https://doi.org/10.1016/j.ijproman.2011.05.005

[41] Carasco-Saul, M., Kim, W., Kim, T. (2015). Leadership and Employee Engagement: Proposing Research Agendas Through a Review of Literature. *Human Resource*

Development Review, *14*(1), 38–63. doi: https://doi.org/10.1177/1534484314560406

[42] Carson, D., Gilmore, A. (2000). SME marketing management competencies. *International Business Review*, *9*(3), 363–382. doi: https://doi.org/10.1016/s0969-5931(00)00006-8

[43] CGMA (2014). Big Data - Readying business for the big data revolution. Chartered global Management accountant® (CgMa®). Dostupno na: https://www.cgma.org/Resources/Reports/DownloadableDocuments/CGMA-briefing-big-data.pdf

[44] Chen, C. J., Huang, J. W. (2007). How organizational climate and structure affect knowledge management-The social interaction perspective. *International Journal of Information Management*, *27*(2), 104–118. doi: https://doi.org/10.1016/j.ijinfomgt.2006.11.001

[45] Chen, H., Chiang, R. H. L., Storey, V. C. (2012). Business Intelligence and Analytics: From Big Data to Big Impact. *MIS Quarterly*, *36*(4), 1165–1188.

[46] Chenhall, R. H., Morris, D. (1986). The Impact of Structure, Environment, and Interdependence on the Perceived Usefulness of Management Accounting Systems. *The Accounting Review*, *61*(1), 16–35.

[47] Chiou, B. (2011). Which types of management accounting system information can be used to respond adequately to environmental uncertainty? The effects of user participation and tolerance of ambiguity. *African Journal of Business Management*, *5*(34), 13293–13301. doi: https://doi.org/10.5897/AJBM11.2207

[48] Chou, D. C., Tripuramallu, H. B., Chou, A. Y. (2005). BI and ERP integration. *Information Management & Computer Security*, *13*(5), 340–349. doi: https://doi.org/10.1108/09685220510627241

[49] Clarke, N., Alshenalfi, N., Garavan, T. (2019). Upward influence tactics and their effects on job performance ratings and flexible working arrangements: The mediating roles of mutual recognition respect and mutual appraisal respect. *Human Resource Management*, *58*(4), 397–416. doi: https://doi.org/10.1002/hrm.21967

[50] Clarke, N., Mahadi, N. (2017). Mutual Recognition Respect Between Leaders and Followers: Its Relationship to Follower Job Performance and Well-Being. *Journal of Business Ethics*, *141*(1), 163–178. doi: https://doi.org/10.1007/s10551-015-2724-z

[51] Cohen, J. (1988). Set Correlation and Contingency Tables. *Applied Psychological Measurement*, *12*(4), 425–434. doi: https://doi.org/10.1177/014662168801200410

[52] Côrte-real, N., Ruivo, P., Oliveira, T. (2014). The Diffusion Stages of Business Intelligence & Analytics (BI&A): A systematic mapping study. *Procedia Technology* (Vol. 16, str. 172–179). Elsevier B.V. doi: https://doi.org/10.1016/j.protcy.2014.10.080

[53] Daryabari, A. (2018). Investigating the Effect of Management Accounting on Business Intelligence of Companies Accepted in Stock Exchange. *International Journal of Management Sciences and Economic*, *6*(4), 85–96.

[54] Davenport, T. H. (2014). *Big data at work : dispelling the myths, uncovering the opportunities*. Boston, Massachusetts: Harvard Business Review Press.

[55] Davenport, T., Harris, J. (2017). *Competing on Analytics: The New Science of Winning, Updated, with a New Introduction*. Boston: Harvard Business Review Press.

[56] Deinert, M. (2013). Wie IT-Trends das Controlling verändern werden.U: P. Horvath, U. Michel (ur.), *Controlling integiert und global* (str. 277–283). Stutgart: Schäffer Poeschel.

[57] Deloitte (2020). Robotics Process Automation (RPA): Introducing RPA through the OGP Single Supplier Framework. Deloitte Ireland LLP. Dostupno na: https://www2.deloitte.com/content/dam/Deloitte/ie/Documents/PublicSector/IE_PS_CF_RPA_PS_Brochure.pdf

[58] Deloitte Insights (2019). Leading the social enterprise: Reinvent with a human focus / 2019 Deloitte Global Human Capital Trends. Deloitte Development LLC.

[59] Dijkstra, T. K., Henseler, J. (2015). Consistent Partial Least Squares Path Modeling. *MIS Quarterly*, *39*(2), 297–316. doi: https://doi.org/10.25300/MISQ/2015/39.2.02

[60] Drerup, B., Suprano, F., Wömpener, A. (2016). Controller 4.0: Anforderungsprofil des Controllers im digitalen Zeitalter. *Controlling*, *30*(1), 57–63. doi: https://doi.org/10.15358/0935-0381-2018-1-57

[61] Eiselmayer, K., Gleich, R., Losbichler, H., Niedermayr-Kruse, R., Rieder, L., Schulze, M., et al. (2015). *Controller-Kompetenzmodell: Ein Leitfaden für die moderne Controller-Entwicklung mit Muster-Kompetenzprofilen*. International Group of Controlling. Freiburg: Haufe Gruppe.

[62] Eker, S., Eker, M. (2019). Exploring The Relationships Between Environmental Uncertainty, Business Strategy and Management Control System on Firm Performance. *Business and Economics Research Journal*, *10*(1), 115–129. doi: https://doi.org/10.20409/berj.2019.158

[63] El Hilali, W., El Manouar, A., Janati Idrissi, M. A. (2020). Reaching sustainability during a digital transformation: a PLS approach. *International Journal of Innovation Science*, *12*(1), 52–79. doi: https://doi.org/10.1108/IJIS-08-2019-0083

[64] Elnihewi, I., Fadzil, F. H., Mohamed, R. (2015). Effect of Organisational Structure and Competition on Organisational Performance in Libyan Commercial Banks Ismail. *Inforamtion Managment and Business Review*, *7*(6), 50–55. doi: https://doi.org/10.22610/imbr.v7i6.1182

[65] Erhart, R., Mahlendorf, M. D., Reimer, M., Schäffer, U. (2017). Theorizing and testing bidirectional effects: The relationship between strategy formation and involvement of controllers. *Accounting, Organizations and Society*, *61*, 36–52. doi: https://doi.org/10.1016/j.aos.2017.07.004

[66] Evans, J. R. (2017). *Business Analytics*. C. Hoag, D. Lynch, P. Barbera, J. Billing (2. izdanje). Harlow, Engleska: Pearson.

[67] Evelson, B. (2008). The Forrester Wave ™: Enterprise Business Intelligence Platforms, Q3 2008. Cambridge: Forrester Research, Inc.

[68] Fadhilah, A., Harahap, S. N., Setyaningrum, D. (2015). Investigating the Role of Management Accountants in Indonesia. *International Research Journal of Business Studies*, *8*(2), 81–96. doi: https://doi.org/10.21632/irjbs.8.2.81-96

[69] Farhat, K., Mohd Mokhtar, S. S., Salleh, S. M. (2020). Connecting the dots of customer-based brand equity to brand engagement: using the disjoint two stage approach of PLS-SEM. *Market-Tržište*, *32*(2), 147–168. doi: https://doi.org/10.22598/mt/2020.32.2.147

[70] Feeney, O. (2007). *Management Perspectives on the Role of the Management Accountant as an Information Provider*. Dublin City University Business School.

[71] Fenyves, V., Tarnóczi, T. (2019). Examination of the expectations of controllers on the labour market. *Corporate Ownership & Control*, *17*(1), 60–70. doi:

https://doi.org/10.22495/cocv17i1art6

[72] Filipčić, H. (2018). Smjernice za pisanje menadžerskih izvještaja. *Kontroling, Financije i Menadžment*, 6, 30–37.

[73] Filipčić, H. (2019). "Meke" ili moćne vještine. *Kontroling, Financije i Menadžment*, 11, 63–72.

[74] Finstad, K. (2010). Response interpolation and scale sensitivity: Evidence against 5-point scales. *Journal of Usability Studies, 5*(3), 104–110. Dostupno na: https://uxpajournal.org/wp-content/uploads/sites/8/pdf/JUS_Finstad_May_2010.pdf

[75] Fisher, C. W., Chengalur-Smith, I., Ballou, D. P. (2003). The Impact of Experience and Time on the Use of Data Quality Information in Decision Making. *Information Systems Research, 14*(2), 170–188. doi: https://doi.org/10.1287/isre.14.2.170.16017

[76] Fourné, S. P. L., Guessow, D., Schäffer, U. (2018). Controller Roles: Scale Development and Validation. U: M. J. Epstein, F. H. M. Verbeeten, S. K. Widener (ur.), *Performance Measurement and Management Control: The Relevance of Performance Measurement and Management Control Research* (str. 143–190). Emerald Publishing Limited. doi: https://doi.org/10.1108/S1479-351220180000033007

[77] Francioni, B., Musso, F., Cioppi, M. (2015). Decision-maker characteristics and international decisions for SMEs. *Management Decision*, *53*(10), 2226–2249. doi: https://doi.org/10.1108/MD-03-2015-0094

[78] Frese, M., Fay, D., Hilburger, T., Leng, K., Tag, A. (1997). The concept of personal initiative: Operationalization, realiability and validity in two German samples. *Journal of Occupational and Organizational Psychology, 70,* 139–161. Dostupno na: http://www.evidence-based-entrepreneurship.com/content/publications/043.pdf%0Azotero://attachment/291/

[79] Fuadah, L., Nasir, M., Isgiqarta, J. (2014). The Relationship between Intensity of Competition, Delegation of Authority, Management Accounting and Control Systems Changes, Organizational Performance (Empirical Study in Manufacturing Companies Listed in Indonesian Stock Exchange) Lukluk. *Malaysia Indonesia Internatiional Conference on Economics, Management and Accounting; Global Economic Climate: Issues and Challenges* (str. 439–450).

[80] Fuchs, C., Diamantopoulos, A. (2009). Using single-item measures for construct measurement in management research, *69*, 195–210.

[81] Futivić, K. (2018). Digitalna transformacija. *Kontroling, Financije i Menadžment*, 5, 28–30.

[82] Galetto, M. (2016). What Is Business Analytics? Preuzeto (14.02.2019) na: https://www.ngdata.com/what-is-business-analytics/

[83] Gänßlen, S. (2008). Was macht Controller erfolgreich? U: P. Horváth (ur.), *Mehr Verantwortung für den Controller* (str. 33–47). Stuttgart: Schäffer-Poeschel.

[84] Gänßlen, S., Losbichler, H., Niedermayr, R., Rieder, L., Schäffer, U., & Weber, J. (2012). Temeljna načela kontrolinga. Internationaler Controller Verein (ICV) i International Group of Controlling (IGC).

[85] Gärtner, B., Hiebl, M. R. W. (2018). Issues with Big Data. U: M. Quinn, E. Strauß (ur.), *The Routledge Companion to Accounting Information Systems* (str. 161–172). Abingdon: Routledge. doi: https://doi.org/10.4324/9781315647210-13

[86] Gaumer Erickson, A. S., Noonan, P. M. (2018). Assertiveness formative questionnaire. U: P.M. Noonan, A.S. Gaumer Erickson, *The skills that matter: Teaching interpersonal and intrapersonal competencies in any classroom* (str. 181–182). Corwin: Thousand Oaks, CA.

[87] Gerhardt, M., Ashenbaum, B., Newman, W. R. (2009). Understanding the Impact of Proactive Personality on Job Performance: The Roles of Tenure and Self-Management. *Journal of Leadership and Organizational Studies*, *16*(1), 61–72. doi: https://doi.org/10.1177/1548051809334192

[88] Ghadi, M. Y., Fernando, M., Caputi, P. (2013). Transformational leadership and work engagement: The mediating effect of meaning in work. *Leadership and Organization Development Journal*, *34*(6), 532–550. doi: https://doi.org/10.1108/LODJ-10-2011-0110

[89] Ghasemaghaei, M., Ebrahimi, S., Hassanein, K. (2018). Data analytics competency for improving firm decision making performance. *Journal of Strategic Information Systems*, *27*(1), 101–113. doi: https://doi.org/10.1016/j.jsis.2017.10.001

[90] Ghasemi, R., Mohamad, N. A., Karami, M., Bajuri, N. H. (2016). The Mediating Effect of Management Accounting System on the Relationship between Competition and Managerial Performance. *International Journal of Accounting & Information Management*, *24*(3), 272–295. doi: https://doi.org/10.1108/IJAIM-05-2015-0030

[91] Ghasemi, R., Mohamad, N. A., Karami, M., Bajuri, N. H., Asgharizade, E. (2015). The Relationship among Strategy , Competition and Management Accounting Systems on Organizational Performance. *European Online Journal of Natural and Social Sciences*, *4*(3), 565–581.

[92] Ghasemi, R., Mohamad, N. A., Karami, M., Hafiz Bajuri, N., Asgharizade, E. (2015). The Relationship among Strategy, Competition and Management Accounting Systems on Organizational Performance. *European Online Journal of Natural and Social Sciences*, *4*(3), 565–581. Dostupno na: https://core.ac.uk/download/pdf/296307396.pdf

[93] Ghosh, A. (1999). Measuring managerial skills using a forced-choice questionnarire. *Management & Labour Studies*, *24*(2), 89–95.

[94] Giri, K. J., Lone, T. A. (2014). Big Data -Overview and Challenges. *International Journal of Advanced Research in Computer Science and Software Engineering*, *4*(6), 525–529.

[95] Gleich, R., Göttling, A., Lauber, A., Overesch, A. (2013). Entwicklung eines Kompetenzmodells für Controller. U: P. Horváth, U Michel (ur.), *Controlling integriert und global: erfolgreiche Steuerung von komplexen Organisationen* (str. 71–85). Stuttgart: Schäffer-Poeschel.

[96] Gleich, R., Lauber, A. (2018). Ein aktuelles Kompetenzmodell für Controller. *Controlling*, *25*(10), 512–514. doi: https://doi.org/https://doi.org/10.15358/0935-0381_2013_10_512

[97] Gleich, R., Munck, J. C., Schulze, M. (2016). Osnove industrije 4.0 i učinci na kontroling. U: M. Meter, *Kontroling u praksi - Najnoviji trendovi u kontrolingu* (str. 49–62). Zagreb: Poslovna učinkovitost d.o.o. za poslovno savjetovanje.

[98] Goretzki, L., Strauss, E., Weber, J. (2013). An institutional perspective on the changes in management accountants ' professional role. *Management Accounting Research*, *24*(1), 41–63. doi: https://doi.org/10.1016/j.mar.2012.11.002

[99] Gray, G. L., Alles, M. (2015). Data Fracking Strategy: Why Management Accountants Need It. *Management Accounting Quarterly*, *16*(3), 22–33.

[100] Grönke, K., Kirchmann, M., Leyk, J. (2014). Big Data: Auswirkungen auf Instrumente und Organisation der Unternehmenssteuerung. U: R. Gleich, K. Grönke, M. Kirchmann, J. Leyk (ur.), *Controlling und Big Data* (str. 63–82). Freiburg: Haufe-Lexware.

[101] Gul, F. A., Chia, Y. M. (1994). The effects of management accounting systems, perceived environmental uncertainty and decentralization on managerial performance: A test of three-way interaction. *Accounting, Organizations and Society*, *19*(4–5), 413–426. doi: https://doi.org/10.1016/0361-3682(94)90005-1

[102] Gul, F. A., Glen, W., Huang, A. R. (1993). The Effects of Environmental Uncertainty, Computer Usage, and Management Accounting Systems on Small Business. *Journal of Small Business Finance*, *2*(3), 251–271.

[103] Gullkvist, B. M. (2013). Drivers of change in management accounting practices in an ERP environment. *International Journal of Economic Sciences and Applied Research*, *6*(2), 149–174. Dostupno na: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=2348581

[104] Gürtner, B., Krichbaum, A. (2014). the Role of Management Accountants in the Use of Erp Systems in Large Companies. *European Journal of Management*, *14*(2), 91–108. doi: https://doi.org/10.18374/EJM-14-2.9

[105] Habib, A., Hossain, M. (2013). CEO / CFO characteristics and financial reporting quality: A review. *Research in Accounting Regulation*, *25*(1), 88–100. doi: https://doi.org/10.1016/j.racreg.2012.11.002

[106] Hair, Jr. F. J., Hult, T. G. M., Ringle, C. M., Sarstedt, M. (2017). *A Primer on Partial Least Squares Structural Equation Modeling (PLS-SEM)* (Edition, 2). Los Angeles: Sage.

[107] Hair, Jr. F. J., Risher, J. J., Sarstedt, M., Ringle, C. M. (2019). When to use and how to report the results of PLS-SEM. *European Business Review*, *31*(1), 2–24. doi: https://doi.org/10.1108/EBR-11-2018-0203

[108] Hair, Jr. J. F., Sarstedt, M., Ringle, C. M., Gudergan, S. P. (2018). *Advanced Issues in Partial Least Squares Structural Equation Modeling (PLS-SEM)*. Thousand Oaks, CA: Sage.

[109] Haldma, T., Lääts, K. (2002). Contingencies influencing the management accounting practices of Estonian manufacturing companies. *Management Accounting Research*, *13*(4), 379–400. doi: https://doi.org/10.1006/mare.2002.0197

[110] Haluk, R., Rante, Y., Risamasu, F., Syauta, J. H. (2016). The Mediation Effect of Work Motivation in Relationship Between Employee Competencies, Leadership, Education and Training Toward Employee Performance (Case Study On Social And Settlement In Papua Province). *Science Arena Publications International Journal of Business Management*, *2*(2), 40–52.

[111] Hammad, S. A., Jusoh, R., Ghozali, I. (2013). Decentralization, perceived environmental uncertainty, managerial performance and management accounting system information in Egyptian hospitals. *International Journal of Accounting and Information Management*, *21*(4), 314–330. doi: https://doi.org/10.1108/IJAIM-02-2012-0005

[112] Hassan, S., Hatmaker, D. M. (2015). Leadership and Performance of Public Employees: Effects of the Quality and Characteristics of Manager-Employee Relationships. *Journal of Public Administration Research and Theory*, *25*(4), 1127–1155. doi: https://doi.org/10.1093/jopart/muu002

[113] Hauck, Y., Lewis, L., Kuliukas, L., Butt, J., Wood, J. (2016). Graduate midwives' perception of their preparation and support in using evidence to advocate for women's

choice: A Western Australian study. *Nurse Education in Practice*, *16*(1), 305–311. doi: https://doi.org/10.1016/j.nepr.2015.06.004

[114] Hede, A. (2005). *Patterns of power and leadership: Understanding Total Behaviour Leadership*.

[115] Henseler, J., Ringle, C. M., Sarstedt, M. (2015). A new criterion for assessing discriminant validity in variance-based structural equation modeling. *Journal of the Academy of Marketing Science*, *43*(1), 115–135. doi: https://doi.org/10.1007/s11747-014-0403-8

[116] Heupel, T., Reinhardt, M. (2019). Das Controlling-Bild der Zukunft.U: T. Kümpel, K. Schlenkrich, T. Heupel (ur.), *Controlling & Innovation 2019* (str. 111–134). Wiesbaden: Springer Gabler. doi: https://doi.org/10.1007/978-3-658-23474-4_6

[117] Hilton, R. W., Platt, D. E. (2014). *Managerial Accounting: Creating Value in a Dynamic Business Enviroment* (10th Editi). New York, NY: McGraw-Hill Education.

[118] Hinton, H. P., McMurray, I., Brownlow, C. (2014). *SPSS explained* (drugo izda). London: Routledge.

[119] Hirsch, B., Nitzl, C., Schauß, J. (2015). The Influence of Management Accounting Departments Within German Municipal Administrations. *Financial Accountability and Management*, *31*(2), 192–218. doi: https://doi.org/10.1111/faam.12052

[120] Horng, J. S., Tsai, C. Y., Yang, T. C., Liu, C. H., Hu, C. H. (2016). Exploring the relationship between proactive personality, work environment and employee creativity among tourism and hospitality employees. *International Journal of Hospitality Management*, *54*, 25–34. doi: https://doi.org/10.1016/j.ijhm.2016.01.004

[121] ICV (2015). Controlling im Zeitalter der intelligenten Vernetzung Dream Car der Ideenwerkstatt im ICV 2015. Internationaler Controller Verein. Dostupno na: https://www.icv-controlling.com/fileadmin/Assets/Content/AK/Ideenwerkstatt/Files/Dream_Car_Industrie4.0_DE.pdf

[122] ICV (2018). Digital Business Model Innovations Controlling - Controlling in the Digital Transformation. Internationaler Controller Verein. Dostupno na: https://www.icv-controlling.com/fileadmin/Assets/Content/AK/Ideenwerkstatt/Files/Dream_Car_GMI_EN.pdf

[123] IGC (2013). *Rječnik za kontrolere*. Zagreb: Poslovna učinkovitost d.o.o. za poslovno savjetovanje.

[124] Iivari, J. (2005). An Empirical Test of the Model of Information System Success. *The DATA BASE for Advances in Information Systems*, *36*(2), 8–27. doi: https://doi.org/10.1145/1066149.1066152

[125] Ishwarappa, K., Anuradha, J. (2015). A Brief Introduction on Big Data 5Vs Characteristics and Hadoop Technology. *Procedia Computer Science*, *48*, 319–324. doi: https://doi.org/10.1016/j.procs.2015.04.188

[126] Ismail, K., Isa, C. R., Mia, L. (2018). Market Competition , Lean Manufacturing Practices and The Role of Management Accounting Systems (MAS) Information. *Jurnal Pengurusan*, *52*(2018), 47–61. doi: https://doi.org/10.17576/pengurusan-2018-52-04

[127] Jamada, D. W., Ainebyona, G. (2019). Understanding Employee Motivational Nature and its Influence on Performance and Managerial Behaviour in Selected Organizations of

Burco, Somaliland. *American Research Journal of Humanities Social Science*, *02*(09), 32–40. Dostupno na: https://gollisuniversity.org/wp-content/uploads/2019/11/Motivation-Gerald-Dauda-Publication-E293240.pdf

[128] Järvenpää, M. (2007). Making Business Partners: A Case Study on how Management Accounting Culture was Changed. *European Accounting Review ISSN:*, *16*(1), 99–142. doi: https://doi.org/10.1080/09638180701265903

[129] Jaworski, B. J., Kohli, A. K. (1993). Market Orientation: Antecedents and Consequences. *Journal of Marketing*, *57*(3), 53–70. doi: https://doi.org/10.4135/9781452231426.n5

[130] Jayachandran, S., Sharma, S., Kaufman, P., Raman, P. (2005). The role of relational information processes and technology use in customer relationship management. *Journal of Marketing*, *69*(4), 177–192. doi: https://doi.org/10.1509/jmkg.2005.69.4.177

[131] Jermias, J., Gani, L., Juliana, C. (2018). Performance Implications of Misalignment among Business Strategy, Leadership Style, Organizational Culture and Management Accounting Systems. *2018 Canadian Academic Accounting Association (CAAA) Annual Conference*. Canadian Academic Accounting Association (CAAA) Annual Conference, Dostupno na: SSRN: https://ssrn.com/abstract=3099151 or http://dx.doi.org/10.2139/ssrn.3099151

[132] Joharia, J., Subramaniamb, H. (2018). Enhancing job performance through proactive personality and human resource management practices: A case of banking sector employees. U: T. F. Yean, K. K. Yahya, N. Mat, J. Johari, Z. Hassan (ur.), *Proceedings of National Human Resource Management Conference (NHRMC) 2018* (str. IV28–IV40). Sintok, Kedah: Department of Human Resource Management School of Business Management, College of Business Universiti Utara Malaysia.

[133] Joo, B. B., Bennett III, R. H. (2018). The Influence of Proactivity on Creative Behavior, Organizational Commitment, and Job Performance: Evidence from a Korean Multinational. *Journal of International & Interdisciplinary Business Research Volume*, *5*, Article 2. Dostupno na: https://scholars.fhsu.edu/jiibr/vol5/iss1/2

[134] Kafetzopoulos, D., Psomas, E., Skalkos, D. (2019). Innovation dimensions and business performance under environmental uncertainty. *European Journal of Innovation Management*, *23*(5), 856–876. doi: https://doi.org/10.1108/EJIM-07-2019-0197

[135] Kaštelan Mrak, M. (2005). Procesna organizacija – pojam i ishodišta modela uz osvrt na restrukturiranje hrvatske prerađivačke industrije. *Zbornik Radova Ekonomskog Fakulteta u Rijeci: Časopis Za Ekonomsku Teoriju i Praksu*, *23*(1), 113–132.

[136] Kaštelan Mrak, M., Sokolic, D. (2017). The evolution of work organization and its implication for educational policies and managerial practices utjecaj evolucije organizacije rada na obrazovne. U: A. Masek Tonkovic (ur.), *Proceedings of the 6th International Scientific Symposium Economy of Eastern Croatia - Vision And Growth* (str. 335–344). Osijek: University J.J. Strossmayera Osijek.

[137] Kavanagh, M. H., Drennan, L. (2008). What skills and attributes does an accounting graduate need? Evidence from student perceptions and employer expectations. *Accounting and Finance*, *48*(2007), 279–300. doi: https://doi.org/10.1111/j.1467-629x.2007.00245.x

[138] Keimer, I., Egle, U. (2020). Digital Controlling – Grundlagen für den erfolgreichen digitalen Wandel im Controlling. U: I. Keimer, U. Egle (ur.), *Die Digitalisierung der Controlling-Funktion; Anwendungsbeispiele aus Theorie und Praxis* (str. 1–16). Wiesbaden: Springer Gabler. doi: https://doi.org/https://doi.org/10.1007/978-3-658-

29196-9

[139] Kieninger, M., Mehanna, W., & Vocelka, A. (2016). Wie Big Data das Controlling verändert. *Controlling*, *28*(4/5), 241–247. doi: https://doi.org/10.15358/0935-0381-2016-4-5-241

[140] Kim, T.-Y., Hon, A. H. Y., Lee, D.-R. (2010). Proactive Personality and Employee Creativity: The Effects of Job Creativity Requirement and Supervisor Support for Creativity. *Creativity Research Journal*, *22*(1), 37–45. doi: https://doi.org/10.1080/10400410903579536

[141] Kock, N. (2015). Common method bias in PLS-SEM: A full collinearity assessment approach. *International Journal of E-Collaboration*, *11*(4), 1–10. doi: https://doi.org/10.4018/ijec.2015100101

[142] Kock, N., Hadaya, P. (2018). Minimum sample size estimation in PLS-SEM: The inverse square root and gamma-exponential methods. *Information Systems Journal*, *28*(1), 227–261. doi: https://doi.org/10.1111/isj.12131

[143] Krishnan, A., Ramasamy, R. (2011). Accessing the Construct and Content Validity of Uncertainty Business Using Sem Approach- An Exploratory Study of Manufacturing Firms. *Global Journal of Management and Business Research*, *11*(12), 1–9.

[144] Kulkarni, U. R., Robles-Flores, J. A., Popovič, A. (2017). Business Intelligence Capability: The Effect of Top Management and the Mediating Roles of User Participation and Analytical Decision Making Orientation. *Journal of the Association for Information Systems*, *18*(7), 516–541. doi: https://doi.org/10.17705/1jais.00462

[145] Labaš, D., Rajsman, M. (2020). Istraživanje uloge i perspektive razvoja kontrolera kao poslovnog partnera menadžmentu. *Ekonomski Pregled*, *71*(3), 239–270. doi: https://doi.org/https://doi.org/10.32910/ep.71.3.3

[146] Lal, M., Hassel, L. (1998). The joint impact of environmental uncertainty and tolerance of ambiguity on top managers' perceptions of the usefulness of non-conventional management accounting'information. *Scandinavian Journal of Management*, *14*(3), 259–271. doi: https://doi.org/10.1016/S0956-5221(98)80010-9

[147] Langmann, C. (2019). *Digitalisierung im Controlling*. Wiesbaden: Springer Gabler. doi: https://doi.org/https://doi.org/10.1007/978-3-658-25017-1

[148] Lee, S. (Ally), Ravichandran, S. (2019). Impact of employees' job control perceptions on their work-related responses in the hospitality industry. *International Journal of Contemporary Hospitality Management*, *31*(7), 2720–2738. doi: https://doi.org/10.1108/IJCHM-09-2018-0784

[149] Liden, R. C., Maslyn, J. M. (1998). Multidimensionality of leader-member exchange: An empirical assessment through scale development. *Journal of Management*, *24*(1), 43–72. doi: https://doi.org/10.1177/014920639802400105

[150] Lin, H. F. (2010). An investigation into the effects of IS quality and top management support on ERP system usage. *Total Quality Management*, *21*(3), 335–349. doi: https://doi.org/10.1080/14783360903561761

[151] Lindelöf, P., Löfsten, H. (2006). Importance of management accounting in new technology-based firms in Sweden analysis of environmental and strategic variables. *International Journal of Business Environment*, *1*(2), 137. doi: https://doi.org/10.1504/ijbe.2006.010681

[152] Listeš, M. (2019). Podatkovna pismenost. *Kontroling, Financije i Menadžment*, 11, 39–40.

[153] Löfsten, H., Lindelöf, P. (2005). Environmental hostility, strategic orientation and the importance of management accounting - An empirical analysis of new technology-based firms. *Technovation, 25*(7), 725–738. doi: https://doi.org/10.1016/j.technovation.2004.01.007

[154] Luković, T., Lebefromm, U. (2009). *Controlling-Koncepcija i slučajevi*. Dubrovnik: Sveučilište u Dubrovniku.

[155] Maas, V. S. (2019). *The effect of controller involvement in management on performance measurement system gaming*. Amsterdam.

[156] Mäder, O. B. (2018). Der objektivierungsorientierte Controllingansatz. U: Mäder, O. B., *Controlling klipp & klar* (str. 129–157). Wiesbaden: WiWi klipp & klar, Springer Gabler. doi: https://doi.org/10.1007/978-3-658-15747-0_9

[157] Mahlendorf, M. D., Rehring, J., Schäffer, U., Wyszomirski, E. (2012). *Influencing foreign subsidiary decisions through headquarter performance measurement systems*. *Management Decision* (Vol. 50). doi: https://doi.org/10.1108/00251741211220354

[158] Maisel, L. S., Cokins., G. (2014). *Predictive Business Analytics: Forward-Looking Capabilities to Improve Business Performance*. John Wiley & Sons, Inc., Hoboken, New Jersey.

[159] Mališ, T. (2017). Microsoft Power BI - vizionar u svijetu poslovne analitike. *Kontroling, Financije i Menadžment*, 4, 28–34.

[160] Manyika, J., Chui, M., Brown, B., Bughin, J., Dobbs, R., Roxburgh, C., Hung Byers, A. (2011). *Big data : The next frontier for innovation , competition , and productivity*. Dostupno na: https://bigdatawg.nist.gov/pdf/MGI_big_data_full_report.pdf

[161] Matejka, M. (2002). *Management accounting in organizational design: Three Essays*. Tilburg Universitiy.

[162] Mayr, A., Losbichler, H., Brückl, V. (2020). Berufsfeld Controlling – Was Stellenanzeigen - verraten. *Controlling & Management Review, 64*, 8–19. doi: https://doi.org/https://doi.org/10.1007/s12176-020-0344-7

[163] Meter, M., Pureta, T. (2016). Primjena modela kompetencija kontrolera u praksi. U: M. Meter (ur.) *Kontroling u praksi - Najnoviji trendovi u kontrolingu* (str. 113–126). Zagreb: Poslovna učinkovitost d.o.o. za poslovno savjetovanje.

[164] Meter, M., Šarčević, M. (2017). Najznačajni rezultati istraživanja o standardima u kontrolingu u hrvatskoj. *Kontroling, Financije i Menadžment*, 1, 14–18.

[165] Meter, M., Šarčević, M. (2018). Suradnja menadžmenta i kontrolinga u hrvatskim poduzećima. *Kontroling, Financije i Menadžment*, 6, 12–17.

[166] Mia, L., Clarke, B. (1999). Market competition, management accounting systems and business unit performance. *Management Accounting Research, 10*(2), 137–158. doi: https://doi.org/10.1006/mare.1998.0097

[167] MicroStrategy (2019). *2020 Global State of Enterprise Analytics: Minding the data-driven gap*. Dostupno na: https://www3.microstrategy.com/getmedia/db67a6c7-0bc5-41fa-82a9-bb14ec6868d6/2020-Global-State-of-Enterprise-Analytics.pdf

[168] Mihăilă, M. (2014). Managerial accounting and decision making , in energy industry.

Procedia - Social and Behavioral Sciences (Vol. 109, str. 1199–1202). 2nd World Conference On Business, Economics And Management - WCBEM 2013. doi: https://doi.org/10.1016/j.sbspro.2013.12.612

[169] Miller, D., Friesen, P. H. (1983). Strategy-Making and Environment: The Third Link. *Strategic Management Journal*, *4*(3), 221–235. Dostupno na: https://www.jstor.org/stable/2486083

[170] Mitamura, T. (2018). Developing the Functional Assertiveness Scale: Measuring Dimensions of Objective Effectiveness and Pragmatic Politeness. *Japanese Psychological Research*, *60*(2), 99–110. doi: https://doi.org/10.1111/jpr.12185

[171] Mitchell, J. R., Shepherd, D. A., Sharfman, M. P. (2011). Erratic strategic decisions: when and why managers are inconsistent in strategic decision making. *Strategic Management Journal*, *32*, 683–704. doi: https://doi.org/10.1002/smj.905

[172] MojPosao. (2019). Preuzeto (30.01.2019.) na: https://www.moj-posao.net/?gclid=CjwKCAiAo5qABhBdEiwAOtGmbkuNKtRX_AqiCXsnDXyNAunANRFzXPVvFtxKA8KgyNQuHrJQ8_0sdBoCrd8QAvD_BwE

[173] Möller, K., Seefried, J., Wirnsperger, F. (2017). Wie Controller zu Business-Partnern werden. *Controlling & Management Review*, *2*, 64–67.

[174] Monje Amor, A., Abeal Vázquez, J. P., Faíña, J. A. (2020). Transformational leadership and work engagement: Exploring the mediating role of structural empowerment. *European Management Journal*, *38*(1), 169–178. doi: https://doi.org/10.1016/j.emj.2019.06.007

[175] Mreža znanja (2012). Kontroling poslovanja-pojmovno određenje, razvoj i uloga kontrolinga u poslovanju. Zagreb: Mreža znanja d.o.o.

[176] Mrkonjić, M. (2019). Unos i migracija podataka u informacijski sustav. *Kontroling, Financije i Menadžment*, 11, 34–37.

[177] Musso, F., Francioni, B. (2012). The Influence Of Decision-Maker Characteristics On The International Strategic Decision-Making Process : An SME Perspective The Influence Of Decision-Maker Characteristics On The International Strategic Decision-Making Process : An SME Perspective. *Procedia - Social and Behavioral Sciences*, *58*, 279–288. doi: https://doi.org/10.1016/j.sbspro.2012.09.1002

[178] Musso, F., Francioni, B. (2013). The Decision-Making Process in International Business Strategies : Factors of Influence on Small and Medium Enterprises. *International Journal of Applied Behavioral Economics*, *2*(2), 1–22. doi: https://doi.org/10.4018/ijabe.2013040101

[179] Nelson, R. R., Todd, P. A., Wixom, B. H. (2005). Antecedents of information and system quality: An empirical examination within the context of data warehousing. *Journal of Management Information Systems*, *21*(4), 199–235. doi: https://doi.org/10.1080/07421222.2005.11045823

[180] Ngah, H. A., Kamalrulzaman, I. N., Ibrahim, F., Abu Osman, A. N., Ariffin, N. A. (2021). The effect of soft skills, ethics, and value on the willingness of employers to continue recruiting UMT graduates. *Management Science Letters*, *11*, 1689–1698. doi: https://doi.org/10.5267/j.msl.2020.12.002

[181] Nguyen, T. T., Mia, L., Winata, L., Chong, V. K. (2017). Effect of transformational-leadership style and management control system on managerial performance. *Journal of Business Research*, *70*, 202–213. doi: https://doi.org/10.1016/j.jbusres.2016.08.018

[182] Nicolescu, L., Nicolescu, C. (2019). Using PLS-SEM to build an employability confidence model for higher education recipients in the field of business studies. *Kybernetes*, *48*(9), 1965–1988. doi: https://doi.org/10.1108/K-04-2018-0165

[183] Nielsen, L. B., Mitchell, F., Nørreklit, H. (2015). Management accounting and decision making: Two case studies of outsourcing. *Accounting Forum*, *39*(1), 64–82. doi: https://doi.org/https://doi.org/10.1016/j.accfor.2014.10.005

[184] Nielsen, S. (2018). Reflections on the Applicability of Business Analytics for Management Accounting – and Future Perspectives for the Accountant. *Journal of Accounting & Organizational Change*, *14*(2), 167–187. doi: https://doi.org/10.1108/JAOC-11-2014-0056

[185] Nitzl, C. (2016). The use of partial least squares structural equation modelling (PLS-SEM) in management accounting research: Directions for future theory development. *Journal of Accounting Literature*, *37*, 19–35. doi: https://doi.org/10.1016/j.acclit.2016.09.003

[186] Nitzl, C. (2018). Management Accounting and Partial Least Squares-Structural Equation Modelling (PLS- SEM): Some Illustrative Examples. U: N. K. Avkiran, C. M. Ringle (ur.), *Partial Least Squares Structural Equation Modeling: Recent Advances in Banking and Finance* (str. 211–229). Cham, Switzerland: Springer International Publishing AG 2018. doi: https://doi.org/https://doi.org/10.1007/978-3-319-71691-6

[187] Nitzl, C., Hirsch, B. (2016). The drivers of a superior's trust formation in his subordinate. *Journal of Accounting & Organizational Change*, *12*(4), 472–503. doi: https://doi.org/10.1108/JAOC-07-2015-0058

[188] Nobach, K. (2019). Bedeutung der Digitalisierung für das Controlling und den Controller. U: P. Ulrich, B. Baltzer (ur.), *Wertschöpfung in der Betriebswirtschaftslehre* (str. 247-269). Springer Gabler, Wiesbaden. doi: https://doi.org/https://doi.org/10.1007/978-3-658-18573-2_11

[189] Nwankpa, J. K., Roumani, Y. (2016). IT capability and digital transformation: A firm performance perspective. *37th International Conference on Information Systems, ICIS* (str. 1–16). Dublin. Dostupno na: https://core.ac.uk/download/pdf/301370499.pdf

[190] Očko, J. (2018). Zanimanje budućnosti – kontroleri sve bliži IT-ju, IT kontrolingu. *Lider Media*, 58–59. Dostupno na: https://issuu.com/kognosko/docs/o_ko-_lanak

[191] Očko, J., Švigir, A. (2009). *Kontroling-upravljanje iz backstagea*. Zagreb: Altius savjetovanje d.o.o.

[192] Oesterreich, D. T., Teuteberg, F., Bensberg, F., Buscher, G. (2019). The controlling profession in the digital age: Understanding the impact of digitisation on the controller ' s job roles , skills and competences. *International Journal of Accounting Information Systems*, *35*, 100432. doi: https://doi.org/10.1016/j.accinf.2019.100432

[193] Ohly, S., Fritz, C. (2007). Challenging the status quo: What motivates proactive behaviour? *Journal of Occupational and Organizational Psychology*, *80*, 623–629. doi: https://doi.org/10.1348/096317907X180360

[194] Omarli, S. (2017). *Which Factors have an Impact on Managerial Decision-Making Process? An Integrated Framework. Essays in Economics and Business Studies*. doi: https://doi.org/10.18427/iri-2017-0068

[195] Osmanagić Bedenik, Nidzara. (1998). *Kontroling-Abeceda poslovnog uspjeha*. Zagreb: Školska knjiga.

[196] Osmanagić Bedenik, Nidzara. (2015). The Challenge of Controlling. *Journal of Industrial Engineering and Management*, *6*(4), 153–163.

[197] Osmanagić Bedenik, Nidžara. (2018). Menadžement i kontrling: rasterećenje, suradnja ili ograničenje? *Kontroling, Financije i Menadžment*, 6, 18–21.

[198] Osmanagić Bedenik, Nidžara, Lizzul, A. (2015). Komparativna analiza obilježja kontrolera u poduzećima koja kotiraju na zagrebačkoj i frankfurtskoj burzi, *EFZG working paper series, (*15), 1-17. Dostupno na: https://hrcak.srce.hr/147954.

[199] Osmanić Bedenik, N. (2007). *Kontroling: Abeceda poslovnog uspjeha* (3. izdanje). Zagreb: Školska knjiga.

[200] Otache, I. (2019). The mediating effect of teamwork on the relationship between strategic orientation and performance of Nigerian banks. *European Business Review*, *31*(5), 744–760. doi: https://doi.org/10.1108/EBR-10-2017-0183

[201] Padukkage, A., Hooper, V., Toland, J. (2016). Implications of Environmental Uncertainty for Business-IT Alignment: A Comparative Study of SMEs and Large Organizations. *Australasian Conference on Information Systems*. Adelaide, Australia.

[202] Pan, J., Liu, S., Ma, B., Qu, Z. (2018). How does proactive personality promote creativity ? A multilevel examination of the interplay between formal and informal leadership. *Journal of Occupational and Organizational Psychology*, *91*(4), 852–874. doi: https://doi.org/10.1111/joop.12221

[203] Pangaribuan, L. V. R. (2016). The impact of Management Accounting Information System and Environmental uncertainty on the Quality of Management Accounting Information. *Proceeding Forum in Research, Science, and Technology (FIRST)* (str. G17–G22). Palembang, Indonesia: State Polytechnic of Sriwijaya – Indonesia. Dostupno na: http://eprints.polsri.ac.id/3650/3/G4.pdf

[204] Papadakis, V. M. (2006). Do CEOs shape the process of making strategic decisions? Evidence from Greece. *Management Decision*, *44*(3), 367–394. doi: https://doi.org/10.1108/00251740610656269

[205] Pasch, T. (2019). Strategy and innovation: the mediating role of management accountants and management accounting systems' use. *Journal of Management Control*, *30*(2), 213–246. doi: https://doi.org/10.1007/s00187-019-00283-y

[206] Paterson, T. R., Vermaas, B. (2011). Too little eye for effectiveness in controlling. *Management*, (November-December), 1–3.

[207] Pedroso, E., Gomes, C. F., Yasin, M. M. (2020). Management accounting systems: an organizational competitive performance perspective. *Benchmarking: An International Journal*, *27*(6), 1843–1874. doi: https://doi.org/10.1108/BIJ-12-2019-0547

[208] Pervan, I., Dropulić, I. (2019). The impact of integrated information systems on management accounting: Case of Croatia. *Journal of Contemporary Management Issues*, *24*(1), 21–38. doi: https://doi.org/10.30924/mjcmi.24.1.2

[209] Phornlaphatrachakorn, K. (2019). Effects of Transformational Leadership, Organisational Learning and Technological Innovation on Strategic Management Accounting in Thailand's Financial Institutions. *Asian Journal of Business and Accounting*, *12*(1), 165–188. doi: https://doi.org/10.22452/ajba.vol12no1.6

[210] Pierce, B., O'Dea, T. (2003). Management accounting information and the needs of managers Perceptions of managers and accountants compared. *The British Accounting*

Review, *35*, 257–290. doi: https://doi.org/10.1016/S0890-8389(03)00029-5

[211] Pietrzak, Z., Wnuk-Pel, T. (2015). The roles and qualities of management accountants in organizations – evidence from the field. *Procedia - Social and Behavioral Science* (213), 281–285. doi: https://doi.org/10.1016/j.sbspro.2015.11.538

[212] Pitan, O. S. (2015). An assessment of generic skills demand in five sectors of the Nigerian labor market. *Public and Municipal Finance*, *4*(1), 28–36.

[213] Pleshko, L. P. (2007). Strategic orientation, organisational structure, and the associated effects on performance. *Journal of Financial Services Marketing*, *12*(1), 53–64. doi: https://doi.org/10.1057/palgrave.fsm.4760061

[214] Podsakoff, P. M., MacKenzie, S. B., Lee, J.-Y., Podsakoff, N. P. (2003). Common method biases in behavioral research: A critical review of the literature and recommended remedies. *Journal of Applied Psychology*, *88*(5), 879–903. doi: https://doi.org/10.1037/0021-9010.88.5.879

[215] Preenen, P., van Vianen, A. E. M., de Pater, I. (2014). Challenging tasks: The role of employees' and supervisors' goal orientations. *European Journal of Work and Organizational Psychology*, *23*(1), 48–61. doi: https://doi.org/10.1080/1359432X.2012.702420

[216] Preis, A. (2012). *Controller-Anforderungsprofile: Eine empirische Untersuchung*. Wiesbaden: Gabler Verlag | Springer Fachmedien. doi: https://doi.org/10.1007/978-3-8349-6760-2

[217] Prihantari, G. A. P. E. D., Astika, I. B. P. (2019). Effect of role overload, budget participation, environmental uncertainty, organizational culture, competence, and compensation on employee performance. *International Research Journal of Management, IT and Social Sciences*, *6*(4), 197–206. doi: https://doi.org/10.21744/irjmis.v6n4.682

[218] Pugh, D. S., Hickson, D. J., Hinings, C. R., Turner, C. (1968). Dimensions of Organizational Stucture. *Administrative Science Quarterly.*, *13*(1), 65–105.

[219] PwC (2017). Finance as Business Partner - "Adding up or adding value". PricewaterhouseCoopers (PwC). Dostupno na: https://www.pwc.nl/nl/assets/documents/pwc-finance-as-business-partner-adding-up-or-adding-value-2017.pdf

[220] Rachmawati, R., Saudi, M. H. M. (2019). Environmental uncertainty, quality of management accounting information systems and quality of management accounting information. *Journal of Advanced Research in Dynamical and Control Systems*, *11*(3 Special Issue), 981–986.

[221] Rahman, S. A., Amran, A., Ahmad, N. H., Taghizadeh, S. K. (2015). Supporting entrepreneurial business success at the base of pyramid through entrepreneurial competencies. *Management Decision*, *53*(6), 1203–1223. doi: https://doi.org/10.1108/MD-08-2014-0531

[222] Ramadhan, Y. (2018). Determinants of Management Accounting Information Systems Quality on Management Accounting Information Quality. *Proceedings of the International Conference on Business, Economic, Social Science and Humanities* (225), 124–130.

[223] Ramli, A., Zainuddin, Z. N., Sulaiman, S., Muda, R. (2013). Changing Roles of Management Accountants in Malaysian Companies: A Preliminary Study. *International Journal of Finance and Accounting*, *2*(2), 89–93. doi:

https://doi.org/10.5923/j.ijfa.20130202.06

[224] Rante, A., Warokka, A. (2016). Leadership style, decentralisation and managerial performance: Does the management accounting system mediate the relationship? *Journal for Global Business Advancement*, *9*(1), 79–89. doi: https://doi.org/10.1504/JGBA.2016.074897

[225] Reinartz, W., Haenlein, M., Henseler, J. (2009). An empirical comparison of the efficacy of covariance-based and variance-based SEM. *International Journal of Research in Marketing*, *26*(4), 332–344. doi: https://doi.org/10.1016/j.ijresmar.2009.08.001

[226] Reuschenbach, D., Isensee, J., Ostrowicz, S. (2019). RPA u kontrolingu. *Kontroling, Financije i Menadžment*, 12, 32–36.

[227] Richards, G., Yeoh, W., Chong, A. Y. L., Popovič, A. (2017). Business Intelligence Effectiveness and Corporate Performance Management: An Empirical Analysis. *Journal of Computer Information Systems*, *59*(2), 188–196. doi: https://doi.org/10.1080/08874417.2017.1334244

[228] Richardson, J., Sallam, R., Schlegel, K., Kronz, A., Sun, J. (2020). *Magic Quadrant for Analytics and Business Intelligence Platforms*. *Gartner Reprint*. Preuzeto (10.04.2021.) na: https://www.gartner.com/doc/reprints?id=1-1Y7VEZB3&ct=200128&st=sb

[229] Richmond, V. P., McCroskey, J. C. . (2013). SocioCommunicative Style Scale (SCS). Measurement Instrument Database for the Social Science. Dostpuno na: https://www.midss.org/sites/default/files/scs.pdf

[230] Rikhardsson, P., Yigitbasioglu, O. (2018). Business intelligence & analytics in management accounting research: Status and future focus. *International Journal of Accounting Information Systems*, *29*(February), 37–58. doi: https://doi.org/10.1016/j.accinf.2018.03.001

[231] Ritonga, K., Zainuddin, Y. (2002). The effect of perceived environmental uncertainty on management accounting systems in Indonesian manufacturing companies: The role of Firm's Decentralization. *Jurnal Strategi Bisnis*, *8*, 17–30.

[232] Rogova, G. L. (2019). Information Quality in Fusion-Driven Human-Machine Environments. *Information Quality in Information Fusion and Decision Making. Information Fusion and Data Science*, 3–29. doi: https://doi.org/https://doi.org/10.1007/978-3-030-03643-0

[233] Roozen, F., Steens, B. (2006). *Reflections on the Future of Finance and Control*. Kluwer, Deventer.

[234] Rosenzweig, K. (1981). An Exploratory Field Study ff The Relationships Between The Controller 's Department And Overall Organizational Characteristics. *Accounting, Organizations and Society*, *6*(4), 339–354. doi: https://doi.org/10.1016/0361-3682(81)90013-1

[235] Rouwelaar, H. ten, Bots, J., De Loo, I. (2018). The influence of management accountants on managerial decisions. *Journal of Applied Accounting Research*, *19*(4), 442–464. doi: https://doi.org/10.1108/JAAR-10-2016-0101

[236] Rupčić, N. (2018). *Suvremeni menadžment - teorija i praksa*. Rijeka: Ekonomski fakultet Sveučilišta u Rijeci.

[237] Sarstedt, M., Hair, J. F. J., Cheah, J.-H., Becker, J.-M., Ringle, C. M. (2019). How to specify, estimate, and validate higher-order constructs in PLS-SEM. *Australasian*

Marketing Journal, *27*(3), 197–211. doi: https://doi.org/10.1016/j.ausmj.2019.05.003

[238] Sarstedt, M., Ringle, C. M., Hair, J. F. (2017). Partial Least Squares Structural Equation Modeling. U: C. Homburg, M. Klarmann, A. Vomberg (ur.), *Handbook of Market Research* (str. 2–40). Heidelberg: Springer. doi: https://doi.org/10.1007/978-3-319-05542-8

[239] Sathe, V. (1982). *Controller Involvment in Management*. Englewood Cliffs, New Jersey: Prentice Hall Inc.

[240] Sathe, V. (1983). The Controller's Role in Management. *Organizational Dynamics*, *11*(3), 31–48. doi: https://doi.org/10.1016/0090-2616(83)90004-9

[241] Schacht, S. (2020). Controlling 2025 – Exploring the future of controlling: Virtueller Gastvortrag aus der Praxis. Deloitte Consulting GmbH. Dostupno na: https://www.dillerup.net/fileadmin/default/Media/Vorträge/V_2020_WS/Deloitte_Controlling_2025_Gastvortrag_Exkl_Video.pdf

[242] Schäffer, U. (2007). *Management Accounting & Control Scales Handbook* (1. izdanje). Wiesbaden: Deutscher Universitäts-Verlag GmbH.

[243] Schäffer, U. (2017). Man muss die Maschine einfach mal machen lassen. *Controlling & Management Review*, *61*, 24–31. doi: https://doi.org/https://doi.org/10.1007/s12176-017-0115-2

[244] Schäffer, U., Brückner, L. (2019). Rollenspezifische Kompetenzprofile für das Controlling der Zukunft. *Controlling & Management Review*, *63*, 14–31. doi: https://doi.org/https://doi.org/10.1007/s12176-019-0046-1

[245] Schäffer, U., Steiners, D. (2004). *The use of management accounting information, learning and organizational performance*. *European Business School Working Papers on Management Chair of Management Accounting & Control European Business School* (Vol. 11). Oestrich-Winkel. Dostupno na: https://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.118.1961&rep=rep1&type=pdf

[246] Schön, D. (2018). *Planung und Reporting im BI-gestützten Controlling: Grundlagen, Business Intelligence, Mobile BI und Big-Data-Analytics* (3. izdanje). Wiesbaden: Springer Gabler. doi: https://doi.org/10.1007/978-3-658-19963-0

[247] Seibert, S., Kraimer, M., Crant, J. . (1999). Proactive Personality and Career Success. *Journal of Applied Psychology*, *84*(3), 416–427. doi: https://doi.org/10.1037/0021-9010.84.3.416

[248] Sejdić, G. (2017). Kontroling u industriji 4.0. *Kontroling, Financije i Menadžment*, (1), 20–25.

[249] Sejdić, G. (2019). Model digitalne transformacije kontrolinga i financija. *Kontroling, Financije i Menadžment*, 12, 18–24.

[250] Shahzad, I. A., Farrukh, M., Ahmed, N. O. A., Lin, L., Kanwal, N. (2018). The role of transformational leadership style, organizational structure and job characteristics in developing psychological empowerment among banking professionals. *Journal of Chinese Human Resource Management*, *9*(2), 107–122. doi: https://doi.org/10.1108/JCHRM-01-2018-0002

[251] Shirazi, A., Mortazavi, S. (2009). Effective Management Performance A Competency-Based Perspective. *International Review of Business Research Papers*, *5*(1), 1–10.

[252] Shmueli, G., Ray, S., Velasquez Estrada, J. M., Chatla, S. B. (2016). The elephant in the room: Predictive performance of PLS models. *Journal of Business Research*, *69*(10), 4552–4564. doi: https://doi.org/10.1016/j.jbusres.2016.03.049

[253] Shmueli, G., Sarstedt, M., Hair, J. F. J., Cheah, J.-H., Ting, H., Vaithilingam, S., Ringle, C. M. (2019). Predictive model assessment in PLS-SEM: guidelines for using PLSpredict. *European Journal of Marketing*, *53*(11), 2322–2347. doi: https://doi.org/10.1108/EJM-02-2019-0189

[254] Sijbom, R. B. L., Janssen, O., Van Yperen, N. W. (2015). Leaders' receptivity to subordinates' creative input: The role of achievement goals and composition of creative input. *European Journal of Work and Organizational Psychology*, *24*(3), 462–478. doi: https://doi.org/10.1080/1359432X.2014.964215

[255] Sikavica, P., Bahtijarević-Šiber, F. (2004). *Menadžment: Teorija menadžmenta i veliko empirijsko istraživanje u Hrvatskoj*. Zagreb: Masmedia.

[256] Šimić, D. (2015). Karakteristike vođenja kod menadžera u javnom i privatnom sektoru Šibensko-kninske županije. *Zbornik Radova Veleučilišta u Šibeniku*, *3–4*, 107–118.

[257] Singh, S., Sood, S., Bala, R. (2021). Passive leadership styles and perceived procrastination in leaders: a PLS-SEM approach. *World Review of Entrepreneurship Management and Sustainable Development*, *17*(1), 20–37. doi: https://doi.org/10.1504/WREMSD.2021.112085

[258] Smith, E. E., Krüger, J. (2008). A critical assessment of the perceptions of potential graduates regarding their generic skills level: An exploratory study. *South African Journal of Economic and Management Sciences*, *11*(2), 121–138. doi: https://doi.org/10.4102/sajems.v11i2.304

[259] Spillecke, D. (2006). *Interne Kundenorientierung des Controllerbereichs: messung - Erfolgsauswirkungen - Determinanten*. Wiesbaden: Gabler Verlag | Springer Fachmedien Wiesbaden GmbH. doi: https://doi.org/10.1007/978-3-8350-9101-6

[260] Stamatović, D. (2019). RPA-Robotic process automation. *Kontroling, Financije i Menadžment*, 12, 29–31.

[261] Steyn, Z., Van Staden, L. J. (2018). Investigating selected self-management competencies of managers. *Acta Commercii*, *18*(1), a530. doi: https://doi.org/10.4102/ac.v18i1.530

[262] Strajher, A. (2019, September). Podaci - najvrjednija imovina poduzeća. *Kontroling, Financije i Menadžment*, 11, 28–32.

[263] Streukens, S., Leroi-Werelds, S. (2016). Bootstrapping and PLS-SEM: A step-by-step guide to get more out of your bootstrap results. *European Management Journal*, *34*(6), 618–632. doi: https://doi.org/10.1016/j.emj.2016.06.003

[264] Sujiati, Ma'arif, M. S., Najib, M. (2017). the Effect of Motivation and Competence on Employee Performance in Satellite Technology Center - National Institute Aeronautics and Space. *Jurnal Aplikasi Manajemen*, *15*(2), 229–237. doi: https://doi.org/10.21776/ub.jam.2017.015.02.06

[265] Timmins, F., McCabe, C. (2005). Nurses ' and midwives ' assertive behaviour in the workplace. *Journal of Advanced Nursing*, *51*(1), 38–45. doi: https://doi.org/10.1111/j.1365-2648.2005.03458.x

[266] Toderi, S., Balducci, C. (2018). Stress-preventive management competencies, psychosocialwork environments, and affective well-being: A multilevel, multisource

investigation. *International Journal of Environmental Research and Public Health*, *15*(3), 1–16. doi: https://doi.org/10.3390/ijerph15030397

[267] Tuan Mat, Z., Smith, M. (2014). The Impact of Changes in Environment and AMT on Management Accounting Practices and Organizational Strategy, Structure and Performance. *Journal of Applied Management Accounting Research*, *12*(1), 55–82.

[268] Tucker, B. J., Foldesy, J., Roos, A., Rodt, M. (2017). How Digital CFO s Are Transforming Finance. The Boston Consulting group.

[269] Ulich, E. (2013). Arbeitssysteme als Soziotechnische Systeme – eine Erinnerung. *Psychology of Everyday Activity*, *6*(1), 4–12.

[270] Vareschi&Partners. (n.d.). Business partner controller: Development models for business controllers. Dostupno na: https://www.vareschipartners.it/media/eng/BP_controller_ENG.pdf

[271] Vijayabanu, C., Arunkumar, S. (2018). Strengthening the Team Performance through personality and emotional intelligence: Smart PLS approach. *Scientific Annals of Economics and Business*, *65*(3), 303–316. doi: https://doi.org/10.2478/saeb-2018-0019

[272] Vitezić, N. (2002, April). Upravljačka uloga interne revizije i kontrolinga. *Računodstvo, Revizija i Financije*, 47–54.

[273] Vitezić, N. (2008). Interaktivni odnos računovodstva, kontrolinga i internog nadzora. *Računovodstvo i porezi u sadašnjim uvjetima poslovanja, IX. Savjetovanje* (str. 29–46). Zagreb-Šibenik: Hrvatski računovođa.

[274] Vitezić, N. (2011). Kontroling – plansko analitička i informativna aktivnost i podrška efikasnijem upravljanju u uvjetima dugoročne održivosti. *Kontroler: Bilten Udruge Hrvatskih Kontrolera*, *9*, 2–3.

[275] Vitezić, N. (2016). Kontroling i korporativno upravljanje (autorizirana predavanja), poslijediplomski specijalistički sveučilišni studij Kontroling. Rijeka: Sveučilište u Rijeci, Ekonomski fakultet.

[276] Vitezić, N. (2018). Digitalni kontroling. *Kontroler: Bilten Udruge Hrvatskih Kontrolera*, (10), 2–3.

[277] Vitezić, N. (2020). Kontroling (autorizirana predavanja), diplomski specijalistički sveučilišni studij. Rijeka: Sveučilište u Rijeci, Ekonomski fakultet.

[278] Vitezić, N., Lebefromm, U. (2019). *Production Controlling in the Digital Age*. Rijeka: Sveučilište u Rijeci, Ekonomski fakultet.

[279] Vitezić, N., Lebefromm, U., Petrlić, A. (2019). From analytic to predictive digital performance measurement - A new challenge for controlling. U: S. Drezgić, S. Žiković, M. Tomljanović (ur.), *Economics of Digital Transformation* (str. 239–251). Rijeka: University of Rijeka, Faculty of Economics and Business.

[280] Vitezić, N., Petrlić, A. (2017). Kontroling u javnom sektoru. *Računodstvo, Revizija i Financije, Prilog*, 36–40.

[281] Wadan, R., Teuteberg, F., Bensberg, F., Buscher, G. (2019). Understanding the Changing Role of the Management Accountant in the Age of Industry 4.0 in Germany. *Proceedings of the 52nd Hawaii International Conference on System Sciences* (str. 5817–5826). HICSS. doi: https://doi.org/10.24251/HICSS.2019.702

[282] Wahdiat, I. S., Syifaudin, A., Mardi, M., Nurhadiyati, S., Neliana, T. (2018). Factors that

Affect Management Accounting Information Systems and its Implication to the Quality of Management Accounting Information (Cooperative industries at Kuningan Indonesia). *1st International Conference on Economics, Business, Entrepreneurship, and Finance (ICEBEF 2018)* (Vol. 65, str. 437–440). doi: https://doi.org/10.2991/icebef-18.2019.95

[283] Wang, G., Netemeyer, R. G. (2004). Salesperson creative performance: conceptualization, measurement, and nomological validity. *Journal of Business Research*, *57*, 805–812. doi: https://doi.org/10.1016/S0148-2963(02)00483-6

[284] Wang, R. Y., Strong, D. M. (1996). Beyond Accuracy: What Data Quality Means to Data Consumers. *Journal of Management Information Systems*, *12*(4), 5–33. doi: https://doi.org/10.1080/07421222.1996.11518099

[285] Wardhani, K. N. (2017). Influence of Competence, Transformational Leadership, Social Capital and Performance on Employee Careers. *International Journal of Human Capital Management*, *1*(2), 81–94. doi: https://doi.org/10.21009/ijhcm.012.10

[286] Warren, J. D. J., Moffitt, K. C., & Byrnes, P. (2015). How Big Data Will Change Accounting. *Accounting Horizons*, *29*(2), 397–407. doi: https://doi.org/10.2308/acch-51069

[287] Weber, J., Schäffer, U. (2014). The Journey from " Master of Numbers " to Business Partner. WHU – Otto Beisheim School of Management. Dostupno na: https://www.whu-on-controlling.com/en/latest-thinking/business-partner/

[288] Wegener, D. (2019). Industrie 4.0 – wie die Digitalisierung die Produktionskette revolutioniert. U: R. Obermaier (ur.), *Handbuch Industrie 4.0 und Digitale Transformation: Betriebswirtschaftliche, technische und rechtliche Herausforderungen* (str. 73–89). Wiesbaden: Springer Gabler. doi: https://doi.org/https://doi.org/10.1007/978-3-658-24576-4_3

[289] Weichel, P., Herrmann, J. (2016). Wie Controller von Big Data profitieren können. *Controlling & Management Review Sonderheft*, 8–14. doi: https://doi.org/10.1007/978-3-658-13444-0

[290] Weinzimmer, L., Robin, J., Michel, E. (2012). The Measurement of Strategic Orientation and its Efficacy in Predicting Financial Performance. *Journal of Business Strategies*, *29*(2), 81.

[291] Weißenberger, B. E., Angelkort, H. (2011). Integration of financial and management accounting systems: The mediating influence of a consistent financial language on controllership effectiveness. *Management Accounting Research*, *22*(3), 160–180. doi: https://doi.org/10.1016/j.mar.2011.03.003

[292] Weißenberger, B. E., Angelkort, H., Holthoff, G. (2012). MAS Integration and Controllership Effectiveness: Evidence of a Preparer-User Perception Gap. *German Academic Association for Business Research (VHB)*, *5*(2), 134–153.

[293] Wieder, B., & Ossimitz, M. L. (2015). The Impact of Business Intelligence on the Quality of Decision Making - A Mediation Model. *Procedia Computer Science* (Vol. 64, str. 1163–1171). Elsevier Masson SAS. doi: https://doi.org/10.1016/j.procs.2015.08.599

[294] Williams, S., Williams, N. (2007). *The Profit Impact of Business Intelligence*. San Francisco: Morgan Kaufmann Publishers in an imprint of Elsevier. doi: https://doi.org/10.1017/CBO9781107415324.004

[295] Wixom, B. H., Todd, P. A. (2005). A Theoretical Integration of User Satisfaction and Technology Acceptance.

[296] Wolf, S., Weißenberger, B. E., Wehner, M. C., Kabst, R. (2015). Controllers as business partners in managerial decision-making: Attitude, subjective norm, and internal improvements. *Journal of Accounting & Organizational Change*, *11*(1), 24–46. doi: https://doi.org/10.1108/JAOC-10-2012-0100

[297] Wolf, T., Heidlmayer, M. (2019). Die Auswirkungen der Digitalisierung auf die Rolle des Controllers. U: B. Feldbauer-Durstmüller, S. Mayr (ur.), *Controlling – Aktuelle Entwicklungen und Herausforderungen* (str. 21–48). Wiesbaden: Springer Gabler. doi: https://doi.org/https://doi.org/10.1007/978-3-658-27723-9_1

[298] Xu, H. (2015). What are the most important factors for accounting information quality and their impact on AIS data quality outcomes? *Journal of Data and Information Quality*, *5*(4), 14. doi: https://doi.org/10.1145/2700833

[299] Xu, H., Nord, J. H., Nord, G. D., & Lin, B. (2003). Key issues of accounting information quality management: Australian case studies. *Industrial Management & Data Systems*, *103*(7), 461–470. doi: https://doi.org/10.1108/02635570310489160

[300] Yigitbasioglu, O. M. (2017). Drivers of management accounting adaptability: The agility lens. *Journal of Accounting and Organizational Change*, *13*(2), 262–281. doi: https://doi.org/10.1108/JAOC-12-2015-0092

[301] Zekić, Z. (2007). *Menadžment*. Rijeka: Ekonomski fakultet Sveučilišta u Rijeci.

[302] Zhou, J., George, J. M. (2001). When Job Dissatisfaction Leads to Creativity: Encouraging the Expression of Voice. *The Academy of Management Journal*, *44*(4), 682–696. doi: https://doi.org/10.5465/3069410

[303] Zoni, L. (2017). Management accountants in Italy: economic, institutional and educational environment, and evidence from the job market. U: L. Goretzki, E. Strauss (ur.), *The Role of the Management Accounting: Local Variations and Global Influences* (str. 117–135). Routledge Studies in Accounting.

[304] Zoni, L., Merchant, K. A. (2007). Controller Involvement in Management : an empirical study in large Italian corporations. *Journal of Accounting & Organizational Change*, *3*(1), 29–43. doi: https://doi.org/10.1108/18325910710732849

POPIS TABLICA

Tablica 1: Prilike i izazovi/prijetnje Big Data za kontroling 20
Tablica 2: Orijentacija i tehnike poslovne analitike 26
Tablica 3: Karakteristike „jakog“ kontrolera 50
Tablica 4: „Meke“ vještine potrebne u poslovanju 57
Tablica 5: Pregled HOC konstrukata, pripadajućih LOC-ova i broja čestica konceptualnog modela 85
Tablica 6: Operacionalizacija HOC konstrukta *Karakteristike kontrolera* 90
Tablica 7: Operacionalizacija HOC konstrukta *Karakteristike menadžera* 93
Tablica 8: Operacionalizacija HOC konstrukta *Karakteristike poduzeća* 94
Tablica 9: Operacionalizacija HOC konstrukta *Karakteristike okruženja* 95
Tablica 10: Operacionalizacija konstrukta *Kvaliteta kontrolerovog outputa* i *Kontrolerov utjecaj na donošenje odluka* 96
Tablica 11: Socio-demografska obilježja uzorka kontrolera (n=148) 99
Tablica 12: Socio-demografska obilježja „dyadic“ uzorka menadžera i kontrolera (n=64) .. 101
Tablica 13: Preporuka minimalne veličina uzorka pri statističkoj snazi od 80% 104
Tablica 14: Multivarijatne statističke metode 106
Tablica 15: Analiza vrsta i učestalosti kontrolerovih aktivnosti - analiza i informacija (n = 131; Likert 1-nikada; 2-gotovo nikada; 3-rijetko; 4-ponekad; 5-često; 6-vrlo često; 7-redovito) 108
Tablica 16: Analiza vrsta nefinancijskih informacija i učestalosti njihova pružanja menadžmentu u svrhu poslovnog odlučivanja (n = 131; Likert 1-nikada; 2-gotovo nikada; 3-rijetko; 4-ponekad; 5-često; 6-vrlo često; 7-redovito) 109
Tablica 17: Analiza korisnosti primjene Big Data (n = 131) 110
Tablica 18: Deskriptivna statistička analiza HOC, LOC i endogenih jednodimenzionalnih čestica prvog uzorka (n=148) 112
Tablica 19: Deskriptivna statistička analiza HOC, LOC i endogenih jednodimenzionalnih čestica drugog uzorka (n=64) 115
Tablica 20: Rezultati LOC konstrukata mjernog modela (Model 1) 123
Tablica 21: HTMT vrijednosti modela (Model 1) 127
Tablica 22: Rezultati HOC konstrukata mjernog modela (Model 1) 128
Tablica 23: Unutarnji faktori inflacije varijance (Model 1) 130
Tablica 24: Rezultati značajnosti i jačine koeficijenata puta strukturnog modela (Model 1) 131

Tablica 25: PLSpredict rezultati (Model 1)..... 138
Tablica 26: Unutarnji faktori inflacije varijance (Model 1a)..... 141
Tablica 27: Rezultati značajnosti i jačine koeficijenata puta strukturnog modela (Model 1a) 142
Tablica 28: PLSpredict rezultati (Model 1a)..... 142
Tablica 29: Rezultati LOC konstrukata mjernog modela (Model 2)..... 143
Tablica 30: HTMT vrijednosti modela (Model 2)..... 146
Tablica 31: Rezultati HOC konstrukata mjernog modela (Model 2)..... 147
Tablica 32: Unutarnji faktori inflacije varijance (Model 2)..... 148
Tablica 33: Rezultati značajnosti i jačine koeficijenata puta strukturnog modela (Model 2) 148
Tablica 34: Rezultati značajnosti i jačine koeficijenata puta strukturnog modela (Model 2a) 149
Tablica 35: PLSpredict rezultati (Model 2a)..... 151

POPIS GRAFIKONA

Grafikon 1 - 4: Ocjena značajki korištenih BI sustava..... 134
Grafikon 5 - 9: PLS manifestni rezidualni histogrami (Model 1)..... 138

POPIS SLIKA

Slika 1: Generacije kontrolinga..... 14
Slika 2: Model digitalne transformacije kontrolinga..... 16
Slika 3: Pregled razvoja poslovne analitike..... 17
Slika 4: Odnos kontrolera i menadžera kao poslovnih partnera..... 30
Slika 5: Ovisnost kontrolinga o obilježjima menadžmenta..... 31
Slika 6: Budućnost odnosa menadžera, kontrolera i podatkovnog znanstvenika..... 34
Slika 7: Utjecaj digitalizacije na centralnu funkciju kontrolinga..... 35
Slika 8: Temeljni konceptualni model istraživanja..... 40
Slika 9: Karakteristike kvalitete podataka i informacija..... 46
Slika 10: Konceptualni model istraživanja..... 81
Slika 11: Vrste drugo-rednih HCM modela..... 83
Slika 12: Primjer reflektivno-reflektivnog HOC-a konceptualnog modela istraživanja..... 84

Slika 13: Primjer primjene pristupa ponovljenog indikatora na HOC-u Karakteristike kontrolera 86
Slika 14: G*Power rezultati 105
Slika 15: Kriteriji procjene reflektivnog mjernog modela 120
Slika 16: Postupak i kriteriji procjene strukturnog modela 121
Slika 17: Konceptualni model istraživanja postavljen u softveru SmartPLS (v. 3.3.3) 122
Slika 18: Heterotrait-Monotrait - HTMT 129
Slika 19: Rezultati značajnosti (p-vrijednosti) i jačine koeficijenata puta strukturnog modela (Model 1) 133
Slika 20: Gartnerov magični kvadrant primjene BI sustava 135
Slika 21: Modificirani strukturni model (Model 1a) 140
Slika 22: Strukturni Model 2a 149

POPIS PRIVITAKA

Privitak 1: Anketa za kontrolere - 1.dio 193
Privitak 2: Anketa za kontrolere - 2.dio 222
Privitak 3: Anketa za menadžera 234
Privitak 4: PLS algoritam rezultati modela (Model 1) 246
Privitak 5: Izračun Cronbach Alfe visoko-rednih konstrukata (Model 1) 247
Privitak 6: Izračun AVE i CR visoko-rednih konstrukata (Model 1) 248
Privitak 7: Izračun HTMT vrijednosti visoko-rednih konstrukata (Model 1) 249
Privitak 8: Izračun Cronbach Alfe visoko-rednih konstrukata (Model 2) 251
Privitak 9: Izračun AVE i CR visoko-rednih konstrukata (Model 2) 252
Privitak 10: Izračun HTMT vrijednosti visoko-rednih konstrukata (Model 2) 253

PRIVICI

Privitak 1: Anketa za kontrolere - 1.dio

Anketa za kontrolere (1. DIO)

Poštovani,

popunjavanje upitnika je dobrovoljno i anonimno, a podaci će se koristiti isključivo u znanstveno-istraživačke svrhe i neće se zlorabiti na bilo koji način. Odnosno, sudionicima koji i odluče navesti vlastite podatke (naziv poduzeća i/ili e-adresu) osigurana je stroga anonimnost svih podataka.

Dobiveni rezultati će se analizirati na razini ukupnog uzorka te koristiti isključivo u svrhe ovog istraživanja. Upitnik se sastoji od više skupina precizno sažetih tvrdnji, tj. pitanja. Molim Vas da pažljivo pročitate svaku tvrdnju jer ne postoje točni i netočni odgovori, te da objektivno odgovorite s obzriom na to da je svaki Vaš odgovor od presudne važnosti za utvrđivanje postavljenog cilja istraživanja.

Očekivano vrijeme potrebno za ispunjavanje ovog dijela upitnika je 20 minuta.

NAPOMENA 1:
Prije početka ispunjavanja molim Vas da proizvoljno kreirate i upišete tzv. "Zajedničku oznaku". Oznaka može biti bilo koje duljine i može sadržavati bilo koju kombinaciju slova, brojki i simbola. Molim da kreiranu oznaku proslijedite svom nadređenom (osobi kojoj dostavljate izvještaje i pomažete u poslovnom odlučivanju) skupa s linkom ankete za menadžere dostavljene u e-mailu.

NAPOMENA 2:
Ukoliko se odlučite ne navesti ime poduzeća, na kraju ankete molit ću da ispunite sljedeća četiri financjiska podatka za 2019 godinu (na dan, 31.12.2019):

1. Dobit (ili gubitak) nakon oporezivanja (AOP 183)
2. Ukupna aktiva (AOP 065)
3. Kapital i rezerve (AOP 067)
4. Ukupni prihod (AOP 177)

Ukoliko imate pitanja ili nejasnoća molim Vas da me kontaktirate na e-adresu ili mobitel: antonija.petrlic@efri.hr ili 095/864-1991

* Required

1. ZAJEDNIČKA OZNAKA: *

NAPOMENA: Molim Vas da si zapišete i spremite oznaku jer će Vam biti potrebna za popunjavanje drugog dijela ankete, kao i za potrebe slanja upitnika menadžeru.

INFORMACIJE O ISPITANIKU, PODUZEĆU I ODJELU KONTROLINGA

2. Spol: *

Mark only one oval.

- ◯ Muško
- ◯ Žensko
- ◯ Ostalo

3. Dob (u godinama): *

_____

4. Stupanj obrazovanja: *
(moguć višestruki odabir)

Check all that apply.

- ☐ SSS ili SŠS
- ☐ VŠS (npr. bacc.oec.)
- ☐ VSS (npr. mag.oec.)
- ☐ sveučilišni specijalist struke (npr. univ.spec.oec.)
- ☐ magistar znanosti (mr. sc.)
- ☐ doktor znanosti (dr. sc)

Other: ☐ _____

5. Ukupno radno iskustvo (u godinama): *

Check all that apply.

- ☐ 1
- ☐ 2
- ☐ 3
- ☐ ....

6. Ukupno radno iskustvo na poslovima kontrolinga (u godinama): *

Check all that apply.

- [ ] 1
- [ ] 2
- [ ] 3
- [ ] ....

7. Ukupno radno iskustvo na srodnim poslovima kao nrp. računovodstvo, financije, revizija, razvoj itd. (u godinama): *

Check all that apply.

- [ ] 1
- [ ] 2
- [ ] 3
- [ ] ....

8. Puni naziv odjela u kojem radite: *

_____

9. Naziv radnog mjesta: *

_____

10. Broj zaposlenih koji vrše posao kontrolinga u poduzeću:

_____

11. Odjel kontrolinga organizacijski je: *

Centraliziran=kontroling postavljen kao štabna služba, najčešće odgovorna menadžmentu (direktoru) tj. upravi poduzeća / Decentraliziran=kontroling koji je smješten u svim relevantnim odjelima ili sektorima organizacije

Mark only one oval.

- ◯ Centraliziran
- ◯ Decentraliziran
- ◯ Kombinacija centraliziranog i decentraliziranog

12. Vlasništvo kapitala:

Mark only one oval.

- ◯ hrvatsko
- ◯ većinsko hrvatsko
- ◯ većinsko strano
- ◯ strano

13. Poduzeće ima internu reviziju: *

Mark only one oval.

- ◯ DA
- ◯ NE

14. Koje poduzeće vrši eksternu reviziju vašeg poslovanja: *

Mark only one oval.

- ◯ Nemamo eksternu revziju
- ◯ Deloitte & Touche
- ◯ Ernst & Young
- ◯ KPMG
- ◯ PricewaterhouseCoopers (PwC)
- ◯ Other: _____

KARAKTERISTIKE KONTROLERA

U kojoj se mjeri slažete sa sljedećim tvrdnjama koje se odnose na VAŠE osobne karakteristike?

15. ANALITIČNOST *

Mark only one oval per row.

	1 - u potpunosti se ne slažem	2 - ne slažem se	3 - donekle se ne slažem	4 - niti se slažem niti se ne slažem	5 - donekle se slažem	6 - slažem se	7 - u potpunosti se slažem
Sposoban sam objasniti značenje brojeva.	◯	◯	◯	◯	◯	◯	◯
Fokusiran sam i razumijem izvore problema.	◯	◯	◯	◯	◯	◯	◯
Usmjeren sam ka budućnosti.	◯	◯	◯	◯	◯	◯	◯
Sposoban sam uočiti trendove prije nego postanu stvarnost.	◯	◯	◯	◯	◯	◯	◯
Dobar sam u korištenju, strukturiranju i obradi brojeva.	◯	◯	◯	◯	◯	◯	◯

16. KOMUNIKATIVNOST *

Mark only one oval per row.

	1 - u potpunosti se ne slažem	2 - ne slažem se	3 - donekle se ne slažem	4 - niti se slažem niti se ne slažem	5 - donekle se slažem	6 - slažem se	7 - u potpunosti se slažem
Lako uspostavljam kontakt s drugima i slušam sugovornike.	◯	◯	◯	◯	◯	◯	◯
Jasno komuniciram svoje ideje usmenim putem.	◯	◯	◯	◯	◯	◯	◯
Jasno komuniciram svoje ideje pismenim putem.	◯	◯	◯	◯	◯	◯	◯
Mogu uvjeriti druge ljude da slijede moje ideje.	◯	◯	◯	◯	◯	◯	◯
Sposoban sam prenijeti poruku, tj. važni sadržaj.	◯	◯	◯	◯	◯	◯	◯

17. ASERTIVNOST *

Mark only one oval per row.

	1 - u potpunosti se ne slažem	2 - ne slažem se	3 - donekle se ne slažem	4 - niti se slažem niti se ne slažem	5 - donekle se slažem	6 - slažem se	7 - u potpunosti se slažem
Jasno izražavam svoje mišljenje, osjećaje i stavove.	⬭	⬭	⬭	⬭	⬭	⬭	⬭
Izražavam svoje neslaganje sa mišljenjima drugih.	⬭	⬭	⬭	⬭	⬭	⬭	⬭
Dajem konstruktivne kritike.	⬭	⬭	⬭	⬭	⬭	⬭	⬭
Nije mi problem reći NE drugima.	⬭	⬭	⬭	⬭	⬭	⬭	⬭
Dopuštam drugima da izraze svoje mišljenje.	⬭	⬭	⬭	⬭	⬭	⬭	⬭

18. PROAKTIVNOST *

Mark only one oval per row.

	1 - u potpunosti se ne slažem	2 - ne slažem se	3 - donekle se ne slažem	4 - niti se slažem niti se ne slažem	5 - donekle se slažem	6 - slažem se	7 - u potpunosti se slažem
Prilika i izazov mi je vidjeti da se moje ideje pretvaraju u stvarnost.	◯	◯	◯	◯	◯	◯	◯
Samoinicijativno popravljam uočene greške, probleme i nedostatke.	◯	◯	◯	◯	◯	◯	◯
Uvijek tragam za boljim načinima rada i načinima rješavanja problema.	◯	◯	◯	◯	◯	◯	◯
Prepreke me ne sprječavaju u ostvarenju ciljeva i ideja u koje vjerujem.	◯	◯	◯	◯	◯	◯	◯
Izravno se suočavam s problemima.	◯	◯	◯	◯	◯	◯	◯
Probleme pretvaram u prilike.	◯	◯	◯	◯	◯	◯	◯

19. KREATIVNOST *

Mark only one oval per row.

	1 - u potpunosti se ne slažem	2 - ne slažem se	3 - donekle se ne slažem	4 - niti se slažem niti se ne slažem	5 - donekle se slažem	6 - slažem se	7 - u potpunosti se slažem
Predlažem kreativna rješenja problema i pri tome se ne bojim preuzeti rizik.	◯	◯	◯	◯	◯	◯	◯
Promičem i zagovaram vlastite kreativne ideje i ideje drugih.	◯	◯	◯	◯	◯	◯	◯
Moja kreativnost dolazi do izražaja prilikom rješavanja složenih problem.	◯	◯	◯	◯	◯	◯	◯
Predlažem nove načine postizanja ciljeva i ciljanih vrijednosti.	◯	◯	◯	◯	◯	◯	◯

20. POZNAVANJE POSLOVANJA *

Mark only one oval per row.

	1 - u potpunosti se ne slažem	2 - ne slažem se	3 - donekle se ne slažem	4 - niti se slažem niti se ne slažem	5 - donekle se slažem	6 - slažem se	7 - u potpunosti se slažem
Razumijem viziju / misiju / ciljeve poduzeća u cijelosti.	⬭	⬭	⬭	⬭	⬭	⬭	⬭
U cijelosti razumijem ključne resurse i/ili procese koje osiguravaju stratešku prednost poduzeću.	⬭	⬭	⬭	⬭	⬭	⬭	⬭
Razumijem poslovne procese u poduzeću.	⬭	⬭	⬭	⬭	⬭	⬭	⬭
Razumijem postupak stvaranja dodane vrijednosti u cijelosti.	⬭	⬭	⬭	⬭	⬭	⬭	⬭

21. Koju bi ste ukupnu ocjenu dali svim vašim gore navedenim kompetencijama? *

1 - neprihvatljivo / 2 - jako loše / 3 - loše / 4 - zadovoljavajuće / 5 - dobro / 6 - jako dobro / 7 - odlično

Mark only one oval.

1	2	3	4	5	6	7
◯	◯	◯	◯	◯	◯	◯

22. Kako biste ocijenili svoje sljedeće profesionalne i IT vještine?

Mark only one oval per row.

	1- neprihvatljivo poznavanje	2-jako loše	3-loše	4- zadovoljavajuće	5- dobro	6- jako dobro	7-odlično poznavanje
Strateški instrumenti kontrolinga	◯	◯	◯	◯	◯	◯	◯
Operativni instrumenti kontrolinga	◯	◯	◯	◯	◯	◯	◯
Sustav internih kontrola i ulogu interne revizije u ocjeni pouzdanosti internih podataka.	◯	◯	◯	◯	◯	◯	◯
Microsoft Excel	◯	◯	◯	◯	◯	◯	◯

Skip to question 23

KARAKTERISTIKE MENADŽERA

U kojoj se mjeri slažete sa sljedećim tvrdnjama koje se odnose na vašeg menadžera, tj. osobu kojoj pomažete u donošenju odluka?

23. PROAKTIVAN I USMJEREN CILJEVIMA *

„Moj menadžer..."

Mark only one oval per row.

	1 - u potpunosti se ne slažem	2 - ne slažem se	3 - donekle se ne slažem	4 - niti se slažem niti se ne slažem	5 - donekle se slažem	6 - slažem se	7 - u potpunosti se slažem
Uočava i rješava probleme na vrijeme.	◯	◯	◯	◯	◯	◯	◯
Preuzima inicijativu za rješavanje problema.	◯	◯	◯	◯	◯	◯	◯
Ne zazire od rješavanja problema.	◯	◯	◯	◯	◯	◯	◯
Učinkovito koristi prilike kako bi postigao svoje ciljeve.	◯	◯	◯	◯	◯	◯	◯
Aktivno se uključuje u rješavanje nastalih problema.	◯	◯	◯	◯	◯	◯	◯
Ističe se u realizaciji ideja.	◯	◯	◯	◯	◯	◯	◯

24. VOĐA I INICIJATOR *

„Moj menadžer..."

Mark only one oval per row.

	1 - u potpunosti se ne slažem	2 - ne slažem se	3 - donekle se ne slažem	4 - niti se slažem niti se ne slažem	5 - donekle se slažem	6 - slažem se	7 - u potpunosti se slažem
Iskazuje povjerenje i etičnost.	◯	◯	◯	◯	◯	◯	◯
Naglašava kolektivnu misiju.	◯	◯	◯	◯	◯	◯	◯
Govori pozitivno o budućnosti.	◯	◯	◯	◯	◯	◯	◯
Ima poštovanje kontrolera i ostalih zaposlenika.	◯	◯	◯	◯	◯	◯	◯
Potiče svijest kontrolera i ostalih zaposlenika o onome što je doista važno.	◯	◯	◯	◯	◯	◯	◯

25. UVAŽAVANJE KONTROLERA *

„Moj menadžer..."

Mark only one oval per row.

	1 - u potpunosti se ne slažem	2 - ne slažem se	3 - donekle se ne slažem	4 - niti se slažem niti se ne slažem	5 - donekle se slažem	6 - slažem se	7 - u potpunosti se slažem
Cijeni znanje kontrolera.	◯	◯	◯	◯	◯	◯	◯
Poštuje kontrolerove vještine i kompetencije.	◯	◯	◯	◯	◯	◯	◯
Pouzdaje se u kontrolerove zaključke i prijedloge.	◯	◯	◯	◯	◯	◯	◯
Smatra kontrolera svojim poslovnim partnerom.	◯	◯	◯	◯	◯	◯	◯
Posao kontrolera smatra izuzetno važnom profesijom.	◯	◯	◯	◯	◯	◯	◯

26. Koju bi ste ukupnu ocjenu dali svim gore navedenim kompetencijama tj. sposobnostima vašeg menadžera? *

1 - neprihvatljivo / 2 - jako loše / 3 - loše / 4 - zadovoljavajuće / 5 - dobro / 6 - jako dobro / 7 - odlično

Mark only one oval.

1	2	3	4	5	6	7
◯	◯	◯	◯	◯	◯	◯

27. Kako biste ocijenili potrebu svog menadžera za dostizanjem poslovnog učinka?

1 - uopće mu nije važno / 2 - od male mu je važnosti / 3 - od prosječne mu je važnosti / 4 - vrlo mu je važno / 5 - izuzetno mu je važno

Mark only one oval.

1	2	3	4	5
◯	◯	◯	◯	◯

Skip to question 28

KARAKTERISTIKE PODUZEĆA

U kojoj se mjeri slažete sa sljedećim tvrdnjama vezane uz vaše poduzeće?

28. STRATEŠKA ORIJENTIRANOST *

Mark only one oval per row.

	1 - u potpunosti se ne slažem	2 - ne slažem se	3 - donekle se ne slažem	4 - niti se slažem niti se ne slažem	5 - donekle se slažem	6 - slažem se	7 - u potpunosti se slažem
Strateški smjer je transparentan.	◯	◯	◯	◯	◯	◯	◯
Postoji kolektivna vizija o tome kakvo će biti poduzeće u budućnosti.	◯	◯	◯	◯	◯	◯	◯
Postavljeni ciljevi i ciljane vrijednosti poduzeća povezane su s misijom, vizijom i strategijom.	◯	◯	◯	◯	◯	◯	◯
Postoji učinkovit strateški plan.	◯	◯	◯	◯	◯	◯	◯

29. FORMALIZACIJA ORGANIZACIJSKE STRUKTURE *

Mark only one oval per row.

	1 - u potpunosti se ne slažem	2 - ne slažem se	3 - donekle se ne slažem	4 - niti se slažem niti se ne slažem	5 - donekle se slažem	6 - slažem se	7 - u potpunosti se slažem
Poduzeće ima veliki broj propisanih pravila i procedura.	⬭	⬭	⬭	⬭	⬭	⬭	⬭
Postoji jasno definirana sistematizacija radnih mjesta - zadaci, odgovornosti i ovlasti.	⬭	⬭	⬭	⬭	⬭	⬭	⬭
Postoje jasno definirane hijerarhijske razine autorizacije i/ili odlučivanja.	⬭	⬭	⬭	⬭	⬭	⬭	⬭
Zaposlenici, uključujući kontroler, se pridržavaju jasno definiranih procedura.	⬭	⬭	⬭	⬭	⬭	⬭	⬭
Poduzeće vrši nadzor svakodnevnih operacija.	⬭	⬭	⬭	⬭	⬭	⬭	⬭

30. KVALITETA INFORMACIJSKOG SUSTAVA *

Informacijski sustav (ERP - Enterprise resource planning; npr. SAP, Oracle, Microsoft Dynamics, Pantheon itd.) ...

Mark only one oval per row.

	1 - u potpunosti se ne slažem	2 - ne slažem se	3 - donekle se ne slažem	4 - niti se slažem niti se ne slažem	5 - donekle se slažem	6 - slažem se	7 - u potpunosti se slažem
ima zadovoljavajuće vrijeme obrade podataka.	◯	◯	◯	◯	◯	◯	◯
čini informacije lako dostupnima.	◯	◯	◯	◯	◯	◯	◯
učinkovito integrira podatke različitih područja, tj. odjela poduzeća.	◯	◯	◯	◯	◯	◯	◯
omogućava učinkovitu analizu i obradu prikupljenih podataka.	◯	◯	◯	◯	◯	◯	◯
prilagodljiv je potrebama poduzeća, tj. izvršavanju poslovnih zadataka.	◯	◯	◯	◯	◯	◯	◯

31. DIGITALEN TEHNOLOGIJE *

Digitalna tehnologija predstavlja tehnologiju koja se oslanja na uporabu računala, tableta i mobitela, kao i aplikacija koje ovise o internetu i drugim uređajima kao što su videokamere, mikrofon i sl. (npr. razne aplikacije, platforme, informacijski sustavi itd.)

Mark only one oval per row.

	1 - u potpunosti se ne slažem	2 - ne slažem se	3 - donekle se ne slažem	4 - niti se slažem niti se ne slažem	5 - donekle se slažem	6 - slažem se	7 - u potpunosti se slažem
Poduzeće pokreće nove poslovne procese zasnovane na digitalnim tehnologijama.	◯	◯	◯	◯	◯	◯	◯
Poduzeće potiče korištenje digitalnih tehnologija u svakodnevnim poslovnim operacijama.	◯	◯	◯	◯	◯	◯	◯
Poduzeće integrira digitalne tehnologije kako bi potaknulo promjene i napredak.	◯	◯	◯	◯	◯	◯	◯

32. Koju bi ste ukupnu ocjenu dali svim gore navedenim karakteristikama vašeg poduzeća? *

1 - neprihvatljivo / 2 - jako loše / 3 - loše / 4 - zadovoljavajuće / 5 - dobro / 6 - jako dobro / 7 - odlično

Mark only one oval.

1	2	3	4	5	6	7
◯	◯	◯	◯	◯	◯	◯

33. Molim Vas navedite koji ERP sustav koristite unutar organizacije (npr. SAP, Oracle, Microsoft Dynamics, Pantheon, GoSoft, neki drugi ili vlastito razvijeni)

_____

Skip to question 34

KARAKTERISTIKE OKRUŽENJA

U kojoj se mjeri slažete sa sljedećim tvrdnjama vezane za poslovno okruženje, tj. djelatnost/ granu u kojoj posluje vaše poduzeća?

34. INTENZITET KONKURENTNOSTI *

Mark only one oval per row.

	1 - u potpunosti se ne slažem	2 - ne slažem se	3 - donekle se ne slažem	4 - niti se slažem niti se ne slažem	5 - donekle se slažem	6 - slažem se	7 - u potpunosti se slažem
Poslujemo u okruženju vrlo agresivnih konkurenata.							
Konkurencija je velika.							
Proizvodi, usluge i interni procesi koje imaju poduzeća lako se kopiraju.							
Poduzeća usmjeravaju velike napore k ostvarenju i zadržavaju tržišnog udjela.							
Informacije o konkurentima i njihovim tržišnim potezima su svakodnevne.							
Cjenovna konkurencija je jaka.							

35. TURBULENTNOST TEHNOLOGIJE *

Mark only one oval per row.

	1 - u potpunosti se ne slažem	2 - ne slažem se	3 - donekle se ne slažem	4 - niti se slažem niti se ne slažem	5 - donekle se slažem	6 - slažem se	7 - u potpunosti se slažem
Tehnološke promjene vrlo su česte.	⬭	⬭	⬭	⬭	⬭	⬭	⬭
Tehnološke promjene pružaju velike mogućnosti rasta.	⬭	⬭	⬭	⬭	⬭	⬭	⬭
Tehnološka otkrića prilika su za kreiranje novih ideja - proizvoda i usluga.	⬭	⬭	⬭	⬭	⬭	⬭	⬭
Tehnološka otkrića omogućavaju kreiranje boljih poslovnih procesa unutar poduzeća.	⬭	⬭	⬭	⬭	⬭	⬭	⬭
Tehološka otkrića i inovacije omogućuju efikasniju upotrebu podataka u analizi i poslovnom odlučivanju.	⬭	⬭	⬭	⬭	⬭	⬭	⬭

36. RIZIČNOST *

Mark only one oval per row.

	1 - u potpunosti se ne slažem	2 - ne slažem se	3 - donekle se ne slažem	4 - niti se slažem niti se ne slažem	5 - donekle se slažem	6 - slažem se	7 - u potpunosti se slažem
Stopa neuspjeha poduzeća unutar grane je visoka.	◯	◯	◯	◯	◯	◯	◯
Zbog velike rizičnosti, jedna loša poslovna odluka može ugroziti održivost cijele poslovne jedinice.	◯	◯	◯	◯	◯	◯	◯
Poslovno okruženje je nedovoljno prilagodljivo.	◯	◯	◯	◯	◯	◯	◯
Prevladavaju niske profitne marže.	◯	◯	◯	◯	◯	◯	◯
Odanost kupaca je niska.	◯	◯	◯	◯	◯	◯	◯

37. Kako bi ste sveukupno ocijenili sve prethodno navedene karakteristike okruženja vašeg poduzeća? *

1 - neprihvatljivo / 2 - jako loše / 3 - loše / 4 - zadovoljavajuće / 5 - dobro / 6 - jako dobro / 7 - odlično

Mark only one oval.

1	2	3	4	5	6	7
◯	◯	◯	◯	◯	◯	◯

KVALITETA KONTROLEROVOG OUTPUTA

38. U kojoj se mjeri slažete sa sljedećim tvrdnjama u vezi s kvalitetom outputa (informacije u obliku izvještaja, prezentacija, dashboardova,usmenog savjetovanja itd.) koje dajete menadžeru? *

* Informacije koje pružam... *

Mark only one oval per row.

	1 - u potpunosti se ne slažem	2 - ne slažem se	3 - donekle se ne slažem	4 - niti se slažem niti se ne slažem	5 - donekle se slažem	6 - slažem se	7 - u potpunosti se slažem
pokrivaju sva važna područja poslovnih aktivnosti.							
odražavaju stvarne okolnosti na sveobuhvatan i pravovaljan način.							
odražavaju visoku razinu korisnosti i sadržajnosti.							
vrlo su precizne.							
uvijek su ažurne.							
sadrže točne podatke.							
su jasno prikazane.							
su međusobno usklađene.							
sadrže najrelevantnije informacije.							
osigurane su kroz redovite izvještaje (dnevno/mjesečno itd. ili po zahtjevu).							

KONTROLEROVA UKLJUČENOST i UTJECAJ NA DONOŠENJE POSLOVNIH ODLUKA

39. Molim Vas ocijenite sljedeće stavke glede vaše percepcije korištenja vaših informacija (outputa) od strane menadžmenta tj. neto koristi koje on ima od njihovog korištenja u svrhu poslovnog odlučivanja. *

„Koristeći moje outpute menadžment..."

Mark only one oval per row.

	1 - u potpunosti se ne slažem	2 - ne slažem se	3 - donekle se ne slažem	4 - niti se slažem niti se ne slažem	5 - donekle se slažem	6 - slažem se	7 - u potpunosti se slažem
je učinkovitiji u svakodnevnom radu.	◯	◯	◯	◯	◯	◯	◯
donosi bolje i preciznije odluke.	◯	◯	◯	◯	◯	◯	◯
brže donosi odluke.	◯	◯	◯	◯	◯	◯	◯

40. U kojoj se mjeri slažete sa sljedećim tvrdnjama? *

Mark only one oval per row.

	1 - u potpunosti se ne slažem	2 - ne slažem se	3 - donekle se ne slažem	4 - niti se slažem niti se ne slažem	5 - donekle se slažem	6 - slažem se	7 - u potpunosti se slažem
Igram vrlo važnu ulogu u procesu odlučivanja poduzeća.	◯	◯	◯	◯	◯	◯	◯
Menadžment daje visoku vrijednost mojem mišljenju pri donošenju odluka.	◯	◯	◯	◯	◯	◯	◯
Imam snažan utjecaj pri odabiru ispravne poslovne odluke (odabiru između alternativa).	◯	◯	◯	◯	◯	◯	◯
Prije donošenja važnih odluka, menadžment se uvijek konzultira sa mnom.	◯	◯	◯	◯	◯	◯	◯
Sudjelujem u donošenju odluka menadžera.	◯	◯	◯	◯	◯	◯	◯
Smatram da sam suodgovoran	◯	◯	◯	◯	◯	◯	◯

u donošenju odluka.

41. Kada se radi o sudjelovanju u OPERATIVNIM odlukama (u roku od 1 godine), koliko vas opisuju sljedeće radnje: *

Mark only one oval per row.

	1 - uopće se ne odnosi na mene	2 - uglavnom se ne odnosi na mene	3 - uglavnom se odnosi na mene	4 - u potpunosti se odnosi na mene
Prezentiram informacije i analize.				
Preporučujem akcije koje trebaju biti poduzete.				
Preispitujem planove i akcije.				

42. Kada se radi o sudjelovanju u STRATEŠKIM odlukama (u roku 2 i više godina), koliko vas opisuju sljedeće radnje: *

Mark only one oval per row.

	1 - uopće se ne odnosi na mene	2 - uglavnom se ne odnosi na mene	3 - uglavnom se odnosi na mene	4 - u potpunosti se odnosi na mene
Prezentiram informacije i analize				
Preporučujem akcije koje trebaju biti poduzete				
Preispitujem planove i akcije				

43. Koristite li neko softversko rješenje Poslovne inteligencije (BI-Business Intelligence; npr. Excel- Microsoft Power BI, SAP BI, Oracle BI, IBM Cognos Analytics, MicroStrategy, DataPine, SAS BI itd.) unutar odjela kontrolinga? *

BI je pojam koji objedinjuje skup metodologija (Data Warehousing, Data Mining, OLAP) i softverskih alata kojima se omogućuje korištenje podataka iz različitih skladišta podataka (Data Warehouse) i njihovo pretvaranje u informaciju potrebnu za donošenje poslovnih odluka. Odnosno, BI predstavlja dodatne softverske aplikacije koje pomažu pri obradi podataka, analizi, izradi izvještaja i dashbordova.

Mark only one oval.

- ◯ DA
- ◯ NE

44. Ako da, molim Vas navedite naziv sofverskog rješenje kojeg koristite:

_____

45. Po Vašem mišljenju, kolika je korist primjene BI u svrhu obavljanja zadataka kontrolera? *

1 - u potpunosti nekorisno / 2 - nekorisno / 3 - donekle nekorisno / 4 - niti korisno niti nekorisno / 5 - donekle korisno / 6 - korisno / 7 - izuzetno korisno, gotovo neophodno

Mark only one oval.

1	2	3	4	5	6	7
◯	◯	◯	◯	◯	◯	◯

46. Naziv poduzeća: *

Ukoliko navedete naziv poduzeća onda nije potrebno ispunjavati preostala pitanja koja se odnose na njegove karakteristike, već završavate sa anketnim upitnikom. Ukoliko i navedete naziv poduzeća, svi podaci biti će strogo anonimni i neće se iznositi pod službenim nazivom.

Mark only one oval.

- ◯ Ne želim navesti naziv poduzeća *Skip to question 49*
- ◯ Želim navesti naziv poduzeća *Skip to question 47*

Naziv poduzeća

47. Molim Vas upišite naziv poduzeća: *

Uz naziv navedete i pravni oblik (d.d., d.o.o., jtd., ...)

48. Ukoliko želite primiti konačne rezultate ovog istraživanja i sudjelovati u nagradnom izvlačenju, molim Vas da upišete Vašu e-adresu.

PREOSTALA PITANJA O PODUZEĆU

Napomena: ukoliko ste se ipak odlučili da želite navesti naziv poduzeća možete se vratiti na prethodnu stranicu sa tipkom "back" koja se nalazi na dnu ove stranice.

49. Dobit (ili gubitak) nakon oporezivanja u 2019. godinu (u 000 kn): *

AOP 183

50. Ukupna aktiva u 2019. godinu (u 000 kn): *

AOP 065

51. Kapital i rezerve u 2019. godinu (u 000 kn): *

AOP 067

52. Ukupni prihod u 2019. godinu (u 000 kn): *

AOP 177

53. Ukupan broj zaposlenih u poduzeću: *

54. Veličina poduzeća prema Zakonu o računovodstvu: *

Mark only one oval.

- ◯ Veliko
- ◯ Srednje
- ◯ Malo

55. Odaberite djelatnost prema NKD područjima ili upišite šifru djelatnosti u polje "other": *

Mark only one oval.

- ◯ A-Poljoprivreda, šumarstvo i ribarstvo
- ◯ B-Rudarstvo i vađenje
- ◯ C-Prerađivačka industrija
- ◯ D-Opskrba električnom energijom, plinom, parom i klimatizacija
- ◯ E-Opskrba vodom; uklanjanje otpadnih voda, gospodarenje otpadom te djelatnosti sanacije okoliša
- ◯ F-Građevinarstvo
- ◯ G-Trgovina na veliko i na malo; popravak motornih vozila i motocikala
- ◯ H-Prijevoz i skladištenje
- ◯ I-Djelatnosti pružanja smještaja te pripreme i usluživanja hrane
- ◯ J-Informacije i komunikacije
- ◯ K-Financijske djelatnosti i djelatnosti osiguranja
- ◯ L-Poslovanje nekretninama
- ◯ M-Stručne, znanstvene i tehničke djelatnosti
- ◯ N-Administrativne i pomoćne uslužne djelatnosti
- ◯ O-Javna uprava i obrana; obvezno socijalno osiguranje
- ◯ P-Obrazovanje
- ◯ Q-Djelatnosti zdravstvene zaštite i socijalne skrbi
- ◯ R-Umjetnost, zabava i rekreacija
- ◯ S-Ostale uslužne djelatnosti
- ◯ T-Djelatnosti kućanstava kao poslodavaca
- ◯ U-Djelatnosti izvanteritorijalnih organizacija i tijela
- ◯ Other: _____

56. Ukoliko želite primiti konačne rezultate ovog istraživanja i sudjelovati u nagradnom izvlačenju, molim Vas da upišete Vašu e-adresu (može biti i privatna zbog anonimnosti poduzeća).

_____

Privitak 2: Anketa za kontrolere - 2.dio

Anketa za kontrolere (2. DIO)

Poštovani,

drugi dio ankete sastoji se od sljedeća dva područja:

1. Digitalizacija, korištenje poslovne inteligencije i analitike te Big data
2. Trenutni zadaci kontrolinga i poslovanje poduzeća

Očekivano vrijeme potrebno za ispunjavanje je 5 -10 minuta.

Ukoliko imate pitanja ili nejasnoća molim Vas da me kontaktirate na e-adresu ili mobitel:
antonija.petrlic@efri.hr ili 095/864-1991

Unaprijed hvala na sudjelovanju!
Antonija Petrlić, univ.spec.oec.
Ekonomski fakultet sveučilišta u Rijeci
Ivana Filipovića 4,51000 Rijeka

* Required

1. ZAJEDNIČKA OZNAKA: *

Molim Vas da upišete svoju oznaku koju ste koristili pri popunjavanju prvog dijela ankete.

DIGITALIZACIJA, KORIŠTENJE POSLOVNE INTELIGENCIJE i ANALITIKE te BIG DATA

2. Molim Vas ocijenite sljedeće stavke koje se odnose na sposobnost BI-a u vašem odjelu, ako ga/ih koristite.

Mark only one oval per row.

	1 - u potpunosti se ne slažem	2 - ne slažem se	3 - donekle se ne slažem	4 - niti se slažem niti se ne slažem	5 - donekle se slažem	6 - slažem se	7 - u potpunosti se slažem
BI sustavi podržavaju tijek rada (tj. jednostavnije izvršavanje poslovnih aktivnosti).	◯	◯	◯	◯	◯	◯	◯
BI sustavi omogućuju istraživanje alternativnih scenarija.	◯	◯	◯	◯	◯	◯	◯
BI sustavi su prilagodljivi.	◯	◯	◯	◯	◯	◯	◯
BI sustavi imaju potrebne sadržaje/značajke/ funkcionalnost.	◯	◯	◯	◯	◯	◯	◯

3. Krenuvši od sebe, smatrate li da bi trebalo povećati korištenje BI-a u području rada kontrolera?

1 - u potpunosti se ne slažem / 2 - ne slažem se / 3 - donekle se ne slažem / 4 - niti se slažem niti se ne slažem / 5 - donekle se slažem / 6 - slažem se / 7 - u potpunosti se slažem

Mark only one oval.

1	2	3	4	5	6	7
◯	◯	◯	◯	◯	◯	◯

4. Molim Vas označite koje od navedenih metoda i u kojoj mjeri koristite:

Mark only one oval per row.

	1 - nikada	2 - gotovo nikada	3 - ponekad	4 - gotovo redovito	5 - redovito
Prediktivni modeli	◯	◯	◯	◯	◯
Analitički hijerarhijski proces (eng. Analytical Hierarchy Processes-AHP)	◯	◯	◯	◯	◯
Linearna regresija (univarijatna i multivarijatna)	◯	◯	◯	◯	◯
Monte Carlo simulacije	◯	◯	◯	◯	◯
Modeliranje strukturnih jednadžbi (eng. Structural Equation Models-SEM)	◯	◯	◯	◯	◯
Regresija vremenskih serija	◯	◯	◯	◯	◯

5. Ako za navedene metode koristite neke dodatne softvere koje niste prethodno naveli, molim Vas da ih navedete ovdje:

Molim Vas ocijenite sljedeće stavke koje se odnose na Big Data unutar vašeg poduzeća.

Big Data je velika količina raznolikih, strukturiranih, nestrukturiranih i polustrukturiranih podataka koja poduzeću stoji na raspolaganju unutar i izvan poduzeća (npr. interni dokukmenti, arhiva i serveri strojeva, svi podaci dostupni na Internetu, podaci s mobilnih aplikacja, društvenih mreža, javnih baza podatkak, medija itd.).

6. VELIČINA

Mark only one oval per row.

	1 - u potpunosti se ne slažem	2 - ne slažem se	3 - donekle se ne slažem	4 - niti se slažem niti se ne slažem	5 - donekle se slažem	6 - slažem se	7 - u potpunosti se slažem
Poduzeće obrađuje jako veliku količinu podataka.	⬭	⬭	⬭	⬭	⬭	⬭	⬭
Poduzeće koristi podatke u stvarnom vremenu.	⬭	⬭	⬭	⬭	⬭	⬭	⬭
Poduzeće obrađuje različite vrste podataka.	⬭	⬭	⬭	⬭	⬭	⬭	⬭

7. KORIŠTENJE *

„Big data..."

Mark only one oval per row.

	1 - u potpunosti se ne slažem	2 - ne slažem se	3 - donekle se ne slažem	4 - niti se slažem niti se ne slažem	5 - donekle se slažem	6 - slažem se	7 - u potpunosti se slažem
koristi kontrolingu za generiranje i obradu aktualnih internih i eksternih podataka u svrhu poslovnog odlučivanja.	◯	◯	◯	◯	◯	◯	◯
omogućava izradu učinkovitih (operativnih i strateških) analiza i efikasnije poslovno odučivanje.	◯	◯	◯	◯	◯	◯	◯
omogućava kontrolingu uštedu vremena pronalaženja potrebnih podatka za obradu i time pridodaje vrijednosti analizama.	◯	◯	◯	◯	◯	◯	◯
koristi se za razumijevanje i mjerenje utjecaja okruženja na poslovanje poduzeća	◯	◯	◯	◯	◯	◯	◯

(npr.ekološki rizici, gospodarski uvjeti, dostupnost ljudskih resursa itd.)

TRENUTNI ZADACI KONTROLINGA i POSLOVANJE PODUZEĆA

8. Označite koliko često ste uključeni u sljedeće aktivnosti unutar vaše trenutne pozicije:

Mark only one oval per row.

	1 - nikada	2 - gotovo nikada	3 - rijetko	4 - ponekad	5 - često	6 - vrlo često	7 - redovito
Praćenje likvidnosti	◯	◯	◯	◯	◯	◯	◯
Analiza uspješnosti (rentabilnost, produktivnost, ekonomičnost,obrtaji imovine)	◯	◯	◯	◯	◯	◯	◯
Analiza odstupanja (kontrola planirano/izvršeno)	◯	◯	◯	◯	◯	◯	◯
Operativno planiranje i budžetiranje	◯	◯	◯	◯	◯	◯	◯
Analiza i planiranje prihoda i troškova	◯	◯	◯	◯	◯	◯	◯
Analiza boniteta kupaca i dobavljača	◯	◯	◯	◯	◯	◯	◯
Rolling planiranje	◯	◯	◯	◯	◯	◯	◯
Prognoziranje i predviđanje	◯	◯	◯	◯	◯	◯	◯
Usporedna analiza i benchmarking	◯	◯	◯	◯	◯	◯	◯
Analiza proizvoda i usluga, profitabilnost kupca, podružnica i dr.	◯	◯	◯	◯	◯	◯	◯
Analiza efikasnosti procesa nabave (narudžbe, dobavljači, otpimizacija troškova...) i/ili proizvodnje (količina proizvodnje, vrijeme izrade, količina škarta...)	◯	◯	◯	◯	◯	◯	◯
	◯	◯	◯	◯	◯	◯	◯

Razvoj i praćenje ključnih pokazatelja poslovanja (KPI)							
Razvoj i vrednovanje investicija i projekata (stupanj isplativosti i dovršenosti)							
Analiza ostalih vrsta ulaganja (ulaganja u vrijednosne papire, nekretnine, oročavanje sredstava...)							
Ispomoć u procesu reinžinjeringa i inovacija.							
Uravnoteženo mjerenje uspješnosti poslovanja (Balanced scorecarda)							
Analiza rizika i ostalih neizvjesnosti							
Analiza snaga, slabosti, prilika i prijetnji (SWOT)							
Analiza učinkovitosti djelatnika							

9. Ako postoje druge radnje koje nisu navedene gore, a izvršavate ih redovito, molim Vas da ih ovdje nabrojite:

Ocijenite koliko često pružate sljedeće informacije menadžeru u svrhu poslovnog odlučivanja:

A - Informacije koje se odnose buduće događaje.

B - Eksterne informacije kao npr. preferencije i zadovoljstvo kupaca, zadovoljstvo postojećih i dostupnost novih dobavljača, konkurentske prijetnje, odluke državnih i lokalnih tijela itd.

C - Interne informacije kao npr. zadovoljstvo, motiviranost i stavovi zaposlenika, kvaliteta upravljanja i organizacije internih procesa, radna okolina itd.

D - Informacije o brojnim čimbenicima koji su izvan vaše poduzeća (poput ekonomskih uvjeta, rasta stanovništva, dostupnosti ljudskih resursa, tehnološkog razvoja, ekoloških rizika, BDP, rasta cijena, troškova života itd.)

E - Nefinancijske informacije koje doprinose većoj efikasnosti kao npr. stopa rasta proizvodnje i/ili prodaje, smanjenje škarta i nesukladnih proizvoda, ušteda vremena pružanja usluge, unaprjeđenje efikasnosti procesa nabave, fluktuacija i izostanci učinkovitosti zaposlenika, pokazatelji odnosa prema ekologiji i društvenim aspektima poslovanja (zaštita na radu, zdravstvena zaštita, diskriminacija, korupcija) itd.

10.

Mark only one oval per row.

	1 - nikada	2 - gotovo nikada	3 - rijetko	4 - ponekad	5 - često	6 - vrlo često	7 - redovito
A	◯	◯	◯	◯	◯	◯	◯
B	◯	◯	◯	◯	◯	◯	◯
C	◯	◯	◯	◯	◯	◯	◯
D	◯	◯	◯	◯	◯	◯	◯
E	◯	◯	◯	◯	◯	◯	◯

11. PROCJENA I PRIZNANJE KONTROLERA

Mark only one oval per row.

	1 - u potpunosti se ne slažem	2 - ne slažem se	3 - donekle se ne slažem	4 - niti se slažem niti se ne slažem	5 - donekle se slažem	6 - slažem se	7 - u potpunosti se slažem
Redovito dobivam povratne informacije o tome kako obavljam svoj posao.	◯	◯	◯	◯	◯	◯	◯
Ohrabren sam u svom radu kroz pohvale, zahvale ili druga priznanja za dobro obavljeni posao.	◯	◯	◯	◯	◯	◯	◯

12. Smatrate li da je posao kontrolera stresan?

1 - nimalo / 2 - malo / 3 - umjereno / 4 - vrlo / 5 - izuzetno

Mark only one oval.

1	2	3	4	5
◯	◯	◯	◯	◯

13. Ocijenite predvidljivost sljedećih stavki okruženja s obzirom na vaše poduzeće i vašu ulogu unutar istog. *

Mark only one oval per row.

	1- vrlo nepredvidljiv	2- nepredvidljiv	3-donekle nepredvidljiv	4-nije predvidljiv niti nepredvidljiv	5-donekle predvidljiva	6- predvidljiv
Radnje i zahtjevi dobavljača i distributera (npr. dostupnost sirovina, cijena itd.)	◯	◯	◯	◯	◯	◯
Zahtjevi, ukusi i sklonosti kupca	◯	◯	◯	◯	◯	◯
Tržišne aktivnosti konkurenata	◯	◯	◯	◯	◯	◯
Stabilnost regulatornih promjena	◯	◯	◯	◯	◯	◯

14. Kako biste, u prosjeku, ocijenili poslovni rezultat svojeg poduzeća u posljednje tri godine (pokazatelje koje ne pratite nije potrebno ocijeniti) *

Mark only one oval per row.

	1-znatno se pogoršalo	2-pogoršalo se	3-malo se pogoršalo	4-ostalo je nepromijenjeno	5-malo se poboljšalo	6-poboljšalo se	7-pol
Bruto dobit	◯	◯	◯	◯	◯	◯	
EBIT/ EBITDA	◯	◯	◯	◯	◯	◯	
Marža profita (ROS)	◯	◯	◯	◯	◯	◯	
Povrat na imovinu (ROA)	◯	◯	◯	◯	◯	◯	
Povrat na kapital (ROE) ili ROI	◯	◯	◯	◯	◯	◯	
Prodaja	◯	◯	◯	◯	◯	◯	
Tržišni udjel	◯	◯	◯	◯	◯	◯	
Zadovoljstvo kupaca	◯	◯	◯	◯	◯	◯	
Razvoj ljudskih resursa	◯	◯	◯	◯	◯	◯	
Ukupno poslovanje	◯	◯	◯	◯	◯	◯	

15. Ukoliko želite primiti konačne rezultate ovog istraživanja i sudjelovati u nagradnom izvlačenju, molim Vas da upišete Vašu e-adresu.

_____

Privitak 3: Anketa za menadžera

Anketa za menadžere

Poštovani,

molim Vas da izdvojite dio svojeg dragocjenog vremena i popunite ovaj upitnik koji se koristi u svrhu izrade doktorske disertacije pod nazivom „Obilježja kontrolera i menadžera u funkciji efikasnog donošenja odluka u uvjetima digitalizacije". Cilj istraživanja jest utvrditi imaju li obilježja kontrolera, menadžera i poduzeća te digitalnog okruženja, značajan utjecaj na učinke kontrolerovih aktivnosti i doprinos u donošenju poslovnih odluka.

Popunjavanje upitnika je dobrovoljno i anonimno, a podaci će se koristiti isključivo u znanstveno-istraživačke svrhe i neće se zlorabiti na bilo koji način.

Dobiveni rezultati će se analizirati na razini ukupnog uzorka te koristiti isključivo u svrhe ovog istraživanja. Upitnik se sastoji od skupine precizno sažetih tvrdnji, tj. pitanja. Molim Vas da pažljivo pročitate svaku tvrdnju jer ne postoje točni i netočni odgovori, te da objektivno odgovorite s obzriom na to da je svaki Vaš odgovor od presudne važnosti za utvrđivanje postavljenog cilja istraživanja.

Očekivano vrijeme potrebno za ispunjavanje upitnika je 5 -10 minuta.

Ukoliko imate pitanja ili nejasnoća molim Vas da me kontaktirate na e-adresu ili mobitel: antonija.petrlic@efri.hr ili 095/864-1991

Svaki ispitanik ima priliku osvojiti poklon bon u vrijednosti od 500 HRK. Dobitnik će biti kontaktiran e-poštom nakon završetka anketiranja.

* Required

1. ZAJEDNIČKA OZNAKA: *

Molim Vas da upišete oznaku koju Vam je dostavio kontroler uz link za anketu. Oznaka omogućuje uparivanje odgovora u svrhu pravilne analize rezultata.

INFORMACIJE O ISPITANIKU

2. Spol: *

Mark only one oval.

- ◯ Muško
- ◯ Žensko
- ◯ Ostalo

3. Dob (u godinama): *

_____

4. Stupanj obrazovanja: *
(moguć višestruki odabir)

Check all that apply.

- [ ] SSS ili SŠS
- [ ] VŠS (npr. bacc.oec.)
- [ ] VSS (npr. mag.oec.)
- [ ] sveučilišni specijalist struke (npr. univ.spec.oec.)
- [ ] magistar znanosti (mr. sc.)
- [ ] doktor znanosti (dr. sc)
- [ ] Other: _____

5. Ukupno radno iskustvo (u godinama): *

Check all that apply.

- [ ] 1
- [ ] 2
- [ ] 3
- [ ] ...

6. Ukupno radno iskustvo na poslovima rukovođenja (u godinama): *

Check all that apply.

- [ ] 1
- [ ] 2
- [ ] 3
- [ ] ...

7. Ukupno radno iskustvo gdje ste radili/surađivali s kontrolerom (u godinama): *

Check all that apply.

- [ ] 1
- [ ] 2
- [ ] 3
- [ ] ...

8. Naziv radnog mjesta: *

_____

9. Puni naziv odjela u kojem radite:

_____

KVALITETA KONTROLEROVOG OUTPUTA

10. U kojoj se mjeri slažete sa sljedećim tvrdnjama u vezi s kvalitetom outputa (informacije u obliku izvještaja, prezentacija, dashboardova,usmenog savjetovanja itd.) koje Vam daje kontroler? *

" Informacije koje pruža kontroler... "

Mark only one oval per row.

	1 - u potpunosti se ne slažem	2 - ne slažem se	3 - donekle se ne slažem	4 - niti se slažem niti se ne slažem	5 - donekle se slažem	6 - slažem se	7 - u potpunosti se slažem
pokrivaju sva važna područja poslovnih aktivnosti.							
odražavaju stvarne okolnosti na sveobuhvatan i pravovaljan način.							
odražavaju visoku razinu korisnosti i sadržajnosti.							
vrlo su precizne.							
uvijek su ažurne.							
sadrže točne podatke.							
su jasno prikazane.							
su međusobno usklađene.							
sadrže najrelevantnije informacije.							
osigurane su kroz redovite izvještaje (dnevno/mjesečno itd. ili po zahtjevu).							

KONTROLEROVA UKLJUČENOST i UTJECAJ NA DONOŠENJE POSLOVNIH ODLUKA

11. Molim Vas ocijenite sljedeće stavke glede koristi koje imate od informacija (outputa) koje vam pruža kontroler u svrhu poslovnog odlučivanja. *

„Koristeći kontrolerove outpute ..."

Mark only one oval per row.

	1 - u potpunosti se ne slažem	2 - ne slažem se	3 - donekle se ne slažem	4 - niti se slažem niti se ne slažem	5 - donekle se slažem	6 - slažem se	7 - u potpunosti se slažem
učinkovitiji sam u svakodnevnom radu.	◯	◯	◯	◯	◯	◯	◯
donosim bolje i preciznije odluke.	◯	◯	◯	◯	◯	◯	◯
brže donosim odluke.	◯	◯	◯	◯	◯	◯	◯

12. U kojoj se mjeri slažete sa sljedećim tvrdnjama? *

Mark only one oval per row.

	1 - u potpunosti se ne slažem	2 - ne slažem se	3 - donekle se ne slažem	4 - niti se slažem niti se ne slažem	5 - donekle se slažem	6 - slažem se	7 - u potpunosti se slažem
Kontroler igra vrlo važnu ulogu u procesu odlučivanja poduzeća.	◯	◯	◯	◯	◯	◯	◯
Dajem visoku vrijednost kontrolerovom mišljenju pri donošenju odluka.	◯	◯	◯	◯	◯	◯	◯
Kontroler ima snažan utjecaj pri odabiru ispravne poslovne odluke (odabiru između alternativa).	◯	◯	◯	◯	◯	◯	◯
Prije donošenja važnih odluka, uvijek se konzultiram sa kontrolerom.	◯	◯	◯	◯	◯	◯	◯
Kontroler sudjeluje u donošenju odluka.	◯	◯	◯	◯	◯	◯	◯
Smatram da je kontroler suodgovoran u donošenju odluka.	◯	◯	◯	◯	◯	◯	◯

KARAKTERISTIKE KONTROLERA

OVO JE POSLJEDNJI DIO ANKETE.
Stoga Vas molim da izdvojite još malo vremena i popunite ju do kraja.

U kojoj se mjeri slažete sa sljedećim tvrdnjama koje se odnose na karakteristike vašeg kontrolera?

13. ANALITIČNOST

Mark only one oval per row.

	1 - u potpunosti se ne slažem	2 - ne slažem se	3 - donekle se ne slažem	4 - niti se slažem niti se ne slažem	5 - donekle se slažem	6 - slažem se	7 - u potpunosti se slažem
Sposoban je objasniti značenje brojeva.	◯	◯	◯	◯	◯	◯	◯
Fokusiran je i razumije izvore problema.	◯	◯	◯	◯	◯	◯	◯
Usmjeren je ka budućnosti.	◯	◯	◯	◯	◯	◯	◯
Sposoban je uočiti trendove prije nego postanu stvarnost.	◯	◯	◯	◯	◯	◯	◯
Dobar je u korištenju, strukturiranju i obradi brojeva.	◯	◯	◯	◯	◯	◯	◯

14. KOMUNIKATIVNOST

Mark only one oval per row.

	1 - u potpunosti se ne slažem	2 - ne slažem se	3 - donekle se ne slažem	4 - niti se slažem niti se ne slažem	5 - donekle se slažem	6 - slažem se	7 - u potpunosti se slažem
Lako uspostavlja kontakt s drugima i sluša sugovornike.	◯	◯	◯	◯	◯	◯	◯
Jasno komunicira svoje ideje usmenim putem.	◯	◯	◯	◯	◯	◯	◯
Jasno komunicira svoje ideje pismenim putem.	◯	◯	◯	◯	◯	◯	◯
Može uvjeriti druge ljude da slijede njegove ideje.	◯	◯	◯	◯	◯	◯	◯
Sposoban je prenijeti poruku, tj. važni sadržaj.	◯	◯	◯	◯	◯	◯	◯

15. ASERTIVNOST

Mark only one oval per row.

	1 - u potpunosti se ne slažem	2 - ne slažem se	3 - donekle se ne slažem	4 - niti se slažem niti se ne slažem	5 - donekle se slažem	6 - slažem se	7 - u potpunosti se slažem
Jasno izražava svoje mišljenje, osjećaje i stavove.							
Izražava svoje neslaganje sa mišljenjima drugih.							
Daje konstruktivne kritike.							
Nije mu problem reći NE drugima.							
Dopušta drugima da izraze svoje mišljenje.							

16. PROAKTIVNOST

Mark only one oval per row.

	1 - u potpunosti se ne slažem	2 - ne slažem se	3 - donekle se ne slažem	4 - niti se slažem niti se ne slažem	5 - donekle se slažem	6 - slažem se	7 - u potpunosti se slažem
Prilika i izazov mu je vidjeti da mu se ideje pretvaraju u stvarnost.	◯	◯	◯	◯	◯	◯	◯
Samoinicijativno popravlja uočene greške, probleme i nedostatke.	◯	◯	◯	◯	◯	◯	◯
Uvijek traga za boljim načinima rada i načinima rješavanja problema.	◯	◯	◯	◯	◯	◯	◯
Prepreke ga ne sprječavaju u ostvarenju ciljeva i ideja u koje vjeruje.	◯	◯	◯	◯	◯	◯	◯
Izravno se suočava s problemima.	◯	◯	◯	◯	◯	◯	◯
Probleme pretvara u prilike.	◯	◯	◯	◯	◯	◯	◯

17. KREATIVNOST

Mark only one oval per row.

	1 - u potpunosti se ne slažem	2 - ne slažem se	3 - donekle se ne slažem	4 - niti se slažem niti se ne slažem	5 - donekle se slažem	6 - slažem se	7 - u potpunosti se slažem
Predlaže kreativna rješenja problema i pri tome se ne boji preuzeti rizik.	⬭	⬭	⬭	⬭	⬭	⬭	⬭
Promiče i zagovara vlastite kreativne ideje i ideje drugih.	⬭	⬭	⬭	⬭	⬭	⬭	⬭
Njegova kreativnost dolazi do izražaja prilikom rješavanja složenih problem.	⬭	⬭	⬭	⬭	⬭	⬭	⬭
Predlaže nove načine postizanja ciljeva i ciljanih vrijednosti.	⬭	⬭	⬭	⬭	⬭	⬭	⬭

18. Koju bi ste ukupnu ocjenu dali svim gore navedenim kontrolerovim karakteristikama?

1 - neprihvatljivo / 2 - jako loše / 3 - loše / 4 - zadovoljavajuće / 5 - dobro / 6 - jako dobro / 7 - odlično

Mark only one oval.

1	2	3	4	5	6	7
◯	◯	◯	◯	◯	◯	◯

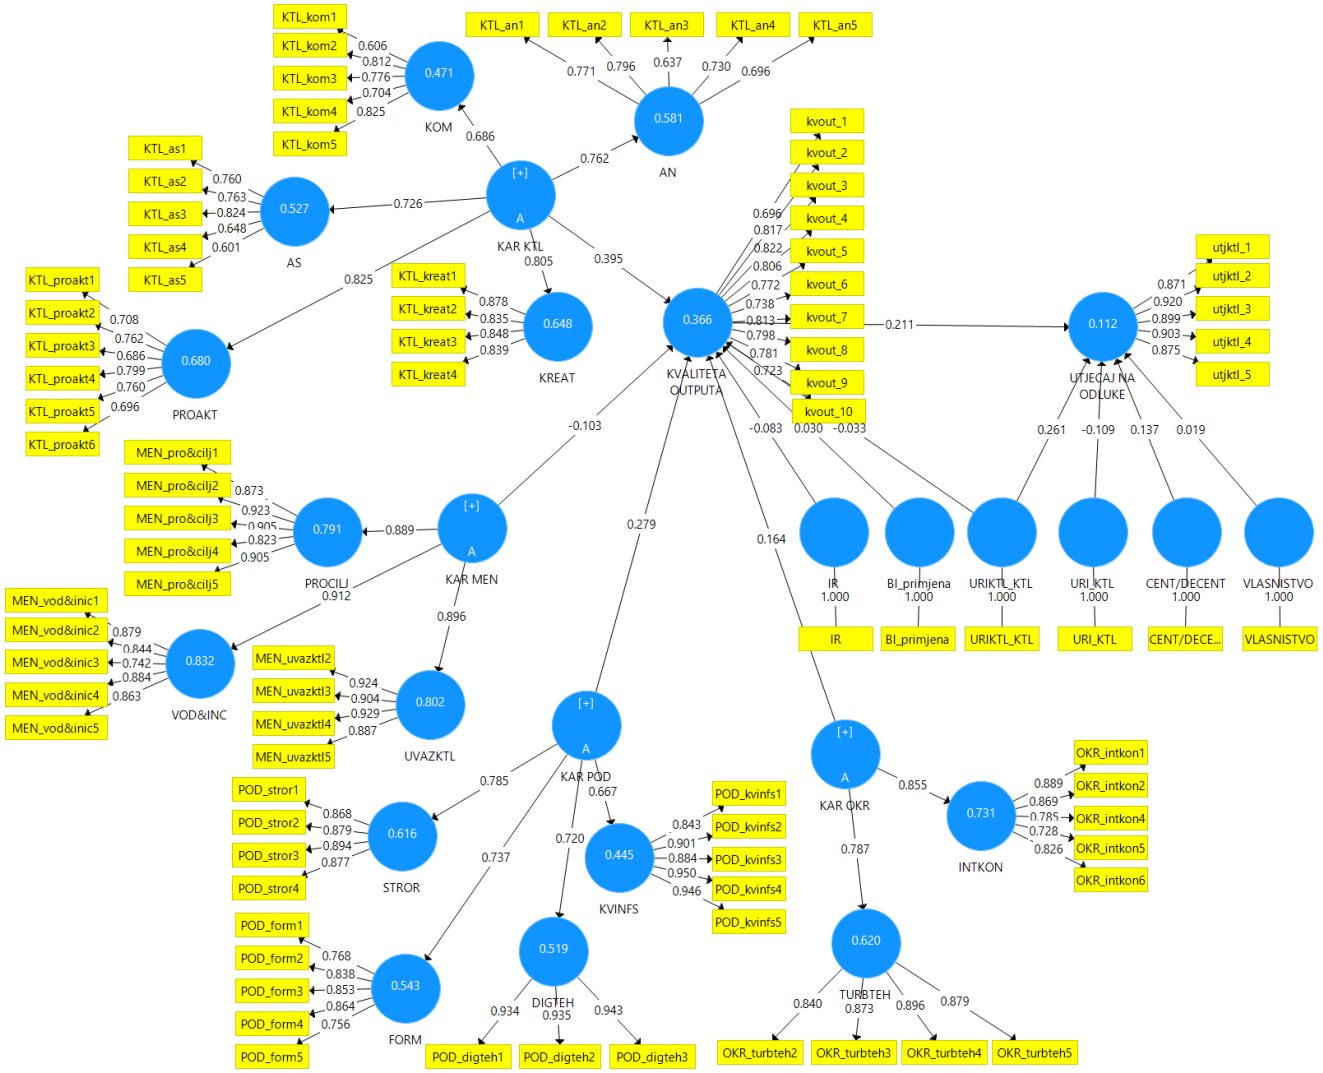
19. Ukoliko želite primiti konačne rezultate ovog istraživanja i sudjelovati u nagradnom izvlačenju, molim Vas da upišete Vašu e-adresu (može biti i privatna).

_____

This content is neither created nor endorsed by Google.

Google Forms

Privitak 4: PLS algoritam rezultati modela (Model 1)



Izvor: SmartPLS (v. 3.3.3)

Privitak 5: Izračun Cronbach Alfe visoko-rednih konstrukata (Model 1)

Korelacija latentnih varijabli	AN	AS	KOM	KREAT	PROAKT
AN		0,389	0,503	0,500	0,531
AS	0,389		0,494	0,464	0,489
KOM	0,503	0,494		0,372	0,342
KREAT	0,500	0,464	0,372		0,673
PROAKT	0,531	0,489	0,342	0,673	
CRONBACH_HOC_KAR KTL (M*r)/(1+(M-1)*r)	**0,819**				
PROSJEČNA KORELACIJA (r)	0,476				
BROJ VARIJABLI (M)	5				
*BROJNIK CRONBACH (M*r)*	2,379				
*NAZVINIK CRONBACH (1+(M-1)*r)*	2,903				

Korelacija latentnih varijabli	PROCILJ	UVAZKTL	VOD&INC
PROCILJ		0,675	0,701
UVAZKTL	0,675		0,762
VOD&INC	0,701	0,762	
CRONBACH_HOC_KAR MEN (M*r)/(1+(M-1)*r)	**0,882**		
PROSJEČNA KORELACIJA (r)	0,713		
BROJ VARIJABLI (M)	3		
*BROJNIK CRONBACH (M*r)*	2,138		
*NAZVINIK CRONBACH (1+(M-1)*r)*	2,425		

Korelacija latentnih varijabli	DIGTEH	FORM	KVINFS	STROR
DIGTEH		0,379	0,338	0,486
FORM	0,379		0,239	0,517
KVINFS	0,338	0,239		0,288
STROR	0,486	0,517	0,288	
CRONBACH_HOC_KAR POD (M*r)/(1+(M-1)*r)	**0,705**			
PROSJEČNA KORELACIJA (r)	0,375			
BROJ VARIJABLI (M)	4			
*BROJNIK CRONBACH (M*r)*	1,498			
*NAZVINIK CRONBACH (1+(M-1)*r)*	2,124			

Korelacija latentnih varijabli	INTKON	TURBTEH
INTKON		0,354
TURBTEH	0,354	
CRONBACH_HOC_KAR OKR (M*r)/(1+(M-1)*r)	**0,523**	
PROSJEČNA KORELACIJA (r)	0,354	
BROJ VARIJABLI (M)	2	
*BROJNIK CRONBACH (M*r)*	0,708	
*NAZVINIK CRONBACH (1+(M-1)*r)*	1,354	

Izvor: izrada i izračuna autora prema SmartPLS (v. 3.3.3), Hair *et al.* (2018) i Sarstedt *et al.* (2019)

Privitak 6: Izračun AVE i CR visoko-rednih konstrukata (Model 1)

HOC	Faktorska opterećenja													
	AN	AS	KOM	KREAT	PROAKT	PROCILJ	VOD&INC	UVAZKTL	STROR	FORM	DIGTEH	KVINFS	TURBTEH	INTKON
KAR KTL	0,762	0,726	0,686	0,805	0,825									
KAR MEN						0,889	0,912	0,896						
KAR POD									0,785	0,737	0,720	0,667		
KAR OKR													0,787	0,855

AVE=SUMA FAKTROSKIH OPTEREĆENJAA^2/M

AVE_HOC_KAR KTL	**0,581**													
LOADINGS^2	0,581	0,527	0,471	0,648	0,681									
SUMA LOADINGS^2	2,906													
M	5													

AVE_HOC_KAR MEN	**0,808**													
LOADINGS^2						0,790	0,832	0,803						
SUMA LOADINGS^2	2,425													
M	3													

AVE_HOC_KAR POD	**0,531**													
LOADINGS^2									0,616	0,543	0,518	0,445		
SUMA LOADINGS^2	2,123													
M	4													

AVE_HOC_KAR OKR	**0,675**													
LOADINGS^2													0,619	0,731
SUMA LOADINGS^2	1,350													
M	2													

CR(pc)= (SUM LOADINGS)^2/(SUM LOADINGS)^2+(1-LOADINGbr1^2)+(1-LOADINGbr2^2)+n…

CR(pc)_HOC_KAR KTL	**0,874**										
(SUM LOADINGS)^2	14,470										
(1-LOADINGbrn^2)	0,419	0,473	0,529	0,352	0,319						
suma svih (1-LOADINGbrn^2)	2,093										
CR(pc)_HOC_KAR MEN	**0,927**										
(SUM LOADINGS)^2	7,274										
(1-LOADINGbrn^2)						0,210	0,168	0,197			
suma svih (1-LOADINGbrn^2)	0,575										
CR(pc)_HOC_KAR POD	**0,818**										
(SUM LOADINGS)^2	8,462										
(1-LOADINGbrn^2)									0,384	0,457	0,482	0,555		
suma svih (1-LOADINGbrn^2)	1,877										
CR(pc)_HOC_KAR OKR	**0,806**										
(SUM LOADINGS)^2	2,696										
(1-LOADINGbrn^2)													0,381	0,269
suma svih (1-LOADINGbrn^2)	0,650										

Izvor: izrada i izračuna autora prema SmartPLS (v. 3.3.3), Hair *et al.* (2018) i Sarstedt *et al*. (2019)

Privitak 7: Izračun HTMT vrijednosti visoko-rednih konstrukata (Model 1)

HTMT (Y1, Y2)	Prosj. unakrsna faktorska opterećenja	Prosječne korelacije				**HTMT = HT / BROJ LOC √**
	HT	Između LOC Y1	Između čestica Y2	BROJ LOC	MT_1*MT_2	

		(MT_1)	(MT_2)			**(MT_1*MT_2)**
HTMT (KAR KTL, QUAL)	0,303	0,476	0,559	5	0,266	**0,394**
HTMT (KAR MEN, QUAL)	0,095	0,713	0,559	3	0,399	**0,129**
HTMT (KAR POD, QUAL)	0,224	0,375	0,559	4	0,209	**0,331**
HTMT (KAR OKR, QUAL)	0,222	0,354	0,559	2	0,198	**0,500**
HTMT (KAR KTL, UTJEC)	0,246	0,476	0,749	5	0,356	**0,302**
HTMT (KAR MEN, UTJEC)	0,199	0,713	0,749	3	0,534	**0,246**
HTMT (KAR POD, UTJEC)	0,185	0,375	0,749	4	0,280	**0,254**
HTMT (KAR OKR, UTJEC)	0,156	0,354	0,749	2	0,265	**0,303**
HTMT (KAR KTL, IR)	-0,062	0,476	1,000	5	0,476	**-0,072**
HTMT (KAR MEN, IR)	-0,057	0,713	1,000	3	0,713	**-0,064**
HTMT (KAR POD, IR)	0,119	0,375	1,000	4	0,375	**0,152**
HTMT (KAR OKR, IR)	0,080	0,354	1,000	2	0,354	**0,134**
HTMT (KAR KTL, BI)	0,056	0,476	1,000	5	0,476	**0,065**
HTMT (KAR MEN, BI)	0,043	0,713	1,000	3	0,713	**0,049**
HTMT (KAR POD, BI)	0,183	0,375	1,000	4	0,375	**0,234**
HTMT (KAR OKR, BI)	0,204	0,354	1,000	2	0,354	**0,342**
HTMT (KAR KTL, URIKTL_KTL)	0,030	0,476	1,000	5	0,476	**0,035**
HTMT (KAR MEN, URIKTL_KTL)	-0,079	0,713	1,000	3	0,713	**-0,089**
HTMT (KAR POD, URIKTL_KTL)	-0,030	0,375	1,000	4	0,375	**-0,038**
HTMT (KAR OKR, URIKTL_KTL)	-0,010	0,354	1,000	2	0,354	**-0,017**
HTMT (KAR KTL, URI_KTL)	-0,014	0,476	1,000	5	0,476	**-0,016**
HTMT (KAR MEN, URI_KTL)	-0,112	0,713	1,000	3	0,713	**-0,126**
HTMT (KAR POD, URI_KTL)	-0,129	0,375	1,000	4	0,375	**-0,165**
HTMT (KAR OKR, URI_KTL)	-0,075	0,354	1,000	2	0,354	**-0,125**
HTMT (KAR KTL, CENT/DECENT)	0,067	0,476	1,000	5	0,476	**0,078**
HTMT (KAR MEN, CENT/DECENT)	0,112	0,713	1,000	3	0,713	**0,125**
HTMT (KAR POD, CENT/DECENT)	0,054	0,375	1,000	4	0,375	**0,069**
HTMT (KAR OKR, CENT/DECENT)	-0,035	0,354	1,000	2	0,354	**-0,058**
HTMT (KAR KTL, VLASNISTVO)	0,087	0,476	1,000	5	0,476	**0,101**
HTMT (KAR MEN, VLASNISTVO)	0,118	0,713	1,000	3	0,713	**0,132**
HTMT (KAR POD, VLASNISTVO)	0,138	0,375	1,000	4	0,375	**0,176**
HTMT (KAR OKR, VLASNISTVO)	0,234	0,354	1,000	2	0,354	**0,393**

Izvor: izrada i izračuna autora prema SmartPLS (v. 3.3.3), Hair *et al.* (2018) i Sarstedt *et al.* (2019)

Privitak 8: Izračun Cronbach Alfe visoko-rednih konstrukata (Model 2)

Korelacija latentnih varijabli	AN	AS	KOM	KREAT	PROAKT
AN		0,483	0,689	0,664	0,700
AS	0,483		0,642	0,528	0,534
KOM	0,689	0,642		0,624	0,644
KREAT	0,664	0,528	0,624		0,682
PROAKT	0,700	0,534	0,644	0,682	

CRONBACH_HOC_KAR KTL	**0,890**
(M*r)/(1+(M-1)*r)	
PROSJEČNA KORELACIJA (r)	0,619
BROJ VARIJABLI (M)	5
BROJNIK CRONBACH (M*r)	3,095
NAZVINIK CRONBACH (1+(M-1)*r)	3,476

Korelacija latentnih varijabli	PROCILJ	UVAZKTL	VOD&INC
PROCILJ		0,666	0,665
UVAZKTL	0,666		0,793
VOD&INC	0,665	0,793	

CRONBACH_HOC_KAR MEN	**0,879**
(M*r)/(1+(M-1)*r)	
PROSJEČNA KORELACIJA (r)	0,708
BROJ VARIJABLI (M)	3
BROJNIK CRONBACH (M*r)	2,124
NAZVINIK CRONBACH (1+(M-1)*r)	2,416

Korelacija latentnih varijabli	DIGTEH	FORM	KVINFS	STROR
DIGTEH		0,339	0,261	0,465
FORM	0,339		0,219	0,413
KVINFS	0,261	0,219		0,354
STROR	0,465	0,413	0,354	

CRONBACH_HOC_KAR POD	**0,675**
(M*r)/(1+(M-1)*r)	
PROSJEČNA KORELACIJA (r)	0,342
BROJ VARIJABLI (M)	4
BROJNIK CRONBACH (M*r)	1,367
NAZVINIK CRONBACH (1+(M-1)*r)	2,026

Korelacija latentnih varijabli	INTKON	TURBTEH
INTKON		0,217
TURBTEH	0,217	

CRONBACH_HOC_KAR OKR	**0,357**
(M*r)/(1+(M-1)*r)	
PROSJEČNA KORELACIJA (r)	0,217
BROJ VARIJABLI (M)	2
BROJNIK CRONBACH (M*r)	0,434
NAZVINIK CRONBACH (1+(M-1)*r)	1,217

Izvor: izrada i izračuna autora prema SmartPLS (v. 3.3.3), Hair *et al.* (2018) i Sarstedt *et al.* (2019)

Privitak 9: Izračun AVE i CR visoko-rednih konstrukata (Model 2)

HOC	Faktorska opterećenja													
	AN	AS	KOM	KREAT	PROAKT	PROCILJ	VOD&INC	UVAZKTL	STROR	FORM	DIGTEH	KVINFS	TURBTEH	INTKON
KAR KTL	0,857	0,726	0,857	0,845	0,876									
KAR MEN						0,878	0,906	0,908						
KAR POD									0,811	0,688	0,689	0,652		
KAR OKR													0,71	0,842

AVE=SUMA FAKTROSKIH OPTEREĆENJA^2/M

AVE_HOC_KAR KTL	**0,695**													
LOADINGS^2	0,734	0,527	0,734	0,714	0,767									
SUMA LOADINGS^2	3,477													
M	5													

AVE_HOC_KAR MEN	**0,805**													
LOADINGS^2						0,771	0,821	0,824						
SUMA LOADINGS^2	2,416													
M	3													

AVE_HOC_KAR POD	**0,508**													
LOADINGS^2									0,658	0,473	0,475	0,425		
SUMA LOADINGS^2	2,031													
M	4													

AVE_HOC_KAR OKR	**0,607**													
LOADINGS^2													0,504	0,709
SUMA LOADINGS^2	1,213													
M	2													

CR(pc)= (SUM LOADINGS)^2/(SUM LOADINGS)^2+(1-LOADINGbr1^2)+(1-LOADINGbr2^2)+n…

CR(pc)_HOC_KAR KTL	**0,919**									
(SUM LOADINGS)^2	17,314									
(1-LOADINGbrn^2)	0,266	0,473	0,266	0,286	0,233					
suma svih (1-LOADINGbrn^2)	1,523									
CR(pc)_HOC_KAR MEN	**0,925**									
(SUM LOADINGS)^2	7,247									
(1-LOADINGbrn^2)						0,229	0,179	0,176		
suma svih (1-LOADINGbrn^2)	0,584									
CR(pc)_HOC_KAR POD	**0,804**									
(SUM LOADINGS)^2	8,066									
(1-LOADINGbrn^2)									0,342	0,527	0,525	0,575
suma svih (1-LOADINGbrn^2)	1,969									
CR(pc)_HOC_KAR OKR	**0,754**									
(SUM LOADINGS)^2	2,409									
(1-LOADINGbrn^2)													0,496	0,291
suma svih (1-LOADINGbrn^2)	0,787									

Izvor: izrada i izračuna autora prema SmartPLS (v. 3.3.3), Hair *et al.* (2018) i Sarstedt *et al*. (2019)

Privitak 10: Izračun HTMT vrijednosti visoko-rednih konstrukata (Model 2)

HTMT (Y1, Y2)	Prosječna unakrsna faktorska opterećenja	Prosječne korelacije		BROJ LOC	MT_1*MT_2	**HTMT = HT / BROJ LOC √ (MT_1*MT_2)**
	HT	Između LOC Y1 (MT_1)	Između čestica Y2 (MT_2)			
HTMT (KAR KTL, QUAL)	0,364	0,619	0,494	5	0,305	**0,462**
HTMT (KAR MEN, QUAL)	0,148	0,708	0,494	3	0,349	**0,210**
HTMT (KAR POD, QUAL)	0,092	0,342	0,494	4	0,169	**0,144**
HTMT (KAR OKR, QUAL)	0,049	0,217	0,494	2	0,107	**0,148**
HTMT (KAR KTL, UTJEC)	0,427	0,619	0,709	5	0,439	**0,504**
HTMT (KAR MEN, UTJEC)	0,311	0,708	0,709	3	0,502	**0,391**
HTMT (KAR POD, UTJEC)	0,137	0,342	0,709	4	0,242	**0,196**
HTMT (KAR OKR, UTJEC)	0,073	0,217	0,709	2	0,154	**0,186**
HTMT (KAR KTL, URIKTL_KTL)	0,053	0,619	1,000	5	0,619	**0,058**
HTMT (KAR MEN, URIKTL_KTL)	-0,159	0,708	1,000	3	0,708	**-0,179**
HTMT (KAR POD, URIKTL_KTL)	-0,116	0,342	1,000	4	0,342	**-0,152**
HTMT (KAR OKR, URIKTL_KTL)	-0,020	0,217	1,000	2	0,217	**-0,043**

Izvor: izrada i izračuna autora prema SmartPLS (v. 3.3.3), Hair *et al.* (2018) i Sarstedt *et al.* (2019)

IZJAVA

kojom ja, Antonija Petrlić, broj indeksa: 214/17 doktorandica Ekonomskog fakulteta Sveučilišta u Rijeci, kao autorica doktorske disertacije s naslovom: KARAKTERISTIKE KONTROLERA I MENADŽERA U FUNKCIJI EFIKASNOGA DONOŠENJA ODLUKA U UVJETIMA DIGITALIZACIJE.

1. Izjavljujem da sam doktorsku disertaciju izradila samostalno pod mentorstvom prof. dr. sc. Nede Vitezić. U radu sam primijenila metodologiju znanstvenoistraživačkog rada i koristila literaturu koja je navedena na kraju rada. Tuđe spoznaje, stavove, zaključke, teorije i zakonitosti koje sam izravno ili parafrazirajući navela u radu citirala sam i povezala s korištenim bibliografskim jedinicama sukladno odredbama Pravilnika o izradi i opremanju doktorskih radova Sveučilišta u Rijeci, Ekonomskog fakulteta u Rijeci. Rad je pisan u duhu hrvatskog jezika.

2. Dajem odobrenje da se, bez naknade, trajno pohrani moj rad u javno dostupnom digitalnom repozitoriju ustanove i Sveučilišta te u javnoj internetskoj bazi radova Nacionalne i sveučilišne knjižnice u Zagrebu, sukladno obvezi iz odredbe članka 83. stavka 11. Zakona o znanstvenoj djelatnosti i visokom obrazovanju (NN 123/03, 198/03, 105/04, 174/04, 02/07, 46/07, 45/09, 63/11, 94/13, 139/13, 101/14, 60/15).

Potvrđujem da je za pohranu dostavljena završna verzija obranjene i dovršene doktorske disertacije. Ovom izjavom, kao autor dajem odobrenje i da se moj rad, bez naknade, trajno javno objavi i besplatno učini dostupnim studentima i djelatnicima ustanove.

Antonija Petrlić

_____