Utjecaj financijskog sustava na gospodarski rast

Grizelj, Slaven

Doctoral thesis / Disertacija

2016

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

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:124:929695

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-28**

Repository / Repozitorij:

REFST - Repository of Economics faculty in Split

SVEUČILIŠTE U SPLITU
EKONOMSKI FAKULTET

SLAVEN GRIZELJ

UTJECAJ FINANCIJSKOG SUSTAVA NA GOSPODARSKI RAST

DOKTORSKI RAD

Split, 2016.

SVEUČILIŠTE U SPLITU
EKONOMSKI FAKULTET

POSLIJEDIPLOMSKI SVEUČILIŠNI STUDIJ
EKONOMIJA I POSLOVNA EKONOMIJA

Slaven Grizelj

UTJECAJ FINANCIJSKOG SUSTAVA NA GOSPODARSKI RAST

DOKTORSKI RAD

Mentor: prof.dr.sc.Cota Boris

Split, 2016.

Članovi povjerenstva za obranu doktorske disertacije:

Prof.dr.sc. Filipić Petar, Ekonomski fakultet Sveučilišta u Splitu (predsjednik)

Prof.dr.sc. Pećarić Mario, Ekonomski fakultet Sveučilišta u Splitu **(**član)

Prof.dr.sc.Cota Boris, Ekonomski fakultet Sveučilišta u Zagrebu (član i mentor)

PREDGOVOR

Postati doktorom znanosti nužan je korak u izgradnji akademske karijere, ali je za mene bio i velik izazov i obveza. Nakon završetka dodiplomskoga studija imao sam želju nastaviti u napredovanju u razvoju svoje akademske karijere i to sam i uradio upisom na poslijediplomski magistarski studij na Ekonomskom fakultetu u Sarajevu, ali zbog odlaska izvan zemlje radi posla nisam bio u mogućnosti završiti isti. Nakon povratka u Bosnu i Hercegovinu 2008. godine, financijska je kriza već uzela maha i počelo je narušavanje gospodarstava zemalja u svijetu. Istodobno je gospodarska kriza pokazala koliko su gospodarstva globalizirana i povezana. Pogledamo li razinu BDP po stanovniku, vidljivo je da su se neke zemlje vratile na razinu devedesetih godina prošloga stoljeća. Upravo me je to i inspiriralo da krenem u istraživanje međusobne ovisnosti financijskoga sustava i gospodarskoga rasta.

Put do naslova doktora znanosti isprepleten je mnogim pitanjima, sumnjama, razmišljanjima, promjenama raspoloženja, ali i upornošću za stizanjem do željena cilja. Mogao bih stjecanje ove titule slikovito opisati kao uspon na planinu. Čar penjanja nije doći na vrh, već upravo onaj dio vremena od podnožja kada se starta pa sve do vrha, napose onaj dio kada se dogode padovi i kada se razmišlja o odustajanju. Upravo su to trenutci koji se pamte.
Stjecanje titule doktora znanosti bio je izrazito težak put, ali mi je znatno olakšan zahvaljujući mojoj supruzi Sanji koja se cijelo vrijeme trudila osigurati mi odlične uvjete za rad, iako sam bio i poslovno odsutan od kuće. Ona je preuzela na sebe cijelu brigu u odrastanju naše djece Sarah Sofije i Roberta. Zahvaljujem i Sanjinoj mami koja je bila uvijek tu kada je trebala pomoć.

Iako ovaj rad potpisuje jedan autor, u ovaj su tekst utkana razmišljanja, savjeti, prijedlozi i kritike mnogih kolega. Veliko hvala profesoricama i profesorima sa Ekonomskog fakulteta u Splitu i Ekonomskog fakulteta u Mostaru. Posebno veliko hvala prof.dr.sc. Filipić Petru, prof.dr.sc. Pećarić Mariu, prof.dr.sc. Garača Željku, prof.dr.sc. Dulčić Želimiru, prof.dr.sc.Pavić Ivanu, prof.dr.sc. Nikoliću Nikši i kolegici Marini Katić Smoljo. Zahvaljujem i svim profesorima koji su pomogli kroz niz prijedloga koje su nam dali kroz ciklus od 5 radionica.

Na kraju, posebno i veliko hvala mom mentoru prof. Borisu Coti koji je uz sve svoje obveze uspio kvalitetno i bezrezervno pratiti i pomagati mi u radu.

Zasluge u ovome radu imaju i moj tata i braća Mate, Bruno, Igor i Boris te mnogobrojni prijatelji koji su trpjeli moja promjenjiva stanja duha. Ovo se „putovanje“ ne završava stjecanjem titule doktora znanosti, već nastavlja dalje u potrazi za odgovorima na mnoga pitanja koja su nastala u ovom istraživanju čemu se i radujem.

Doktorsku disertaciju posvećujem svojoj pok. mami Nadi koja je ostavila ogroman utisak u mom odrastanju i kojoj sam neizmjerno zahvalan na svemu.

Autor

SAŽETAK

Ovo istraživanje daje prikaz analize utjecaja razvoja financijskog sustava na gospodarski rast u odabranim zemljama središnje, istočne i jugositočne Europe. Prije svega, daje se pregled dosadašnjih istraživanja na temu utjecaja razvoja financijskog sustava na gospodarski rast. Teorijska istraživanja pokazuju da usljed averzije rizika i asimetrije informacija između zajmoprimatelja i zajmodavatelja motivira postojanje financijskih intermedijatora i financijskog stržišta.

Razlike u razvijenosti financijskog sustava u promatranim zemljama daje objašnjenje za različiti utjecaj na akumulaciju kapitala i tehnološke inovacije a koje su osnovne i glavne odrednice održivog dugoročnog gospodarskog rasta. S empirijskog stajališta, ovo istraživanje je produbilo postojeće istraživačke strategije kroz prikaz i kritički osvrt dosadašnjih istraživanja, analizu funkcija financijskog sustava i dostupnosti podataka i identifikacije specifičnih kanala putem kojih razvoj financijskog sustava može utjecati na gospodarski rast. I teorijski i empirijski dio ove disertacije je potvrdilo pozitivan utjecaj razvoja financijskog sustava na gospodarski rast. Nalaže se posebna pažnja nositeljima ekonomske politike da razvoj financijskog sustava uzmu ozbiljno u razmatranju kroz prizmu njegovog razvoja i utjecaja na gospodarski rast. Isto tako, ova disertacije predlaže dodatne pravce gdje je potrebno odraditi dodatna istraživanja.

Ključne riječi: financijski sustav, gospodarski rast, tranzicijske zemlje, panel modeli

SUMMARY

This study presents the analysis of the impact of the development of the financial system on economic growth in selected countries of Central, Eastern and Southeastern Europe. First of all, it provides an overview of previous research about the influence of the development of the financial system on economic growth. Theoritical research shows that, as a result of risk aversion and the information asymmetry between borrower and lender, it motivates the existence of financial intermediaries and financial market.

Differences in the development of the financial system in the observed countries provide an explanation for the different effects on capital accumulation and technological innovation which are basic and the main determinants of sustainable long-term economic growth. From an empirical point of view, this research has deepened the existing research strategies through representation and critical review of previous studies, the analysis of the functions of the financial system and the availability of data and identification of specific channels through which the development of the financial system may affect the economic growth. Both theoretical and empirical part of this thesis has confirmed the positive effect of the development of the financial system on economic growth. Special focus is suggested to economic policy holders to take the development of the financial system under serious consideration through the prism of its development and impact on economic growth. Also, this thesis proposes additional directions where it is necessary to do additional research.

Keywords: financial system, economic growth, transition countries, panel models.

SADRŽAJ

PREDGOVOR

SAŽETAK

SUMMARY

SADRŽAJ

I. UVOD 1

1.1. DEFINIRANJE PROBLEMA I PREDMETA ISTRAŽIVANJA 1
1.2. SVRHA I CILJEVI ISTRAŽIVANJA 3
1.3. POSTAVLJANJE ZNANSTVENIH HIPOTEZA 4
1.4. METODE ISTRAŽIVANJA 6
1.5. SADRŽAJ I STRUKTURA RADA 7
1.6. OČEKIVANI ZNANSTVENI DOPRINOS 9

II. TEORIJSKI OKVIR ISTRAŽIVANJA FINANCIJSKOGA SUSTAVA I GOSPODARSKOGA RASTA 12

2.1. TEORETSKI ASPEKTI FINANCIJSKOGA SUSTAVA 12
2.1.1. Pojmovno određenje financijskog sustava 12
2.1.1.1. Karakteristike razvoja financijskoga sustava 17
2.1.1.2. Determinante razvoja financijskoga sustava 19
2.1.2. Funkcije financijskoga sustava 21
2.1.3. Ekonomija i financijski sustav 23
2.1.4. Financijska intermedijacija 25
2.1.5. Financijska regulacija 27
2.2. TEORIJSKI ASPEKTI GOSPODARSKOG RASTA 33
2.2.1. Definiranje pojma gospodarskog rasta 33
2.2.2. Modeli rasta 37
2.2.2.1. Neoklasičan model rasta 37
2.2.2.2. Endogeni modeli rasta 46
2.2.2.3. Determinante gospodarskog rasta 54
2.2.3. Kanali utjecaja financijskog sustava na gospodarski rast 59
2.3. FINANCIJSKI SUSTAV I FINANCIJSKA STRUKTURA U ODABRANIM ZEMLJAMA 67
2.3.1. Razvoj bankarskoga sustava 67
2.3.2. Razvoj nebankarskoga sustava 80
2.3.3. Financijska struktura promatranih zemalja 83

III. ANALIZA PREDHODNIH TEORIJSKIH I EMPIRIJSKIH ISTRAŽIVANJA O VEZI FINANCIJSKE RAZVIJENOSTI I GOSPODARSKOGA RASTA 98

3.1. UVODNE NAPOMENE 98
3.2. RADOVI KOJI UKAZUJU NA POZITIVNU VEZU IZMEĐU FINANCIJA I GOSPODARSKOGA RASTA 104
3.3. RADOVI KOJI NE POKAZUJU UVIJEK POZITIVNU VEZU IZMEĐU FINANCIJA I GOSPODARSKOG RASTA ILI UPUĆUJU NA NEPOSTOJANJE TE VEZE 109
3.4. NELINEARNOST IZMEĐU FINANCIJA I GOSPODARSKOGA RASTA 114
3.5. RADOVI KOJI SU TEMELJENI NA ISTRAŽIVANJU UTJECAJA NA RAST NA PODATCIMA NA RAZINI GRANA PODUZEĆA 115

IV. KONCEPTUALNI MODEL UTJECAJA FINANCIJSKOG SUSTAVA NA GOSPODARSKI RAST

4.1. POLAZIŠTA I SADRŽAJNE ODREDNICE ZA FORMIRANJE MODELA VEZE IZMEĐU FINANCIJSKOG SUSTAVA I GOSPODARSKOG RASTA 118
4.2. ELEMENTI MODELA I NJIHOVA OPERACIONALIZACIJA 123
4.3. GRAFIČKA FORMALIZACIJA ISTRAŽIVANJA 125

V. EMPIRIJSKO UTVRĐIVANJE UTJECAJA FINANCIJSKOG SUSTAVA NA GOSPODARSKI RAST 129

5.1. ISTRAŽIVAČKE HIPOTEZE 129
5.2. METODOLOŠKI ASPEKTI ISTRAŽIVANJA 131

5.2.1. Sadržajni, prostorni i vremenski obuhvat istraživanja ... 131
5.2.2. Instrumenti i faze istraživanja ... 132
5.2.3. Metodologija obrade podataka ... 134
5.2.4. Statističke metode istraživanja ... 134
5.2.4.1. Panel-modeli ... 134
5.2.4.1.1. Združeni model ... 136
5.2.4.1.2. Model s fiksnim efektom ... 137
5.2.4.1.3. Model sa slučajnim efektom ... 142
5.2.4.1.4. Problem autokorelacije ... 146
5.2.4.2. Dinamički panel-modeli ... 149
5.2.4.2.1. Karakteristike dinamičkog panel-modela ... 149
5.2.4.2.2. Autoregresijski dinamički panel-model ... 151
5.2.4.2.3. Dinamički panel-model s nezavisnim varijablama ... 156
5.3. REZULTATI EMPIRIJSKOG ISTRAŽIVANJA ... 160
5.3.1. Odabrane zemlje središnje, istočne i jugoistočne Europe ... 160
5.3.2. Deskriptivna analiza ... 163
5.3.3. Izbor odgovarajućeg panel-modela i interpretacija panel-analize ... 170

VI. ZAKLJUČNA RAZMATRANJA ... 194

6.1. SAŽETAK REZULTATA EMPIRIJSKOG ISTRAŽIVANJA I RASPRAVA ... 194
6.2. DOPRINOSI I IMPLIKACIJE REZULTATA ISTRAŽIVANJA ... 199
6.2.1. Teorijski doprinosi i implikacije istraživanja ... 199
6.2.2. Empirijski doprinosi i implikacije istraživanja ... 200
6.3. OGRANIČENJA PROVEDENOG ISTRAŽIVANJA I PREPORUKE ZA DALJNJA ISTRAŽIVANJA ... 203

VII. POPIS LITERATURE ... 205

VIII. POPIS TABLICA ... 216

IX. POPIS GRAFIKONA ... 217

X. POPIS SLIKA ... 218

XI. PRILOG 1 ... 219

I. UVOD

1.1. Definiranje problema i predmeta istraživanja

Financijski sustav obavlja nekoliko osnovnih funkcija: mobilnost štednje, platežnu funkciju, gospodarsko-političku funkciju, alokaciju resursa, korporativnu kontrolu, upravljanje rizikom i olakšavanje razmjene roba i uslužno-kreditnih funkcija. Svaka od ovih funkcija može imati značajan učinak na gospodarski rast jer se preko njih može utjecati na akumulaciju kapitala i na tehnološke inovacije.

Bitan razlog nastanka financijskoga sustava, odnosno financijskih institucija i tržišta, su asimetrična distribucija informacija te troškovi prikupljanja informacija i obavljanja transakcija. Različite kombinacije informacijskih i transakcijskih troškova rezultiraju u različitim osobinama i organizaciji financijskih institucija i tržišta.

Financijski sustavi zemalja Europske unije, kao i nove zemlje pristupnice EU-a, posljednjih godina prolaze kroz kontinuiran proces transformacije i dubokih reformi. Promjene su inicirane informatičkom tehnologijom i internacionalizacijom tržišta. Razvoj informatičke tehnologije svakako je prvi razlog koji ima za posljedicu stvaranje novih proizvoda i smanjenje troškova nastalih pružanjem tradicionalnih usluga. Drugi je razlog internacionalizacija financijskih tržišta. Europske integracije svakako predstavljaju u svojoj evoluciji jak čimbenik internacionalizacije financijskih tržišta odabranih zemalja.

Za razliku od razvijenih zemalja, makroekonomski utjecaj (utjecaj na gospodarski rast) financijskoga sektora u Hrvatskoj, Bosni i Hercegovini i ostalim tranzicijskim zemljama, uspoređujući ih sa zemljama središnje i istočne Europe, još je uvijek nedovoljno znanstveno obrađena tema. Veza između razvijenosti financijskog sustava i gospodarskog rasta predmet je istraživanja mnogih ekonomista.

U prošlosti je najveća prepreka u daljnjem napretku bio upravo nedostatak odgovarajućih podataka kojima bi se bolje mogla ocijeniti učinkovitost financijskoga sustava. U budućnosti bi istraživači trebali obratiti više pozornosti na moguće nelinearnosti i heterogenosti u procesu rasta u pojedinim zemljama, kao i na negativnu stranu financija, kako je to pokazala posljednja

financijska kriza koja je startala u SAD-u. (Usp. Bađun, 2009.) Detaljnije analize utjecaja financijskoga sustava na gospodarski rast bit će prezentirane u posebnom dijelu ovoga rada.

Premda se na prvu pomisao čini logičnim da razvoj financijskoga sustava pozitivno utječe na gospodarski rast, konačan odgovor na to pitanje još nije dan. U istraživanju veze između financija i rasta posebno je i pitanje kauzalnosti kao i smjera veze financija i rasta.

Iz prethodno navedenoga nameće se glavni razlog da će predmet ovoga istraživanja – utjecaj financijskoga sustava na gospodarski rast – pridonijeti njegovu jasnijemu razumijevanju. Rad će se fokusirati na istraživanju veze i utjecaja financijskoga sustava i gospodarskoga rasta.

U kontekstu navedene problematike definira se problem istraživanja:

Ekonomska teorija još nema jednoznačno stajalište o utjecaju financijskoga sustava na gospodarski rast. Stoga valja posegnuti za empirijskom analizom kako bi se odgovorilo na pitanje ima li razvoj financijskoga sustava pozitivan utjecaj na gospodarski rast. Sam proces razvoja financijskog sustava (tehnologija, usluge,...) i priključenja tranzicijskih zemalja u EU i integracija financijskoga sustava u unutarnji financijski sustav EU-a ima utjecaj na financijski sustav zemalja kandidatica, a time i na njihovo djelovanje u smjeru jačanja gospodarstva. Problematika koju ovdje treba istražiti jest konkurentnost financijskoga sustava, njihova učinkovitost i udovoljavanje preduvjetima gospodarskoga rasta. Upravo je ovo problem koji treba konzistentno istražiti, dijagnosticirati i primjereno riješiti jer u protivnom može implicirati brojne štete za financijski sustav i gospodarstva zemalja.

Iz ovako formulirane problematike i problema istraživanja moguće je postaviti predmet istraživanja:

- istražiti i analizirati sve relevantne performanse i elemente strukture financijskih sustava zemalja, koncentracije, konkurencije i učinkovitosti, dokazati mikroekonomsko i makroekonomsko značenje učinkovitosti, odnosno, konkurencije financijskoga sustava
- istražiti značaj i definirati ključne elemente za kreiranje prikladne i dobro osmišljene prilagodbe tržišnog i institucionalnog okvira na planu integracije financijskoga sustava u EU s posebnim osvrtom na Bosnu i Hercegovinu i na temelju istraživanja predložiti mjere za povećanje koristi razvoja financijskog sustava
- utvrditi utjecaj i intenzitet utjecaja financijskog sustava na gospodarski rast
- usporediti razvijene zemlje i zemlje u razvoju.

1.2. Svrha i ciljevi istraživanja

Ciljevi ovog istraživanja proizlaze iz problema i predmeta istraživanja:

1. na primjeru odabranih zemalja provjeriti povezanost financijskoga sustava i njegova razvoja te utjecaj na gospodarski rast (radit će se usporedba razvijenih financijskih sustava te financijskog sustava zemalja središnje, istočne i jugoistočne Europe);
2. ako postoji razlika utjecaja financijskoga sustava na gospodarski rast, utvrditi razloge i obrazložiti ih.

Prvi cilj istraživanja odgovorit će na sljedeća pitanja:

- utječe li financijski sustav na gospodarski rast
- kada i u kojim okolnostima financijski sustavi potiču gospodarski rast i što definira njegovu učinkovitost u tom kontekstu
- ako su financije važne za rast, zašto neke zemlje imaju financijske sustave koji potiču rast, a neke nemaju.

Drugi cilj istraživanja odgovorit će na sljedeća pitanja:

- postoji li razlika utjecaja financijskoga sustava na gospodarski rast između razvijenih zemalja i zemalja u tranziciji
- ako postoji razlika utjecaja financijskog sustava na gospodarski rast s obzirom na razvijenost financijskog sustava, treba utvrditi zašto postoji
- analizirati teorijske osnove i dosadašnja istraživanja o predmetnom odnosu

Svrha je ocijeniti ulogu, značaj te modalitete financijskog sustava i njegovog razvoja na gospodarski rast. Na temelju spoznaja dati smjernice i mjere vezane za reformu i tendencije razvoja financijskog sustava.

Istraživanje će poslužiti nositeljima ekonomske politike za poboljšanje učinkovitosti ekonomske politike uz saznanja o interakciji financijskoga sustava te prvenstveno monetarne i fiskalne politike, a u cilju povećanja gospodarskoga rasta.

1.3. Postavljanje znanstvenih hipoteza

Pod hipotezom se podrazumijeva svojevrstan misaoni odgovor o predmetu istraživanja, odnosno manje ili više vjerojatnu pretpostavku da postoji neka pojava kao uzrok ili kao posljedica neke druge pojave.

U radu će se promatrati utjecaj financijskoga sustava na gospodarski rast. Na temelju tog koncepta definirana je i polazna hipoteza koja glasi:

H1: Financijski sustav utječe na gospodarski rast.

Tijekom razrade konstrukta za prijedlog modela istraživanja pojavila se potreba za uvođenjem dviju pomoćnih hipoteza koje međusobno povezuju konstrukte modela koji su građeni od indikatora. Dakako, pomoćne hipoteze u sinergiji direktno i/ili indirektno daju doprinos temeljnoj radnoj hipotezi.

Slijedi prikaz i kratko pojašnjenje hipoteza proisteklih iz predložena naslova potencijalne disertacije.

Prva pomoćna hipoteza glasi:

H1a: ***Razvijeniji i aktivniji financijski sustavi imaju značajnu ulogu u razvoju realnog sektora gospodarstva, što pozitivno utječe na ukupan gospodarski rast.***

Prva pomoćna hipoteza trebala bi pomoći u potvrdi teze u postojanju povezanosti između razvijenijih i aktivnijih financijskih sustava i njihova utjecaja na gospodarski rast. Ova će se hipoteza analizirati kroz indikatore veličine financijskoga sustava i njegova odnosa s BDP-om kao i aktivnost financijskoga sustava kroz kreditnu aktivnost. Budući da su financijski sustavi promatranih zemalja bankocentrični, u analizi ove hipoteze posebno će se pozorno koristiti upravo analiza veze i utjecaja bankarskoga sektora na gospodarski rast.

Druga pomoćna hipoteza glasi:

H1b ***Učinkovitiji i operativniji financijski sustavi omogućuju bolju alokaciju kapitala i na taj način potiču gospodarski rast.***

Druga pomoćna hipoteza uvodi se zato da bi se potvrdilo da su financijski sustavi koji vode bolju troškovnu politiku bolji i učinkovitiji u analizi određenih investicijskih zahtjeva. Na ovaj se način radi selekcija boljih investicijskih projekata i time potiče gospodarski rast. Liberalniji financijski sustavi u pogledu ulaska konkurencije pridonose boljem financijskom sustavu u pogledu novih proizvoda, tehnologija i općenito novoga načina poslovanja, a sve to pozitivno utječe na gospodarstvo zemlje.

Iz postavljenih hipoteza, a da bi se navedene istražile, te na temelju dobivenih rezultata prihvatile ili odbacile, mogu se identificirati dvije varijable:

- financijski sustav – nezavisna varijabla
- gospodarski rast – zavisna varijabla

1.4. Metode istraživanja

Struktura rada temelji se na teorijskome dijelu, empiriji i zaključcima. U teorijskome dijelu bit će opisani pojam i oblici razvijenosti financijskoga sustava te izložiti različiti modeli gospodarskoga rasta.

Za empirijski će se dio na temelju prikupljenih statističkih podataka za odabrane zemlje vršit analiza prema statističkim i ekonometrijskim metodama. U empirijskom će se dijelu analizirati sekundarni podatci za Hrvatsku i odabrane zemlje srednje, istočne i jugoistočne Europe prikupljeni na temelju relevantnih svjetskih publikacija. U analizi podataka, dakako, koristit će se Excel i SPSS, a od statističkih tehnika panel-analiza.

U deskriptivnom dijelu je opisana financijska struktura zemalja kako bi se usporedila razina razvijenosti financijskoga sustava.

Prikupljanje podataka o istraživačkoj temi, odnosno pokazateljima za mjerenje identificiranim varijablama, provest će se na zemljama središnje, istočne i jugoistočne Europe: Albanije, Austrije, Bosne i Hercegovine, Bugarske, Hrvatske, Češke, Njemačke, Grčke, Mađarske, Italije, Makedonije, Crne Gore, Poljske, Rumunjske, Srbije, Slovačke i Slovenije.

Za potrebe ovoga znanstvenoga istraživanja koristit se znanstvene metode indukcije, dedukcije, analize, sinteze, deskripcije, apstrakcije, konkretizacije, komparacije te statističke analize.

Indukcija i dedukcija pomoći će u izvođenju zaključaka na temelju dinamike i intenziteta u promjenama u pojedinim pojavama i procesima u tržišnoj strukturi i izvođenju zaključaka za mjesto i položaj financijskoga sustava u kontekstu gospodarskoga rasta (utjecaj na isti).
Metoda statističke analize (regresijska analiza, analize vremenskih serija, panel-analiza,...) koristi se prilikom izračuna vrijednosti i dinamike pokazatelja koji preslikavaju stanje i performanse financijskoga sustava zemalja srednje, istočne i jugoistočne Europe. Sve statističke metode, analize i prikazi podataka temeljit će se na analizi za financijske sustave zemalja koje će se promatrati u ovome radu.
Metoda deskripcije koristit će se u radu pri opisivanju pojava, trendova, činjenica i promjena u financijskome sustavu promatranih zemalja.
Komparativna će se metoda koristiti prilikom usporedbe stanja i rezultata u financijskoj intermedijaciji, konkurentnosti i učinkovitosti bankovnoga sustava promatranih zemalja.
Metodom apstrakcije analizirati će se utjecaj i drugih varijabli na gospodarski rast, ali i isključiti one varijable koje nisu bitne.

1.5. Sadržaj i struktura rada

Doktorska se disertacija sastoji od šest tematskih cjelina, odnosno poglavlja. Detaljnije obrazloženje svakog poglavlja dano je u nastavku, a finalna dispozicija u sadržaju ove disertacije.

U prvome poglavlju (uvodnom dijelu) definirat će se i objasniti predmet istraživanja; činjenicama potkrijepiti i elaborirati važnost te aktualnost razmatrane problematike; opisat će se spoznajni i praktični ciljevi koji se ovim istraživanjem namjeravaju ostvariti te znanstvene metode koje će se koristiti u teorijskom i empirijskom dijelu istraživanja. Sadržajna struktura rada bit će izložena u završnom dijelu prvoga poglavlja.

U drugome poglavlju dat će se teorijski okvir istraživanju financijskoga sustava i gospodarskoga rasta. U prvome dijelu ovoga poglavlja razmatrat će se teorijske spoznaje o financijskome sustavu polazeći od definiranja pojma financijskoga sustava, funkcija financijskoga sustava i regulacije financijskoga sustava. U drugome dijelu promatraju se gospodarski rast s ciljem utvrđivanja adekvatnog načina mjerenja gospodarskoga rasta i nekoliko modela gospodarskoga rasta. Treći dio drugoga poglavlja govori o financijskim sustavima i strukturi odabranih zemalja. Četvrti dio drugoga poglavlja bavi se formiranjem modela veze između financijskoga sustava i gospodarskoga rasta.

U trećem poglavlju izvršit će se analiza prethodnih, dosadašnjih teorijskih i empirijskih istraživanja na temelju kojih će se pokušati utvrditi povezanost, utjecaj i smjer utjecaja razvoja financijskoga sustava na gospodarski rast.

U četvrtom poglavlju prikazat će se polazište od kojega se krenulo u istraživanje i formulirat će se model na temelju kojeg se radi istraživanje utjecaja financijskoga sustava na gospodarski rast. Izložit će se osnovni model nakon kojeg je nastao finalan model i iz kojeg su definirane hipoteze. Sve će se ovo i grafički formulirati i objasniti.

U petome poglavlju prezentirat će se rezultati empirijskog istraživanja tako da će se prvo izložiti i obrazložiti postavljene istraživačke hipoteze, elaborirat će se metodološki aspekt definiranjem njegova vremenskoga, prostornoga i sadržajnoga obuhvata, opisati instrumenti istraživanja te načini prikupljanja i obrade podataka. Nakon eksplikacije metodološkog aspekta

empirijskog istraživanja slijedi prezentacija rezultata empirijskog istraživanja utjecaja financijskoga sustava na gospodarski rast u okviru čega će se izvršiti i prosudba postavljenih istraživačkih hipoteza.

U šestom poglavlju ovoga rada uslijedit će sažetak ukupnih rezultata te njihova rasprava nakon čega će se izložiti glavni teorijski i praktični doprinosi nastali kao rezultat testiranja postavljenoga modela istraživanja, odnosno uklapanja rezultata istraživanja u polazni teorijski model. Iznijet će se zaključna razmatranja do kojih se došlo na temelju rezultata cjelokupnog (teorijskog i empirijskog) istraživanja te će se ukazati na zaključke do kojih se došlo u pogledu praktičnoga i spoznajnoga doprinosa. Na samu kraju ukazat će se na potencijalna ograničenja ovoga istraživanja i dati smjernice za daljnja znanstvena istraživanja.

1.6. Očekivani znanstveni doprinos

U skladu s prethodno navedenim, temeljni cilj doktorske disertacije naslovljene „Utjecaj financijskog sustava na gospodarski rast“ jest oblikovanje modela utjecaja financijskoga sustava na gospodarski rast, odnosno, promatranje indikatora financijskoga sustava i njihova utjecaja na rast BDP-a po glavi stanovnika u odabranim zemljama kako bi se odgovorilo na pitanja postavljena u cilju istraživanja.

Glavni očekivani znanstveni doprinos disertacije proizići će iz potvrđivanja glavne hipoteze, tj. tvrdnje da financijski sustav utječe na gospodarski rast. Upravo je ovo istraživanje interesantno iz dvaju aspekata. Prvo, istraživanje se radi na uzorku zemalja u kojem su razvijene zemlje s razvijenim financijskim sustavom i gospodarstvom te zemlje u tranziciji i na taj će se način moći povući paralela odnosa između financijskoga sustava i njegova razvoja i utjecaja na gospodarski rast. Drugo, ovo će istraživanje dati još jednu znanstvenu potporu značaju financijskoga sustava u cijelosti, a pogotovo njegovu utjecaju na rast.

Dodatni znanstveni doprinos ove disertacije jest kritički prikaz dosadašnjih istraživanja o financijskome sustavu i gospodarskome rastu, njihovoj međuovisnosti i utjecaju, uzročnicima i problemima mjerenja.

Stoga bi se znanstveni doprinos predložene doktorske disertacije ogledao:

- u povezivanju dviju veličina (varijabli) kako bi se detaljnije objasnio utjecaj financijskoga sustava kao neovisne varijable na gospodarski rast kao ovisne varijable
- u razvoju znanstvenih spoznaja o financijskome sustavu
- u razvoju znanstvenih spoznaja o gospodarskome rastu
- u razvoju znanstvenih spoznaja o vezi financijskoga sustava i gospodarskoga rasta čime će se unaprijediti već postojeća znanja i pridonijeti daljnjem razvoju navedenih objekata istraživanja
- u razvoju znanstvenih spoznaja pri kreiranju i kreiranju takva odnosa.

Najutjecajniji radovi iz područja odnosa financijskoga sustava i gospodarskoga rasta, iako sadrže vrijedne teorijske postavke i nadopune postojećega koncepta, ne sadrže empirijska istraživanja ovoga opsega i na ovaj način.

Naime, dosadašnja istraživanja o ovoj temi sve su do 90-ih godina prošloga stoljeća bila koncipirana na teoretskim razmatranjima i u tim su radovima autori svoje postavke pokušali dokazati uglavnom preko ilustrativnih primjera. Nakon tog razdoblja budi se svijest o potrebi za empirijskim istraživanjima koja ne jenjavaju u proteklih 30-ak godina. Glavni nedostatak koji prati ova istraživanja do danas jest neuređenost ili nepostojanje statističkih podataka po zemljama i uglavnom su u ovim istraživanjima u većem dijelu bile izostavljene zemlje u razvoju (zemlje u tranziciji). Dodatan problem koji se javlja kod dosadašnjih istraživanja financijskoga sustava (nedostatak odgovarajućih podataka kojima bi se mogla bolje ocijeniti razvijenost financijskoga sustava) jest taj da se većina istraživanja fokusira na određen broj indikatora.[1] U ovom istraživanju obratit će se više pozornosti na moguće nelinearnosti i heterogenosti u procesu rasta u pojedenim zemljama, te na učinak financijske kriz . Promatrat će se zemlje u razvoju kao i zemlje koje imaju razvijen financijski sustav i već se duže vrijeme nalaze integrirani u veće financijsko tržište (npr. Njemačka i Austrija). Na ovaj se način može raditi analiza i uspoređivanje između zemalja istoga stupnja gospodarskoga razvoja i razvoja financijskoga sustava, s jedne strane, i stavljanje u odnos tih zemalja sa razvijenim zemljama i koje imaju razvijeniji financijski sustav.

Sve navedeno ukazuje na empirijski doprinos koji se očituje:

- u empirijskoj verifikaciji predloženog teorijskog i matematičkog modela
- u konstruiranju skupina indikatora financijskoga sustava te njihovog testiranja na uzorku više različitih zemalja
- u testiranju hipoteza.

[1] Najčešći je slučaj u dosadašnjim istraživanjima da se u razmatranje uzimaju tri ili četiri indikatora financijskoga sustava ili se promatrao samo bankarski sustav jer su u tim istraživanjima odabrane zemlje imale uglavnom bankocentrične sustave. Dakako, problem je i u tome što je velik broj dosadašnjih istraživanja bio usredotočen na razvijene zemlje i nije se radilo na usporedbi zemalja različita stupnja razvijenosti financijskog sustava kako će se uraditi u ovoj disertaciji(odabrane su zemlje središnje, istočne i jugoistočne Europe).

Ukratko, kao glavne elemente znanstvenoga doprinosa možemo istaknuti:

- prvo istraživanje takvoga tipa u Hrvatskoj i regiji
- povijesni pregled dosadašnjih istraživanja
- istraživanje i analiza svih relevantnih pojmova i koncepata iz područja financijskog sustava
- oblikovanje originalnog teorijskog i empirijskog modela
- sistematizaciju i klasifikaciju pojmova, koncepata i događaja iz područja istraživanja
- doprinos boljem razumijevanju i funkcioniranju financijskog sustava
- nove spoznaje o procesu utjecaja financijskoga sustava na gospodarski rast
- empirijska testiranja veza između financijskoga sustava i gospodarskoga rasta.

Istraživanje teme disertacije je interesantno iz dvaju aspekata. Prvo, s obzirom na to da se istraživanje provodi na uzorku zemalja s razvijenim financijskim sustavom i gospodarstvom i na uzorku manje razvijenih zemalja sa slabije razvijenim financijskim sustavom i gospodarstvom, moći će se jasnije objasniti odnos financijskoga sustava i njegova razvoja i utjecaja na gospodarski rast. Drugo, istraživanje će omogućiti još jednu znanstvenu potporu značaja financijskoga sustava i njegova utjecaja na gospodarski rast.

II. TEORIJSKI OKVIR ISTRAŽIVANJA FINANCIJSKOGA SUSTAVA I GOSPODARSKOGA RASTA

2.1. Teoretski aspekti financijskoga sustava

Financijski sustav i njegov utjecaj na gospodarski rast sustavno počinje biti proučavan već krajem 50-ih godina prošloga stoljeća, a posebno se intenzivira 90-ih godina do danas. Naime, najvažniji razlog razlikama u stupnju gospodarskoga razvoja pojedinih zemalja nije u njihovim prirodnim bogatstvima, nego u učinkovitosti njihova korištenja. Primjerice, Rusija je vrlo bogata prirodnim resursima koji se ne koriste učinkovito za razliku od Japana koji je u resursima siromašan, ali ih vrlo uspješno koristi. Razvijen i učinkovit financijski sustav može bitno utjecati na povećanje iskoristivosti oskudnih resursa, a time i na gospodarski rast.
Dakako, postoje razlike u stupnju razvijenosti financijskih sustava zemalja. U skladu s time rađeno je i ovo istraživanje koje će se usredotočiti upravo na tu problematiku. Doprinos financijskog sustava gospodarskom rastu i razvoju ovisi o njegovoj učinkovitosti u davanju kvalitetnih usluga ostalim sektorima nekog gospodarstva.

2.1.1. Pojmovno određenje financijskog sustava

Dobro organiziran financijski sustav glavni je sastojak održiva gospodarskoga razvoja i rasta i smanjenja siromaštva (*World Bank Jurnal*, 2011.). Ova tvrdnja posebno dobiva na težini kada je riječ o zemljama jugoistočne i istočne Europe, a što je upravo i u fokusu ovoga istraživanja. Banke predstavljaju glavninu financijskog sustava i dominantan instrument akumulacije i alokacije štednje te poticanje gospodarskoga rasta i razvoja. Promatranje i analiziranje razvoja financijskoga sustava te njihove spremnosti i stupnja integracije u monetarnu politiku EU-a, kao i priključivanje unutarnjem bankarskom tržištu EU-a od posebnog je značaja zbog više razloga za promatrane zemlje u ovom istraživanju. Dakako, s obzirom na to da su banke srž monetarnog sustava i kanal monetarnog transmisijskog mehanizma zemalja slabo razvijenog financijskog sustava, posve je razumljiv interes za promatranje banaka u procesu integracije, kao i njihove spremnosti za takav izazov. Utjecaj novog okruženja, operativnog okvira

monetarne politike EU-a, pravna prilagodba i prilagodba infrastrukture čimbenici su integracije financijskoga sustava zemalja istočne i jugoistočne Europe, a istodobno je ključ za provođenje nacionalne, a poslije i jedinstvene monetarne politike EU-a. Siguran i stabilan bankovni sustav, a s tim u vezi i financijski sustav, izložen raznim rizicima, dobro uvezan putem platnoga sustava i međubankovnoga tržišta omogućava disperziju rizika što osigurava učinkovit financijski posrednik, a time i pozitivne učinke na stimuliranje gospodarskoga rasta i razvoja.

Banke posjeduju specifičnost koja ih razlikuje od drugih sektora aktivnosti u svim zemljama: one predstavljaju „sustav“, tj. pripadaju ukupnom institucionalnom i hijerarhijskom ustroju. Prema tomu, banke predstavljaju ključ financijske stabilnosti i ekonomskog razvoja svake zemlje. Međutim, ne treba umanjiti važnost i drugih čimbenika financijskoga sustava i važnost razvoja istih.

Samo pretpostavimo da želimo osnovati poduzeće za proizvodnju nekog proizvoda, no nemamo dovoljno vlastita novca za početak proizvodnje i nećemo biti u mogućnosti ni realizirati projekt. Ali, ako bismo imali nekoga tko ima višak sredstava i s njim dogovorimo da nam iste pozajmi da možemo realizirati svoj projekt, onda imamo situaciju u kojoj smo mi realizirali projekt, a onaj tko nam je posudio novac, stvara određen prinos u višku sredstava koja ima kod sebe. Ukratko, cijelo je gospodarstvo na dobitku.
Dakle, glavna funkcija financijskoga sustava je spajanje ljudi kao u prethodno opisanu slučaju. Kako bismo istražili utjecaje razvoja financijskoga sustava i financijskih posrednika na ekonomiju, prvo moramo razumjeti njihovu opću strukturu i način funkcioniranja.

Slika 2.1. Financijski sustav i tok sredstava

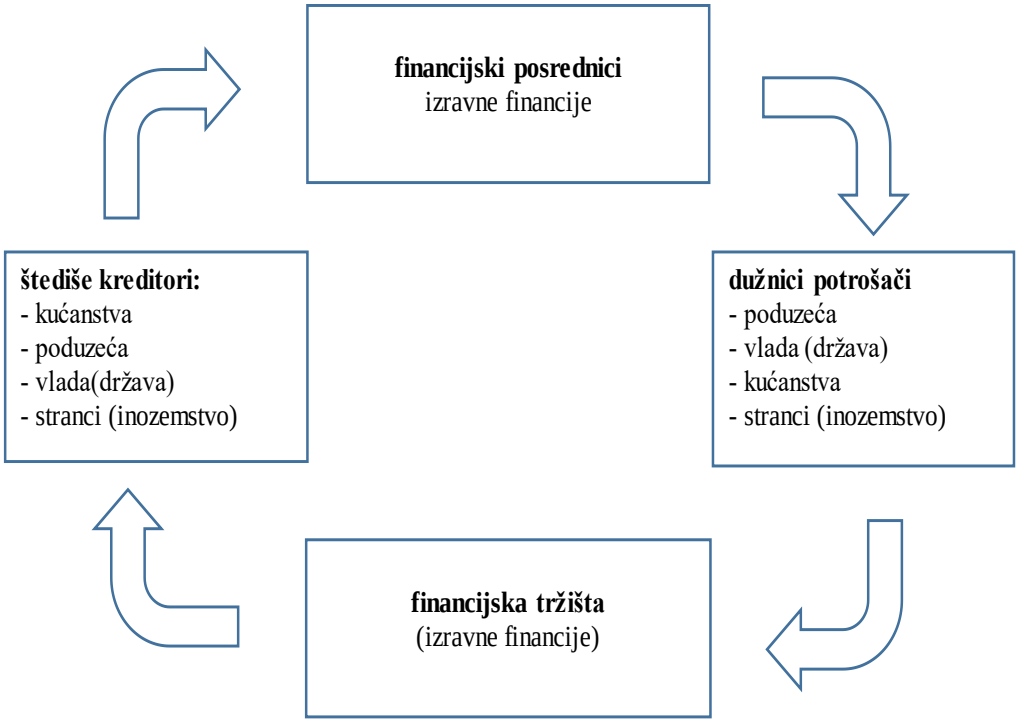

U svakoj ekonomiji financijski sustav obavlja bitnu ulogu preusmjeravanjem sredstava od ljudi koji su uštedjeli novčane viškove trošeći manje od dohotka do ljudi kojima nedostaju novčana sredstva jer žele trošiti više od dohotka.

Uloga je shematski prikazana na slici 2.1. Oni koji štede i kreditiraju (štediše kreditori) prikazani su na lijevoj strani, a oni koji moraju posuditi novac radi financiranja svojih izdataka (dužnici potrošači) prikazani su na desnoj strani. Glavni štediše kreditori su građani, no tu ulogu imaju i poduzeća te vlada (središnja i lokalna vlast). Čak se i stranci i njihove vlade ponekad nađu s viškovima sredstava koja nastoje koristiti za odobravanje kredita.

Najvažniji dužnici potrošači su poduzeća i država. No, kućanstva i stranci također posuđuju sredstva za razna investiranja u nekretnine, pokretnine itd.

Na prethodnoj slici strelice pokazuju kako sredstva teku od štediša kreditora prema dužnicima potrošačima koristeći pritom dva smjera.

U izravnim financijama (smjer u dnu slike), dužnici posuđuju novčana sredstva izravno od kreditora tako što im na financijskim tržištima prodaju vrijednosne papire (vrijednosnice ili

financijski instrumenti). Vrijednosni papiri predstavljaju potraživanja prema dužnikovu budućem dohotku ili imovini. Vrijednosni su papiri imovina osobe koja ih kupi, ali i obveza (dug) za pojedinca ili poduzeće koje ih prodaje (izdaje ili emitira). Primjerice, neko poduzeće XY treba posuditi novčana sredstva kako bi se kupio nov pogon za proizvodnju sokova. Ta bi se sredstva mogla posuditi od štediša tako što bi se prodale obveznice – dužnički vrijednosni papiri – koji su u stvari obećanje o plaćanju u redovitu vremenskome intervalu tijekom unaprijed utvrđenog vremenskog razdoblja.

Postavlja se pitanje zašto je preusmjeravanje sredstava od štediša prema potrošačima toliko važno za jedno gospodarstvo. Dakako, odgovor je u činjenici da ljudi koji štede najčešće nisu poduzetnici – ljudi koji znaju za raspoložive profitabilne prigode za ulaganja. Kada ne bi postojala financijska tržišta, ne bi se nikad sreo poduzetnik koji bi investirao naš višak sredstava. Dakle, u takvim su situacijama obje strane na gubitku kada ne bi postojalo financijsko tržište. Stoga su financijska tržišta ključna za napredak ekonomske učinkovitosti.
Postojanje financijskih tržišta korisno je i kada netko posjeduje sredstva zbog cilja koji nije izravno povezan s povećanjem proizvodnje u poduzeće ili nešto slično. Ako su financijska tržišta postavljena tako da vam ljudi koji su prikupili štednju mogu posuditi novac za kupnju kuće, bit ćete više nego spremni platiti mu neku kamatu kako biste posjedovali kuću dok ste još uvijek mladi da uživate u njoj. Ishod je taj, kako je i prethodno konstatirano, da ste zadovoljni i vi i onaj tko vam je posudio novac. Iz svega predočenoga jasno je zašto su financijska tržišta važna za jednu ekonomiju. Naime, njihova je temeljna funkcija omogućiti premještaj viška sredstva od onih koji ih imaju prema onima kojima su potrebna iz raznih razloga, tj. prema onima kojima nedostaju.

Financijsko posredovanje način je prijenosa novčanih sredstava od krajnjih pozajmljivača krajnjim uzajmljivačima kada se između njih pojavljuje financijski posrednik ili intermedijar.
Drugim riječima, to je proces ustupanja novčanih sredstava novčano suficitarnih jedinica novčano deficitarnim jedinicama tako da se jedan oblik financijskog potraživanja preoblikuje u druge oblike financijskog potraživanja uz pomoć financijskih posrednika.
Financijski posrednik kupuje direktna financijska potraživanja jednih karakteristika i pretvara ih u indirektna potraživanja drugih karakteristika. Proces transformacije potraživanja naziva se financijsko posredovanje, a institucije koje se time bave financijski posrednici.
Financijski posrednici prikupljaju novčana sredstva u obliku depozita na transakcijskim računima, ročnih depozita i depozita po viđenju, prodajom polica osiguranja, naplatom članskih

uloga, prodajom udjela u investicijskim fondovima, emisijom obveznica, blagajničkih zapisa, uzimanjem kredita i sl. što predstavlja potraživanje krajnjih pozajmljivača prema njima. Istodobno, financijski posrednici kupuju vrijednosnice, odobravaju kredite i sl. te tako stječu direktna potraživanja prema krajnjim uzajmljivačima umjesto stvarnih pozajmljivača novčanih sredstava.

Financijski posrednici kupuju dnevna potraživanja od krajnjih pozajmljivača na isti način kao što ih kupuju od krajnjih pozajmljivača u sustavu direktnog financiranja, no za njih je takvo stjecanje direktnih potraživanja samo dio sustava posredovanja. Tu kupnju financiraju prikupljajući novčana sredstva emisijom sekundarnih obveza prema krajnjim pozajmljivačima. Financijsko posredovanje način je prijenosa novčanih sredstava od krajnjih pozajmljivača krajnjim uzajmljivačima, kada se između njih pojavljuje financijski posrednik ili intermedijar.

Drugim riječima, to je proces ustupanja novčanih sredstava novčano suficitarnih jedinica novčano deficitarnim jedinicama tako da se jedan oblik financijskog potraživanja preoblikuje u druge oblike financijskoga potraživanja uz pomoć financijskih posrednika.
Financijski posrednik kupuje direktna financijska potraživanja jednih karakteristika i pretvara ih u indirektna potraživanja drugih karakteristika. Proces transformacije potraživanja naziva se financijsko posredovanje, a institucije koje se time bave financijski su posrednici.
Financijski posrednici prikupljaju novčana sredstva u obliku depozita na transakcijskim računima, ročnih depozita i depozita po viđenju, prodajom polica osiguranja, naplatom članskih uloga, prodajom udjela u investicijskim fondovima, emisijom obveznica i blagajničkih zapisa, uzimanjem kredita i sl., što predstavlja potraživanje krajnjih pozajmljivača prema njima. Istodobno financijski posrednici kupuju vrijednosnice, odobravaju kredite i sl. te tako stječu direktna potraživanja prema krajnjim uzajmljivačima umjesto stvarnih pozajmljivača novčanih sredstava.

Indirektna potraživanja prema krajnjim pozajmljivačima prikazuju se u bilanci financijskih posrednika kao obveze, a direktna potraživanja prema krajnjim uzajmljivačima dio su aktive.
Financijski posrednici su banke, štedne depozitne institucije, osiguravatelji života i imovine, mirovinski fondovi, fondovi zajedničkog investiranja, raznolike državne financijske institucije, stambena društva, odnosno sva ona društva koja u svojoj aktivi imaju direktna financijska potraživanja, a u pasivi indirektna potraživanja kao obvezu prema štedišama i investitorima.

Prednosti indirektnog financiranja:

1. omogućuje se kreiranje financijskog potraživanja raznolikih denominacija (npr. veliki krediti na bazi malih štednih uloga)
2. lakša disperzija rizika – financijski posrednici preuzimaju najveći dio rizika
3. usklađivanje dospijeća – moguća ročna transformacija sredstava (usmjeravanje kratkoročnih izvora u dugoročne plasmane)
4. velika likvidnost sekundarnih obveza financijskih posrednika – lako se pretvaraju u novac ili druga manje likvidna sredstva koja su potrebna investitorima
5. informacijska intermedijacija – investitori ne moraju analizirati svaki projekt niti bonitet krajnjeg pozajmljivača.

2.1.1.1. Karakteristike razvoja financijskoga sustava

Iako u svim promatranim zemljama imamo dominaciju bankarskog sustava u ukupnom financijskom sustavu, posljednjih je godina zamjetan porast drugih financijskih sporednika. U ovom dijelu najviše se ističu mirovinski i investicijski fondovi. Razvoj tržišta dionica u promatranim zemljama može se dijelom zahvaliti privatizacijama putem IPO-a (engl. *initial public offering*). Premda je ova razvojna faza zamjetna nakon krize na svjetskim tržištima, aktivnost na tržištima kapitala zadržala se sve do financijske krize na visokoj razini. Isto tako zamjetno je da su se u zemljama koje su ušle u EU dogodile značajne promjene i u financijskoj strukturi. Ponajprije gotovo su sve banke u stranom vlasništvu u odnosu na ostale financijske sektore. Osim toga, proces konvergencija , pogotovo u vidu smanjenja kamatnih stopa, dovest će do daljnjeg ubrzanja razvoja investicijskih fondova te tržišta kapitala. Na žalost, financijska kriza na globalnoj je razini usporila sve ove procese ne zato što financijski sustavi promatranih zemalja nisu imali snagu za to, već zato što je nestao interes ulagača za novim investicijama. Također, povećanje štednje stanovništva prije 20-ak godina, koja se pojavila povećanjem bogatstva tijekom procesa konvergencije prema EU, dovelo je do očekivanog rasta sektora osiguranja. Na kraju, mirovinska reforma provedena je u većini promatranih poslijetranzicijskih zemalja iz uzorka i može se očekivati rast priljeva novih sredstava. Zbog toga se dogodilo jačanje ostalog dijela financijskoga sustava iz izrazito bankocentričnog u razmjerno uravnoteženiji financijski sustav. Međutim, financijska kriza u dijelu financijskoga sustava u

koji spadaju i nebankarske institucije dovela je do naglog pada udjela u ukupnoj aktivi financijskoga sustava. Banke su opet počele ojačavati i u nekim zemljama njihov udjel u ukupnom financijskom sustavu prelazi čak i 90 %. Dakle, zamjetan je drastičan pad aktivnosti mirovinskih fondova i inače tržišta kapitala koje je postalo nelikvidno u posljednjih šest-sedam godina. Zamjetan je pad aktivnosti i u sektoru lizinga, a i sektor osiguranja doživio je određenu restrukturu i zadnjih se godina podiže s udjelom u financijskom sustavu promatranih zemalja. Ono što je zamjetno za sve zemlje jest to da su im financijski sustavi stabilni i to već duže vrijeme, što pokazuje određenu sigurnost. Dakako, događaju se određene anomalije u bankarskome sustavu gdje dolazi do spajanja manjih banaka, a u nekim zemljama i do njihova nestajanja, odnosno bankrota.

Financijski se sustav smatra konsolidiranim, internacionaliziranim i spremnim za uključivanje u tržišno natjecanje na nekom budućem otvorenom tržištu. Problemi se vide uglavnom u realnom sektoru pa su se modeli poticanja gospodarskoga rasta u promatranim zemljama u proteklu desetljeću zasnivali uglavnom na državnim infrastrukturnim investicijama i pratećem proračunskom deficitu. Premda različite, politike poticanja privatnih ulaganja i razvoja tržišta i tržišne infrastrukture (npr. reforma pravosuđa i sl.) u promatranim zemljama istočne i jugoistočne Europe nisu izostale iz vladinih akcija. Iznosi koji su ulagani u pojedine vladine projekte jasno pokazuju na kojoj su se strani nalazili politički prioriteti. Ovakav model politike poticanja rasta putem državnih ulaganja iscrpio je svoje mogućnosti pa stopa rasta BDP-a bilježi kontinuirano usporavanje, a u većini zemlja i negativan trend.

2.1.1.2. Determinante razvoja financijskoga sustava

Determinante razvoja financijskoga sustava su dohodak, financijska otvorenost i tržišna otvorenost. Dohodak, kao pokazatelj ekonomskog razvoja, smatra se jednom od važnih determinanti razvoja financijskoga sustava. Ta je varijabla posebice značajna za razvoj bankarskoga sustava. Kao pokazatelj dohotka uzima se bruto nacionalni dohodak po glavi stanovnika.

Financijska otvorenost smatra se jednim od najvažnijih preduvjeta razvoja financijskoga sustava. Postoji više ekonomskih varijabli koje se mogu uzeti za pokazatelje financijske otvorenosti.

Jedan od pokazatelja financijske otvorenosti jest udio bruto stranih direktnih investicija u BDP-u (eng. *Gross foreign direct investment to GDP*). Bruto strane direktne investicije računaju se kao zbir apsolutnih vrijednosti priljeva i odljeva stranih direktnih investicija zabilježenih u bilanci plaćanja financijskih računa. U ovaj indikator uključeni su dionički kapital,[2] reinvestirana dobit te ostala dugoročna i kratkoročna kretanja kapitala. Ovaj se indikator razlikuje od standardne mjere za direktne investicije jer računa samo ulazne investicije.

Drugi pokazatelj financijske otvorenosti, vezan za kontrolu kapitalnih optjecaja, udjel je bruto privatnih kapitalnih tokova u BDP-u (eng. *Gross private capital flows to GDP*). Bruto privatni kapitalni optjecaji apsolutan su zbir direktnih priljeva i odljeva investicija, portfelj investicija i drugih priljeva i odljeva investicija zabilježenih na financijskom računu bilance plaćanja s time da su isključene promjene u aktivi i pasivi monetarne vlasti i države.[3]

Treći pokazatelj financijske otvorenosti je indikator financijske globalizacije koji su definirali Lane i Milesi-Ferretti (2006.), a odnosi se na 42 zemlje u razvoju. Podatci za taj indikator dostupni su od 1980. godine. Indikator se definira kao udio strane aktive i pasive u zemlji u BDP-u.[4]

---

[2] Ako je riječ o kupnji više od 10 % dioničkog kapitala.

[3] Definicije za strane direktne investicije i privatne kapitalne optjecaje preuzete su prema: Huang, W. (2006.) Emerging Markets Financial Openness and Financial Development, *Working paper No. 06/588*, Department of Accounting and Finance, University of Bristol.

[4] Ovaj se indikator sve češće koristi kao pokazatelj financijske otvorenosti.

Četvrti pokazatelj financijske otvorenosti je idealan pokazatelj za otvorenost bankarskoga sustava. Ovaj pokazatelj definira se kao omjer broja banaka u stranom vlasništvu i ukupnog broja banaka.

Tržišna otvorenost još je jedna determinanta razvoja financijskoga sustava. Tržišna otvorenost definira se kao udio zbroja uvoza i izvoza u BDP-u.
Financijska otvorenost i tržišna otvorenost jednom se riječju nazivaju *otvorenost*. U mnogim istraživanjima postavlja se pitanje jesu li financijska i tržišna otvorenost međusobno neovisne ili među njima postoji neka veza. Neovisnost varijabli značila bi da povećanje tržišne otvorenosti bez povećanja financijske otvorenosti dovodi do razvoja financijskoga sustava. Naravno, vrijedilo bi i obratno, povećanje financijske otvorenosti bez povećanja tržišne otvorenosti također bi dovelo do razvoja financijskoga sustava. Neki pak smatraju da financijska otvorenost bez tržišne otvorenosti ne vodi do razvoja financijskoga sustava. O financijskoj i tržišnoj otvorenosti i njihovu značaju u razvoju financijskoga sustava provedena su brojna istraživanja.

Rajan i Zingales (2003.) dali su pregled razvoja financijskoga sustava zemalja u dvadesetom stoljeću. Oni su dvadeseto stoljeće podijelili u više vremenskih razdoblja s obzirom na povijesna, politička i ekonomska zbivanja. Na temelju empirijskih rezultata za sva vremenska razdoblja došli su do jedinstvenog zaključka da financijska otvorenost bez tržišne otvorenosti i obratno ne vodi do razvoja financijskoga sustava. Isto tako, naglasili su da otvaranje samo jednog od tržišta može dovesti do financijske represije. Zaključak je kako jedino simultana financijska otvorenost i tržišna otvorenost vode do razvoja financijskoga sustava.[5] Taj se zaključak u radovima naziva RZ-hipoteza o simultanu otvaranju.

Chinn i Ito (2006.) ispitivali su kako financijska otvorenost uzrokuje financijski rast na uzorku od 108 zemalja u razdoblju od 1980. do 2000. godine. U svom radu došli su do zaključka da je tržišna otvorenost preduvjet financijskom otvaranju, a financijska otvorenost uzrokuje financijski rast. Također su došli do zaključka da je razvoj bankarskoga sustava preduvjet za

[5] Rajan, R. G. i Zingales, L. (2003.) „The great reverals: the politics of financial development in the twenty century“, *Juornal of Financial Economics*, 69, str. 5. – 50.

razvoj tržišta kapitala. U slabije razvijenim zemljama razvoj bankarskoga sustava djeluje na razvoj tržišta kapitala i razvoj tržišta kapitala djeluje na razvoj bankarskoga sustava.[6]
Law i Demetriades (2006.) u svom su radu procijenili po tri modela za razvoj bankarskoga sustava i tri modela za razvoj tržišta kapitala za zemlje u razvoju. Na temelju rezultata analize nisu mogli potvrditi ni odbaciti Rajan-Zingales-hipotezu (RZ - hipoteza) o simultanu otvaranju. Došli su do zaključka da tržišna otvorenost različito djeluje na razvoj financijskoga sustava s obzirom na stupanj ekonomske razvijenosti. U zemljama koje su na višem stupnju razvoja, tržišna otvorenost ima jači utjecaj na razvoj financijskoga sustava nego u zemljama koje su na nižem stupnju ekonomskog razvoja. Financijska otvorenost ima pozitivan utjecaj na razvoj financijskoga sustava, a posebno se očituje u razvoju tržišta kapitala.[7]

Hipotezu o simultanu otvaranju djelomično su potvrdili Baltagi, Demetriades i Siong (2008.). Oni su procjenjivali model razvoja financijskoga sustava za razvijene zemlje i zemlje u razvoju. Njihov je zaključak da će se zemlje najbolje razvijati ako se oba tržišta otvaraju istodobno. Suprotno RZ-hipotezi o simultanu otvaranju pokazali su da će se bankarski sustav razvijati ako se bude otvaralo samo jedno od tržišta. Nadalje, pokazali su da dodatno financijsko i tržišno otvaranje zemalja u razvoju koje su već otvorene, može biti pogubno za razvoj financijskoga sustava.[8]

2.1.2. Funkcije financijskoga sustava

Financijski sustavi razvijenih zemalja u novije vrijeme obogaćeni su, dakle, pojavom i razvojem novih tipova financijskih posrednika od kojih se poseban značaj pridaje upravo mirovinskim fondovima. Ove relativno mlade financijske organizacije ostavile su dubok trag na tim financijskim tržištima i danas čine njihov nezaobilazan sastavni dio. Razvoj ovih institucija pozitivno je utjecao na razvoj gospodarstva i financijskoga sustava u razvijenim zemljama što se, kao najbitnije, očitovalo u porastu razine institucionalne štednje, u porastu broja alternativa

[6] Chinn, M. C. i Ito, H. (2006.) „What maters for financial development? Capital controls, institutions, and interactions“, *Journal of Development Economics*, 81, str. 191. – 192.
[7] Law, H. S. i Demetriades, P. (2006.) „Openness, Institutions and Financial Development“, *Working paper* WEF 0012, World Economy & Finance Research Programme, University of London, ISSN 1749-8279.
[8] Baltagi, B. H. i Demetriades, P. O., Law, S. H. (2008.) „Financial development and openness:Evidence from panel dana“, *Journal of development Economics*, Published in 2009.

za pribavljanje izvora financijskih sredstava poduzeća, u jačanju konkurencije među financijskim institucijama, u intenzivnu razvoju financijskih inovacija, u produbljivanju i razvoju tržišta kapitala, napose tržišta korporativnih akcija i obveznica, itd. Financijski sustav jedne zemlje u znatnoj je mjeri određen strukturom nacionalnog gospodarstva i mijenjan ekonomskom politikom.

U financijskom sustavu možemo razlikovati tri različita područja:

a) financijske institucije (monetarne i nemonetarne)
b) područje ponude i potražnje (javljaju se sektori koji mogu biti suficitarni i deficitarni)
c) novčano potraživanje.

Temeljna su dva zadatka financijskoga sustava:

1. mobilizirati sva novčana sredstva koja mogu poslužiti kao zajam i prenijeti ih – transferirati – od štediša onima koji ih trebaju za potrošnju ili investiranje
2. raspoloživ novčani kapital usmjeriti u one pothvate koji su profitabilni i ekonomski opravdani.

Uz formiranje dovoljnog kapitala i njegovu uspješnu alokaciju, financijski sustav ima i sljedeće funkcije:

1. štednu funkciju - transfer štednje iz suficitarnih sektora u deficitarne sektore
2. platežnu funkciju - osigurati dovoljan broj uslužnih mjesta i bankovnih institucija
3. gospodarsko-političku funkcij- podupirati temeljne strateške ciljeve gospodarske politike i mora biti u funkciji ostvarenju pune zaposlenosti
4. alokativnu funkciju (koja je i najvažnija) - osigurati mehanizme koji će štednju alocirati u najprofitnije grane i projekte
5. funkciju čuvanja kupovne moći domicilne valute (što je temeljni cilj središnje banke)
6. kreditnu funkcija - omogućiti dostupnost financijskih sredstava svakom gospodarskom subjektu
7. funkciju sigurnosti i likvidnosti - omogućiti brzo pretvaranje vrijednosnih papira u novac
8. olakšati trgovinu robom i uslugama.

Model financijskog sustava svake zemlje obuhvaća nositelje ponude i potražnje, financijske instrumente – potraživanja, financijske institucije i financijske optjecaje koji integrirani u financijskim tržištima omogućavaju usmjeravanje novčanih viškova na ona mjesta proizvodnje i prometa gdje su oni potrebni i koji mogu ispuniti vladajuće tržišne uvjete.

2.1.3. Ekonomija i financijski sustav

Financijski sustav sastavni je dio ekonomskoga sustava jedne zemlje. Financijski sustav, kako je u dosadašnjem dijelu teksta već rečeno, predstavlja ključni dio kojim se omogućuje alokacija financijskih sredstava od onih koji imaju višak prema onima koji imaju potrebu iz različitih razloga, a najviše iz investicijskih razloga. Dakako, financijski sustavi zemalja različiti su i strukturno i prema razini razvijenosti. Danas je općenito nezamislivo djelovanje u jednoj ekonomiji bez financijskoga sustava.

Financijske se discipline mogu podijeliti:

- na poslovne financije
- na osobne financije
- na nacionalne financijske institucije i tržišta
- na monetarne financije
- na javne financije
- na međunarodne financijske institucije i tržišta.

Model financijskoga sustava jedne zemlje u znatnoj je mjeri određen strukturom nacionalnog gospodarstva te mijenjan ekonomskom politikom.

Strukturu financijskog sustava jedne zemlje čine sljedeći sektori:

- tvrtke
- kućanstva
- financijski sektor
- država
- inozemstvo.

Financijski sektor sastoji se od depozitnih institucija, tržišta deviza, tržišta kapitala i tržišta novca. Imovina na početku razdoblja predstavlja bilancu stanja dotičnog gospodarstva na početku razdoblja dok imovina na kraju razdoblja predstavlja bilancu stanja dotičnog gospodarstva na kraju razdoblja. Između dviju bilanci stanja imamo bilancu uspjeha dotičnog razdoblja što za jedno nacionalno gospodarstvo predstavlja veličinu nacionalnog dohotka.
Ekonomisti se slažu s tim da između razvitka financijskog sustava i gospodarstva, odnosno gospodarskog rasta postoji uska povezanost. Sudionici u jednom modelu gospodarstva vode se po principu salda, što znači da se ne identificira promet promatrana sektora u promatranoj aktivnosti (uvođenje prometa u model tehničko je pitanje).

Realni i financijski procesi odvijaju se na temelju uzajamnosti i povezanosti svih sektora i svih oblika aktivnosti. Tijek, odnosno proces reprodukcije određuje uzajamnost svih sektora pri čemu financijski sektor služi kao medijator i ima funkciju /ulogu „učinkovitijeg odvijanja“ samog procesa reprodukcije. Tijekovi imaju svoj odraz na povećanje, odnosno smanjenje imovine sljedećeg razdoblja jednako kao i na visinu obveza vlasnika imovine „prebačene“ na buduće razdoblje. Prema tome, sadašnjost predstavlja tijek procesa reprodukcije, prošlost predstavlja imovinu pojedinog sektora u prethodnom razdoblju (t-1), budućnost predstavlja (t) početno stanje imovine za sljedeće razdoblje uključujući i obveze koje su preuzete iz prošlosti korigirane za povećanje, odnosno smanjenje obveza u sadašnjosti. I tako iz jedne „sadašnjosti“ u drugu „sadašnjost“ (bilancu uspjeha).

Ono što se može konstatirati za promatrane zemlje jest da imaju izrazito razvijen bankarski sektor i relativno slabo razvijeno tržište kapitala (ako se izuzmu Njemačka i Austrija). Zbog nasljeđa socijalističkog ekonomskog obrazovnog i traumatičnog iskustva „pretvorbe“ uglavnom se tržište kapitala promatra kao mjesto za spekulaciju i zaradu malobrojnih. Iz vida je izgubljena činjenica da su se manipulacije u pretvorbi događale upravo zato što burze nisu funkcionirale i što prethodno nisu doneseni zakoni (i osigurana njihova provedba) koji bi zaštitili investitore. Također, iz vida je izgubljena i važna funkcija nebankarskog posrednika i tržišna alokacija kapitala. Dakle, može se reći da je uveden kapitalizam i pritom je zaboravljen njegov najvažniji sastavni dio.

Razvijeno tržište kapitala i nebankarski financijski posrednici mogu pozitivno utjecati na razvoj jednog gospodarstva i to na nekoliko načina.

Prvo, u nedostatku razvijenog tržišta kapitala, srednje i velike tvrtke nailaze na ograničenje rasta kapitala. Pretjerano oslanjanje na dug može učiniti te tvrtke ranjivima, a posebno na krize. Drugo, kad imamo nerazvijeno tržište kapitala, ograničena je i mogućnost šireg sloja investitora. Sve to može imati negativne posljedice na raspodjelu dohotka.

Treće, nerazvijeno i nelikvidno tržište kapitala na strani ponude ne može odgovoriti potrebama potražnje koja raste zbog razvoja mirovinskih i investicijskih fondova zbog čega može doći do nepotrebna odljeva kapitala (npr. do ulaganja u inozemstvo).

Četvrto, ako tržište kapitala nije razvijeno, tada ne postoji temeljni društveni mehanizam koji potiče optimalnu diverzifikaciju i preuzimanje rizika. (Usp. Obstfeld, 1994.)[9]

Ekonomisti se slažu kako između razvoja financijskoga sustava i gospodarstva jedne zemlje postoji uska povezanost, a posebno s gospodarskim rastom, no slaganje prestaje kada se postavi pitanje o naravi, smjeru i intenzitetu te veze.[10]

Važno je istaknuti da poslovi što ih obavljaju banke i nebankarske financijske institucije nisu identične. Ako je tomu tako, onda banke i nebankarske financijske institucije te tržišta nisu konkurenti, nego komplementari. Upravo je zbog toga potrebno dodatno djelovati na razvoj kako bankarskog tako i nebankarskog sektora jedne ekonomije.

2.1.4. Financijska intermedijacija

Sve veća globalizacija znatno utječe ne samo na gospodarstvo nego i na društvo u cjelini jedne zemlje, posebno na financijska tržišta i njihovu integraciju. Globalizacija je veoma kompleksna pojava, ali i vrlo aktualna i to naročito u smislu financijskih integracija pojedine ekonomije u razvijena globalna financijska tržišta. Financijska intermedijacija sastavni je dio globalizacije i predstavlja značajan izazov i ključnu vezu s globalnim financijskim integracijama. Teorija o „nemogućem trojstvu“ ističe kompleksnost teme globalizacije analizirajući kombinaciju političkih ciljeva argumentirano kroz globalizaciju institucija i institucionalno jačanje. Na temelju analize teorija financijske intermedijacije može se zaključiti da postoji još puno izazova na putu prema globalizaciji, no financijska intermedijacija i nadalje je aktualna tema i ubuduće će biti vrlo bitan instrument globalizacije.

[9] Premda postoje teorijski modeli koji pokazuju da poboljšanje diverzifikacije može dovesti do smanjenja štednje i posljedično pada gospodarskog rasta (Levhari i Srinisivan, 1969.), ovdje ćemo se usredotočiti na faktor preuzimanja rizika, koji se javlja usporedo s mogućnošću diverzifikacije, a koja neosporno doprinosi gospodarskom rastu.

[10] Prvo istraživanje u kojem je ta veza pokazana objavljeno je prije više od 45 godina (Goldsmith, 1969.).

Što je to financijska intermedijacija i zašto smatramo da predstavlja bitan proces prema dubljoj financijskoj integraciji i razvoju financijskih tržišta?
Naime, financijski se sustav vremenom mijenjao. Na samu početku razvoja financijskoga sustava obavljale su se jednostavne funkcije razmjene novca, koje su s vremenom postale kompleksne funkcije financijskih tržišta i njihovih instrumenata te direktno utjecale na razvoj i dubinu financijske integracije financijskih sustava, kao i na razvoj uloge intermedijacije u financijskome sustavu.

Financijski sustavi stalno se mijenjaju kako bi udovoljili zahtjevima tržišta kojima dominira konkurencija. Financijske institucije, žele li opstati i zadržati vodeću ulogu u financijskoj utakmici, moraju reagirati na zahtjeve klijenata i nuditi nove financijske usluge kako bi održale poziciju na financijskom tržištu, a time i ostvarile uspješno poslovanje.

Različiti autori različito definiraju financijsku intermedijaciju. Lloyd (2002.) financijsku intermedijaciju definira kroz financijske institucije dok Gorton i Winton (2002.) financijskom intemedijacijom smatraju pravne osobe koje posuđuju od potrošača/štediša, a sredstva daju u zajam onima kojima su ta sredstva potrebna za investiranje. Prema tome, financijske su institucije posrednici u novčanim transferima između pojedinaca, poduzeća i drugih jedinki koje ostvaruju pozitivne financijske rezultate, dakle, kreiraju suficitarne fondove iz kojih posuđuju sredstva pojedincima, poduzećima i jedinkama kojima su fondovi potrebni za poslovanje.

Financijska intermedijacija promovira ekonomsku učinkovitost kroz štednju domaćinstava i drugih jedinica koje ostvaruju suficit tako da suficitarna sredstva posuđuje pojedincima kojima su ta ista sredstva potrebna. Ovaj proces omogućava poboljšanje životnog standarda jer na ovaj način financijska intermedijacija omogućava da i štediše i zajmoprimci ostvare dobit.

Kada govorimo o financijskoj intermedijaciji, potrebno je istaknuti da je ona ostvariva direktno i indirektno.
Direktna (izravna) financijska intermedijacija odnosi se na direktno financiranje, tj. kontakt je izravan između dviju strana bez posredovanja treće. Direktno financiranje je organizirano u smislu dogovora, zajedničkim sporazumom o uvjetima zajma gdje se jedna strana obvezuje da će posuditi drugoj strani određen iznos sredstava bez posredovanja treće strane. Na direktnom kreditnom tržištu deficitarne jedinice (pojedinci, poduzeća,...) emitiraju svoje financijske

instrumente kao što su dionice, obveznice i drugi dinamički instrumenti koji se mogu izravno prodati suficitarnim jedinicama kao što su brokeri i dileri.

Indirektna (neizravna) financijska intermedijacija uključuje posredovanje odgovarajućeg financijskog posrednika između suficitarnih i deficitarnih jedinica. Kod indirektnog posredovanja promet novca od suficitarnih k deficitarnim jedinicama obavlja se putem banaka, investicijskih fondova i drugih sudionika financijskog sustava. Osnovna uloga financijskog intermedijatora jest ta da djeluje kako bi se zadovoljile financijske potrebe i suficitarnih i deficitarnih jedinica u ostvarenju svojih ciljeva. Na taj način vrši se transfer sredstava od štediša/kreditora prema zajmoprimcima/korisnicima kredita.

2.1.5. Financijska regulacija

Tržišni uvjeti poslovanja, trendovi globalizacije, procesi uključivanja u međunarodne financijske tokove te mobilnost kapitala i potrebe njegove zaštite zahtijevaju institucionalno definiranje i uspostavljanje regulatora i regulatornog okvira za djelovanje i nadgledanje svih segmenata financijskoga sustava. Supervizija financijskoga sustava ima značajnu funkciju u ovim procesima i njezine se aktivnosti proširuju i u okvire međunarodne suradnje. Cilj uspostave supervizije financijskoga sustava i njegovih segmenata jest postizanje financijske stabilnosti.

Financijska regulacija i supervizija bitni su elementi financijske stabilnosti.[11] Jedan od razloga tomu jest taj što financije podrazumijevaju rizik. J. Benjamin (2008., 14) smatra da je „rizik sirovina koju financije koriste u proizvodnji“. Dakle,ako su financije neodvojive od rizika,[12] država je pozvana na intervenciju. Ta se intervencija očituje u financijskoj regulaciji i superviziji koja djeluje kao svojevrstan „pravni lijek“ na potencijalne rizike. Iz ovoga možemo zaključiti da ako država stvori primjerenu financijsku regulaciju koju primjenjuje kroz odgovarajuću financijsku superviziju, financijska stabilnost neće izostati.

[11] Financijska regulacija (mikro- i makroprudencijalna, kodeksi ponašanja, i dr.) podrazumijeva propise i druga pravila kojima se uređuje ponašanje subjekata unutar financijskoga sustava (tzv. adresatima). Financijska supervizija podrazumijeva nadzor nad tim istim subjektima u smislu provjere njihova pridržavanja onoga što je određeno regulacijom u svakodnevnim aktivnostima. Iako različite u svojem djelovanju, financijska regulacija i supervizija međusobno su ovisne. Naime, regulacija ne može ostvariti svoje ciljeve bez djelovanja supervizije dok supervizija ne bi imala smisla kada ne bi bilo regulacije.

[12] Primjerice, zbog asimetričnih informacija, neinformiranosti investitora, niske razine financijske pismenosti te drugih rizika povezanih s financijskim institucijama i tržištima.

Financijska stabilnost u velikoj je mjeri uvjetovana mogućnošću da financijski sustav jedne zemlje ima odgovor na ekstremne šokove, a ogleda u stabilnosti bankarskog sustava, koji čini u najvećem broju zemalja najznačajniji dio financijskoga sustava. Za postizanje zdrava i stabilna bankarskoga sustava bitna je stabilnost svake banke pojedinačno. Preduvjet učinkovitoj superviziji banaka jest uspostavljanje odgovarajućeg institucionalnog i regulatornog okvira. Regulacija bankarskoga sustava u biti je institucionalno uspostavljanje pravila kojima se propisuju odnosi među pojedinim bilančnim pozicijama, pravila i organizacijski status banke, statusna pitanja i djelokrug pojedinih vrsta bankarskih poslova. Ovo upućuje na nužnost definiranja ove oblasti po međunarodnim standardima i uspostavljanje odgovarajućeg nadzora nad poslovanjem banaka. Bankarska regulativa i supervizija banaka predmet su stalnih debata i diskusija u međunarodnim okvirima. To je proces koji stalno traje i koji se mora unaprjeđivati. Da bi promovirao i osigurao cjelokupnu makroekonomsku i financijsku stabilnost, Bazelski odbor za bankarsku superviziju (eng.*Basel Committee for Banking Supervision*) usvojio je temeljne principe koji se moraju poštivati da bi se ta aktivnost provodila i bila djelotvorna. Osnovni cilj bazelskih principa jest jačanje stabilnosti i sigurnosti međunarodno aktivnih banaka. Principi podrazumijevaju minimalne zahtjeve koje banka treba ispuniti i u mnogim ih slučajevima treba dopuniti drugim mjerama kako bi se zadovoljili specifični uvjeti ili regulirali rizici u financijskim sustavima pojedinih zemalja. Osnovni se principi odnose na preduvjete za učinkovitu superviziju banaka i izdavanje dozvola, na donošenje propisa i zahtjeva za upravljanje rizikom, na metode za stalnu superviziju banaka, na davanje nužnih informacija iz oblasti prekogranične supervizije.

Međunarodni sporazum o mjerenju kapitala i standardima kapitala (Basel II) predstavlja rezultat rada Bazelskog odbora za nadzor banaka na osiguranju međunarodnog usklađivanja revizije nadzorne regulative koja upravlja adekvatnošću kapitala međunarodno aktivnih banaka. Odbor je objavio opća načela za prekograničnu implementaciju revidiranog okvira te se fokusirao na načela za prepoznavanje kapitalnog izračunavanja operativnog rizika prema pristupima naprednog mjerenja za supervizore države sjedišta i države domaćina. Bankarska supervizija predstavlja nadzor nad poštivanjem utvrđenih pravila u bankarskom poslovanju i utvrđivanje odgovornosti za nepoštivanje pravila koja su definirana bankarskom regulativom.

Prema općeprihvaćenim standardima supervizija banaka zasniva se na trima osnovnim načelima:

- na minimalnom kapitalnom zahtjevu
- na supevizijskom nadzoru
- na tržišnoj disciplini.

Minimalni kapitalni zahtjev definira pravila za usklađivanje u održavanju minimalnih kapitalnih zahtjeva za kreditni, operativni i tržišni rizik. Zahtjev za minimalnim kapitalom utvrđen je zato što kapital treba ublažiti nepredviđene gubitke poslovanja banaka te kako bi se stvorilo povjerenje najšire javnosti o poslovnoj sposobnosti i učinkovitosti banke. U teoriji su poznate četiri osnovne funkcije kapitala banke: zaštita deponenata, pokriće neočekivanih gubitaka, kontrolna funkcija i funkcija financiranja banke. Te osnovne funkcije upućuju na značaj i potrebu za definiranje kapitalnih zahtjeva.Banka ima obvezu procijeniti adekvatnost kapitala, a supervizori ocjenjuju bankovni sustav procjene i daju odobrenje za korištenje modela procjene pa tako i osiguravaju da banka ima dovoljno kapitala.

Tržišna disciplina odnosi se na javno objavljivanje, odnosno transparentnost u objavljivanju podataka o procesu upravljanja rizicima, visini kapitala i izloženosti rizicima. Tržišna disciplina podrazumijeva skup zahtjeva za objavljivanjem podataka kako bi se sudionicima na tržištu omogućila procjena ključne informacije o obimu primjene propisa, o kapitalu, o izloženosti rizicima, o procesima procjenjivanja rizika te o adekvatnosti kapitala institucije. Nacionalni supervizori odgovorni su i za usklađivanje i utvrđivanje zadovoljava li vanjska institucija za kreditno ocjenjivanje (eng.*External Credit Assessment Institution – ECAI*) propisane kriterije. Ti se kriteriji odnose na objektivnost, nezavisnost, na međunarodnu dostupnost (transparentnost), na objavljivanje podataka, na resurse i kredibilitet. Za menadžment banke bitno je prepoznavanje rizika, preuzimanje rizika i upravljanje njime dok je za supervizore bitno nadgledanje adekvatnosti upravljanja rizikom kako bi regulatorne agencije mogle procijeniti djelovanje uprave.

U praksi su prisutna tri najčešća modela organizacijske bankarske supervizije:

- u okviru središnje ili nacionalne banke
- posebne supervizijske agencije za superviziju banaka
- supervizija banaka u okviru tijela odgovorna za superviziju cjelokupnog financijskog sustava.

Od početka tranzicije 1991. godine Hrvatska je bila odlučna u provođenju institucionalnog pristupa superviziji. Tako je Hrvatska narodna banka bila prva institucija nadležna za provođenje nadzora nad bankama (danas kreditnim institucijama) u Hrvatskoj.[13] Tijekom godina rastao je broj supervizora u sustavu pa je već za desetak godina pristup financijskoj superviziji postao institucionalan – brojio je ukupno šest supervizora, uključujući i HNB:

1. Komisija za vrijednosne papire Republike Hrvatske
2. Agencija za nadzor mirovinskih fondova i osiguranja
3. Direkcija za nadzor društava za osiguranje
4. Državna agencija za osiguranje štednih uloga i sanaciju banaka
5. Ministarstvo financija.

Naravno da je ovako velik broj nadzornih institucija bio administrativno zahtjevan, a preklapale su se i nadležnosti nekih institucija zbog čega su troškovi regulacije bili veći za financijske institucije koje su morale udvostručiti svoja izvješća. I sama supervizija nije bila dovoljno učinkovita jer odgovornosti pojedinih nadzornika nisu bile jasne. Stoga nije neobično da je ideja o integraciji supervizije obilježila hrvatski sustav financijske regulacije i supervizije. No, iskustva posljednjih godina pokazuju da postoje značajni nedostatci u našem poznavanju sustava financijske regulacije i supervizije. Te su manjkavosti u razdoblju financijske krize samo pogoršale negativne učinke poteškoća koje su se tada javljale. Dakle, buduća financijska regulacija i supervizija (na nacionalnoj i nadnacionalnoj razini) morale bi biti temeljitije i učinkovitije u održavanju financijske stabilnosti. Takva svojstva regulacije omogućena su informacijama prikupljenima putem financijske supervizije.

Očito je, dakle, da supervizija ima važnu ulogu u postizanju i održavanju financijske stabilnosti. Ta uloga dobiva na važnosti uzmemo li u obzir da u suvremenim financijama supervizija često podrazumijeva i određenu regulatornu aktivnost. Supervizori često djeluju kao sekundarni zakonodavci u odnosu na državna legislativna tijela i to u smislu da vlastitim djelovanjem interpretiraju samu regulaciju kroz niz administrativnih mjera i drugih uredaba. Stoga je jasno kako za učinkovitost supervizije nisu odlučne samo mjere, odnosno instrumenti kojima se supervizija služi u svojoj praksi. Iznimno važnu ulogu ima i tzv. institucionalni poredak financijske supervizije (eng. *institutional setup of supervision, supervisory architecture,*

[13] Zakon o Hrvatskoj narodnoj banci, *NN* 75/08.

supervisory structure) unutar neke države i povjerenje koje pojedina institucija unutar tog poretka uživa kod javnosti. U tom smislu od kraja 90-ih godina prošloga stoljeća do danas traje rasprava unutar znanstvene i stručne zajednice o tome postoji li jedan institucionalni poredak supervizije koji bi najbolje odgovarao zahtjevima financijske stabilnosti te, slijedom toga, koja je uloga institucija unutar njega. Pogotovo u razdoblju nakon financijske krize svjetske države ponovno promišljaju o postojećem institucionalnom sastavu supervizije na nacionalnoj (ali i nadnacionalnoj) razini polazeći od pretpostavke kako danas financijska tržišta i institucije postavljaju sasvim nove izazove pred državu, odnosno financijske subjekte i ostale aktere na koje postojeće strukture više ne mogu učinkovito odgovoriti. Ta su promišljanja, s aspekta europskih država, snažno obilježena trendom institucionalne konsolidacije supervizije (eng. *institutional consolidation, supervisory unification, integration of supervision*), odnosno smanjenjem broja supervizora unutar financijskoga sustava te integracijom supervizije uspostavom „jedinstvenog supervizora“, nadležnog za cijeli financijski sustav (engl. *single supervisory*). Ovaj trend nije specifičan isključivo za europsko područje jer ga možemo zamijetiti diljem svijeta (npr. Tajvan, Japan, Singapur), no njegovi su korijeni europski (odnosno skandinavski), a sudbina, usudili bismo se reći, vezana uz britansko područje. Naime, upravo je Ujedinjeno Kraljevstvo 1998. godine osnivanjem Financial Services Authority (FSA) dalo potvrdu institucionalnoj konsolidaciji supervizije i poticaj ostalim europskim državama da se priklone trendu. Slično tomu upravo je razdvajanje FSA i uspostava dvaju novih supervizora 2011. (Prudential Regulatory Authority i Financial Policy Committee) unutar britanskih financija potaknulo sumnju u ispravnost odluke o konsolidaciji kod mnogih država. Slijedom toga, a kao što smo već istaknuli, svaka je država pozvana na ponovno promišljanje o sastavu svog financijskog sustava i primjerenosti njegova nadzora.

U proteklih nekoliko godina hrvatsko gospodarstvo prošlo je sveobuhvatne procese transformacije u svrhu prilagođavanja tržišnim standardima te kriterijima konvergencije kao makroekonomskim okvirima uključivanja u europske integracije. Stabilnost cijena i deviznog tečaja postoje, uz povremena odstupanja, punih deset godina. Banke su likvidne i konkurencija je na zadovoljavajućem nivou. Kamatne stope su značajno niže nego je to bio slučaj od prije desetak godina. Ipak, kamatne stope su još uvijek više nego je to slučaj europskog prosjeka i svakako da će se i dalje smanjivati. Međutim, ovdje je potrebno napomenuti da je došlo i do smanjenja kamatnih stopa i na štednju što je također stvorilo preduvjet smanjenju kamata na kredite. Kad je riječ o kreditima u Hrvatskoj je ogroman nerazmjer kredita stanovništvu i poduzećima gdje je značajno više kredita stanovništvu nego poduzećima. Kroz kredite stanovništvu kreditira se potrošnja i uvoz sektora stanovništva a s druge strane dugoročno

financiranje potreba poduzeća je ograničeno. U ovom slučaju možemo sa sigurnošću reći da se ovdje javlja efekt istiskivanja investicija poduzeća od strane izraženijeg financiranja potrošnje stanovništva.

Dodatni efekt istiskivanja hrvatsko gospodarstvo doživljava od strane budžetske potrošnje gdje država svoju potrošnju financira zaduživanjem na domaćem i inozemnom financijskom tržištu. Zaduživanjem države u zemlji onemogućava daljnje smanjenje kamatnih stopa na kredite a što je nužno za nove investicije, zapošljavanje i rast. S druge strane, zaduživanje države u inozemstvu rezultira snažnim aprecijacijskim pritiscima koji se negativno odražavaju na izvoznu poziciju zemlje te pridonose rastu vanjske zaduženosti koja se već danas nalazi na gornjoj granici srednjoročne održivosti.

U odsustvu adekvatne koordinacije mjera makroekonomskih politika kojima se usmjerava aktivnost u financijskoj sferi, financijski sustav djeluje autonomno te spontano odlučuje o smjeru i dinamici razvoja nacionalnog gospodarstva.

2.2. Teorijski aspekti gospodarskog rasta

2.2.1. Definiranje pojma gospodarskog rasta

Proučavanje gospodarskoga rasta kao makroekonomskog fenomena novijega je datuma i biva intenzivirano tek nakon Drugoga svjetskoga rata. Ekonomisti su se od samih početaka razvoja moderne ekonomske znanosti pa do danas bavili problemima gospodarskoga rasta, povećanja nacionalnoga bogatstva i društvenoga blagostanja. Već iz naslova glavnoga dijela Adama Smitha, objavljena 1776. godine, kojim su udareni temelji modernoj ekonomskoj znanosti (eng.*Inquiry into Nature and Causes of the Wealth of Nations),* vidimo da je osnovna preokupacija povećanje bogatstva i blagostanja naroda. Prema Smithu gospodarski razvoj počinje s podjelom rada, što povećava produktivnost. Produktivnost povećava nacionalni dohodak. Povećanje nacionalnoga dohotka omogućuje povećanje potrošnje. Povećanje potrošnje omogućuje povećanje podjele rada, proizvodnje itd. Na rad A. Smitha nadovezali su se radovi mnoštva drugih ekonomista sve do današnjih dana.

Od tad ekonomska teorija razlučuje pojmove gospodarskoga rasta i gospodarskoga razvoja. U ovome istraživanju u fokusu istraživanja je gospodarski rast jer gospodarski razvoj pored gospodarskoga rasta uključuje i još neke druge komponente.
Gospodarski rast je dugoročno povećanje proizvodnje, odnosno, uvećanje realnog bruto društvenog proizvoda. Postojanje gospodarskoga rasta pretpostavka je zadovoljavanja stalno rastućih potreba ljudi pa je gospodarski rast osnovni ekonomski i politički cilj svake zemlje.
Gospodarski se rast kvantitativno izražava na različite načine, a najčešće uz pomoć pokazatelja stope rasta BDP-a po glavi stanovnika u određenom razdoblju.

U dugom razdoblju gospodarski rast govori o napredovanju nacionalne ekonomije, odnosno, gospodarski je rast dugoročno najznačajniji čimbenik ekonomskog uspjeha nacije. Drukčije rečeno, gospodarski se rast ostvaruje kada se granice proizvodnih mogućnosti pomiču naviše kao izraz povećanja kapaciteta za proizvodnju u nekom nacionalnom gospodarstvu. Stopa rasta proizvodnje određuje stopu kojom raste standard stanovništva jedne zemlje.

I međunarodne usporedbe stupnja razvijenosti obično se obavljaju na temelju razine *per capita* proizvoda dok se brzine razvoja mjere stopama rasta realnog domaćeg proizvoda. No, tu se odmah javlja problem roka u kojem će se mjeriti porast domaćeg proizvoda. Naime, može se dogoditi da u jednoj nerazvijenoj zemlji iz različitih razloga dođe do kratkoročnog naglog porasta domaćeg proizvoda, što ne mora uopće bitnije utjecati na dugoročniji trend gospodarskog razvoja te zemlje. Zbog toga se prihvaća definicija gospodarskog razvoja kao dinamički proces dugoročnog rasta domaćeg proizvoda.
Godišnje povećanje BDP-a u odnosu na baznu godinu pokazuje stopu gospodarskog rasta.

Prve analize gospodarskog rasta u 40-im i 50-im godinama prošloga stoljeća imale su za predmet isključivo kvantitativni rast nacionalnog gospodarstva (proizvodnja i BDP).
Danas, među osnovnim karakteristikama gospodarskog rasta su sporost i dugotrajnost, s jedne strane, i razlike od zemlje do zemlje, s druge strane.
Kada govorimo o gospodarskom rastu, svakako da je potrebno objasniti i čimbenike gospodarskoga rasta. Prethodne razlike u životnim standardima različitih zemalja (ostvarenima stopama gospodarskog rasta, odnosno visini BDP-a) objašnjavaju se razlikama u dostignutoj razini produktivnosti, a time i konkurentnosti ekonomije jedne zemlje. Produktivnost izražava sposobnost da se određena količina dobara i usluga proizvede u određenom vremenu. Produktivnost, odnosno ekonomski rast i razvoj, određena je četirima čimbenicima: ljudskim kapitalom, prirodnim bogatstvom, fizičkim kapitalom i tehnologijom:

1. *Ljudski kapital* je ekonomski izraz za znanje i vještine koje radnici stječu kroz obrazovanje (spretnost, znanje i motivacija radne snage); obično se uzima kao najvažniji čimbenik gospodarskoga rasta.
2. *Prirodna bogatstva* (zemlja i uopćeno svi prirodni resursi) nekada su bili prvi preduvjet gospodarskoga napretka. Danas prirodna bogatstva ne određuju je li neka zemlja uspješna ili ne. Primjer su zemlje poput Japana i Hong Konga, koje su napredovale i pored tog što imaju skromna prirodna bogatstva. Te su zemlje svoj brzi rast bazirali na sektorima koji više ovise o radu i kapitalu. Zemlje bogate naftom, kao S. Arabija koja na temelju toga ostvaruje visoke dohotke, iznimke su, a ne pravilo.
3. *Fizički kapital* (ili samo *kapital*) izražen je u obliku kapitalnih dobara (oprema i strojevi, zgrade, infrastruktura i sl.) i investicija za izgradnju kapitalnih dobara. Raspoloživost s više kapitalnih dobara omogućuje bržu i obilniju proizvodnju dobara i usluga.

4. *Tehnologija* (tehničko-tehnološki napredak, inovacije) podrazumijeva najbolje/najbrže tehnološke načine proizvodnje dobara i usluga.

Produktivnost (determinanta s prethodnim četirima faktorima), dakle, generira razinu dohotka koji pored podmirivanja potreba potrošnje omogućava i određenu razinu štednje (akumulacije). U makroekonomiji je štednja ključno pitanje formiranja investicija kao nužnog uvjeta za postizanje gospodarskoga rasta. Visoke investicije omogućuju nove tehnologije, a time se osvajaju nova tržišta i usvajaju nova znanja (uvećava se fizički kapital i razina znanja). Na ovaj se način zaokružuje „razvojni krug“, na novoj i višoj razini razvijenosti od prethodnog.
U prošlosti je nastao velik broj studija o doprinosima pojedinih čimbenika gospodarskoga rasta pojedinih zemalja. (Babić, 1996.) Iz njih se nameću dva zaključka. Prvo, ustrajan rast u mnogim zemljama može se najvećim dijelom objasniti obrazovanjem i ekonomskom politikom koja promiče izvoznu orijentaciju i konkurenciju. Drugo, dugotrajna makroekonomska neravnoteža šteti razvoju.
Izvozno orijentirana politika rasta pomiče gospodarski rast i produktivnost. Nasuprot tomu, politike orijentirane na supstituciju uvoza uglavnom imaju slabe rezultate. Dugo štićene industrije rijetko kad postanu odrasle i ojačale za samostalan razvoj.
Da bismo odredili koliki je udio rada, kapitala ili tehnološke promjene u rastu napredne tržišne ekonomije, moramo koristiti kvantitativnu analizu ekonomskog rasta, odnosno obračun rasta. To je način odvajanja različitih elemenata koji su uzrokovali zapažene trendove rasta.

Na grafičkom prikazu 2.2 vidimo da se proizvodnja može rastaviti na tri odvojena izvora: na rast rada, rast kapitala i tehnološku inovaciju. Tri četvrtine nacionalnog dohotka pripisuje se radu, a samo jedna četvrtina kapitalu, što upućuje na to da će rast rada pridonositi proizvodnji više nego rast kapitala. Ako rastu utrošaka dodamo tehnološku promjenu, dobijemo sve izvore rasta:

postotak rasta proizvodnje (Q) = ¾ (% rasta L) + ¼ (% rasta K) + TC

Gdje su :

Q = proizvodnja

L = rad

K = kapital

TC = tehnološka promjena

Da bismo vidjeli rast *per capita* iz jednadžbe eliminiramo rad (L) kao poseban izvor rasta:

postotak rasta Q/L = ¼ (% rasta K/L) + T C

Kada bi tehnološka promjena bila jednaka nuli, proizvodnja bi rasla samo jednu četvrtinu isto kao i kapital po radniku, što preslikava djelovanje padajućih prinosa.

Tehnološku promjenu možemo izračunati samo kao ostatak nakon što se izračuna proizvodnja i ostale sastavnice rasta:

TC = % rasta Q – ¾ (% rasta L) – ¼ (% rasta K)

Ova nam jednadžba omogućuje da vidimo koji je dio proizvodnje uzrokovao rast kapitalne opremljenosti rada, a koji dio tehnološki napredak.

2.2.2. Modeli rasta

Makroekonomska politika mora biti i kvantitativno određena (ekonometrijski, matematički, statistički). U tom kvantitativnom pristupu naglašeno mjesto imaju ekonomski modeli koji dinamičkom analizom opisuju promjenu pojedinih makroekonomskih varijabli u vremenu pri čemu su modeli rasta instrument makroekonomske analize.

Gospodarski rast oduvijek je izazivao velik interes i kontraverze kod ekonomista. Uz one rane (A. Smith, T. Maltus, K. Marks), moderne teorije gospodarskoga rasta nikle su pod utjecajem makroekonomskih modela, a imaju korijene u keynesijansko-neoklasičnoj teoriji.

Među ekonomistima postoje neslaganja o tome koliko poticati pojedine čimbenike ekonomskoga rasta pri ukupnom ekonomskom rastu. Kroz povijest se razvilo više modela ekonomskoga rasta. Među najcitiranijim radovima o gospodarskom rastu su neoklasični modeli rasta i endogeni modeli rasta.

2.2.2.1. Neoklasičan model rasta

Temelje neoklasičnoga modela rasta postavili su američki ekonomist Robert Solow (1956.) i australski ekonomist Trevor Swan (1956.) pa se prema njima model često naziva i Solow-Swanov model rasta. Neoklasičan pristup rastu naglašava ulogu ponude proizvodnih čimbenika u procesu rasta u kratkom i srednjem roku dok je u dugom roku stopa rasta određena tehnološkim napretkom. U središtu neoklasičnog modela rasta nalazi se agregatna funkcija proizvodnje. Prema funkciji, razina proizvodnje određena je na temelju doprinosa proizvodnih čimbenika kapitala i rada te razine tehnologije, odnosno znanja, što se može općenito prikazati u sljedećem obliku:

$$Y = F(A, K, L)$$

gdje A predstavlja razinu tehnologije, odnosno znanja, K je kapital, a L rad, odnosno radna snaga. Kapital se odnosi na ulaz trajnih fizičkih resursa (strojevi, zgrade, itd.), a rad uključuje broj radnika i količinu vremena koju provode u radu. Neoklasični modeli rasta počivaju na dvjema važnim pretpostavkama:

a) konstantan prinos na obujam

Ovo svojstvo podrazumijeva da ako pomnožimo rad i kapital s istom pozitivnom konstantom λ, dobijemo λ povećanje proizvodnje:

$$\lambda Y = F(\lambda K, \lambda AN) \text{ za sve } \lambda > 0$$

Ovo je svojstvo poznato i kao homogenost prvog stupnja za K i L.

b) Pozitivni i opadajući prinosi proizvodnih čimbenika

Za sve K > 0 i L > 0, F(A, K, L) ima pozitivne i padajuće granične prinose u odnosu na svaki proizvodni čimbenik:

$$\frac{\partial F}{\partial K} > 0 \qquad \frac{\partial^2 F}{\partial K^2} < 0$$

$$\frac{\partial F}{\partial L} > 0 \qquad \frac{\partial^2 F}{\partial L^2}$$

Drugim riječima, neoklasičan pristup pretpostavlja da, uz konstantne razine tehnologije i rada, dodatna jedinica kapitala povećava proizvodnju, ali se dodatno povećanje proizvodnje smanjuje kako broj jedinica kapitala raste. Isto svojstvo vrijedi i za čimbenik rada.

Problem nestabilnosti u Harrod- Domarovu modelu ili problem održavanja stabilnosti (*knife-edge problem*) potječe od vrlo rigidnih pretpostavki na kojima se taj model temelji. To je prije svega pretpostavka o konstantnom kapitalnom koeficijentu *b*, tj. o nepostojanju supstitucije proizvodnih čimbenika.

Omjer konstantnih koeficijenata $\frac{s}{b}$ daje potrebnu stopu rasta domaćeg proizvoda koja mora biti jednaka prirodnoj stopi rasta radne snage *n* uvećanoj za porast produktivnosti rada *m*.

$$\frac{s}{b} = n + m \qquad (2.1.1)$$

Budući da su svi elementi u modelu (2.1.1) konstante, ne postoji nikakva mogućnost uspostavljanja nove ravnoteže ako se padne u neravnotežu. Svako odstupanje od uvjeta (2.1.1) vodi u trajnu neravnotežu jer je model (2.1.1) previše egzogeno determiniran.

Početna točka svih modela rasta i uopće izučavanja rasta je svakako neoklasičan model rasta. (Aghion, 2009.) Neoklasičan pristup problemu stabilna rasta temelji se na pretpostavci

postojanja velikog broja proizvodnih procesa, s istim tolikim brojem kapitalnih koeficijenata. U ovom ćemo dijelu rada ukratko upoznati neoklasičan model rasta R. M. Solowa[14].

Malthusova prognoza ekonomije kao „zlosretne znanosti“ nije bila točna. Zahvaljujući tehnološkom razvoju, zemlja nije postala ograničavajući čimbenik proizvodnje. Industrijska revolucija donosila je sve bolje strojeve koji su sve više povećavali proizvodnju, željeznice i brodove koji su povezivali udaljene točke svijeta. Nove tehnologije postale su odlučujuće za ekonomski razvoj.

Neoklasičan model rasta želi postići rast gospodarstva tako da omjer konstantnih koeficijenata između stope štednje i graničnoga kapitalnoga koeficijenta bude jednak prirodnoj stopi rasta stanovništva uvećanoj za porast proizvodnosti rada. Nove sastavnice neoklasičnoga modela su kapital i tehnološka promjena.

Uz pretpostavku da se tehnologija ne mijenja, ekonomski rast ovisi o rastu kapitalne opremljenosti rada (*K/L*), odnosno kapitala po radniku. Kapital se sastoji od trajnih dobara koja se koriste za proizvodnju drugih dobra. Ekonomski rast odvijat će se s rastom kapitalne opremljenosti rada (povećanje broja strojeva, računala, autoceste, željeznice, itd.). Pri nepromijenjenu stanju tehnologije prinos na kapital u počeku brzo raste dok poslije sve više dolazi do zasićenja. Jednom kada kompjuteriziramo sustav bez nove tehnologije, daljnjim investicijama udvostručujemo već postojeće. Stopa prinosa u sljedećim investicijama bit će sve niža. Kako raste kapitalna opremljenost rada tako rastu i nadnice jer svaki radnik radi s većom količinom kapitala i stoga raste njegov granični proizvod. Rast kapitalne opremljenosti rada javlja se kada fond kapitala raste brže od radne snage.

[14] Detaljnije vidjeti u radu R. M. Solow, „A contribution to the Theory of Economic Growth“, *Quarterly Journal of Economics*, sv. 70, 1956., Pretiskano u A. Sen, *Growth Economics*, Penguin, 1970.

Standard življenja prestat će rasti kada je ekonomski rast u skladu samo s akumulacijom kapitala putem koje se obavlja zamjena postojećih tvornica i metoda proizvodnje.

Neoklasičan model rasta, koji je razvio Solow (1956.)[15], a koji se smatra začetkom moderne teorije rasta, stavio je pak naglasak na omogućavanje supstitucije između kapitala i rada u procesu proizvodnje.

Supstitutivnost čimbenika proizvodnje osigurala je uravnotežen rast u neoklasičnom modelu uz izbjegavanje problema nestabilnosti, koji je bio prisutan u Harrod-Domarovu modelu, a u kojem se pretpostavlja fiksan omjer rada i kapitala. Upravo je ideja o fiksnom odnosu rada i kapitala ponukala je Solowa, koju je on smatrao dvojbenom, da pristupi izgradnji novog modela. Drugi razlog razvoja novog modela jest jedna od implikacija Harrod-Domarova modela koji upućuje da će se gospodarstvo gotovo redovito nalaziti izvan ravnotežne putanje rasta. U Harrod-Domarovu modelu, naime, ne postoji nikakva sila koja bi gospodarstvo, kada se ono jednom nađe izvan ravnotežne putanje rasta, ponovno u nju vratila.

Solowljev model gospodarskog rasta vrlo često predstavlja ishodišnu točku razvoja modela gospodarskog rasta. U svom temeljnom obliku proizvodnja je određena trima čimbenicima: brojem zaposlenih (N), kapitalom (K) i stanjem tehnologije (A). Pretpostavlja se da je ekonomija zatvorena, da se proizvodi samo jedno složeno dobro korištenjem rada i kapitala, a da su tehnološki progres i stopa štednje određeni egzogeno. Pretpostavit ćemo neutralan tehnološki napredak u Harrodovu smislu pa će funkcija agregatne proizvodnje poprimiti sljedeći oblik:[16]

$$Y = F(K, AN) \qquad (2.1.2)$$

pri čemu varijabla *AN* označava efektivni rad.

[15] Značajne doprinose razvoju neoklasičnoga modela rasta dali su Swan (1956.), Koopmans (1965.) i Cass (1965.). Drugi naziv ovog modela je Solow-Swanov model rasta.

[16] Neutralan tehnološki napredak postoji kada se ne mijenja odnos graničnog proizvoda rada i kapitala ako se ne mijenja kapitalna opremljenost rada. *Hicksov* neutralan tehnološki napredak postoji kada se pomiče cijela proizvodna funkcija naviše uz nepromijenjen odnos graničnih proizvoda rada i kapitala kad odnos njihovih ulaganja ostaje nepromijenjen. Agregatna proizvodna funkcija tada je dana sa Y= Af(K,N). *Harrodov* neutralni tehnološki napredak postoji kada je čitav tehnološki napredak apsorbiran u porast granične proizvodnosti rada zbog čega raste kapitalna opremljenost rada. Agregatna proizvodna funkcija tada je dana jednakošću Y = f(K, AN) – ovdje je manji broj radnika kompenziran njihovom povećanom efikasnošću. Kod neutralnog tehnološkog napretka *Solowljev* tehnološki napredak apsorbiran je u porast granične proizvodnosti kapitala pa je manja količina kapitala (i smanjen odnos kapitala – rad) nadomještena većom njegovom efikasnošću. Agregatna proizvodna funkcija stoga poprima oblik Y = f(AK, N).

Pretpostavke ovog modela rasta su:

1. granični proizvod svakog faktora je pozitivan, tj. $\frac{\partial Y}{\partial K} > 0$ i $\frac{\partial Y}{\partial AN} > 0$, ali raste po padajućem prinosu ($\frac{\partial^2 Y}{\partial K^2} < 0$ i $\frac{\partial^2 Y}{\partial AN^2} < 0$); iz ovog svojstva neposredno proizlazi zaključak da je granični proizvod kapitala vrlo velik kada je razina kapitala (dovoljno) mala, a jako malen kada je razina kapitala velika;
2. konstantan je prinos na obujam, što znači da udvostručenje i kapitala i efektivnog rada dovodi do udvostručenja proizvoda i što se matematički može zapisati ovako:

$$\lambda Y = F(\lambda K, \lambda AN) \qquad (2.1.3)$$

Matematičkim rječnikom rečeno, funkcija proizvodnje je homogena, prvog stupnja homogenosti. Stavimo li $\lambda = \frac{1}{AN}$, tada proizvod po efektivnom radniku zapisujemo kao funkciju kapitala po efektivnom radu: $\frac{Y}{AN} = f\left(\frac{K}{AN}, 1\right)$. Zbog prvog svojstva ova će funkcija biti konkavna.

Zbog svojstva prikazana zapisom 2.1.3 proizvod po efektivnom radu ovisi o kapitalu po efektivnom radu. Zato nam je bitno odrediti promjenu kapitala po efektivnom radu. Zbog vizualnog pojednostavljivanja cjelokupnog zapisa najprije uvodimo sljedeće oznake :

$$k = \frac{K}{AN} \text{ i } y = \frac{Y}{AN} \text{ i } y = f(k)$$

U ovom dijelu imamo i sljedeće pretpostavke:

3. da štednja obuhvaća fiksni dio dohotka pa imamo da je S = sY pri čemu je stopa štednje *s* egzogeno određena
4. da je ekonomija zatvorena, G i T = 0 i sva se štednja iskorištava za investicije pa imamo da je I = sY

5. da tehnološki napredak A (ili produktivnost rada) raste po stopi g_A koja je egzogeno određena; matematički se to zapisuje ovako:[17] $\frac{\frac{dA}{dT}}{A} = g_A$

6. da su stope rasta radne snage, populacije i zaposlenosti identične i jednake g_N koja je također egzogeno određena, što se matematički zapisuje:[18] $\frac{\frac{dN}{dt}}{N} = g_N$.

Zbog svojstva (7.2.3) imamo da proizvod po efektivnom radu ovisi o kapitalu po efektivnom radu. Zato nam je bitno odrediti promjenu kapitala po efektivnom radu. Promjene razine kapitala $\frac{dK}{dt}$ definira se kao razlika između investicija i amortizacije pa imamo:

$$\frac{dK}{dt} = sY - \delta K \qquad (2.1.4)$$

pri čemu δ označava stopu amortizacije. Imajući na umu da vrijedi *y = f(k)*, imamo sljedeći izraz:

$$\frac{dk}{dt} = sf(k) - k(\delta + g_A + g_N) \qquad (2.1.5)$$

Prvi član razlike na desnoj strani izraza (2.1.5) predstavljat će *investicije po efektivnom radu.* Drugi član razlike na desnoj strani izraza (2.1.5) predstavljat će *potrebne investicije da se održi postojeća razina kapitala po efektivnom radu.* Zbog jednostavnijeg zapisa drugi član razlike nazvat ćemo *potrebnim investicijama.* Međutim, prilikom interpretacije potrebno je imati na umu cijeli naziv izraza. Iz zapisa (2.1.6) mogu se izvesti dva zaključka:

---

[17] Stopa rasta kada se neka varijabla zapisuje kao funkcija vremena definira se kao omjer između derivacija po vremenu i same funkcije. Derivaciju stanja tehnologije označit ćemo s $\frac{dA}{dt}$, ali se u literaturi često koristi i izraz $\dot{A}$ pri čemu točka upozorava da je riječ o derivaciji po vremenu.

[18] Budući da su stope rasta i rada i tehnološkog napretka egzogeno određene, znači da su njihove *apsolutne razine* dane sljedećim zapisima: $N = N_0 e^{g_{Nt}} iA = A_0 e^{g_A t}$.

1. ako stvarne investicije prelaze potrebne, rast će razina kapitala po efektivnom zaposlenom; prema svojstvu (2.1.2) to znači da će rasti i razina proizvoda po efektivnom zaposlenom;
2. ako su stvarne investicije manje od potrebnih, tada će se razina kapitala po efektivnom zaposlenom smanjivati; prema svojstvu (2.1.2) to znači da će se smanjivati i razina proizvoda po efektivnom zaposlenom.

Postavlja se pitanje do koje će razine rasti kapital po efektivnom zaposlenom. Intuicija nam nalaže da potrebne investicije rastu linearno. Budući da stvarne investicije po efektivnom zaposlenom ovise o dohotku po efektivnom zaposlenom, zbog padajućih prinosa na opseg i egzogeno određenu stopu štednje stvarne investicije rastu u sve manjem i manjem obujmu. Posljedica je da se investicije po efektivnom radu u jednom trenutku moraju izjednačiti s potrebnim investicijama i tu se postiže dugoročna ravnoteža. Kolika je stabilna ravnoteža? Odgovor na ova dva pitanja bit će prikazan matematički.

Prvi korak u traženju tog odgovora bit će izvor prikladne matematičke funkcije. Budući da zadovoljava prvi i drugi uvjet, a i empirijski se pokazala najprikladnijom, najčešći matematički zapis proizvodne funkcije jest Cobb-Douglasova funkcija:[19]

$$Y = K^{\alpha}(AN)^{1-\alpha} \qquad 0<\alpha<1 \tag{2.1.6}$$

Radi vizualizacije i jednostavnijega zapisa, uvode se sljedeće oznake:

$$Y = k^{\alpha}, 0 < \alpha < 1 \tag{2.1.7}$$

Umetanjem (2.1.7) u (2.1.5) i prebacivanjem potrebnih investicija na lijevu stranu imamo:

$$\frac{dk}{dt} + (\delta + g_A + g_N) = sk^{\alpha} \tag{2.1.8}$$

Množenjem izraza (2.1.8) s objema stranama s $k^{-\alpha}$ daje:

$$\frac{dk}{dt}k^{-\alpha} + k^{1-\alpha}(\delta + g_A + g_N) = s \tag{2.1.9}$$

[19] Iz same proizvodne funkcije (6) vidi se da je zbroj eksponenata jednak 1 što je preduvjet da se zadovolji pretpostavka (2). Imamo li Cobb-Douglasovu funkciju $Y = K^{\alpha}(AN)^{\beta}$ $0 < \alpha i \beta < 1$ i $\alpha + \beta \neq 1$, tada tu funkciju više ne karakteriziraju konstantni prinosi na obujam.

Izraz (2.1.9) predstavlja nelinearnu diferencijalnu jednadžbu prvoga reda. Lako se može riješiti ako se linearizira jednom supstitucijom. Da bismo lakše obavili supstituciju, množenjem izraza (2.1.9) s 1-α imamo:

$$\frac{dk}{dt}k^{-\alpha}(1-\alpha)+k^{1-\alpha}(1-\alpha)(\delta+g_A+g_N)=s(1-\alpha) \qquad (2.1.10)$$

Linearizacija izraza (2.1.10) provodi se sljedećom supstitucijom nove varijable:

$$z=k^{1-\alpha} \qquad (2.1.11)$$

I njezina derivacija po vremenu jednaka je:

$$\frac{dz}{dt}=(1-\alpha)k^{-\alpha}\frac{dk}{dt} \qquad (2.1.12)$$

Umetanjem (2.1.11) i (2.1.12) u (2.1.10) imamo:

$$\frac{dz}{dt}+(1-\alpha)(\delta+g_A+g_N)z=(1-\alpha)s \qquad (2.1.13)$$

Izraz (2.1.13) predstavlja *linearnu nehomogenu diferencijalnu jednadžbu prvoga reda.* Linearna je zato što je definirana kao linearna funkcija, a nehomogena zato što joj je desna strana različita od 0. Prvoga je reda zato što u sebi sadrži prvu derivaciju funkcije koju zapravo tražimo, a to je z. Rješenjem niza jednadžbi dobivamo z kao:

$$z=\frac{s}{\delta+g_A+g_N}+Ce^{-(1-\alpha)(\delta+g_A+g_N)t} \qquad (2.1.14)$$

Izraz (2.1.14) opće je rješenje linearne nehomogene jednadžbe (2.1.13) jer sadrži neodređenu konstantu C. Kao takvo ne zadovoljava jer je z supstitucija za kapital po efektivnom radniku i to bi značilo da se ne može uspostaviti stabilna razina kapitala po efektivnom radniku. Zato je potrebno odrediti konstantnu integracije C′, a to će se učiniti tako da se izračuna vrijednost z u vremenu t = 0. Dobivamo sljedeći izraz:

$$z(0)=\frac{s}{\delta+g_A+g_N}+C \qquad (2.1.15)$$

Slijedom dobivamo C:

$$C = z(0) - \frac{s}{\delta + g_A + g_N}$$

(2.1.16)

Sređivanjem jednadžbi ubacivanjem (2.1.16) u (2.1.15) i dobije se partikularno rješenje diferencijalne jednadžbe:

$$z = \left[z(0) - \frac{s}{\delta + g_A + g_N} \right] e^{-(1-\alpha)(\delta + g_A + g_N)^t} + \frac{s}{\delta + g_A + g_N} \qquad (2.1.17)$$

Izraz za stabilnu razinu kapitala po efektivnom radu sada se može zapisati:

$$\left(\frac{K}{AN} \right)^* = \left(\frac{s}{\delta + g_A + g_N} \right)^{\frac{1}{1-\alpha}} \qquad (2.1.18)$$

Ubacivanjem (2.1.18) u (2.1.7) dobivamo stabilnu razinu proizvoda po efektivnom radu (Y/AN):

$$\left(\frac{Y}{AN} \right)^* = \left(\frac{s}{\delta + g_A + g_N} \right)^{\frac{1}{1-\alpha}} \qquad (2.1.19)$$

Po čemu znamo da je razina K/AN u zapisu (2.1.19) ravnotežna razina kapitala po efektivnom zaposlenom dugoročna? Uz dane stope štednje, amortizacije, tehnološkog napretka i rasta zaposlenosti za koje model pretpostavlja da su egzogeno određeni, dugoročno K/AN teži konstantnoj vrijednosti, odnosno teži vrijednosti za koju vrijedi $\frac{dk}{dt} = 0.$ Iz zapisa (2.1.5) izravno slijedi da su pri toj razini kapitala po efektivnom radu investicije po efektivnom zaposlenom jednake potrebnim investicijama da bi se održala postojeća razina kapitala po efektivnom zaposlenom.

Dok je god K/AN manji od vrijednosti zadane zapisom (2.1.18), vrijedi $\frac{dk}{dt} > 0,$ odnosno K/AN raste. Analogno tomu, dok je god K/AN veći od vrijednosti dobivene formulom (2.1.18), imamo da je $\frac{dk}{dt} < 0,$ odnosno K/AN se smanjuje. To znači da bez obzira na to kojoj razini K/AN bio,

pod uvjetom da nije jednak 0, K/AN teži prema (K/AN)*. Analogno tomu, zbog neprekidnosti proizvodne funkcije, kada K/AN teži prema (K/KN)*, tada i Y/AN teži prema (Y/AN)*. Stoga se kaže da je proces koji opisuje jednadžba (2.1.5), odnosno uvođenjem Cobb-Douglasove funkcije u jednadžbu (2.1.8), globalno stabilan.

Iz Solowljeva modela može se zaključiti utjecaj štednje na stopu rasta kapitala, proizvoda kapitala po zaposlenom i proizvoda po zaposlenom. Prema njemu stopa štednje nema nikakav utjecaj na dugoročan rast ovih varijabli, već samo na dugoročne razine K/AN, Y/AN, K/N, Y/N te K i N. No, da bi se postigle ove razine, porast štednje neko vrijeme mora imati utjecaj na stope rasta ovih varijabli, a to „neko vrijeme“ može trajati i do 50 godina.

2.2.2.2. Endogeni modeli rasta

Solowljev model rasta (i sve njegove razrade) nazivaju se egzogenim modelima rasta jer je glavni pokretač rasta egzogeno određen tehnološki napredak. Noviji teorijski doprinosi, za razliku od neoklasičnog modela, naglašavaju da je gospodarski rast endogeni rezultat ekonomskog sustava, a ne snage koje djeluju izvan njega. Naime, istraživači su krajem 80-ih i početkom 90-ih godina osjetili potrebu da nešto promijene u tad općeprihvaćenom neoklasičnom modelu u kojem je dugoročni rast u biti određen egzogeno determeniranom stopom tehnološkog napretka.[20] Modeli koji objašnjavaju tehnološki napredak ponekad se zovu endogeni modeli jer je objašnjenje tehnološkog napretka objašnjeno u modelu. Većina tih endogenih modela dijeli jednu vrlo važnu razliku prema Solowljevu modelu: u njima promjena stope štednje (investicija) ima učinak ne samo na razine nego i na stope rasta. Stoga politike rasta imaju u takvim modelima posve drugu ulogu jer u njima politike koje utječu na stopu štednje utječu ne samo na razine nego i na stope rasta. Osim toga, neoklasična teorija nije ponudila odgovarajuće preporuke ekonomskoj politici za postojeće probleme stvarnog svijeta kao što su bili sve slabiji rast zemalja s visokim dohotkom i stalna stagnacija rasta u većini siromašnih zemalja. U literaturi se spominju dva osnovna razloga nastanka novijih teorija rasta.

[20] U vrijeme nastanka neoklasičnog modela nitko nije vjerovao u egzogenost tehničkog napretka. Solow je koristio takvu pretpostavku jer mu je ona odgovarala iz analitičkih razloga. Bilo je prisutno opće uvjerenje da će ona biti ubrzo napuštena daljnjim razvojem modela. Ipak, bez obzira na brojne napore, općeprihvaćeni teorijski model ekonomskog rasta ostao je niz godina vrlo blizak početnoj Solowljevoj formulaciji. (Romer, 1993.b)

Prva se odnosi na činjenicu da se u realnom svijetu ne ostvaruje konvergencija dohotka po stanovniku kao što to implicira neoklasičan model. Romer (1986.) i Lucas (1998.) spominju upravo taj razlog kao motivaciju u svojim pokušajima formuliranja modela rasta s tehnološkim napretkom, koji nije egzogeno zadan, ni besplatno raspoloživ svim zemljama svijeta. Empirijski podatci, naime, pokazuju velike razlike u životnim standardima zemalja svijeta, a stabilne stope rasta mogu se posljednjih desetljeća uočiti samo kod skupine razvijenih zemalja dok je to slučaj kod siromašnih zemalja neprimjetan i moguće je vidjeti neujednačene stope i to kako prema gore, tako i prema dolje.

Drugi razlog koji Romer (1994.) navodi kao poticaj formuliranju novijih teorija rasta odnosi se na potrebu izgradnje vjerodostojne alternative modelu savršene konkurencije na razini agregatnog gospodarstva. Napredak u tehnologiji proizlazi iz onog što ljudi rade, a mnogi pojedinci i poduzeća imaju tržišnu moć zahvaljujući kojoj zarađuju monopolsku rentu koju neoklasičan model nije uzeo u obzir.

Unatoč činjenici da veoma intenzivan rad u području endogenog ekonomskog rasta započet 80-ih godina dvadesetog stoljeća i dalje postoji, pa stoga o tim modelima nije moguće govoriti poopćeno, može se ipak izdvojiti nekoliko osnovnih skupina modela endogenog rasta. To su *modeli zasnovani na eksternalijama, modeli zasnovani na istraživanju i razvitku* i *AK modeli.*

Nova teorija, ili teorija endogenog rasta, ponudila je nešto drukčija objašnjenja gospodarskog rasta od neoklasične teorije. Kao što je prije navedeno, tehnološki je napredak u Solow-Swanovu modelu egzogeno zadan pa ispada da ključni čimbenik koji određuje stopu rasta modelom uopće nije objašnjen. Ovakva je situacija potaknula brojne istraživače da pokušaju „endogenizirati“, odnosno eksplicitno modelirati tehnološki napredak kao rezultat ekonomskih i drugih procesa. Premda je sama ideja o endogenom rastu postojala već otprije, endogeni rast kao široko prihvaćen teoretski koncept datira od sredine 80-ih godina. Temelji moderne endogene teorija rasta nalaze se u Romerovim radovima (1986., 1990.). Osim Romera, važan doprinos dali su Lucas (1988.), Grossman i Helpman (1991.), Aghion i Howitt (1992.) i brojni drugi istraživači.

Dok neoklasični modeli naglasak stavljaju na proces akumulacije fizičkih čimbenika proizvodnje, u endogenim se modelima izvor rasta nalazi u procesu akumulacije znanja. To ne

znači da znanje nije prisutno u Solow-Swanovu modelu, nego jednostavno da ne postoji eksplicitno modeliran proces akumulacije znanja. Naime, znanje se u neoklasičnom modelu implicitno tretira kao javno dobro, kao što je, primjerice, nacionalna sigurnost ili besplatno osnovno školovanje. U slučaju kada javno dobro koristi samo jedan korisnik omogućava se da to dobro istodobno koristi i drugi korisnik te da se nikoga ne može isključiti iz konzumiranja javnoga dobra. Pod takvim uvjetima, prema neoklasičnoj teoriji, nije moguće očekivati lokalnu akumulaciju znanja koja bi onda mogla odigrati ulogu gospodarskog rasta. Međutim, teorija endogenog rasta prepoznaje da postoje znanja koja nisu čisto javno dobro, odnosno koja imaju status tržišnog dobra. Za razliku od javnih dobara, tržišna dobra imaju dvije važne karakteristike koje ih razlikuju od javnih dobara: *suparništvo* – u danom trenutku može ih koristiti samo jedna osoba – i *isključivost* – postoji mogućnost isključivanja drugih od korištenja dobara koja su vaša. Naime, neka znanja nisu u potpunosti dostupna svim sudionicima na tržištu. Riječ je o znanju koje je, primjerice, zaštićeno različitim oblicima intelektualnog vlasništva ili se smatra tajnim vlasništvom korisnika toga znanja. Takva se znanja mogu onda tretirati kao ravnopravni proizvodni čimbenik fizičkom kapitalu koji ima svoju odgovarajuću tržišnu strukturu.

Postoji nekoliko varijanti endogenih modela rasta. Glavna razlika među modelima je u mehanizmima stvaranja i akumulacije znanja. U Romerovu modelu iz 1986. (Romer, 1986.) mehanizam je indirektan. Naime, akumulacija znanja tretira se kao slučajan nusprodukt odluka poduzeća o investiranju u fizički kapital. Riječ je o slučajnom nusproduktu jer akumulacija kapitala indirektno potiče akumulaciju znanja u poduzeću kroz proces „učenja kroz rad“[21]. Od tako stečena znanja, zbog efekata njegova širenja, odnosno „efekta prelijevanja znanja“, koristi imaju i druga poduzeća tako da znanje zadržava svoj karakter javnog dobra. Posljedica prijenosa znanja u druga poduzeća je rastući prinos poduzeća u obliku pozitivnih tehnoloških eksternalija. Spomenute se ideje mogu formalno predstaviti korištenjem Cobb- Douglasove funkcije proizvodnje sljedećeg oblika:

$$Y = AK^{\alpha} LH^{1-\alpha}$$

gdje novi parametar H označava ljudski kapital, odnosno znanja i vještine koja postoje u nekoj ekonomiji. Pretpostavlja se da ljudski kapital raste svjesno zbog odluka pojedinaca o ulaganju u obrazovanje pri čemu je glavni motiv veća plaća. Budući da svaka generacija radnika

[21] U ovom se slučaju može govoriti o učenju kroz investiranje.

nasljeđuje prethodna znanja i stječe nova, nema padajućih prinosa za faktor H. Prema drugoj varijanti modela rastući prinosi proizlaze iz kolektivnog usavršavanja radne snage i procesa učenja kroz rad.

Sljedeći modeli endogenog rasta uspostavili su izravnije mehanizme stvaranja i akumuliranja znanja u odnosu na početni Romerov model. Premda se modeli međusobno razlikuju, svi dijele obilježje da akumulaciju znanja tretiraju kao planiran rezultat odluka o investiranju u istraživanje i razvoj. Implikacije ovakva pristupa su da znanje prestaje biti potpuno javno dobro jer da bi poduzeća uopće imala poticaj za investiranje, znanje mora biti, barem donekle, isključivo. Onemogućavanjem drugih poduzeća da kopiraju njihove izume i inovacije inovativna poduzeća stječu određenu vrstu privremene monopolske moći. Mehanizmi koji omogućuju privremeni monopol već su prije navedeni instrumenti poput prijave patenata i sl. Monopolistička pozicija omogućuje poduzećima da zarađuju profite koji opravdavaju trošak i rizik početnog istraživanja. Monopolistički profiti, pak, stimuliraju nova poduzeća na ulazak u tržište i borbu za tržišne udjele. Naime, u uvjetima rastućih prinosa poduzeće s najvećim tržišnom udjelom ostvaruje najveći profit. Ovakvi modeli rasta, za razliku od Romerova modela, očito zahtijevaju da tržišna konkurencija bude nesavršena. U ovom slučaju umjesto savršene konkurencije tržište karakterizira monopolistička konkurencija. Naime, premda poduzeća mogu onemogućiti konkurente u direktnom kopiranju ideja, to ne znači da nema prelijevanja znanja na konkurentska poduzeća. Konkurentska se poduzeća mogu osloniti na dostupno javno znanje kao uvođenje u proizvodnji novih dobara (*input*) ili na zapošljavanje zaposlenika iz poduzeća koja su vodeća u inovacijama. Stupanj gospodarskog rasta tada je direktno povezan s jačinom prelijevanja znanja s obzirom na to da prelijevanje znanja vodi k inovacijama i rastu.

Romer (1990.) te Grossman i Helpman (1991.) razvili su nove modele u kojima je tehnološki razvoj predočen rastom broja proizvoda. Povećanje broja proizvoda pojednostavljeno se izjednačava s procesom inovacija. Također, poduzeća svjesno ulažu u istraživanje i razvoj kako bi izumila nove proizvode. Jednom kada dođe do inovacije, poduzeće zaštićuje svoj proizvod patentom koji mu omogućava da samo odlučuje o cijeni po kojoj ga prodaje. Proizvodna funkcija za poduzeće *i* u tom slučaju poprima oblik

$$Y_i = AL_i^{1-\alpha} \sum_{j=1}^{N} X_{ij}^{\alpha}$$

gdje je $0 < \alpha < 1$, Yi je proizvodnja poduzeća, Li je radna snaga, X_{ij} je količina j-tog intermedijarnog proizvoda koji se koristi u proizvodnji, a N je broj (intermedijarnih) proizvoda koji se koristi u proizvodnji finalnog proizvoda.[22] Parametar A je opća mjera produktivnosti, odnosno učinkovitosti proizvodnje. Valja primijetiti da je tehnološki napredak predstavljen povećanjem broja intermedijarnih proizvoda N, a ne parametra A. Druga važna relacija u modelu odnosi se na svjesne odluke poduzeća o ulaganju u razvoj novih proizvoda. Prema Romeru (1990.) povećanje broja proizvoda izravno ovisi o broju radne snage uključene u proces istraživanja i razvoja. Naime, veća količina radne snage posvećene istraživanju i razvoju povećava broj proizvoda. Trošak stvaranja novog proizvoda opada kako društvo akumulira znanje. Razlog tomu su efekti prelijevanja znanja jer se korist od sadašnjih izuma prenosi u različite sektore i tako smanjuju troškovi budućih istraživanja.

Grossman i Helpman (1991.) te Aghion i Howitt (1993.) razvili su endogene modele u kojima se tehnološki napredak odvija kroz napredak u kvaliteti postojećih proizvoda. U tim se modelima zrcali tzv. šumpeterijanski pristup inovacijama, nazvan prema austrijskom ekonomistu Josephu Schumpeteru. Kod tih je modela stavljen naglasak na vertikalne inovacije, odnosno na poboljšanje postojećih proizvoda.[23] Zahvaljujući inovacijama, početne proizvode postepeno zamjenjuju novi proizvodi s boljim karakteristikama od dotadašnjih. Proizvođači ostvaruju privremenu rentu od takve situacije dok se ne pojavi novi proizvođači sa još boljim konkurentskim proizvodom. Ovaj proces zamjene postojećih proizvoda novim, kvalitetnijim proizvodima koji zbog svoje tehničke superiornosti potiskuju stare proizvode i penju se na tzv. ljestvici kvalitete, Schumpeter je nazvao procesom *kreativne destrukcije*. Oblik proizvodne funkcije koja sadrži opisan pristup možemo zapisati kao

$$Y_i = AL_j^{1-\alpha} \sum_{j=1}^{N} \tilde{\tilde{X}}_{ij}$$

[22] Parametar N u modelu se pojednostavljeno izjednačava s brojem intermedijarnih proizvoda korištenih u procesu proizvodnje, što je prihvatljivo ako se N uzima diskretno. Međutim, Barro i Sala-i-Martin (2004., str. 287.) smatraju da N treba uzimati kao kontinuiranu varijablu na koju se treba gledati kao aproksimaciju tehnološke složenosti proizvodnog procesa ili, alternativno, kao stupanj specijalizacije faktora proizvodnje koje koristi prosječno poduzeće.

[23] Razlika između horizontalnih i vertikalnih inovacija je sljedeća: u slučaju horizontalnih inovacija prelijevanje znanja uglavnom se odvija među različitim industrijama dok se u slučaju vertikalnih inovacija prelijevanje odvija većinom unutar istih industrija. Dok prve koriste postojeće znanje kao *input* u proizvodnji potpuno novih vrsta proizvoda, potonje se odnose na poboljšanja postojećih proizvoda.

Novi element predstavlja količinu *j*-tog intermedijarnog dobra prilagođena razini kvalitete i koji se može računati kao umnožak razine kvalitete i količine intermedijarnog dobra, $\tilde{\tilde{X}}_{ij} = q^{Kj} X_{ij}$, gdje *Kj* označava najveću trenutnu razinu kvalitete u sektoru *j*. Za razliku od prijašnjeg modela broj intermedijarnih proizvoda *N* je sada konstantan. Međutim, sada se *Kj* mijenja ovisno o ulaganjima u istraživanje i razvoj.

Tablica 2.1. Pregled osnovnih grupa modela endogenog rasta

	Modeli zasnovani na eksternalijama	**Modeli zasnovani na istraživanju i razvitku**	**AK modeli**
Neke od ishodišnih ideja prije se javljaju kod:	Arrow (1962.) Uzawa (1965.) Nelson i Phelps (1966.)	Schumpeter (1942.) Uzawa (1965.) Judd (1985.)	*King (1935., 1944.) von Neumann (1945.) Benveniste (1976.) Eaton (1981.)
1986.	Romer (1986.)		
1987.	Romer (1987.)		
1988.	Lucas (1988.)		
1989.	Murphy, Shleifer i Vishny (1989.)		
1990.	Azardis i Drazen (1990.)	Romer (1990.) Grossman i Helpman (1990.)	Becker, Murphy i Tamura (1990.) Jones i Manuelli (1990.) King i Rebelo (1990.)
1991.	Stokey (1991.) Scott (1991.)	Grossman i Helpman (1991.)	Rebelo (1991.) Tamura (1991.)
1992.		Agnion i Howit (1992.)	
1993.	Lucas (1993.)		
1994.	Romer (1994.)		
1996.		Eathon i Kortun (1996.)	
1997.	Kortum (1997.)		Pritchett (1997.)
1999.		Howit (1999,2000.)	Halle i Jones (1999.)
2002.			Acemoglu i Ventura (2002)
2003.		Lederman i Saenz (2003.)	
2005.			Parente i Prescott (2005.) Pritchett (2005.)

* Prema Grossman (1996.)

Izvor: A. Mervar, *Esej o novijim doprinosima teoriji ekonomskog rasta* (2003.), dopunio autor

Modeli zasnovani na eksternalijama je grupa modela endogenog rasta koja je po svojoj ishodišnoj ideji najbliža neoklasičnom modelu jer je na rast moguće utjecati investicijama i akumulacijom kapitala uz pretpostavku da se kapital shvati u širem smislu. Prilagodba Solowljeva modela, dakako, postiže se tako da se pod kapitalom uz fizički podrazumijeva i ljudski kapital. Zahvaljujući najčešće upravo ljudskom kapitalu, koji se akumulira bilo putem učenja kroz rad (formalnim obrazovanjem ili dodatnim obrazovanjem kroz rad, na poslu), u model se uvode rastući prinosi, a time i mogućnost neograničena rasta. Kada pojedinci ili poduzeća akumuliraju kapital, oni istodobno pridonose porastu proizvodnosti kapitala koji posjeduju drugi ekonomski subjekti u društvu. Temeljne razlike između modela koji pripadaju ovoj grupi, svode se na način kako autori uvode eksternalije u svoje modele. Ova grupa modela predstavlja nadogradnju Solovljevog neoklasičnog modela, koji kao kapital promatraju i fizički i ljudski kapital. Sposobnost učenja kroz rad omogućava uvođenje rastućih prinosa, a sa tim u vezi i neograničen rast. Arov (Arrow, 1962) je objasnio proces učenja kroz rad, tako što je smatrao da nove ideje nastaju slučajno pri korištenju starih ideja (pri uobičajenoj proizvodnoj aktivnosti). Razlike u nivoima ekonomskog rasta između zemalja se temelje upravo na razlikama u nivou akumuliranog znanja između njih.

Romer (Romer, 1986, 1987) pored hipoteze koja se odnosi na učenje kroz rad uvodi i hipotezu o prelijevanju znanja- istovremeno sa nastankom novog znanja ono postaje svima besplatno dostupno. Novo znanje stvara eksternalije, što Romer poistovjećuje sa pojmom tehnološkog napretka. Modeli pretpostavljaju da se znanje stvara izvan firme, također pretpostavljaju da je ekonomija savršeno konkurentna, da pojedinačne firme imaju konstantne prinose[24], dok ekonomija kao cjelina bilježi rastuće prinose. Tehnološki napredak u ovom modelu je dat kao endogeni faktor, ali je analitički nedovoljno objašnjen i predstavlja rezultat ekonomskih aktivnosti poduzeća.

Pretpostavlja se da u osnovi modela zasnovanih na istraživanju i razvitku, koje karakterizira monopolistička moć, postoji odvojen tehnološki sektor u gospodarstvu koji opskrbljuje ostale sektore novim tehnologijama. Proizvođači kupuju nove tehnologije i time stječu pravo na njihovo korištenje. Oni također naplaćuju cijenu koja je veća od graničnog troška njihove proizvodnje, a to zato da bi generirali dovoljan dohodak da pokriju troškove koji uključuju

[24] Kell, M., Rojac, M., (2007), „The economic of knowledge and knowledge accumulation: A literature survey", Understanding the Relationship between Knowledge and Competitiveness in the Enlarging EU.

početne investicije u nove tehnologije. Investicije u inovacijske projekte pritom nemaju osobinu padajućih prinosa. Stoga se proizvodnost novih investicija u inovativnu djelatnost ne smanjuje, već omogućuje stalan održiv rast. U tim modelima stopa rasta ovisi o količini sredstava koja su namijenjena inovacijskoj aktivnosti, tj. istraživanju i razvitku, zatim o razini do koje nove tehnologije mogu biti privatno korištene (dakle o stupnju monopolističke moći) i o vremenskom horizontu investitora.[25] Modeli rasta zasnovani na istraživanju i razvitku često su korišteni za istraživanje uloge otvorenosti gospodarstva. Najjednostavniji kanal kojim veća otvorenost može poticati brži rast jest efekt prelijevanja novoga znanja. Rivera-Batiz i Romer (1991.) pokazuju da je ravnotežni rast brži u integriranu svijetu nego u svijetu izoliranih zemalja, čak i u slučaju kada između zemalja nema razmjene dobara. U svijetu relativno jeftinih komunikacija opće znanje, nastalo u jednoj zemlji, lako postaje dostupno istraživačima u drugoj zemlji, ali postoje i drugi načini kojima otvorenost potiče brži tehnološki napredak. Poduzeća u otvorenim gospodarstvima imaju mogućnost da prodaju svoje inovacije na svjetskom tržištu i, anticipirajući veći profit, ulažu u istraživanje i razvitak više nego poduzeća koja prodaju samo na domaćem tržištu. Osim toga, jedan dio modela zasnovanih na istraživanju i razvitku usmjeren je i na analiziranje procesa u kojima tehnološki manje napredne zemlje imitiraju tehnološka unaprjeđenja u zemljama predvodnicama tehnološkoga napretka.[26]

2.2.2.3. Determinante gospodarskog rasta

Širok raspon studija istraživao je čimbenike na kojima se temelji gospodarski rast. Koristeći različite konceptualne i metodološke stavove, ove studije stavile su naglasak na drukčiji skup bilježaka parametara i nude razne uvide u izvore gospodarskoga rasta.

Investicija je temeljna odrednica gospodarskog rasta utvrđena u objema teorijama, i neoklasičnim i u endogenim modelima rasta. Međutim, u neoklasičnom modelu ulaganja imaju utjecaj u prijelaznom razdoblju dok su endogeni modeli rasta utvrđeni trajnijim učincima.

[25] Kod Helpmana (1992.) i Grossmana i Helpmana (1994.) može se naći iscrpan pregled modela u kojem se rast zasniva na inovativnoj djelatnosti. Modeli endogenog rasta u kojima monopolistički profiti motiviraju inovacije postali su vrlo brzo popularni otkrivajući velik broj zanimljivih veza, posebno između veličine tržišta, međunarodne trgovine i rasta. Grossman i Helpman (1990.; 1991.) raspravljaju općenito o implikacijama međunarodne trgovine, a Rivera-Batiz i Romer (1991.) upozoravaju da međunarodne integracije mogu dati dodatni poticaj industrijskim istraživanjima.

[26] Vidjeti Grossman i Helpman (1991., poglavlje 11.) i Barro i Sala-i-Martin (1995., poglavlje 8.).

Ulaganje je po tim teorijama dovelo do ogromne količine empirijskih studija koje su ispitivale odnos između investicija i gospodarskog rasta (Kormendi i Meguire, 1985.; De Long i Summers, 1991.; Levine i Renelt, 1992.; Mankiw, 1992.; Auerbach i dr., 1994.; Barro i Sala-i-Martin, 1995.; Sala-i-Martin, 1997.; Easterly, 1997.; Bond i dr., 2001.; Podrecca Carmeci, 2001.). Ipak, rezultati nisu konačni.

Ljudski kapital je glavni izvor rasta u nekoliko modela endogenog rasta, kao jedan od ključnih proširenja u neoklasičnom modelu rasta. Budući da se pojam *ljudski kapital* odnosi prvenstveno na stjecanje radnih vještina i *know-how* kroz obrazovanje i obuku, većina je studija mjerila kvalitetu ljudskoga kapitala uz pomoć *proxy*-varijabli koje se odnose na obrazovanje (npr. stope škola – upis, ispitivanje matematike i znanstvenih vještina, itd.). Velik broj studija dokazuje da je obrazovano stanovništvo ključna odrednica gospodarskog rasta (vidjeti Barro, 1991.; Mankiw i dr., 1992.; Barro i Sala-i-Marin, 1995., Brunetti i dr, 1998., Hanushek i Kimko, 2000.). Međutim, bilo je i drugih znanstvenika koji su ispitivali ove rezultate i, dakle, značaj ljudskog kapitala kao bitne odrednice gospodarskog rasta (npr. Levine i Renelt, 1992.; Benhabib i Spiegel, 1994.; Topel, 1999.; Krueger i Lindahl, 2001.; Pritchett, 2001.).

Inovacije i istraživačke aktivnosti i razvoj (R & D) mogu imati važnu ulogu u gospodarskom napretku povećanja produktivnosti i rasta. To je zbog povećanja korištenja tehnologije koja omogućuje uvođenje novih i vrhunskih proizvoda i procesa. Ta je uloga naglašena u raznim endogenim modelima rasta i jaka veza između inovacija, R & D i gospodarskoga rasta empirijski je potvrđena mnogim studijama (vidjeti Fagerberg, 1987.; Lichtenberg, 1992.; Ulku, 2004.). Ekonomska politika i makroekonomski uvjeti, kao odrednice gospodarskog rasta, također su privukli mnogo pozornosti (vidi Kormendi i Meguire, 1985.; Grierand i Tullock, 1989.; Barro, 1991., 1997.; Fischer, 1993., Easterly i Rebelo, 1993., Barro i Sala -i-Martin, 1995.) jer mogu postaviti okvir unutar kojeg se gospodarski rast odvija. Ekonomske politike mogu utjecati s nekoliko aspekata ekonomije kroz ulaganja u ljudski kapital i infrastrukturu, poboljšanje političkih i pravnih institucija i tako dalje (iako postoji neslaganje o ulozi politike na rast). Makroekonomski uvjeti smatraju se potrebnima, ali ne i dovoljnima za gospodarski rast. (Usp. Fischer, 1993.) Općenito, stabilno makroekonomsko okruženje može pogodovati rastu, napose kroz smanjenje nesigurnosti, dok makroekonomska nestabilnost može imati negativan utjecaj na rast preko njegovih učinaka na produktivnost i investicije (npr. veći rizik).

Nekoliko makroekonomskih čimbenika koji utječu na rast identificirani su u literaturi, no značajna je pozornost stavljena na inflaciju, fiskalnu politiku, proračunski deficit i porezna opterećenja. Otvorenost prema trgovini opsežno se koristi u literaturi gospodarskog rasta kao glavna odrednica uspješnosti gospodarskog rasta.

Postoji značajni teorijski razlozi za vjerovanje da postoji jaka i pozitivna veza između otvorenosti i gospodarskog rasta. Otvorenost utječe na gospodarski rast kroz nekoliko kanala, kao što su iskorištavanje komparativnih prednosti, transfer tehnologije i širenje znanja, povećanje ekonomije razmjera i izloženost tržišnom natjecanju. Otvorenost gospodarstva obično se mjeri kroz omjer izvoza u BDP-u[27]. Tu je bitan i rast interesa empirijskih istraživanja odnosa između otvorenosti i rasta. S jedne strane, velik dio literature pokazuje da ekonomije otvorene trgovini i optjecaju kapitala rastu brže i imaju veći BDP po glavi stanovnika (Dollar, 1992., Sachs i Warner, 1995., Edwards, 1998, Dollar i Kraay , 2000.). S druge strane, nekoliko je znanstvenika kritiziralo robusnost tih nalaza, osobito metodološke okosnice istraživanja i mjerenja uzroka (vidjeti Levine i Renelt, 1992.; Rodriguez i Rodrik, 1999.; Vamvakidis, 2002.).

Izravna strana ulaganja (FDI) imala su ključnu ulogu u internacionalizaciji gospodarske aktivnosti i to je primaran izvor transfera tehnologije i gospodarskog rasta. Ta je uloga naglašena u nekoliko modela endogenih teorija rasta. Empirijska istraživanja pokazuju utjecaj FDI-ja na rast i ta su istraživanja dala manje -više dosljedne rezultate koji potvrđuju značajnu pozitivnu vezu s gospodarskim rastom (vidjeti Borensztein i dr., 1998.; Hermesa i Lensink, 2000.; Lensink i Morrissey, 2006.).

Drugi važan izvor rasta istaknut u literaturi jest institucionalni okvir. Iako institucionalni okvir[28] ima vrlo bitnu ulogu u oblikovanju gospodarskog učinka (usp. Lewis, 1955.; Ayres, 1962.), donedavno učinci nisu bili empirijski dosljedno ispitani (vidjeti Knack i Keefer, 1995.; Mauro, 1995., Hall i Jones, 1999.; Rodrik, 1999.; Acemoglu i dr., 2002.).

Rodrik (2000.) ističe pet ključnih institucija (imovinska prava, regulatorne institucije, institucije za makroekonomsku stabilizaciju, ustanove za socijalno osiguranje i institucije upravljanja

[27] Međutim, još jednu mjeru, možda prikladniju, predlažu Sachs i Warner (1995.). Prema tome, ekonomija se smatra vrlo otvorenom ako zadovoljava sljedećih pet kriterija: a) prosječna kvota i licenciranje pokrivenost uvoza manji od 40 %, b) prosječne su carinske stope ispod 40 %, c) crna premija na tržištu manja je od 20 %, d) nema ekstremne kontrole nametnute na izvoz, e) zemlja nije pod socijalističkom režimom.

[28] Prema Northu (1990.) pojam *institucije* odnosi se na formalna pravila, neformalna ograničenja i njihove karakteristike za provođenje koje zajedno oblikuju ljudske interakcije.

konfliktima) koje ne samo da utječu izravno na gospodarski rast nego i na druge odrednice rasta kao što su fizički i ljudski kapital, investicije, tehničke promjene i procesi ekonomskog rasta. Na temelju toga Easterly (2001.) tvrdi da nijedan od tradicionalnih čimbenika neće imati značajan utjecaj na ekonomske performanse ako nije razvio stabilno i pouzdano institucionalno okruženje. Najčešće korištene mjere kvalitete institucija u empirijskoj literaturi uključuju vladino odbacivanje ugovora, rizik od eksproprijacije, korupcije, vlasnička prava, vladavine prava i birokratsku kvalitetu (Knack i Keefer, 1995.).

Odnos između političkih čimbenika i gospodarskog rasta došao je do izražaja u Lipsetovu radu (1959.) koji je istraživao kako gospodarski rast utječe na politički režim. Od tada je nastao čitav niz istraživačkih radova koji su proučavali povezanost političkog okruženja i ekonomskog rasta (vidjeti Kormendi i Meguire 1985.; Scully 1988.; Griera i Tullock, 1989.; Lensink i dr., 1999.; Lensink, 2001.). U temeljnom obliku politička će nestabilnost povećati nesigurnost, obeshrabriti ulagače i na kraju kočiti gospodarski rast. Stupanj demokracije također je povezan s gospodarskim rastom, ali odnos je puno složeniji jer demokracija može i usporiti i povećati gospodarski rast, ovisno o brojnim okolnostima (vidi Alesina i dr., 1994.). U posljednjih nekoliko godina brojni su istraživači uz pomoć varijabli proveli mjerenje kvalitete političkog okruženja kao što su politička nestabilnost, političke i građanske slobode i politički režim. Brunetti (1997.) razlikuje pet kategorija relevantnih političkih varijabli: demokracija, stabilnost vlade, političko nasilje, politička volatilnost i subjektivna percepcija politike.

Odnedavno je došlo do rastućeg interesa za istraživanje o tome kako različiti društveno-kulturni čimbenici mogu utjecati na rast (vidjeti Granato i dr., 1996.; Huntington, 1996., Temple i Johnson, 1998., Landes, 2000.; Inglehart i Baker, 2000.; Zak i Knack, 2001.; Barro i McCleary, 2003.). Povjerenje je važna varijabla koja pripada ovoj kategoriji. Očekuje se da su ekonomije koje uživaju povjerenje i inventivnije, da bolje akumuliraju fizički kapital i imaju jače ljudske resurse koji vode gospodarskom rastu (Knack i Keefer, 1997). Etnička raznolikost, pak, može imati negativan utjecaj na rast smanjenjem povjerenja, povećanje polarizacije i promicanje usvajanje politika koje imaju neutralne ili čak negativne učinke na gospodarski rast (Easterly i Levine, 1997.). Do sada je istraženo nekoliko drugih socijalno-kulturnih čimbenika kao što su etnički sastav i fragmentacije, jezik, vjera, uvjerenja, stavovi i socijalno-etnički sukobi, ali je njihov odnos prema gospodarskom rastu, čini se, neizravan i nejasan. Primjerice, kulturna raznolikost može imati negativan utjecaj na rast zbog pojave socijalne nesigurnosti ili čak društvenih sukoba, ili pozitivan učinak jer to može dovesti do pluralističkog okruženja gdje suradnja može napredovati.

Također, prepoznata je i bitna uloga geografije na gospodarski rast što je tijekom posljednjih godina dovelo do većeg interesa i istraživanja u ovom području (Gallup i sur., 1999.). Istraživači su koristili brojne geografske varijable uključujući apsolutne vrijednosti zemljopisne širine, udaljenost od ekvatora, udio zemljišta unutar 100 km od obale, prosječne temperature i prosječne količine oborina, kvalitetu tla i bolesti ekologije. (Vidi Hall i Jones, 1999., Rodrik i sur., 2002., i Easterly i Levine, 2003.) Isto je tako nedavno urađeno i nekoliko empirijskih studija (Sachs i Warner, 1997., Bloom i Sachs, 1998.; Masters i McMillan, 2001.; Armstrong i Read, 2004.) koje potvrđuju da prirodni resursi, klima, topografija i sl. mogu imati izravan utjecaj na gospodarski rast i produktivnost, ekonomsku strukturu, troškove prijevoza i konkurentnosti. Međutim, drugi autori (npr. Rodrik i sur., 2002.; Easterly i Levine, 2003.) nisu uočili povezanost geografije i gospodarskog rasta nakon kontrole varijabli koje su povezane s institucijama.

Odnos između demografskih trendova i gospodarskog rasta privukao je veliko zanimanje osobito tijekom posljednjih dvadesetak godina, no mnogi demografski aspekti i dalje ostaju neistraženi. Od onih koji su istraženi, porast broja stanovnika, gustoća naseljenosti, migracije i distribucija dobi, čini se da imaju važnu ulogu u gospodarskom rastu (Kormendi i Meguire, 1985.; Dowrick, 1994.; Kelley i Schmidt, 1995.; Barro, 1997., Bloom i Williamson, 1998., Kelley i Schimdt, 2000.). Visok rast stanovništva, primjerice, može imati negativan utjecaj na gospodarski rast. Sastav stanovništva ima i značajne implikacije za rast. Velik udio radno sposobnog stanovništva smatra se vodiljom rasta dok se stanovništvo s mnogo mladih i starijih članova obitelji doživljava kao smetnja. Gustoća naseljenosti, pak, može biti pozitivno povezana s gospodarskim rastom kao rezultat povećane specijalizacije, širenja znanja i sl. Rezultati ovih istraživanja opet nisu konačni budući da su neke studije pokazale da nema (jake) korelacije između gospodarskog rasta i demografskih trendova (npr. Grierand i Tullock, 1989; Pritchett, 2001).

2.2.3. Kanali utjecaja financijskog sustava na gospodarski rast

Ekonomisti su suglasni u mišljenju da su dva glavna kanala gospodarskoga rasta akumulacija kapitala i tehnološke inovacije. Međutim, prethodno spomenuti modeli ne spominju izravno financijske posrednike i financijska tržišta. Od „financijskih“ varijabli u sve je spomenute modele uključena štednja. Modeli polaze od bitne pretpostavke da je štednja jednaka investicijama. Transmisija štednje u investicije temeljna je funkcija i zadaća financijskoga sustava. Pretpostavka da je štednja jednaka investicijama zapravo znači da je u modelu izvrsno financijsko posredovanje što podrazumijeva da se štednja bez ikakvih dodatnih troškova može mobilizirati u investicije.

Neoklasičan model rasta koji je podrazumijevao proizvodnu funkciju Y= f(K,AN), pretpostavljao je samo privremen utjecaj promjene stope štednje na rast proizvoda po zaposlenom. Stopa rasta proizvoda po zaposlenom je u okviru ovoga modela dugoročno jednaka stopi tehnološkog napretka. U vrijeme kad se pojavio Solowljev model velik je broj teoretičara negirao ulogu financijskoga sustava na gospodarski rast. Primjerenije rečeno, utjecaj financijskoga sustava na gospodarski rast može imati samo privremen karakter. Neki teoretičari su zastupali mišljenje da „gdje gospodarski rast predvodi, financije slijede“. Dakle, financijski sustav nema utjecaja na gospodarski rast , nego se on i sam razvija pod utjecajem gospodarskog rasta.

Funkcija mobilizacije štednje bitna je i ujedno i najznačajnija funkcija financijskog sustava jer su, s jedne strane, bez pristupa investitorima mnogi proizvodni procesi neprofitabilni, a s druge strane ona omogućuje kućanstvima posjedovanje diverzificiranog portfelja i povećanje likvidnosti imovine što pridonosi efikasnoj alokaciji resursa. (Usp. Siri i Tufano, 1995.) Svakako treba napomenuti da mobilizacija štednje nije jednostavna i bez troškova jer je koče transakcijski troškovi prikupljanja štednje od različitih pojedinaca i institucionalnih jedinki i informacijske asimetrije. Dakako, financijski posrednici su tu da te probleme ublaže, ali ih svakako ne mogu eliminirati u potpunosti. Kao posljedica toga samo je jedan dio štednje iskorišten, a preostali je izgubljen (Gross, 2002.). Gubitak djela štednje povezuje se s mnogim čimbenicima kao što su aktualni troškovi posredovanja banaka, oligopolističko ponašanje, trošenje prikupljenih poreza na potrošačka dobra itd. Marco Pagano primijenio je *AK*-model kako bi razvio model u kojem razvoj financijskog sustava dovodi do veće razine dugoročnog dohotka i dugoročne stope rasta.

Rast se može shvatiti, u okviru treće grupe modela ekonomskog rasta, kao isključiva posljedica akumulacije kapitala pri čemu se kapital interpretira kao široka mjera različitih oblika uključujući ljudski i fizički kapital. (Vidi Becker, Murphy i Tamura, 1990.; Jones i Manueli, 1990.; King i Rebelo, 1990.; Rebelo, 1991.) U ovim je AK-modelima rast endogen unatoč odsutnosti rastućih prinosa. Kapital je vodeća snaga gospodarskog rasta i poduzeća stalno povećavaju njegovu količinu u savršeno konkurentnim tržištima s konstantnim prinosima. U ovom tipu modela endogenog rasta savršena konkurencija zahtijeva da kapital bude plaćen prema graničnom proizvodu koji ne smije biti niži od eskontne stope da bi ostao profitabilan. Stoga autori određuju donju granicu za privatne prinose na kapital kao obilježje agregatne proizvodne funkcije i time osiguravaju da investicije ostanu profitabilne. U *AK*-modelima ne prepoznaje se da je tehnologija vrsta dobra različita od, primjerice, fizičkog kapitala.

Dakle, kod AK-modela rast je preslika karakteristika agregatne proizvodne funkcije gospodarstva. Granični proizvod kapitala pritom ne smije pasti ispod neke subjektivne stope povrata koja osigurava da pojedinci nastave beskonačno akumulirati kapital. Iako se *AK*- model endogenog rasta najčešće povezuje s radovima Jonesa i Manuellija (1990.) i Rebela (1991.), slični su se linearni modeli pojavljivali u literaturi znatno prije. (Vidi Knight, 1935.; 1944.; von Neumann, 1945.; Benveniste, 1976. i Eaton, 1981.)

AK-modeli rasta po svojoj su strukturi najjednostavniji među novijim modelima rasta. Ako tehnologija proizvodnje ima konstantne prinose u odnosu na razmjer kapitala i rada, onda proizvod gospodarstva mora biti u (asimptotski) linearnom odnosu prema akumuliranom kapitalu kako bi granični proizvod ostao iznad određene donje granice. Zahvaljujući tomu, investicije nikad ne počinju iskazivati padajuće prinose.

U svojoj biti *AK*-model je neoklasičan model bez opadajućih prinosa. U ovom se modelu ne daje eksplicitno objašnjenje razlike između akumulacije kapitala i tehnološkog napretka. Ova vrsta modela (i modela koji se na njima temelje) prva su vrsta modela koji su se pojavili 80-ih godina. U njima se postojani rast postiže neovisno o tehnološkom napretku (dakle, postojani rast *t* moguć je i bez tehnološkog napretka). Model se kao i prije sastoji od dviju jednadžbi: proizvodne funkcije i jednadžbe akumulacije. Jednadžba akumulacije u varijablama izraženima po stanovniku ima isti oblik kao u Solowljevu modelu:

$$k(t) = sy(t) - (n + \delta)k(t)$$

Razlika je u funkciji proizvodnje koja sada ima oblik:

$$Y(t) = AK(t) \tag{2.2.1}$$

gdje je A tehnološki parametar koji se ne mijenja tijekom vremena (nema tehnološkog napretka). Pogledamo li desnu stranu jednadžbe (2.2.1), vidljivo je zašto je ovaj model dobio ime *AK*-model.

Dijeleći jednadžbu (2.2.1) s N, također je moguće uspostaviti vezu između proizvoda po radniku i kapitala po radniku pa imamo:

$$\frac{Y(t)}{N} = \frac{AK(t)}{N} \tag{2.2.2}$$

Granični proizvod kapitala jednak je:

$$\frac{dY}{dK} = \frac{\frac{dY}{N}}{\frac{dK}{N}} = A \tag{2.2.3}$$

Na temelju gore navedenoga možemo zaključiti da granični proizvod kapitala ne opada kako razina kapitala raste.

U *AK*-modelu stopa rasta kapitala dana je izrazom:

$$K = sY - \delta K$$

No zbog (2.2.1) ona prelazi u:

$$K = (sA - \delta)K \tag{2.2.4}$$

Podijelimo li jednadžbu (2.2.4) s K, dobivamo novi izraz za stopu rasta kapitala:

$$\frac{K}{K} = sA - \delta \tag{2.2.5}$$

Stopa rasta kapitala po radu dobije se diferenciranjem logaritma od K/N po vremenu t:

$$\frac{d\ln\frac{K}{N}}{dt} = \frac{d\ln K}{dt} - \frac{d\ln N}{dt} \qquad (2.2.6)$$

Prvi član na desnoj strani izračunat je pod (2.2.5), a za radnu snagu pretpostavimo da raste po stopi *n* iz čega imamo:

$$\frac{d\ln\frac{K}{N}}{dt} = sA - (\delta + g_N) \qquad (2.2.7)$$

Ako je *A* dan egzogeno, tada je stopa rasta proizvodnje po radniku jednaka:

$$\frac{d\ln\frac{Y}{N}}{dt} = \frac{d\ln A}{dt} + \frac{d\ln\frac{K}{N}}{dt} = sA - (\delta + g_N) \qquad (2.2.8)$$

Važna osobina tog modela je da zbog navedene pretpostavke kako je $sA > n + \delta$ rast kapitala, vrijedi za sve razine kapitala po radniku *K(t)* tako da količina kapitala po radniku nastavlja rasti unedogled. Do toga se ne dolazi tehnološkim napretkom, nego zbog činjenice da kapital ima veliku graničnu proizvodnost koja se ne smanjuje kad gospodarstvo akumulira više kapitala. Dva su važna svojstva ovoga modela: da je stopa rasta gospodarstva pozitivna i konstantna kroz vrijeme (uvijek, a ne samo na putu ravnomjerna rasta) i da se stopa rasta povećava s rastom stope štednje.

Za *AK*-model može se zaključiti da ulaganje u fizički i ljudski kapital , što se može promatrati kao oblik štednje, imaju efekt na stopu rasta kapitala i proizvoda, a ne samo na razinu. U *AK*-modelu gospodarski rast nije više samo određen tehnološkim promjenama, nego je i egzogeno određen ulaganjima u fizički, ali i ljudski kapital.

Kad bi sve relevantne informacije bile raspoložive i besplatne te kada bi budućnost bila predvidiva, tada bi akteri s viškovima novčanih sredstava izravno pronalazili aktere kojima ta sredstva nedostaju, a koji ih znaju produktivnije upotrijebiti. Prema teoriji Modiglianija i Millera (1958.), financijska struktura tvrtki (omjer duga i kapitala na strani izvora financiranja) ne bi imala ekonomsku važnost u takvu idealnome svijetu. Funkcija mobilizacije štednje bitna je zadaća financijskoga sustava, ali ona nije tako jednostavna jer ju koče transakcijski troškovi prikupljanja štednje od različitih pojedinaca i informacijske asimetrije. Dakle, stvaran svijet je

potpuno drukčiji i informacije nisu potpune i besplatne. Nitko ne zna sve. Zato se pojavljuju financijski posrednici, a cijena kapitala nije jedinstvena, nego se razlikuje ovisno o podrijetlu i karakteristikama izvora financiranja – zadržanoj zaradi i uplati novoga kapitala ili dugu (koji, ovisno o vrsti duga, može imati različitu cijenu za istog dužnika). Banke, kao sastavni dio financijskoga sustava pritom uživaju komparativnu (troškovnu) prednost u poslovima prikupljanja i analize informacija, predviđanju vjerojatnosti naplate kreditnih potraživanja (upravljanje kreditnim rizikom) i samoj naplati. (Usp. Gershenkorn, 1962.; Rajan i Zingales, 1998.; Levine, 2002.) Kao posljedica svih transakcijskih troškova koji se pojavljuju u intermedijaciji, za investicije se iskoristi samo jedan dio štednje, a preostali se dio „izgubi".

Važno je napomenuti da vezu između financijskoga sustava i gospodarskoga rasta nije dovoljno promatrati samo preko funkcije mobilizacije štednje. Financijski sustav preko svojih drugih funkcija (alokacija resursa, kontrola korporacija, olakšavanje trgovine, upravljanje rizicima, itd.) također može imati značajne efekte na gospodarski rast. Jedan kanal preko kojeg financijski sustav može utjecati na gospodarski rast je akumulacija kapitala, što je moguće kroz promjene stope štednje ili ponovnu alokaciju štednje između različitih tehnologija proizvodnje kapitala, dok je drugi kanal utjecaj na tehnološke inovacije. (Usp. Hass, 2001.) Teoretski gledano na pristup utjecaja financijskoga sustava na gospodarski rast može se i slikovito prikazati (slika 3.). Na toj je slici uočljivo da financijska tržišta i posrednici ublažavaju problem asimetričnih informacija i smanjuju transakcijske troškove vršeći svoje funkcije. Na temelju toga potiče akumulaciju kapitala i tehnološke inovacije utječući tako na (dugoročan) gospodarski rast.

Slika 2.2. Teoretski pristup financijskom sustavu i gospodarskom rastu

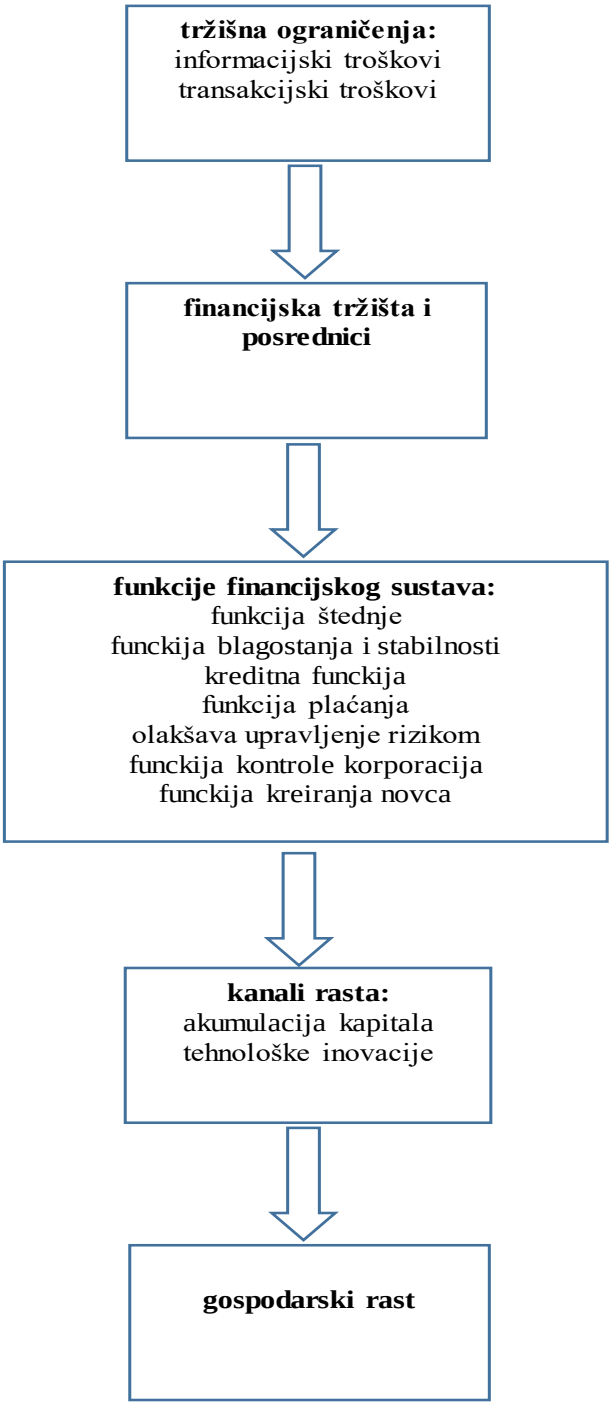

Izvor: Levine, 1997.

Cooly i Smith 1998. godine razvili su model koji analizira ulogu financijskih tržišta u gospodarskom razvoju (model je po prvim slovima prezimena autora Cooly i Smith dobio naziv *SC*-model). Slično kao u modelu preklapajućih generacija, u njihovu modelu postoje subjekti koji prolaze kroz tri razdoblja: vrijeme t je mladost, $t + 1$ zrelost, $t + 2$ starost. Mladi mogu

birati između rada i obrazovanja. Ulaganje u znanje poslije će im omogućiti bolji posao. Prema tome, ljudi u srednjoj dobi mogu iznajmljivati rad ili, ako su prije prošli izobrazbu, mogu voditi tvrtku dok stariji ljudi nisu u mogućnosti iznajmljivati rad, ali mogu voditi tvrtku ako su otprije obrazovani. Ako nema financijskih tržišta, tada subjekti koji su se u mladosti usmjerili prema zarađivanju dohotka umjesto ulaganju u obrazovanje, dobiveni dohodak neće moći uložiti u neki financijski instrument. Oni u srednjim godinama neće moći voditi tvrtku i na taj će način štednja biti izgubljena. U starosti bi im jedina mogućnost za stjecanje prihoda za potrošnju bila posjedovanje tvrtke. Dakle, svi će subjekti biti skloniji obrazovanju u mladosti da bi radili u srednjim godinama i u starosti vodili tvrtku. Učenje kroz rad usko je povezano sa specijalizacijom. Specijalizacija omogućuje postojanje financijskih tržišta i na taj su način financijska tržišta bitna za učenje kroz rad. U takvim uvjetima i subjekti su produktivniji što pridonosi rastu domaćeg proizvoda i štednje, a to onda prema modelima endogenog rasta pozitivno utječe na gospodarski rast. Kad nema financijskih tržišta, nema više ni učenja kroz rad. Stopa rasta je iznimno niska u takvim situacijama pa su autori postavili pitanje mjera koje zemlje moraju poduzeti kako bi se potaknuo razvoj financijskih tržišta i samim time pridonijelo većem gospodarskom rastu.

Michalopoulus, Laeven i Levine su 2009. godine razvili model prema kojem i tehnološke i financijske inovacije, kao posljedica odluka pojedinaca kojima se utječe na maksimalizaciju profita, utječu i na gospodarski rast. Implikacije njihove teorije jesu da će tehnološke promjene i financijske inovacije biti pozitivno kolerirane i da će gospodarski rast stagnirati ne bude li financijskih inovacija. Autori također navode i povijesne primjere da financijske inovacije potiču gospodarski rast i uzimaju primjer islamskih zemalja gdje je islamski sustav ograničavao razvoj financijskog sustava i na taj način poticao tehnološke inovacije i gospodarski rast.

Solowljev model i *MRW*-model (Mankiw-Romer-Weil model) rasta prošireni su utjecajem financijskoga sustava. (Usp. Chou i Chin, 2001.) Oni su pokazali da će veći stupanj financijskog razvoja rezultirati većom razinom BDP-a po glavi stanovnika, ali da neće utjecati na stopu rasta. Stoga oni preporučuju da vlada svoje subvencije usmjeri prema obrazovnom sustavu kako bi se stvorio veći dugoročni gospodarski rast.

Zanimljivo je i istraživanje Berthelemyja i Varoudakisa iz 1996. godine koji su razvili teorijski model višestrukih ravnotežnih stanja prema kojem financijski sustav pozitivno utječe na gospodarski rast ako zemlja već ima određen stupanj financijskog razvoja. U jednom od tih

stanja upada se u zamku siromaštva kada financijski sustav nestaje, a gospodarstvo stagnira dok se u drugom stanju financijski sustav normalno razvija i evidentan je endogen rast gospodarstva. Ono što se može zaključiti jest da financijski razvoj nužno ne utječe na gospodarski rast. Isto tako, empirijska su istraživanja dovela do rezultata da razvoj financijskoga sustava dovodi do povećanja likvidnosti. Isto tako, ograničenje likvidnosti pretpostavlja ograničenje sredstava koja osoba može ponuditi od financijskih institucija, a što joj omogućava trenutno trošenje budućeg dohotka. (Usp. Mankiw, 2002.) Štednja zbog ograničenja likvidnosti može porasti iz dvaju razloga: a) pojedinac troši manje nego što bi inače mogao i b) kada i ne bi postojalo ograničenje likvidnosti, mogućnost da će se pojaviti u budućnosti navest će ga da trenutno troši manje. (Usp. Romer, 2001.) Neki radovi pokazuju i da bolja alokacija resursa potiče smanjenje štednje pa se tako razvoj financijskog sustava može nepovoljno preslikati na gospodarski rast. (Usp. Bencivenga i Smith, 1991.).

Dakako, važno je napomenuti da štednja ovisi i o kamatnoj stopi. Uobičajeno je da će povećane kamatne stope povećati štednju iako ne i nužno. Naime, s jedne strane porast kamatne stope ima pozitivan utjecaj na štednju jer ju s jedne strane povećava zbog nepovoljnog utjecaja na potrošnju (učinak supstitucije), a s druge strane smanjuje zbog smanjenja dohotka (učinak dohotka).

2.3. Financijski sustav i financijska struktura u odabranim zemljama

2.3.1. Razvoj bankarskoga sustava

Bankarski se sustav može definirati kao zbroj svih banaka i kreditnih institucija koje djeluju na području neke zemlje. Pojava bankarstva vezana je uz pojavu novca. Začetke bankarskoga poslovanja nalazimo u središnjoj Aziji. Sumeranski svećenici u 35. stoljeću prije Krista u svojim hramovima počinju obnašati poslove koje danas nazivamo bankarskima. Naime, svećenici, kao najobrazovaniji ljudi svoga vremena, uz to i pismeni, za razliku od većine ljudi, mogli su se baviti poslovima vezanima uz novac, dakle prapočetcima bankarstva (Gregurek i Vidaković, 2011.) Daljnji razvoj gospodarstva i novčarstva u babilonskom carstvu dovodi do pojave pozajmljivanja novca uz plaćanje kamate, dakle do bankarskoga poslovanja koje i danas postoji u tom obliku.

Nadalje, bankarstvo se razvija i u Grčkoj i to u 7. stoljeću prije Krista kada se pojavljuju prvi privatni bankari koji su se bavili novčanim poslovima, a nazivali su se *trapeziti*, što u prijevodu znači *klupa*. U Grčkoj su se pojavile i prve državne banke. Do razvoja trgovine i gospodarstva dovela su i rimska osvajanja. Rimski su bankari u to vrijeme dobivali državne povlastice i financirali sve ostale klase Rimskoga Carstva. U rimskom se društvu prvi put pojavio i pojam tekućeg računa i žiroračuna. Nakon što se raspalo Rimsko Carstvo, barbarska su plemena razorila gradove i razvijene civilizacije nakon čega se život ponovno vratio u prvobitan primitivan oblik. Novac je gotovo nestao iz svakodnevnoga života, a čuvao se za najveće nužde te se zakapao u zemlju.

Nakon gotovo tisuću godina ponovno su stvoreni uvjeti za razvoj bankarstva. Bankarstvo je tada bilo vezano za trgove gdje se odvijala trgovina. „Tako nastaju Banca di Genova i Casa di Sant Georio, te Casa di Rialto i Banca del Giro. Ove su dvije posljednje banke kao državne banke Mletačke Republike. Ujedno se osnivaju udruge bankara koje koncentriraju kapital te omogućuju, kroz monopolno djelovanje, postizanje ekstra zarada. Ove banke razvijaju nove oblike bankarske djelatnosti, kao što su poslovanje sa mjenicama, zadužnicama i drugim vrijednosnim papirima. One se bave i svim klasičnim poslovima kao njihove prethodnice.

Zahvaljujući koncentraciji kapitala uspješno utječu na razvoj trgovine, pogotovo prekomorske, na izgradnju brodova, financiraju razne trgovačke, istraživačke i ine poduhvate."

Nadalje, bankarstvo se intenzivno razvija nakon otkrića Amerike. Naime, tada se razvija prekomorska trgovina što je povećalo potrebu za dodatnim financiranjem i ostalim bankarskim poslovima. Upravo su se u Americi pojavile prve banke koje su se bavile državnim i platnim prometom. Švedska državna banka osnovana je 1668. godine, dok je engleska banka (Bank of England) osnovana 1694.

Razumljivo da banke i bankarski posao dobiva svoj ogroman zamah razvojem kapitalizma i tržišnog gospodarstva. No neke zablude liberalnog kapitalizma, kao prve faze ovog društvenog sustava, rezultiraju strahovitim krahovima i propastima banaka što je imalo odraza na čitave bankarske sustave pa čak i šire. I ovaj puta praksa je bila ispred normativnih rješenja. Konsolidacijom i pravnim reguliranjem tih pitanja te primjenom znanstvenih metoda i saznanja stvaraju se postupno uvjeti da se postigne visoki stupanj stabilnosti bankarskog sustava, a temeljem toga i cjelokupnog gospodarstva.

Analiziranjem niza članaka o razvoju bankovnoga sustava može se zaključiti da je dobro organiziran bankovni sustav glavni čimbenik održivog gospodarskog razvoja i smanjenja siromaštva. Ova tvrdnja posebno dobiva težinu kada se govori o financijskim sustavima zemalja središnje, istočne i jugoistočne Europe, na kojima se ujedno i provodi ovo istraživanje. Banke čine glavninu financijskoga sustava i dominantan instrument akumulacije i alokacije štednje te poticanja gospodarskoga rasta i razvoja. Promatranje i analiziranje spremnosti i stupnja integracije zemlje u monetarnu politiku EU-a, kao i priključivanju unutarbankarskom tržištu EU-a, od posebnog je značaja iz više razloga. S obzirom na to da su banke srž monetarnog sustava i kanal monetarnog transmisijskog mehanizma zemalja slabo razvijenijih financijskih sustava, posve je razumljiv interes za promatranje banaka u procesu integracije, kao i njihove spremnosti na takav izazov. Siguran i stabilan bankovni sustav, izložen različitim izazovima i rizicima, dobro uvezan putem platnog sustava i međubankarskog tržišta daje mogućnost disperzije rizika što osigurava učinkovitog financijskog posrednika, a time i pozitivne učinke na stimuliranje gospodarskoga rasta.

Banke posjeduju specifičnost koja ih razlikuje od drugih sektora aktivnosti u svim zemljama: one predstavljaju „sustav", tj. pripadaju ukupnom institucionalnoom i hijerarhijskom ustroju. Upravo je to razlog zašto se govori o bankovnom sustavu. Naime, bankovni je sustav ključ

financijske stabilnosti i gospodarskoga rasta i razvoja svake zemlje. Dok se koncept *sustav* općenito ne koristi da bi se okarakterizirali drugi sektori aktivnosti (crna metalurgija, automobilska industrija, kemijska industrija, telekomunikacije,...), banke čine „sustav“ jer su međusobno usko povezane, s jedne strane, i jer je njihova organizacija, s druge strane, izrazito ustrojena bankarskim odredbama. Njihovo se ekonomsko značenje prije svega može sagledati posredstvom intermedijarnog koncepta snage zajmoprimca i snage zajmodavca.
Supranacionalno okruženje utječe na bankovni sustav zemalja pristupnica i kroz monetarnu konvergenciju standardima EU-a, kao i kroz financijsku integraciju tržišnih odnosa (*input* i *output*), doživljava preobrazbu iz nacionalnog u globalno tržište.

Nakon desetljeća opsežnih reformi bankarskoga sektora u regiji došlo je vrijeme da se analizira i procijeni je li washingtonski konsenzus, kao skup mjera i politika, bio uspješan u bankarskoj tranziciji. Mjera uspjeha, međutim, nije samo u tome je li se slijedio prijedlog politika, nego i u kojoj je mjeri ta politika pokazala da je model bio dobar za prilagodbu socijalističkog bankarstva i rješenje za pružanje bankovnih usluga poduzećima i kućanstvima. Financijski sustavi nisu statični i stalno se mijenjaju, a naročito kako bi udovoljili zahtjevima tržišta kojima dominira konkurencija. Isto tako, može se zaključiti da u razgovorima i razmišljanjima o ekonomskim i financijskim integracijama postoji još puno izazova na putu ka globalizaciji, ali financijsko će posredovanje uvijek biti bitan element instrumenta globalizacije. Na temeljnoj razini to uključuje davanje niza proizvoda i usluga depozitnih i kreditnih institucija. Mjera za tu aktivnost može se koristiti i na agregatnoj razini bankarskog sustava u cjelini i na raščlanjenim razinama individua pojedinih banaka. Prednost dezagregacije je u tome da otkriva proces prilagodbe pojedinih banaka i mogućeg utjecaja nekih čimbenika povezanih s ponudom bankarskih usluga. Istodobno, agregat analiza može pomoći identificirati čimbenike na razini države koji utječu na razvoj bankarstva kao što je rast proizvodnje i napredak u strukturnim i institucionalnim reformama. Jedan od najčešće analiziranih indikatora razvoja i razvijenosti bankarskog sustava jest svakako udio kredita u BDP-u (eng. *bank credit in GDP- EBRD financial structure database*). U grafikonu br. 2.4. prikazano je kretanje danih kredita u promatranim zemljama i to za 1996. godinu, kao početnu godinu ovoga istraživanja, i 2011., krajnju godinu ovog istraživanja.

Grafički prikaz 2.1. Prikaz bankarskih kredita kao udio u BDP-u promatranim zemljama 1996. i 2011. godine

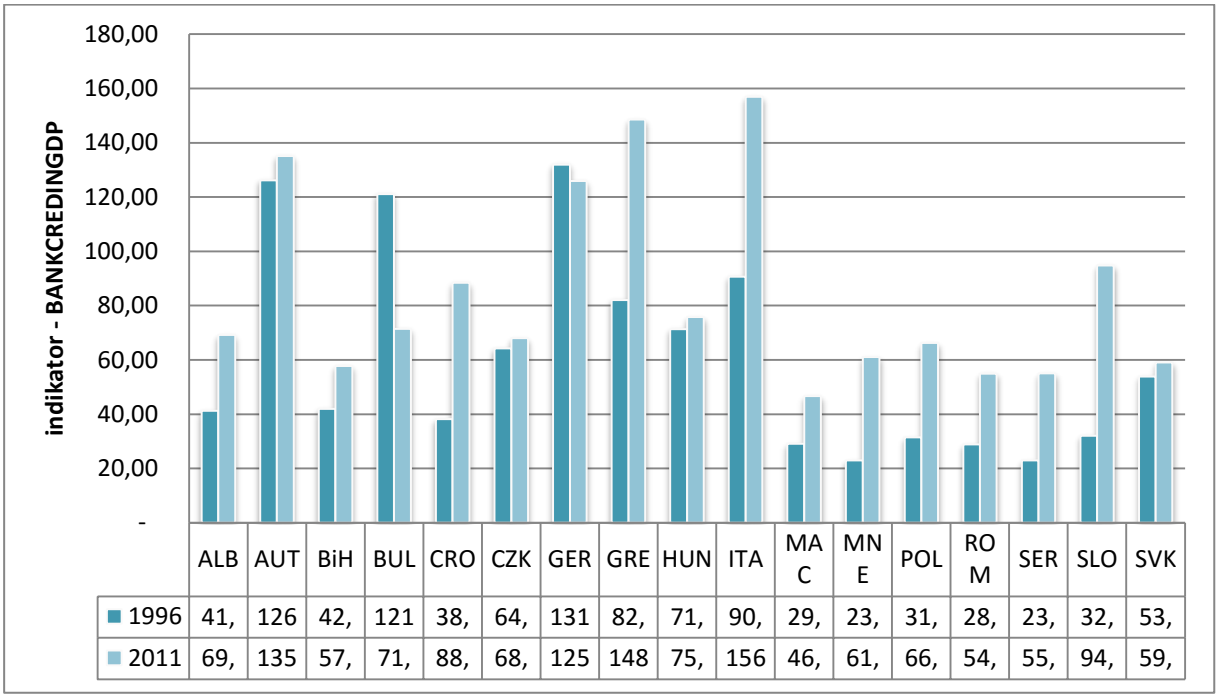

	ALB	AUT	BiH	BUL	CRO	CZK	GER	GRE	HUN	ITA	MAC	MNE	POL	ROM	SER	SLO	SVK
1996	41,	126	42,	121	38,	64,	131	82,	71,	90,	29,	23,	31,	28,	23,	32,	53,
2011	69,	135	57,	71,	88,	68,	125	148	75,	156	46,	61,	66,	54,	55,	94,	59,

Izvor: IFS, WBI, IMF, Središnje banke odabranih zemalja

Iz prethodnog grafičkog prikaza 2.1. vidljiva je ogromna aktivnost u kreditnom rastu u svim zemljama, posebice u razdoblju između 2005. i 2008. godine.

Kada govorimo o intermedijaciji, onda treba napomenuti da se u praksi pojavljuje u obliku direktne i indirektne intermedijacije. Direktna financijska intermedijacija odnosi se na direktno financiranje tj., kontakt je izravan između dviju strana bez posredovanja treće. Direktno financiranje organizirano je u smislu dogovora, zajedničkim sporazumom o uvjetima zajma, gdje se jedna strana obavezuje da će posuditi drugoj strani određen iznos sredstava bez posredovanja treće. Kod ovog postupka dvije strane razmjenjuju isti iznos sredstava istodobno pri čemu jedna strana posuđuje unaprijed dogovoren iznos sredstava drugoj strani uz obvezu povrata sredstava putem instrumenata osiguranja. Na direktnom kreditnom tržištu deficitarne jedinice (pojedinci, poduzeća, itd.) vrše emisiju financijskih instrumenata kao što su, primjerice, dionice, obveznice i drugi instrumenti, koji se mogu izravno prodati suficitarnim jedinicama, npr. brokerima i dilerima. Brokeri imaju ulogu agenta koji zaračunavaju proviziju i pronalaze one jedinice koje žele kupiti ili prodati vrijednosne papire. Dileri, pak, posjeduju vrijednosne papire uz spremnost da ih prodaju ili kupe uz odgovarajuću ponuđenu cijenu. Dileri ne zaračunavaju proviziju, a njihov je prihod razlika između prodajne i kupovne cijene

vrijednosnog papira. Brokeri i dileri doprinose razvoju sekundarnih tržišta na kojima vrijednosni papiri mogu biti ponuđeni na ponovnu prodaju.

Za razliku od izravne financijske intermedijacije, neizravna financijska intermedijacija uključuje posredovanje odgovarajućih financijskih posrednika između suficitarnih i deficitarnih jedinica. Financijski posrednici kod neizravnog oblika posredovanja su banke, investicijski fondovi i osiguravajuća poduzeća. Možemo zaključiti da su komercijalne banke najveće i najvažnije financijske institucije koje se bave financijskim posredovanjem. Inovacije na financijskom tržištu uvode prvenstveno komercijalne banke kroz razne vrste depozitnih certifikata kojima banke vrše povećanje financijskoga potencijala. Te inovacije na financijskome tržištu moraju osigurati poziciju banke u konkurentskoj borbi na razvijenu financijskome tržištu. Oblik pasivnih poslova određuje narav aktivnih poslova pri čemu pasivni čine izvor sredstava, a aktivni njihovo plasiranje. Pritom su depozitni poslovi jako bitni u poslovanju i razvoju poslovanja bankarskih institucija. Udruživanjem resursa u iznosima malih štednih računa, veliki financijski posrednik može istodobno servisirati kreditne potrebe nekoliko poduzeća. Prema tome, financijski su posrednici institucije koje prikupljaju štednju pojedinaca, poduzeća, različitih entiteta…, i ta ista sredstva pozajmljuju poduzećima, pojedincima i entitetima koji taj novac koriste kako bi financirali svoje investicije. Depozitne institucije primaju depozite i štedne uloge pojedinaca, odnosno štediša, a zatim ta sredstva preusmjeravaju na poduzeća, pojedince i druge potrošače. Temeljne depozitne institucije smatraju se komercijalne banke i druge institucije koje se bave štednjom. Lloyd (2006.) pod depozitnim institucijama podrazumijeva komercijalne banke, štedionice, kreditna udruženja i kreditne sindikate.

Dakako, na temelju prethodno opisanog možemo konstatirati da su komercijalne banke najveće i najvažnije financijske institucije koje se bave financijskim posredovanjem. Povijesno gledano, vrsta usluga koje nude komercijalne banke zasigurno je najraznovrsnija u usporedbi sa svim drugim financijskim intermedijatorima. Pasivom komercijalnih banaka dominiraju depoziti po viđenju te oročeni i štedni depoziti.

Štedni depoziti su sredstva po viđenju na štednim računima i smatraju se tradicionalnim oblikom bankarskih depozita. Ovakva vrsta depozita namijenjena je štedišama koji prihvaćaju nešto manju kamatnu stopu od one koju imaju oročeni depoziti s mogućnošću povlačenja štednoga depozita uz primjerenu najavu povlačenja sredstava.

Oročeni depoziti kod banaka predstavljaju oblik štednje pojedinaca, poduzeća i drugih entiteta koji žele oročiti svoja sredstva po određenoj kamatnoj stopi koja je nešto viša od štednih

depozita. Kamatna stopa nije fiksna i mijenja se u skladu s promjenama kamatne stope na financijskim tržištima.

Plasiranje sredstava vrši se putem različitih vrsta kredita i kroz investiranje u različite vrste financijskih instrumenata. Banke mogu odobravati različite vrste kredita, kao što su krediti stanovništvu, krediti poduzećima, krediti javnim sektoru itd.
Kod korelacije izvora i plasmana financijskih institucija jedan od ključnih elemenata, pored depozita kao izvora sredstava, svakako je i likvidnost.[29]

Isto tako, ovdje je jako važno napomenuti značaj monetarnih institucija kao aktera financijske intermedijacije. Uloga središnje banke kao financijskog intermedijatora bazira se na kontroli novčane mase i uvjeta kreditiranja. Generalno promatrano, financijski su sustavi pod utjecajem financijske regulative kako bi financijske informacije bile dostupne svim sudionicima na financijskom tržištu te kako bi se pojačala sigurnost i stabilnost financijskog sustava, a i osnažila uloga središnje banke vezano za reguliranje novčane mase i uvjeta kreditiranja na tržištu[30].

Postojanje asimetrije u informacijama na financijskim tržištima sugerira da potencijalni zajmodavci mogu imati poteškoće zbog nepovoljna izbora. Može se zaključiti da princip asimetrije u informacijama sugerira da management depozitnih institucija i drugih financijskih intermedijatora poznaje bolje financijske uvjete svojih institucija od klijenta (depozitara) tih institucija. Ako depozitari nisu sigurni u uvjete banaka u kojima drže svoje depozite ili ako nisu sigurni da je financijski sustav pouzdan, onda se može zaključiti da će depozitari pokušati podići svoje depozite iz depozitarnih institucija, što može prouzrokovati krizu. U financijskoj terminologiji ovakva je situacija poznata pod nazivom *bankarska kriza* i izravno utječe na zatvaranje kako financijski zdravih banaka tako i onih banaka koje imaju financijskih poteškoća. Regulativa financijskoga sustava postoji kako bi se izbjegle bankarske krize, a monetarna kontrola kroz superviziju banaka svakako je jedan od temeljnih instrumenata financijskoga sustava.

---

[29] Likvidna sredstva su ona koja se dosta brzo mogu pretvoriti u novac uz prihvatljive troškove i za određenu valutnu vrijednost.
[30] Svim sudionicima financijskoga sustava mora biti omogućen pravodoban i točan pristup informacijama. Dakle, transparentnost središnje banke kroz principe predvidivosti, kredibiliteta i reputacije doprinosi da financijske informacije budu dostupne svim akterima na financijskom tržištu te omogućava da središnja banka jedne zemlje utvrdi svoju poziciju institucije koja radi u interesu održanja monetarne stabilnosti kroz ostvarenje definiranih ciljeva.

Uspješnost rada središnje banke mjeri se četirima parametrima:

- neovisnost središnje banke
- kredibilitet središnje banke
- odgovornost središnje banke
- povjerenje u središnju banku.

Neovisnost središnje banke. U većini zemalja središnja je banka u državnom vlasništvu, a moderne središnje banke uživaju sve veći stupanj samostalnosti, što podrazumijeva mogućnost vladavine intervencije u monetarnoj politici. Neovisna središnja banka mogla bi se definirati kao ona središnja banka koja sprječava politički utjecaj.
Zakonom se isključuje mogućnost da središnja banka odobrava direktne pozajmice vladi ili se ograničava na apsolutni iznos zaduženja kod nje i to samo u tijeku fiskalne godine za premošćivanje vremenske neusklađenosti između prihoda i rashoda. Pobornici neovisnosti središnje banke tvrde da središnja banka koja je podložna političkom upravljanju ili utjecaju, može negativno utjecati na ekonomsku stabilnost u dugom roku.[31]

Kredibilitet središnje banke. U prethodnom razdoblju o konceptu kredibiliteta središnje banke intenzivno se raspravljalo ne samo u znanstvenim krugovima koji se bave teorijom monetarne politike već i u praksi središnjih banaka. Interes za kredibilitet središnje banke, odnosno monetarne politike, najvećim je dijelom posljedica shvaćanja značaja veze između očekivanja, odnosno percepcije javnosti i stvarna utjecaja predložene ekonomske politike za ekonomiju zemlje.
Iako je koncept kredibiliteta postao jedan od središnjih pitanja, nema neke generalne suglasnosti u vezi s definiranjem ovog termina u akademskim ili središnjim bankarskim krugovima. Najčešća definicija ovog termina koja se koristi jest ona da središnja banka uživa kredibilitet ako javnost vjeruje da će ona uraditi ono što je i rekla.
Naime, visok stupanj kredibiliteta smanjuje troškove obuzdavanja inflacije, pomaže u održavanju niske inflacije, olakšava obranu domaće valute kada je to potrebno i jača potporu javnosti u neovisnosti središnje banke.

[31] Naime, političari mogu pasti u iskušenje da podupru ekonomski rast pred izbore i potkopaju dugoročnu stabilnost ekonomije. Prema tome, cilj neovisnosti središnje banke trebao bi biti da spriječi negativne utjecaje vlade na ekonomiju kada je njezin motiv trenutna politička korist.

Odgovornost središnje banke**.** Središnja banka, rezervna banka ili monetarna vlast institucija je odgovorna za monetarnu politiku u zemlji ili skupini određenih zemalja kao što je to u monetarnoj uniji Europske unije. Primarna odgovornost središnje banke i zadnja dva desetljeća jest održavanje stabilnosti nacionalne valute i novčane mase. Kada govorimo o funkcijama središnje banke, onda mislimo na monopol nad emisijom novčanica, na vladinog bankara i banku banaka (davalac posljednjeg utočišta), na upravljanje devizama i zlatnim rezervama i vođenje registra vladinih vrijednosnih papira, na reguliranje i superviziju bankarske industrije, na reguliranje kamatne stope (reguliranje inflacije i deviznog tečaja).

Povjerenje u središnju banku**.** Središnja banka, kao temeljni stup sustava, mora izgraditi visok stupanj povjerenja, kako gospodarskih subjekata tako i građana. Sve aktivnosti središnje banke moraju biti dobro osmišljene, transparentne i na prikladan način objavljene javnosti. S obzirom na to da se središnja banka pojavljuje kao emisijska banka, tj. zadužena je za izdavanje i distribuciju domaće valute i kvalitetu te valute, vrlo je važno da šira javnost vjeruje u vrijednost i pouzdanost te valute. Mogućnost zamjene valute u neograničenim količinama u oba smjera jača povjerenje šire javnosti.

Tržišni uvjeti poslovanja, trendovi globalizacije, procesi uključivanja u međunarodne financijske tokove te mobilnost kapitala i potreba njihove zaštite, zahtijevaju institucionalno definiranje i uspostavljanje regulatornog okvira za djelovanje i nadgledanje svih segmenata financijskoga sektora. Cilj supervizija financijskoga sustava općenito i njegovih segmenata je postizanje financijske stabilnosti. Financijska stabilnost u velikoj je mjeri uvjetovana mogućnošću da financijski sustav jedne zemlje ima odgovor na ekstremne šokove, a ogleda se kroz stabilnost bankarskoga sustava koji, u najvećem broju promatranih zemalja, čini najznačajniji dio financijskoga sustava. Za postizanje stabilnog i zdravog bankarskog sustava bitna je stabilnost svake banke u sustavu. Praćenje stabilnosti pojedinačne banke i stabilnosti ukupnog bankarskog sustava u nadležnosti je bankarske supervizije koja se zasniva na mirkopristupu i procjeni. Osnovni se principi odnose na preduvjete za učinkovitu superviziju banaka, za izdavanje dozvola, donošenje propisa i zahtjeva za upravljanjem rizikom, na određivanje metoda za stalnu superviziju banaka, na davanje nužnih informacija iz oblasti prekogranične supervizije.

Bankarska supervizija je nadzor nad poštivanjem utvrđenih pravila u bankarskom poslovanju i utvrđivanju odgovornosti pri nepoštivanju pravila koja su definirana bankarskom regulativom. Razvoj bankarskih institucija nametnuo je potrebu za utvrđivanje i primjenu standarda u superviziji banaka, kako međunarodnih tako i regionalnih. Tako je pored Bazelskog

uspostavljen i Europski odbor za bankarsku superviziju (Committee of European Banking Supervisors), koji ima i savjetodavnu ulogu i nadgleda primjene europskih direktiva u bankarskoj industriji.

Prema općeprihvaćenim standardima supervizija banaka zasniva se na trima stupovima:

- na minimalnom adekvatnošču kapitala
- na supervizijskom nadzoru
- na tržišnoj disciplini.

Minimalni kapitalni zahtjev definira pravila za utvrđivanje i održavanje minimalnih kapitalnih zahtjeva za kreditni, operativni i tržišni rizik. Zahtjev za minimalnim kapitalom utvrđen je zato što kapital treba ublažiti nepredviđene gubitke poslovanja banke kako bi stvorio povjerenje najšire javnosti o poslovnoj sposobnosti i učinkovitosti banke.

Supervizorski nadzor odnosi se na nadzor adekvatnosti kapitala. Banke su u obvezi da same procjenjuju adekvatnost kapitala, a supervizori ocjenjuju bankovni sustav procjene i daju odobrenje za korištenje modela procjene pa tako i osiguravaju da banka ima dovoljno kapitala. Od supervizora se zahtijeva da procjeni koliko dobro banke procjenjuju svoje kapitalne potrebe u odnosu na svoje rizike te da interveniraju tamo gdje je to potrebno. Ovo se naročito odnosi na kreditni i operativni rizik.

Tržišna disciplina odnosi se na javno objavljivanje koje zahtijeva transparentnost i objašnjavanje podataka o procesu upravljanja rizicima, visini kapitala i izloženosti rizicima. Tržišna disciplina predstavlja skup zahtjeva za objavljivanjem preko kojih se sudionicima na tržištu omogućava procjena ključnih informacija o obimu primjene propisa, o kapitalu, o izloženostima riziku, o procesima procjenjivanja rizika te o adekvatnosti kapitala institucije.

Središnje banke koriste više instrumenata da bi utjecale na obim rezervi bankarskoga sustava raspoloživih za kreditiranje i na razini kamatnih stopa u ekonomiji. Neki od tih instrumenata u funkciji su opće kontrole kredita koja, praktično, linearno djeluje na kompletan bankarski i financijski sustav. U linearne instrumente ubrajamo obavezne rezerve, diskontnu stopu središnje banke i djelovanje na otvorenim tržištima. Druga vrsta instrumenata jesu mjere selektivne kreditne politike kojima se djeluje na specifične skupine ili sektore u financijskom sustavu. Marginalne obavezne rezerve i moralni apeli na kupovinu vrijednosnih papira koji kotiraju na burzama primjeri su selektivne kreditne kontrole u razvijenoj tržišnoj ekonomiji.

Tijekom tranzicije središnje banke promatranih zemalja (osim onih koje su od početka članice EU-a ili koje su to postale u prošlom stoljeću) preuzimaju tri temeljne funkcije.

Prva, središnje banke promatranih zemalja preuzimaju sve standardne zadaće nužne za osiguranje stabilnosti nacionalnih valuta. Druga, središnje banke preuzimaju obavezu provođenja transformacije bankarskoga sektora (transformaciju sustava platnoga prometa, informacijskoga sustava, deregulaciju, ozdravljenje bankarskoga sektora, osiguranje depozita, unaprjeđenje konkurencije i oblikovanje planova privatizacije banaka). Središnja je banka trebala doprinijeti stvaranju i razvijanju, odnosno, postati „market maker" deviznog i novčanog tržišta.

Ciljanje u monetarnoj politici daje središnjoj banci mogućnost utvrđivanja gdje želi biti u budućnosti. S druge strane, ima i informativnu ulogu za privatni sektor kako bi taj sektor mogao projicirati promjene koje može očekivati u budućnosti. Monetarna politika može utvrditi jedan ili više ciljeva kojima teži, npr. stabilnost cijena, zaposlenost, rast realnog BDP-a, razinu inflacije, stabilnost financijskog ili deviznog tržišta.[32]

U procesu pridruživanju EU središnje banke promatranih zemalja imaju dominantnu ulogu. Središnja banka ima aktivnu ulogu ili je treba zauzeti u procesima integracije zemlje u EU putem pripreme i integriranja bankovnoga sustava zemalja pristupnica u jedinstveno financijsko tržište EU-a. Uloga središnje banke prije svega se odnosi na pregovore za članstvo u EU i udovoljenje zahtjevima koje je utvrdio Europski sustav središnjih banaka – ESCB. To znači prije svega uspostavljanje prikladnog monetarnog okvira, prilagodbu bankarskih propisa te prilagodbu platnog sustava i financijske statistike *acquis communautaire* i standardima ESCB. Posebno je bitno da središnje banke usklade supervizije banaka prema propisima EU-a i u skladu s međunarodnim standardima. Naposljetku je potrebno voditi brigu o sigurnosti cijelog bankarskog sustava, kao i središnje banke te učiniti niz aktivnosti kako biti u stalnoj interakciji s bankovnim sustavom i kako bi se osigurala jednostavna prilagodba bankovnog sustava zemlje u jedinstveno financijsko tržište EU-a. Stoga je razumljivo kako bankovni sustav jedne zemlje pristupnice i njezina središnja banka također prolaze tri faze pridruživanja: pretpristupnu, članstvo u EU i ulazak u EMU. Do trenutka potpisivanja ugovora o pristupanju do ulaska u EU,

[32] Smatra se da se kao jedini cilj monetarne politike može uzeti stabilnost cijena i financijska stabilnost. Posredni ciljevi mehanički i automatski pristup monetarnoj politici, kao npr. ako monetarni agregat M3 ili neka druga mjera novca pređe utvrđenu razinu, potrebno je implementirati mjere restriktivne monetarne politike.
Pri izboru posrednog cilja treba voditi računa o njegovoj mjerljivosti, mogućnosti upravljanja, o vezi između posrednog i konačnog cilja te predvidivosti učinka na ostvarivanje konačnoga cilja. Najčešće korišteni posredni ciljevi su nominalni BDP, kratkoročne kamatne stope, različiti monetarni agregati i devizni tečaj.

središnja se banka nalazi u ulozi promatrača. Od trenutka pristupanja EU, središnja banka sudjeluje u radu tijela ESCB-a kada se raspravljaju važna pitanja u djelokrugu vijeća.[33]

Za većinu središnjih banaka kratkoročne kamatne stope na međubankarskom tržištu (stope na novčanom tržištu) predstavljaju operativni cilj provedbe monetarne politike. Dvije su operacije otvorenog tržišta koje su uobičajene u njezinoj provedbi: uobičajene stalne pogodnosti i/ili operacije otvorenog tržišta. ECB nudi mogućnost posudbe potrebnih sredstava bankama, kao i mogućnost deponiranja istih kod ECB-a kroz tjedne aukcije.[34]

Brojne su strukturne promjene zabilježene u proteklom razdoblju u bankarskoj industriji u promatranim zemljama, a vežu se za tri procesa: za integraciju, regulaciju i konkurentnost.[35]

Ipak, treba imati u vidu da je integracija bankarskog tržišta dinamičan proces jer se na području EU-a prije svega razvija univerzalni bankarski model koji omogućava slobodu obavljanja različitih financijskih usluga i proizvoda bankama. Utvrditi ima li jedan proizvod istu cijenu na različitim pojedinačnim tržištima doista je teško pogotovo ako uzmemo u obzir naglašenu heterogenost bankarskih proizvoda i usluga. (Manna, 2004.) Financijska integracija bankarskoga sektora istočne i jugoistočne Europe počeo je procesom sanacija i privatizacije banaka i njihovu otvaranju europskom kapitalu. Liberalizacija financijskoga sektora na putu u tržišno gospodarstvo bila je preduvjet stvaranja dominacije stranoga kapitala. Strani kapital ulazi u bankarske sektore kako bi ostvario profit. Ulazak stranoga kapitala u bankarske sektore istočne i jugoistočne Europe smatra se izvorom jačanja kreditne ekspanzije.[36]

---

[33] Uspješnost u procesu konvergencije, odnosno, u pripremama za ulazak u euro-područje redovito prati Convergence Report nadzirući ispunjenje maastrichtškog kriterija i pravne prilagodbe seta zakona vezanih za konvergenciju središnjih banaka Statutu ESCB. U sustavu EMR II zemlja mora uspješno sudjelovati najmanje dvije godine. Uspješno sudjelovanje pretpostavlja utvrđivanje središnjeg tečaja (eng.*central parity*) i upravljanje aktualnim deviznim tečajem unutar standardnih ograničenja fluktuacije oko središnjeg pariteta. Raspon fluktuacije +/- 15 % ili +/- 2,25 uvjet su maastrichtškom kriteriju. Za razliku od Engleske, nove zemlje članice moraju uvesti euro u nacionalni monetarni sustav čim za to ispune uvjete. Odluku o ulasku u euro-područje donosi ECOFIN na prijedlog povjerenstva i konzultacija s Europskim parlamentom i političkom odlukom Vijeća Europe. Odluka se donosi na temelju izvješća o konvergenciji koji odvojeno pripremaju ECB i povjerenstvo.

[34] Kroz pogodnosti posuđivanja ECB ostaje pripravan posuditi gotovinu preko noći uz prikladan kolateral po fiksnoj kamatnoj stopi ili kratkoročnoj stopi kreditiranja (eng.*marginal lending facility rate).*

[35] Pokazatelji integracije bankarskoga tržišta EU: visina prekograničnih posuđivanja ili međunarodnih kredita, otvaranje prekograničnih financijskih institucija ili visina aktive istih, broj prekograničnih akvizicija, promjene na lokalnim bankarskim tržištima, udio inozemnih izvora na lokalnom tržištu, kamatne stope na depozite i kredite.

[36] Primjerice, na kraju 2006. godine Albanija je imala 17 banaka od čega su samo tri bile u domaćem privatnom vlasništvu. Promjene u vlasničkoj strukturi kapitala albanskih banaka pokazuje interes snažnih financijskih grupacija europskih banaka za investiranjem u albanski bankarski sektor. Na kraju 2005. godine stupanj privatizacije dioničarskoga kapitala bankovnog sustava Republike Makedonije 91,9 %. U Bosni i Hercegovini 2006. godine u državnom se vlasništvu nalazilo 12,4 % dioničarskog kapitala banaka dok je privatni dioničarski kapital banaka 87,6 %, a dioničarski kapital nerezeidenata iznosio je 83 % ukupnog dioničarskog kapitala u BiH (CBBiH, 2006.). U Republici Srbiji 2003. godine strani je kapital preuzeo većinsko vlasništvo u pet privatnih banaka, 2005. godini tri državne banke kao i dokapitalizacija i privatizacija četiriju privatnih banaka.

Istraživanja koja su provedena u razdoblju od posljednjih 20-ak godina ukazuju na pozitivan učinak stranog vlasništva na stabilnost bankarskoga sektora. (Caprio, 2000.; Goldberg, 2000.)

Ono što se dogodilo na tržištima jugoistočne i istočne Europe jest to da su strane banke „kćeri“ u uvjetima krize pribavile potrebna sredstva povlačeći ih iz inozemstva od banaka „majki“. Isto tako, ulazak stranih banaka na tržišta promatranih zemalja donio je unaprjeđenja na polju regulacije i supervizije, računovodstva, transparentnosti poslovanja i objavljivanja podataka banaka. Veza između stranoga kapitala i kreditne aktivnosti banaka vidljiva je iz jednostavne analize udjela stranoga kapitala u vlasničkoj strukturi i rasta kredita. Ista veza može se promatrati i udjelom stranih banaka u aktivi bankarskoga sektora u promatranim zemljama. Nakon financijske krize, koja je zahvatila cijeli svijet, jasno je da su središnje banke i supervizori u uvjetima pojačane kreditne ekspanzije trebali znatno hrabrije i odlučnije koristiti instrumente monetarne politike i prudencijalne kontrole.

Nadalje, što se može zaključiti kod analize kredita u promatranim zemljama jest to da se javlja značajan udio kredita odobrenih u stranoj valuti u ukupnim bankarskim kreditima. Najčešća korištena strana valuta je švicarski franak i danas smo svjedoci koliko problema stvara u promatranim zemljama. S druge strane, postavlja se pitanje zašto se krenulo u takvu ekspanziju kredita u stranoj valuti. Jednostavan razlog je u tome što su ti krediti bili povoljniji u pogledu kamatne stope. Rizičnost kredita vezanih za stranu valutu određeni su s više čimbenika počevši od roka dospijeća do ugovorenih varijabilnih kamatnih stopa. Ovakvo kreditiranje može negativno utjecati na visinu obveze servisiranja kredita zajmotražitelja zbog mijenjanja deviznoga tečaja (što se i dogodilo) – revalorizacije strane valute,[37] a potom se vraća bankama u obliku dodatne izloženosti kreditnom riziku. Banke se izlažu valutnom riziku ako odobreni krediti nisu refinancirani u istoj valuti, istim iznosom i dospijećem obveza. U tom slučaju banke ulaze u otvorenu deviznu poziciju.

Banke su u promatranim zemljama bitne za provođenje monetarne politike. Imaju ključnu ulogu u osiguranju usluga platnoga prometa, obavljanja transakcija te u opskrbi likvidnošću kućanstava i gospodarstva. Zbog ovako široke uloge koju imaju, problemi u jednoj banci mogu dovesti do jakih negativnih posljedica u realnom sektoru. S druge strane, oblikovanje politike bankovne stabilnosti je vrlo složen posao. Bankarska aktivnost i stabilnost određena je

[37] Na temelju analize nekih istraživanja kod njemačkih banaka, zabilježena je bilateralna veza u prijenosu rizika. Njemačke banke izložene su riziku iz bankarskoga sektora, npr. Engleske banke istodobno bivaju izložene prijenosu rizika iz Španjolske i Danske; Španjolske banke imaju utjecaja na banke svih promatranih zemalja dok na njih djeluju jedino banke iz Italije.

poslovanjem banaka u sve rizičnijem okruženju, rizicima koji se javljaju u bankarskom poslovanju. Već se dugo pretpostavlja da banke s većom tržišnom snagom utječu na stabilnost financijskog i bankarskog tržišta. Koncentracija se dovodi u vezu s konkurencijom i efikasnošću banaka s jedne strane, a s druge strane sa sposobnošću tih banaka da svojom većom tržišnom snagom aktivnom učine diverzifikaciju i time bolje upravljaju svojom rizičnom izloženošću.[38] Konsolidacija bankarske industrije ima značajan utjecaj na strukturu bankarskoga tržišta i organizaciju banaka. Kao posljedica konsolidacije i M&A smanjuje se broj malih banaka, a raste aktiva koju novonastale banke kontroliraju same ili putem financijskih konglomerata. Ovaj trend okrupnjavanja banaka i nestajanje malih banaka s bankarskog tržišta nameće problem financiranja malih i srednjih poduzeća na lokalnom tržištu kao i u pribavljanju potrebnih sredstava zbog većih kamatnih stopa i gubitka kreditne sposobnosti. (Berger, Rosen, Udell, 2001.)

Isto tako, svjedoci smo da je uslijed procesa spajanja i pripajanja te dominacije stranoga kapitala pojačana ranjivost bankarskoga sektora i da je povećana izloženost financijskoj krizi.

S druge pak strane, ulazak stranoga kapitala u bankarski sektor doveo je do povećanja proizvoda i širenja poslovanja što je dalo mogućnost klijentu da bira iz široke ponude financijskih usluga. Kad se pogleda situacija u promatranim zemljama, može se zaključiti da se banke ovih zemalja posljednjih godina suočavaju s rastom konkurencije unutar sektora i unutar financijskoga sustava. Danas su ključni konkurenti bankarskim sektorima tržište kapitala i nebankarske financijske institucije, o čemu će biti više riječi u daljnjem dijelu teksta.[39]

Financijski sustavi promatranih zemalja, ponavljamo, još uvijek su „bankovno dominantni“, odnosno bankocentrični i kao takav će u ovom istraživanju biti posebno i razmatran, ali neće se umanjiti ni analiza drugih segmenata financijskoga sustava.

[38] Ipak, posljednjih godina u zemljama EU-a koncentracija banaka je posljedica procesa preuzimanja i spajanja između banaka u tim zemljama.
[39] Za proučavanje konkurentnosti bitno je analizirati diverzificiranost financijskog sustava pojedine zemlje.

2.3.2. Razvoj nebankarskoga sustava

Razvoj i rast jedne zemlje ovisi o razvoju svih njezinih jedinki pa tako i cijelog financijskog sustava. Financijski je sustav, prema mišljenju mnogih autora, pokretač rasta i razvoja, a involviran je u intermedijaciji između jedinki koje imaju višak sredstava i jedinki koje imaju manjak i potrebu za njima. Kao što je u prethodnom dijelu teksta rečeno, banke imaju vitalnu ulogu u razmjeni sredstava između subjekata, a posebno u zemljama u razvoju. Dakako, stabilan rast financijskoga sustava, a s tim u vezi i bankarskog i nebankarskog sustava, čini temelj razvoju i rastu gospodarstva jedne zemlje, ali i temelj je razvoju i stabilnosti financijskoga sustava u cjelini. (Pirtea, Iovu & Milos, 2008.; Rainna i Baker, 2003.)
Nebankarski sustav, kao dio financijskoga sustava, upotpunjava ulogu intermedijacije s novim spektrom proizvoda i usluga koje bankarski sustav zbog regulacije ne može pružiti. (Shrestha, 2007.; Sufian, 2007.)Osim toga, razvoj nebankarskoga financijskoga sustava omogućava jačanje financijskoga sustava i otpornost na krize. (Carmichael & Pomcerleano, 2002.) Upravo su supervizija i njezino jačanje doveli do razvoja nebankarskoga sustava u mjeri u kojoj ga poznajemo danas. U svome razvoju banke su se suočile s kratkoročnim izvorima sredstava, ali i zahtjevima za dugoročnim plasmanima sredstava. Upravo je to razlog zašto se kroz povijest nebankarski sustav, kao dio financijskoga sustava, jako brzo razvijao. Rast i razvoj tijekom vremena, kao i utjecaj na rast pojedinih gospodarstava, analizirali su mnogi znanstvenici kroz povijest. Međutim, ta su istraživanja uvijek bila fokusirana na bankarski sektor, a manje na nebankarski zbog čega je ovo područje još uvijek nedovoljno istraženo i na što se svakako treba u budućnosti više fokusirati.

Primaran zadatak nebankarskoga sustava je u ispunjavanju njegovih temeljnih društvenih dužnosti. Isto tako, uloga je ispunjavanje financijskih obveza njezinih korisnika i ispunjavanje očekivanja te pretvaranje ulaganja u profitabilan posao s minimalnim rizikom u odgovarajućem roku. Temelj ove uloge čine promjene u socijalnom i demografskom statusu promatranih zemalja.

Sekundarna zadaća nebankarskoga sustava je financiranje realnog sektora. Povijesna očekivanja uglavnom su ekonomska – kreditiranje ili financiranje realnoga sektora s povezanim rizikom koji taj posao nosi. Nova očekivanja uglavnom su usmjerena na socijalni aspekt dok je ekonomska funkcija uglavnom prioritet bankarskoga sustava kao dijela financijskoga sustava.

Dakako, vrijedno je spomenuti i ulogu mirovinskih fondova u financijskom sustavu i njihovu novu ulogu u gospodarstvu i društvu. Trend koji se pojavljuje svakako je starenje stanovništva, što nije problem samo EU-a, već globalne ekonomije. Mirovinski fondovi trebaju se prilagoditi tim trendovima i osigurati financijska sredstva za ispunjenje svih obveza prema osiguranicima. Plan predstavlja dosta izazovan projekt zaštite mirovinskog sustava kako bi se zadovoljile sve obveze koje jamči mirovinski fond. Razvoj usklađenih mjera pomoći će promicanju prenosivosti socijalnih prava, što će dalje dovesti do još veće mobilnosti radne snage u globalnoj ekonomiji. Sadašnje stanje još uvijek pokazuje ogromne probleme u prekograničnim odlascima u mirovinu, a sve zbog neusklađenosti raznih poreznih i socijalnih zakona. Upravo zbog toga usklađivanje uvjeta za odlazak u mirovinu ostao je u granicama pojedinačnih gospodarstava, a aktivnost mirovinskih fondova još je uvijek sveden na rad u okvirima jednoga gospodarstva. Unutar EU-a radi se na raznim direktivama kako bi se ovaj problem riješio u što kraćem roku, no i dalje je ostala sloboda konačnog odlučivanja o pitanju mirovina na nacionalnoj razini.

Radi održavanja stabilnosti financijskoga sustava svakako da je potrebno vršiti nadzor i regulaciju nebankarskog sustava zbog pojave sustavnoga rizika. Za razliku od bankarskoga sustava u nebankarskom sustavu treba primijeniti pristup sličan tradicionalnom smanjenju sustavnoga rizika. Ono što je cilj praćenja nebankarskoga sustava svakako je to da se njegova veličina zadrži na razini prosjeka europskog tržišta. Dakako, za razliku od bankarskoga sustava u nebankarskom je sustavu moguće postići ravnotežu između financijske stabilnosti i ekonomske učinkovitosti. U tom smislu mirovinski sustav treba imati ulogu stabilizatora financijskoga sustava i održivosti mirovinskog sustava uzimajući u obzir povećanje starosti.

Uloga ostalih sudionika nebankarskoga sustava, kao što su osiguravajuća društva, jest u tome da umanjuje ili uklanja određene rizike u određenim sferama života. Na žalost, ovdje se mora konstatirati da su osiguravajuća društva vrlo slabo razvijena u pogledu životnih osiguranja, a posebno u promatranim zemljama istočne i jugoistočne Europe. Za razliku od zapadne i središnje Europe u istočnoj i jugoistočnoj Europi razvoj životnih osiguranja nema nekih povijesnih korijena. Ono što je najčešće slučaj, osigurava se ono na što ih kod financiranja primora bankarski sustav (stanovi, kuće, automobili i sl.) ili u rijetkim situacijama kad poslodavac daje inicijativu za životno osiguranje. Svakako da ovdje treba uzeti u obzir i razinu BDP-a po glavi stanovnika u promatranim zemljama gdje je ovakav tip osiguranja slabo razvijen. Tako, primjerice, za sve vidove osiguranja jedan građanin Slovenije izdvaja 1.000 €, građanin Hrvatske nekih 300 €, a građanin Bosne i Hercegovine 70 €.

Prema mišljenjima mnogih autora uloga osiguravajućih društava treba se proširiti i na kreditiranje tvrtki u nastajanju, što je ključno za razvoj jednog gospodarstva i s tim u vezi može se očekivati da će se u okvirima financijskih sustava promatranih zemalja doći do preraspodjele podjele rada unutar istih. Kako bi ispunili tu ulogu, osiguravajuća će društva morati biti u poziciji da ulažu u širok spektar financijske imovine. Isto tako, osiguravajuća će društva morati provesti proces diverzifikacije svojih aktivnosti.

Svakako, potrebno je dati na značaju i tvrtkama koje se bave lizingom, koje rade kao dio nebankarskog sustava, ali za koje možemo reći da su od početka financijske krize doživjele drastičan pad aktivnosti u svim promatranim zemljama. Većina poduzeća koja su se bavila lizingom[40] inkorporirano je u banke kako bi se smanjio trošak poslovanja i povećali sinergijski efekti. Današnje lizing financiranje svedeno je na financiranje nabavke opreme i vozila, dakle, pokretnina. Do početka krize, a sve zbog toga jer ovaj sektor nije bio dovoljno nadziran (ili barem nije u ovolikoj mjeri kao danas), lizing poduzeća financirala su i tzv. projektna financiranja i ulazila u sferu investicijskoga bankarstva kako se banke ne bi izlagale tom riziku i kako bi se očuvao rezultat poslovanja i kako se ne bi, u konačnici, ugrožavala kapitalna adekvatnost.

Važno je napomenuti i važnost ostale fondovske industrije koja je još uvijek u razvoju na području većine promatranih zemalja u ovom istraživanju (izuzevši zemlje središnje europe). U okviru ovih fondova karakteristični su novčani fondovi, obveznički, mješoviti i dionički fondovi, zatim fondovi rizičnog kapitala itd. Ono što bi svakako bilo jako interesantno za Hrvatsku jest snažniji razvoj fondova rizičnoga kapitala koji bi pomogli u realizaciji određenih poduzetničkih ideja koje zbog nedostatka novca to nije sad u mogućnosti realizirati.[41]

[40] Lizing poduzeća koja su se bavila lizing financiranjem bila su najčešće u vlasništvu banaka.
[41] Fondovi rizičnoga kapitala ulaze najčešće u financiranja kapitala za određene investicije od početka, a ostatak financira banka. Banka zbog određenih propisa ne može raditi 100 % financiranja i u pogledu financiranja kapitala svakako da fondovi rizičnog kapitala naplaćuju ovu uslugu značajno skuplje od kredita (u nekim slučajevima naknada za kapital je tri puta veća od naknade za bankarski kredit).

2.3.3. Financijska struktura promatranih zemalja

Bankarstvo u tranzicijskim zemljama posebno je zanimljiva tema jer banke nisu imale nikakvu ekonomsku ulogu u planiranim ekonomijama sovjetskoga stila, dok su financijski sustavi u većini tranzicijskih zemalja takvi da sada dominiraju banke, a ne tržišta kapitala. Prva faza tranzicijskog bankarstva je pojava bankarskim sektora od planiranih gospodarstava u kasnim 1980-ih i početkom 90-ih godina.

Financijski sustav europskih tranzicijskih zemalja bio je relativno nerazvijen ako ga kompariramo s realnim sustavom tih istih gospodarstava, a glavni razlog tomu je legislativa predtranzicijskih i centralno planiranih ekonomija. Kao primjer razvijenoga gospodarskoga sustava u odnosu na financijski sustav možemo navesti Češku (tada Čehoslovačku) koja je imala i ima jako modernu autoindustriju ili jedne Mađarske, koja je proizvodila autobuse, te Bugarske koja je radila strojnu opremu (eng. *hardware*) i programsku potporu (eng. *software*) kojom su se najviše koristile zemlje sovjetskoga bloka. U takvim sustavima, planskom okviru, financijska intermedijacija između onih koji su imali novčani suficit i onih koji imaju novčani deficit (oni koji imaju potrebu za financiranjem) strogo su kontrolirali regulatorni državni aparati. Kapital je alociran kroz sustav izravnih kredita prema javnim poduzećima (poduzećima u državnom vlasništvu – eng.State Owned Enterprises-SOEs) i to radi investicija i potreba proračuna za obrtnim kapitalom, a sve zato kako bi se ispunili ciljevi koji su postavljeni. Kreditna analiza i rizici u ovakvom modelu poslovanja nisu postojali.

Novac je u tom procesu posve pasivan jer se koristi isključivo kao jedinica računa u poslovnim transakcijama i kao sredstvo razmjene između kućanstava i sektora državne distribucije. Štednje stanovništva, često kao rezultat prisilne akumulacije novčanih stanja zbog nedostupnosti poželjnih roba široke potrošnje za kupnju, prikupljale su državne štedne banke koje su razvijale mreže podružnica u cijeloj zemlji.

Predtranzicijski bankarski sektori obično uključuju vanjsku banku koja rješava sve devizne transakcije izolirajući ove iz domaćeg financijskog sustava i često sadržane odvojene specijalne banke za nadzor financiranja poljoprivrednog i građevinskog sektora. U takvu okruženju bankarski je sustav bio segmentiran po funkcionalnim linijama i dodjeljivanje kredita bilo je u potpunosti podređeno planu. Dakle, strukturna segmentacija, državna kontrola bankarstva i visoki omjeri koncentracije bili su glavna naslijeđa planskoga razdoblja bankarskoga sektora u tranzicijskim gospodarstvima. Unatoč tim sličnostima, postoje značajne razlike među

iskustvima zemalja prije i tijekom tranzicijskoga razdoblja i svaki ima jedinstvene karakteristike. Primjerice, možemo početi s kratkom raspravom o bankarstvu u jugoistočnim tranzicijskim zemljama među koje spadaju republike bivše Jugoslavije, jer su njihovi sektori naslijedili ponešto specifična naslijeđa. U daljnjem tekstu dan je osvrt na financijske sustave promatranih zemalja u prvoj polovici dekade tranzicije s posebnim osvrtom na republike bivše Jugoslavije.

Godine 1950. Jugoslavija je uspostavila dvorazinski bankarski sustav: sjedište središnje banke Narodne banke Jugoslavije (NBJ) nalazilo se u Beogradu dok su na razini republika bile uspostavljene poslovne banke. Banke su bile u tzv. kolektivnom vlasništvu, kao što su bila i sva poduzeća u jugoslavenskom sustavu samoupravljanja. Budući da je Jugoslavija bila mala, ali relativno otvorena ekonomija, poslovne su banke 80-ih godina XX. st. kreirale značajan broj kredita u stranoj valuti. Međutim, banke na razini republika bile su dužne osloboditi većinu svojih deviznih depozita Narodnoj banci kao zamjenu za kredite u dinarima. Dakle, bilance banaka na razini republika bile su izložene valutnom riziku, a krajem 80-ih godina bilo je očito da ni imovina ni obveze banaka nisu usklađene. Nakon odcjepljenja Hrvatske i Slovenije 1991. NBJ zamrzava strani depozit banaka tih dviju bivših republika stvorivši velike neusklađenosti u svojim bilancama. Iako mnoge privatne banke, često u vlasništvu poduzeća, datiraju iz 1970., u tim je zemljama bila slaba bankarska konkurentnost, slaba kapitalizacija i značajno nakupljanje problematičnih kredita, što je nasljeđe iz jugoslavenske prošlosti. Vladine mjere sanacije koje su dizajnirane da se bave insolventnošću banaka dovele su do nacionalizacije većine banaka. Dakle, banke u državnom vlasništvu stvorene su na početku tranzicije u Sloveniji i Hrvatskoj.

Otpočeo je proces reforme bankarskoga sektora za većinu tranzicijskih gospodarstava uključenih u stvaranje dvorazinskoga sustava s poslovnim aktivnostima proizišlih iz portfelja nacionalnih banka. Prva razina sastoji se od središnje banke, koja ima obvezu provoditi monetarnu politiku, uključujući i tečajnu politiku, te ima određenu odgovornost u nadzoru i praćenju uspona bankarskoga sektora. Druga razina bankarskoga sektora sastoji se od novostvorenih državnih banaka (eng.State Owned Capital Banks - SOCBs), specijaliziranih banaka u državnom vlasništvu, koje su prerasle u SOCBs, bilo da operativno djeluju kao vanjske kroz zajedničko ulaganje (eng.*joint venture*) banaka i svih privatnih domaćih banaka uključujući i one koje su ušle u sustav nakon političke tranzicije. U pravilu, loši uvjeti za ulazak na tržište doveli su do stvaranja mnogih novih privatnih banaka od kojih su neke bile sumnjive

kvalitete, pa čak i lažne, a neke su bile ispod svih razina kapitalne adekvatnosti. Dakle, sjeme bankarske krize posađeno je odmah na početku tranzicije, ili čak i prije, u gotovo svim tranzicijskim zemljama. Razlog tomu dijelom su loši kriteriji pri ulasku na tržište s namjerom poticanja razvoja bankarskog sektora. Osim toga, regulatorni su sustavi bili pretjerano opterećeni neusklađenošću između svojih mogućnosti, koje su strogo ograničene nedostatkom ljudskoga kapitala, i njihovih mandata kao i pravila i propisa koji su užurbano usvajani, osobito u odnosu na naslijeđene portfelje kredita od SOCBs-a.

U Mađarskoj su, primjerice, portfelji komercijalnih banaka bili podijeljeni po sektorima da kreiraju industrijsku proizvodnju, poljoprivredu i infrastrukturu te rast malog gospodarstva. U Poljskoj je komercijalni portfelj podijeljen regionalno i na taj je način stvoreno devet SOCBs-ova. Trgovački portfelj čehoslovačkih banaka organiziran je u dva dijela i regionalno su stvorena dva SOCBs-a: češki i slovački. Nakon osamostaljivanja tih zemalja svaka je nova zemlja imala jedan veliki SOCBs. Slično tomu u Rumunjskoj je stvoren samo jedan SOCBs iz cijelog portfelja banaka. Sve zemlje srednje i istočne Europe imale su banke koje su bile specijalizirane, koje su dobile univerzalne bankovne licencije, a nakon tranzicije postale SOCBs.

Može se reći da se u Bugarskoj dogodila druga krajnost kada je iz bilanci bugarske nacionalne banke 1990. godine stvoreno 145 podružnica koje su dobile univerzalnu bankarsku licenciju po kojoj je bilo dopušteno da se bave poslom komercijalne banke. Svrha je takve politike poticati konkurenciju. Do 1995. godine u Bugarskoj posluje 41 banka, a dvije najveće SOCBs su bivša državna vanjskotrgovinska banka i bivša državna štedionica. U prvom desetljeću tranzicije većina „greenfield“ poslovanja u regiji bile su banke iz Austrije (Raiffeisen, Creditanstalt, Bank Austria i Hypo-Alpe-Adria) i Nizozemske (ING i ABN Amro), a pojavilo se i nekoliko njemačkih banaka (BNP-Dresdner, Commerzbank i HypoVereinsbank). Ranu privatizaciju udjela državnih banaka u drugom dijelu desetljeća odradile su dvije spomenute nizozemske banke i Erste (Austrija), Societe Generale (Francuska), KBC banka (Belgija), Allied Irish Banks (Irska) Bayerische Landesbank (Njemačka), Citibank i GE Capital (SAD).

Tablica 2.2. Prikaz bankarskoga sustava u prvom desetljeću tranzicije

	Broj banaka (u stranom vlasništvu)	**udio stranih banaka u ukupnoj aktivi bankarskoga sektora**	**domaći krediti u odnosu na BDP (%)**	**neto kamatna marža**	**udio NPL-a u ukupnim kreditima (%)**	**EBRD bankarski tranzicijski indeks**
Početno tranzicijsko razdoblje – 1996. godina						
CEE						
Češka	55 (23)	15,5	62,5	3,44	31,5	3
Mađarska	43 (21)	36,8	22,7	5,99	12,1	3
Poljska	81 (18)	4,4	16,7	8,84	23,9	3
Slovačka	33 (18)	32,7	26,3	3,93	41,3	2,7
SEE						
Bugarska	41 (3)	< 1	39,4	2,17	12,5	2
Hrvatska	54 (1)	< 1	33,4	5,73	12,9	2,7
Rumunjska	24 (8)	< 1	7,8	8,27	37,9	3
Srbija	103 (3)	< 1	9,2	3,62	12,0	1
Slovenija	39 (6)	4,8	27,3	4,48	9,3	3

Srednja faza tranzicije – 2001. godina

CEE						
Češka	40 (26)	65,4	44	2,03	33,8	3,3
Mađarska	42 (33)	67,4	29,9	4,01	3,1	4
Poljska	73 (46)	72,6	26,9	4,36	16,8	3,3
Slovačka	23 (13)	42,7	43,7	2,69	26,2	3
SEE						
Bugarska	35 (25)	75,3	12,5	5,52	10,2	3
Hrvatska	45 (21)	84,1	39,9	4,89	22,6	3,3
Rumunjska	33 (21)	46,7	7,2	7,57	5,3	2,7
Srbija	81 (3)	0,5	63,6	3,31	27,8	1
Slovenija	28 (6)	15,3	36,7	3,75	9,3	3,3

Izvor: IFS, WBI, IMF, Središnje banke odabranih zemalja

Tablica 2.3. Prikaz bankarskoga sustava u drugom desetljeću tranzicije

Kasno tranzicijsko razdoblje – 2006. godina

CEE						
Češka	36 (27)	84,4	35,8	2,39	4,0	4
Mađarska	38 (27)	82,6	49,9	4,46	3,1	4
Poljska	61 (50)	74,3	33,4	2,96	11,6	3,7
Slovačka	23 (16)	97,3	35,1	2,08	5,5	3,7
SEE						
Bugarska	34 (23)	74,3	41,0	3,96	3,8	3,7
Hrvatska	34 (13)	91,3	56,4	3,50	6,2	4
Rumunjska	33 (24)	59,2	19,9	4,23	1,7	3
Srbija	40 (17)	66,0	30,7	5,69	-	2,7
Slovenija	25 (9)	22,6	56,3	2,19	6,4	3,3

Postkrizno razdoblje – 2011. godina

CEE						
Češka	37 (15)	84,8	75,3	2,48	2,8	4
Mađarska	38 (23)	81,3	66,5	3,82	6,7	3,7
Poljska	67 (57)	72,3	55,2	3,18	8,0	3,7
Slovačka	26 (13)	91,6	51,1	2,77	5,2	3,7
SEE						
Bugarska	30 (22)	84,0	75,3	3,59	6,7	3,7
Hrvatska	22 (15)	91,0	69,64	2,95	7,8	4
Rumunjska	31 (25)	84,3	40,7	4,35	8,5	3,3
Srbija	33 (--)	72,5	45,0	4,54	16,9	3
Slovenija	25 (11)	29,5	92,7	2,36	6,0	3,3

Izvor: IFS, WBI, IMF, Središnje banke odabranih zemalja

U prikazu prvog desetljeća tranzicije bankarskoga sustava (2.2. tablica) u većini prikazanih zemalja i dalje dominira vlasništvo države ili institucija povezanih s državnom upravom. U ranom prijelaznom razdoblju (2.2. tablica) oko jedne trećine aktive banaka u Mađarskoj, Slovačkoj i Latviji 1996. u vlasništvu je stranih financijskih institucija, a brojke su manje u Češkoj i Poljskoj kao i u prikazanim zemljama bivše Jugoslavije. U Češkoj su banke u državnom vlasništvu uključene u program kuponske privatizacije čime se ograničava ulazak stranih investitora. U Poljskoj je devet banaka u vlasništvu države trebalo biti privatizirano kao dio programa uz potporu američke riznice. Međutim, tadašnje vlade slijede više protekcionističku strategiju uzimajući pristup prema bankarskoj industriji prema kojoj su domaće banke čuvane i tako su postale dovoljno jake da su bile sposobne odbijati inozemnu konkurenciju kad se ona pojavi.

Ako pogledamo 2.3. tablicu, tj. zadnje promatrano desetljeće tranzicije, uočavamo jak utjecaj i priliv stranih banaka u svim prikazanim bankarskim sustavima (broj banaka u stranom vlasništvu): u Češkoj je to 15 banaka od 37, u Mađarskoj 23 od 38, u Poljskoj 57 od 67, u Slovačkoj 13 od 26, u Bugarskoj 22 od 30, u Hrvatskoj 15 od 22, u Rumunjskoj 25 od 31, u Sloveniji 11 od 25 banaka.

Međutim, razvoj učinkovitog bankarskog sektora zahtijeva okončanje triju međusobno povezanih aktivnosti: rješavanje loših kredita, privatizaciju državnih banaka i uspostavu učinkovitih regulatornih institucija.

Danas za financijski sustav Hrvatske možemo reći da su promjene u proteklom razdoblju stvorile osjećaj da možemo biti zadovoljni strukturnim promjenama koje su se dogodile. Financijski se sustav smatra konsolodiranim, internacionaliziranim i spremnim za uključivanje u tržišno natjecanje na budućem otvorenom tržištu Europske unije. Problemi se uglavnom vide u realnom sektoru i u posljednjih 15 godina politika poticanja gospodarskoga rasta temeljila se na državnim infrastrukturnim investicijama i pratećem proračunskom deficitu. Model politike poticanja rasta putem državnih ulaganja u fizički kapital vrlo je vjerojatno iscrpio svoje mogućnosti pa već od 2003. stopa rasta BDP-a bilježi kontinuirano usporavanje. Realno usporavanje dodatno ograničava manevarski prostor za nužne fiskalne prilagodbe. Nov impuls može doći samo iz privatnoga sektora, odnosno od privatnih investicija. Međutim, njihov uzlet nailazi na mnoštvo problema i ograničenja: visoko porezno opterećenje i fiskalni deficit, nedovršene reforme tržišne infrastrukture (registri, pravosuđe, prevelika administracija i korupcija), preprjeke međunarodnom optjecaju kapitala, skupa regulacija banaka koja dugoročno može bankarski sektor učiniti međunarodno nekonkurentnim te izrazita sklonost dužničkom i nesklonost vlasničkom financiranju tvrtki. To je samo niz navedenih čimbenika koji ograničavaju daljnji ukupan gospodarski rast i daljnji financijski razvoj. Hrvatska je, kao i sve promatrane zemlje, bankocentrična.[42]

Praksa je pokazala da je na nižim stupnjevima razvoja, dok privatna financijska imovina još nije ojačala, tržište kapitala nerazvijeno i zbog toga preprjeka ulazu međunarodnog kapitala. Dok je kapital u zemlji nedostatan, nije teško donijeti odluku gdje će se plasirati i donijeti visok povrat. Međutim, s rastom financijske imovine, dok kapital postaje sve pristupačniji, teže je pronaći dobre prilike za ulaganja. U takvim uvjetima, temeljna dilema financijske politike postaje sve izraženija: ili će se razviti domaće tržište kapitala i pružiti nove prilike za ulaganja u vidu vrijednosnih papira ili će se otvarati vrata odljevu kapitala u inozemstvo i ostvarivanje povrata na drugim, propulzivnim tržištima. Tempo rasta imovina svih sastavnica financijskog sustava u Hrvatskoj, uz anemično, odnosno neaktivno dioničko tržište, pokazuje da možda nismo daleko od trenutka kada će ta dilema postati aktualnom. Naprotiv, svjedoci smo ogromne kontrakcije portfelja bankarskoga sektora počevši od nastanka krize i ogromne likvidnosti.

[42] Dominira bankarski sektor u financijskom sustavu i tržište kapitala je nerazvijeno i može se zaključiti da Hrvatska u tom segmentu dramatično zaostaje za drugim zemljama.

Ono što danas banke rade jest da višak likvidnosti ulažu u dionice i obveznice, no izvan Hrvatske. Nije trebalo biti previše pametan ili imati kristalnu kuglu u ruci kako bi se predvidjela ovakva situacija odljeva kapitala u inozemstvo.

Ako veličina zemlje i pravno nasljeđe ne određuju financijsku strukturu i ako iskustva mnogih zemalja pokazuju da se financijska struktura u srednjoročnom razdoblju može mijenjati, nameće se pitanje o tome što Hrvatska želi učiniti sa svojim financijskim sektorom u budućnosti? Je li razvojna putanja po kojoj se sada krećemo dobra pa ju ne treba mijenjati ili se na toj stazi kriju moguće stupice za daljnji financijski i gospodarski rast? S druge strane, moramo se pitati je li razvojna putanja duž koje postajemo sve sličniji austrijskoj financijskoj strukturi toliko štetna da bismo se morali zabrinuti? Ipak je Austrija dosegnula visoku razinu dohotka po glavi stanovnika bez posebno razvijenog tržišta dioničkog kapitala ulažući puno u inozemstvo.

Dakle, da bi se bilo preciznije u razmišljanju o bitnim sastavnicama navedena problema, treba postaviti pitanje koliko gubimo ako se nastavimo razvijati ovako „bankocentrično“ i treba li nešto poduzeti u tom smjeru.

U dosadašnjim teorijskim razmatranjima i različitim empirijskim rezultatima, vlastitim analizama i iskustvima različitih zemalja dalje ćemo pokušati dati neke odgovore, zapažanja i smjernice. Prvo, banke i financijska tržišta komplementarne su financijske institucije koje se razvijaju paralelno s time što su banke razmjerno važnije na nižim stupnjevima razvoja dok tržišta razmjerno poprimaju veću važnost na višim stupnjevima razvoja. Odnos komplementarnosti dominira na eventualnim konkurentskim odnosima banaka i financijskog tržišta. Drugo, financijski će se posrednici prirodno okrenuti prema financijskim tržištima u inozemstvu u mjeri u kojoj domaća tržišta ne mogu ponuditi dobre prilike za ulaganja i njihovu diverzifikaciju. Svaki pokušaj administrativnog pokušaja sprječavanja tog prirodnog trenda (umjesto aktivnog poticanja domaćeg tržišta i njegovog razvoja) dovest će do stvaranja neaktivnog tržišta za strana ulaganja. Treće, mala je vjerojatnost da će se poželjan financijski razvoj dogoditi spontano. Financijska tržišta podložna su tzv. „nesavršenostima“ koje regulatori ne mogu ignorirati, kako s gledišta nadzora tako i s gledišta poticanja razvoja. Četvrto, tržišta vlasničkoga kapitala razvijaju se skokovito: doživljavaju brze uspone u razdobljima kada je djelovanje politike privatizacije i liberalizacije na vrhuncu. Premda nakon takvih razdoblja počinje razdoblje „rashlađivanja“, tržišna likvidnost i aktivnost ostaju na trajno niskoj razini. Peto, pojava tvrtki na tržištu kapitala (engl. *initial public offering* – IPO) nezamjenjiv su instrument državne politike. Osim što izravno doprinose ukupnu razvoju tržišta kapitala, one

proizvode i dodatnu društvenu korist kroz maksimalizaciju prodajne cijene poduzeća u privatizaciji, odnosno javnih prihoda.

Treba napomenuti da veličina tržišta (zemlje) može postati ograničavajući čimbenik promatramo li visokorazvijena tržišta kapitala. Isto tako, među makroekonomistima postoji utjecajna škola mišljenja koja naglašava opasnosti tzv. špekulativnog priljeva kratkoročnog inozemnog kapitala, što je posebno izraženo u malim i otvorenim ekonomijama kao što je Hrvatska. Taj kapital u visokim iznosima ulazi na likvidnija tržišta u nastajanju, ponekad uzrokuje (nepotrebnu) aprecijaciju valute te potom izlazi s tih tržišta uzrokujući (ponekad i opet nepotrebnu) naglu deprecijaciju valute.

Dakako, to može dovesti do valutne i financijske krize te zastoja pa i prekida u razvoju tržišta kapitala. Karikaturalna preporuka koja se ponekad ističe zbog postojanja te opasnosti glasi kako je nelikvidnost tržišta kapitala vrlina jer nerazvijeno tržište neće privući međunarodne portfeljne investitore. Prema tome, navodno je bolje ne poticati razvitak tržišta kapitala i zabraniti ili odvraćati optjecaj kratkoročnog međunarodnog kapitala. (Pill i McKinnon, 1995.)

Postavlja se pitanje neće li u uvjetima potpune otvorenosti malog gospodarstva domaće tvrtke težiti uvrštavanjem na neku od stranih burzi koje su veće i likvidnije, a čije su usluge jeftinije zbog ekonomije obujma. (Malkamaki, 1999.) Nadalje se može postaviti pitanje kako će male i regionalne burze odgovoriti globalnim trendovima povezivanja i okrupnjavanja burzi te razvijanja alternativnih sustava za neposredno trgovanje. Oba se pitanja mogu podvesti pod zajednički nazivnik financijske liberalizacije i internacionalizacije.

Grafički prikaz 2.2. Usporedba udjela aktive stranih banaka u ukupnoj aktivi bankarskog sektora u 1996. i 2011.godini

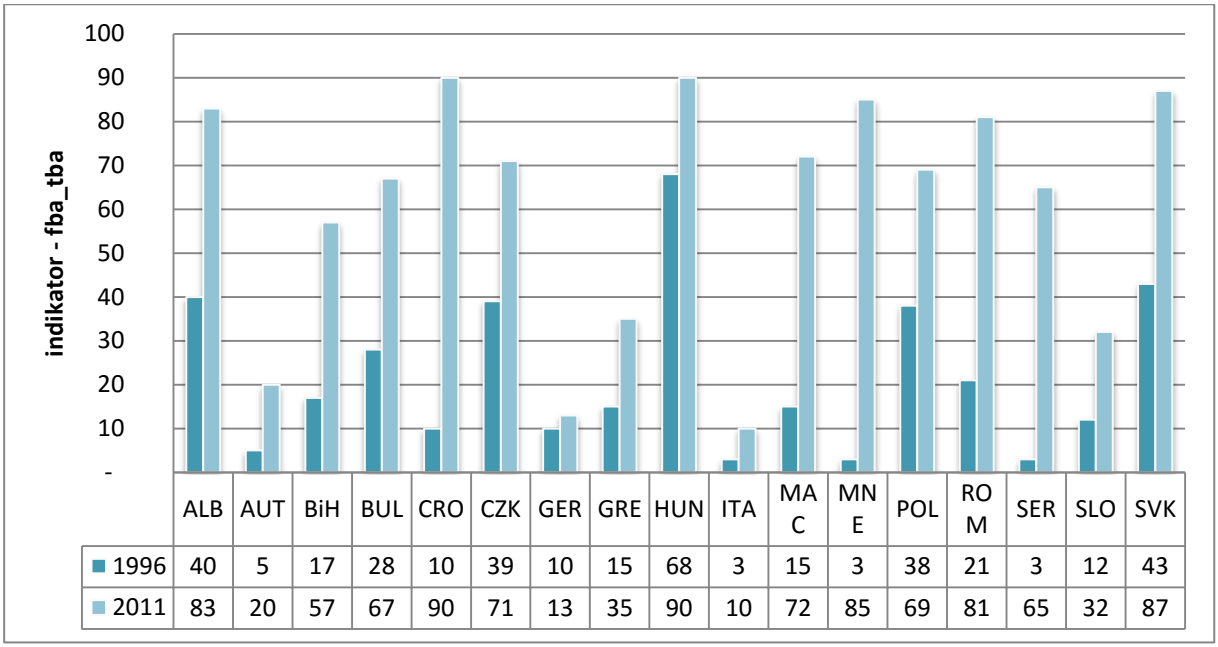

	ALB	AUT	BiH	BUL	CRO	CZK	GER	GRE	HUN	ITA	MAC	MNE	POL	ROM	SER	SLO	SVK
1996	40	5	17	28	10	39	10	15	68	3	15	3	38	21	3	12	43
2011	83	20	57	67	90	71	13	35	90	10	72	85	69	81	65	32	87

Izvor: IFS, WBI, IMF, Središnje banke odabranih zemalja

Pogledamo li grafički prikaz 2.2., vidljiva je ogromna razlika udjela stranih banaka na početku i na kraju promatranog razdoblja. Primjerice, u zemljama poput Hrvatske, Mađarske, pa i Slovačke, taj se udjel penje i do 90 %. Ogromna promjena u strukturi bankarskoga sektora dogodila se u Crnoj Gori, Srbiji, Rumunjskoj i Makedoniji.

Razvoj bankarskog sustava u proteklim godinama, a posebno prije financijske krize u Hrvatskoj pa i u drugim sad već posttranzicijskim zemljama, svjedoči o tome da pozitivni učinci internacionalizacije (u vidu smanjenja troška kapitala i širenja ponude financijskih proizvoda i usluga) mogu nadvladati negativne učinke. Međutim, isto tako svjedoci smo da iskustvo s financijskom liberalizacijom i internacionalizacijom nije bilo tako pozitivno u zemljama koje su pogođene krizom. Svakako, dosadašnja su istraživanja pokazala da financijska liberalizacija i internacionalizacija izrazito pozitivno dugoročno gledajući utječu na financijski razvitak i dohodak po stanovniku. (Abaid, Oomes i Ueda, 2004.) Međutim, neki su se autori složili s time istaknuvši da je to uvjet da zemlja ne doživi financijsku krizu. (Usp. Eichengreen i Leblang, 2003.; Fratzscher i Bussiere, 2004.) Svjedoci smo da uravnotežen razvitak financijske strukture, raspoloživost različitih vrsta izvora financiranja i bolje institucionalna infrastruktura mogu bitno povećati otpornost financijskoga sustava na krize. Nameće se zaključak da konačna

liberalizacija optjecaja kapitala prije ulaska u EU nameće nužnost daljnjeg aktivnog jačanja financijskih posrednika i tržišta. Nadalje, i od malog uvijek postoji manji. Primjerice, burza u Varšavi deklarirala je želju da postane „regionalna luka“ za kompanije koje se žele širiti, ali i baza ulagača u srednjoj i istočnoj Europi. Burza u Budimpešti je u vlasništvu bečke burze i nekoliko austrijskih i njemačkih financijskih institucija. Dakle, internacionalizacija ne znači kraj poslovanja zbog zaoštrene konkurencije na globalnom tržištu. Internacionalizacija može značiti i povezivanje, nastavak života u drugom obliku. Povezivanje burzi ne znači da će nepostojanje lokalne burze ili njezina uklopljenost u regionalni sustav burzi ukinuti domaće tržište kapitala. Naprotiv, to može biti njegov početak jer će se lokalni vrijednosni papiri u okviru internacionalnih mrežnih sustava lakše i jeftinije moći nuditi širem krugu zainteresiranih investitora.

Ako idemo korak dalje u analizi strukture financijskoga sustava promatranih zemalja, možemo zaključiti za sve da su bankocentrične, tj. da dominiraju banke. Ono što ovdje treba istaknuti jest da su banke većine zemalja prošle kompletnu transformaciju i prevladao je utjecaj stranih banaka u promatranim zemljama. Isto tako, može se zaključiti da je bankarska intermedijacija u zemljama istočne i jugoistočne Europe još uvijek nedovoljno razvijena u odnosu na europski prosjek, ali opet bankarski sektori uspješno obavljaju funkciju posredovanja.

Grafički prikaz 2.3. Usporedba provedbe reformi bankarskoga sektora u 1996. i 2011. godini

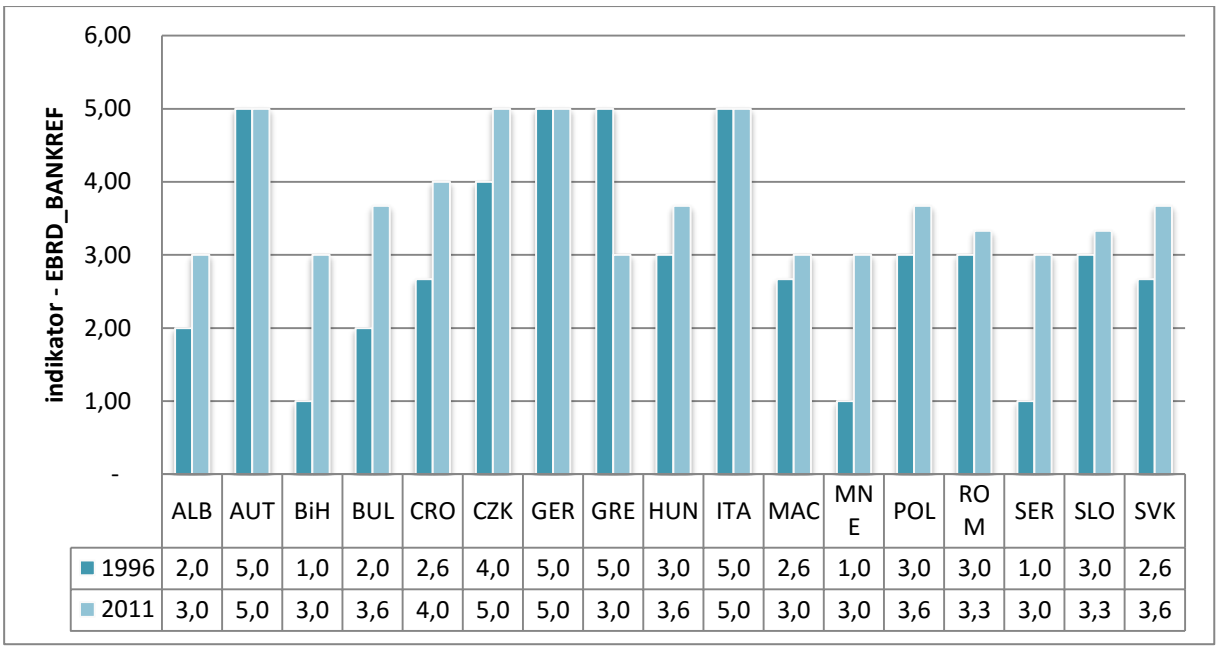

	ALB	AUT	BiH	BUL	CRO	CZK	GER	GRE	HUN	ITA	MAC	MNE	POL	ROM	SER	SLO	SVK
1996	2,0	5,0	1,0	2,0	2,6	4,0	5,0	5,0	3,0	5,0	2,6	1,0	3,0	3,0	1,0	3,0	2,6
2011	3,0	5,0	3,0	3,6	4,0	5,0	5,0	3,0	3,6	5,0	3,0	3,0	3,6	3,3	3,0	3,3	3,6

Izvor: IFS, WBI, IMF, Središnje banke odabranih zemalja

Grafički prikaz 2.4. Usporedba provedbe restrukture financijskoga sustava u 1996. i 2011. godini

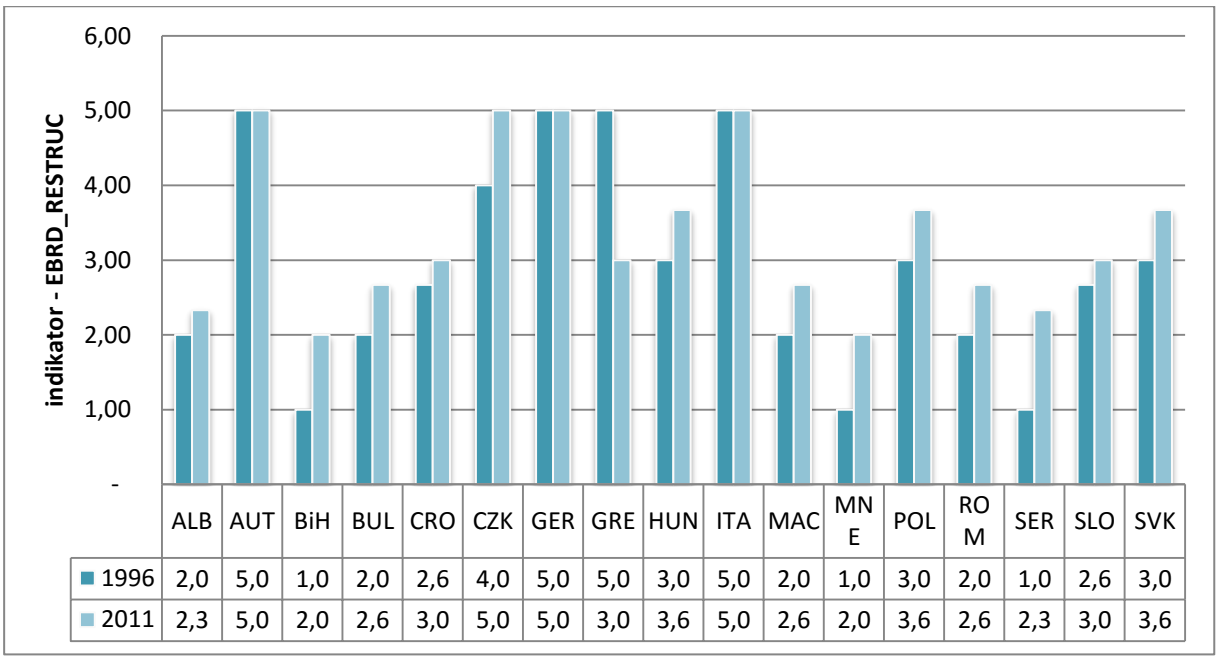

	ALB	AUT	BiH	BUL	CRO	CZK	GER	GRE	HUN	ITA	MAC	MNE	POL	ROM	SER	SLO	SVK
1996	2,0	5,0	1,0	2,0	2,6	4,0	5,0	5,0	3,0	5,0	2,0	1,0	3,0	2,0	1,0	2,6	3,0
2011	2,3	5,0	2,0	2,6	3,0	5,0	5,0	3,0	3,6	5,0	2,6	2,0	3,6	2,6	2,3	3,0	3,6

Izvor: IFS, WBI, IMF, Središnje banke odabranih zemalja

Analizom financijskih sustava promatranih zemalja, u promatranom razdoblju, a posebno od 2000. godine, bankarski sektori zemalja istočne i jugoistočne Europe bilježe intenzivniji razvoj potaknut prvenstveno promjenom vlasništva i kreditnoga okruženja na bankarskom tržištu tih zemalja. Proces financijskoga produbljivanja nije jednaka intenziteta u svim zemljama, a ponajviše kasni na području Srbije, Albanije, Crne Gore i Makedonije dok je Hrvatska dosegnula razinu intermedijacije koju bilježe zemlje članice EU-a. Također, analizom usporednih podataka može se zaključiti da zemlje istočne i jugoistočne Europe zaostaju u implementaciji reformi na polju financijskoga sustava. Iz promatrane skupine zemalja, primjerice, jedina reformska zemlja je Hrvatska s vrlo dobro i kvalitetno provedenim reformama. Dakako, istu ocjenu provedenih reformi dijele i druge nove članice EU-a prilikom pridruživanja EU. Interesantno je primijetiti Sloveniju kao zemlju koja je imala ocjenu 3,3, što je i realno jer se ta zemlja oduprla velikim bankarskim grupacijama koje su trebale provesti privatizaciju bankarskoga sektora (koje su uglavnom dolazile iz EU-a, prvenstveno Austrije i Njemačke).

Grafički prikaz 2.5. Odabrane zemalje za 1996. i 2011. god. – krediti privatnom sektoru/BDP u %

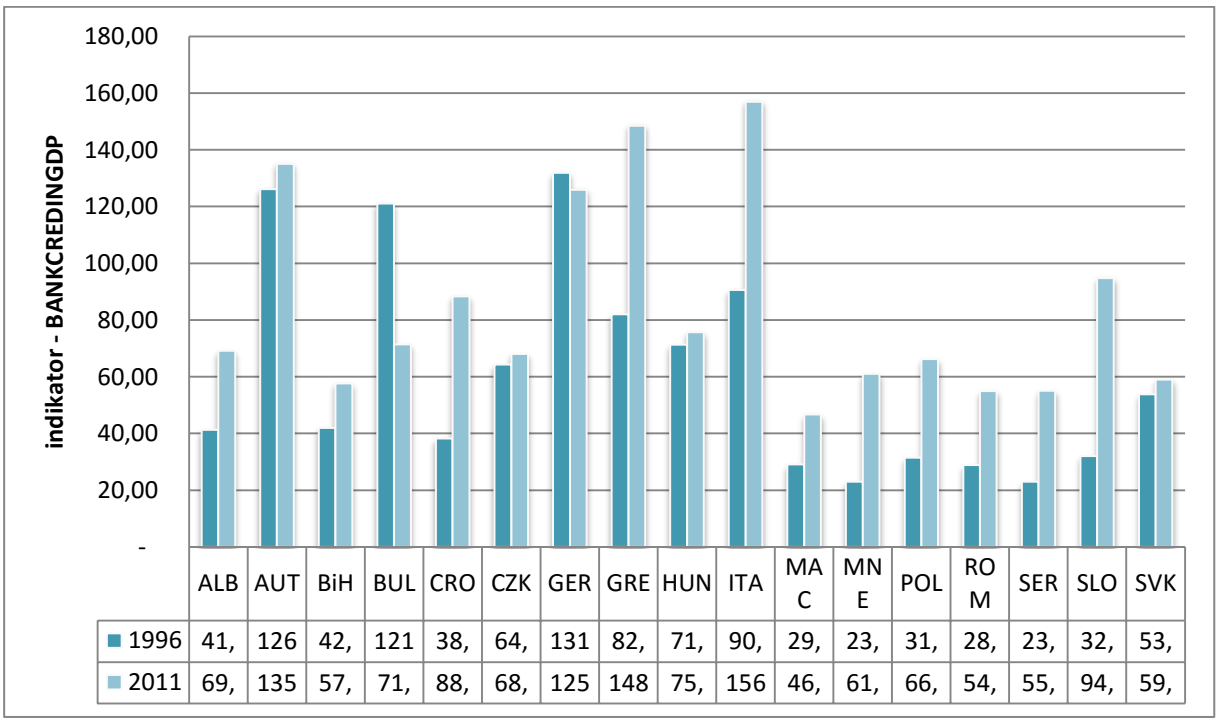

Izvor: IFS, WBI, IMF, Središnje banke odabranih zemalja

Grafički prikaz 2.5. pokazuje razmjere zaostajanja po zemljama iz uzorka kao i razlike u razvijenosti u 1996. i 2011. godini. Uočljiva su dva ključna pokazatelja razvijenosti financijskoga sustava: omjer prometa dionicama i BDP-a (mjera likvidnosti tržišta kapitala) i omjer danih kredita privatnom sektoru i BDP-a. Prema ovom drugom pokazatelju, dakako, možemo zaključiti da se Hrvatska nalazi na očekivanu mjestu u odnosu na druge posttranzicijske zemlje, pa čak i ispred nekih koje su prije postale članice EU-a. Međutim, jednako uočavamo i drugu sliku kada je riječ o tržištu kapitala. Zaključak je vidljiv iz grafa: Hrvatska dramatično zaostaje za drugim tranzicijskim zemljama koje su prije ušle u EU (mjereno predloženim pokazateljem razvijenosti financijskoga sustava – promet dionica u odnosu na BDP). Iako u ovom radu nije predmet istraživanja pravno nasljeđe koje je obilježilo i organizaciju financijskoga sustava, potrebno je napomenuti da postoji raširenо mišljenje da srednjoeuropski ili tzv. germanski model financijskog razvoja zanemaruje tržište kapitala i favorizira banke dok tzv. anglosaksonsko-skandinavski model favorizira razvoj financijskoga tržišta. Upravo zato što su sve zemlje po svojoj prirodi naslijedile ovaj prvi mode,l neće se u ovom istraživanju ići dublje u razmatranje tog problema. Ono što je potrebno naglasiti jest da postoje i ekonomsko pravne teorije koje takvu strukturu objašnjavaju i pravnim nasljeđem. Navodno sustavi običajnog prava pogoduju tržištima kapitala dok sustavi građanskoga prava pogoduju bankama. Međutim, mora se napomenuti da je ova teorija bila relevantna prethodnih 10-ak godina. Naime, Njemačka, koja je u proteklih 10-ak godina bitno promijenila financijsku strukturu u korist tržišta kapitala, propituje takvo promišljanje.

Očigledno je da financijske strukture pojedinih država izmiču jednostavnim objašnjenjima. To je, dakako, loša vijest za one koji vole jednostavna objašnjenja, ali je dobra vijest za one koji promišljaju kako nešto promijeniti. Bilo bi pogrješno donijeti zaključak da je Austrija zemlja u kojoj postoje samo razvijene banke i nerazvijeno tržište kapitala. Tržišta obveznica u pravilu su razvijenija u takvim zemljama, a drugi financijski posrednici, poput investicijskih i mirovinskih fondova, imaju znatan institucionalni tržišni udjel. Primjerice, imovina svih nebankarskih financijskih posrednika zauzima više od 50 % BDP-a (samo imovina otvorenih fondova vrijedi više od 25 % BDP-a).

Na temelju provedene i prezentirane analize financijskih sustava promatranih zemalja može se donijeti nekoliko zaključaka:

- bankocentričnost financijskih sustava – u promatranim zemljama banke su dominantan financijski posrednik, a posebno je potrebno istaknuti da su još uvijek zemlje istočne i jugoistočne Europe mala i nerazvijena financijska tržišta
- izdvojimo li Austriju i Njemačku na jednu stranu i sve ostale promatrane zemlje na drugu stranu, vidljiva je još uvijek mala ukupna aktiva banaka i kredita privatnom sektoru
- banke u istočnoj i jugoistočnoj Europi u većinskom su vlasništvu banaka sa sjedištem u zemljama EU-a
- financijska aktivnost banaka u istočnoj i jugoistočnoj Europi drukčija je od one u središnjoj Europi i imaju drukčiju strukturu kreditiranja
- moguće je primijetiti i slabije razvijenu financijsku intermedijaciju.

Vidljivo je da je ulazak europskih banaka pojačalo konkurenciju na lokalnom tržištu s dominacijom velikih banaka. Ono što je bilo bitno jest da se u takvim uvjetima osigura stabilno i postojano bankarsko tržište unatoč ulasku velikih globalnih invenstitora. Banke moraju biti spremne odgovoriti novim izazovima koje nameću kontinuiran razvoj još uvijek nedovoljno integriranog bankarskog tržišta EU-a. Ulazak europskih banaka u svakom slučaju pojačava konkurenciju na lokalnom tržištu s dominacijom velikih banaka, što otvara pitanje opstojanja malih banaka u domaćem privatnom ili državnom vlasništvu. Razvoj proizvoda investicijskoga bankarstva i upravljanja imovinom odgovor je konkurenciji nebankarskih financijskih institucija. U svakom slučaju, jačanje konkurentnosti otvara kod banaka pitanje njihove učinkovitosti i unaprjeđenja.

Razvidno je, isto tako, da tržišna struktura banaka determinira koncentracijom, konkurentnošću i njihovom učinkovitošću, institucionalnim rješenjima i okvirom djelovanja koji se mijenja i čini odrednicu uspješne integracije bankovnih sektora istočne i jugoistočne Europe u unutarnje bankarsko tržište EU-a. No, iste odrednice određuju ulogu promatranih sustava u ostvarenju nominalne i realne konvergencije. (Živko, 2008.)

III. ANALIZA PREDHODNIH TEORIJSKIH I EMPIRIJSKIH ISTRAŽIVANJA O VEZI FINANCIJSKE RAZVIJENOSTI I GOSPODARSKOGA RASTA

3.1. Uvodne napomene

Istraživanje o utjecaju razvoja financijskoga sustava na gospodarski rast vrlo je ambiciozno i sve je veći interes za istraživana o ovoj temi, a posebno zadnjih trideset godina. Ipak, još uvijek nema konačnog stava o utjecaju razvoja financijskoga sustava na gospodarski rast, kako u teoriji tako ni u praksi (vidi Aziakpono, 2012.; Stolbov, 2012. i Eschebach, 2004.) i upravo je zbog toga ova tema u središtu pozornosti sve većeg broja znanstvenika.

Teorijska razmatranja o utjecaju financijskoga sustava na gospodarski rast mogu se vidjeti već u Bagehotovim radovima 70-ih godina XIX. st. Možda su slična razmišljanja o ovoj temi postojala već i otprije, no tada još uvijek nije postojala literatura koja bi to potvrdila. Na temelju postojeće literature koja se potom javila, dokumentirana su mnoga dosadašnja istraživanja (Stolbov, 2012.).

Pored raznih kritika Bagehotova razmišljanja može se reći da je njegovo temeljno razmišljanje o razvoju financijskoga sustava i njegovu utjecaju na gospodarski rast i danas ostalo vrlo značajno. Naime, ono se temelji na tvrdnji da je glavna uloga financijskoga sustava u razmjeni resursa i alokaciji u najprofitabilnije projekte. Iz Bagehotove teorije može se zaključiti da razvoj financijskoga sustava ima važnu ulogu u gospodarskom rastu. Druga teoretska razmatranja o ovoj temi, a koja su dominantna u 19. stoljeću, uključuju i ona Karla Maxa koji razmatra utjecaj kapitala na gospodarski rast (Hilferding, 1981.). Upravo je Bagehot potaknuo mnoge teoretičare da razmatraju utjecaj razvoja financijskoga sustava na gospodarski rast u XX. stoljeću. Tako Schumeter kroz svoju teoriju o gospodarskom rastu ističe inovacije kao ključni pokretač gospodarskoga rasta. Prema njemu inovacije se mogu pojaviti u smislu novog načina proizvodnje postojećih proizvoda, novoga tržišta, inovacije u sirovinama ili se sve te kombinacije mogu realizirati i kroz kanal bankarskih kredita u slučaju otvorene ekonomije. (Usp. Stolbov, 2012.)

Najveći broj studija nastalih u razdoblju do 90-ih godina dvadesetoga stoljeća bio je usmjeren na detaljne opisne analize pojedinih zemalja. Empirijska istraživanja bila su rijetka, obuhvaćala su ograničen broj zemalja i nisu sustavno uzimala u obzir sve determinante gospodarskoga rasta. (Usp. Levine, 2000.) Značajan doprinos empirijskim istraživanjima dali su Demirgüc-Kunt i Levine 1996. godine te Beck, Demirgüc-Kunt i Levine 2000. Oni su omogućili identificiranje kanala kojima financijski razvoj djeluje na rast kao i provjeru koliko je razlika u financijskoj strukturi financijskoga sustava (bankocentrični nasuprot tržišnocentričnim sustavima) uopće važna za rast.

Mnogobrojna istraživanja veze između financijskoga sustava i gospodarskoga rasta jednoglasno su potvrdila da financijska struktura sama po sebi, odnosno razdvajanje financijskih sustava na bankocentrične i tržišnocentrične sustave, nije dobar način razlikovanja financijskoga sustava. Nasuprot tomu, sva istraživanja potvrđuju da je sveobuhvatna financijska razvijenost, mjerena aktivnošću banaka prema privatnom sektoru i likvidnošću tržišta kapitala, odrednica dugoročnoga gospodarskoga rasta. Naime, u posljednja dva desetljeća usporedo s napretkom u ekonometrijskim istraživanjima ekonomskoga rasta i s razvojem endogene teorije rasta, objavljeno je mnogo članaka koji se bave vezom financijskoga posredovanja i gospodarskoga rasta, a interes o ovoj temi ne jenjava.

Tradicionalno se veza između financijskoga sustava i gospodarske aktivnosti pokušavala objasniti razlikama u načinu na koji bankocentrični sustavi (financijski sustavi u kojima dominiraju banke) i tržišnocentrični sustavi (financijski sustavi kojima dominira tržište kapitala) ispunjavaju prethodno navedene funkcije.

Razmišljanja o vezi između financijskoga sustava i rasta kroz dihotomiju bankocentričnih i tržišnocentričnih sustava ima svoje polazište u studijama koje su razlike u ekonomskoj uspješnosti SAD-a i Velike Britanije s jedne te Njemačke i Japana s druge strane, pokušale objasniti upravo u razlikama u načinu organizacije njihovih financijskih sustava.

Nabrajanje prednosti i nedostataka tržišnocentričnog i bankocentričnog sustava implicitno navodi na zaključak da između tih dvaju načina organizacije financijskih sustava postoji određeni „trade off“. Međutim, u novije se vrijeme javljaju gledišta koja tvrde da suprotstavljanje bankocentričnih i tržišnocentričnih financijskih sustava nije pravilan pristup u razumijevanju veze između financijskoga sustava i gospodarskog rasta. Levin (2007.) stoga predlaže funkcionalan pristup financijskom razvoju.

Funkcionalni pristup naglašava da banke i tržište obavljaju različite i međusobno komplementarne usluge koje imaju pozitivne implikacije na rast. Dakle, može se zaključiti da za gospodarski rast nije važno temelji li se on na bankama ili na tržištu kapitala, već obavlja li on uspješno svoje funkcije. Dakako, važna je dostupnost i sveukupna razvijenost financijskih usluga, a ne organizacija financijskoga sustava.

Međutim, treba naglasiti da su mišljenja ekonomista o ulozi financijskoga posredovanja u gospodarskom rastu još uvijek podijeljena. Dok je Adams (1819.) smatrao da banke potkopavaju „moral, mir, pa čak i bogatstvo naroda“ (Levine, Loayaza i Beck, 2000.), Alexander Hamilton (1971.) tvrdio je da su „banke najsretniji motor koji je ikad bio izumljen“ za ubrzavanje gospodarskoga rasta.

Neki autori, poput Bagehota (1873.), ustanovili su da uspješna mobilizacija štednje može poboljšati alokaciju resursa i potaknuti tehnološke inovacije, a time i potaknuti gospodarski rast. Dok su drugi smatrali da u biti financijski sustav slijedi gospodarski rast (Robinson, 1952.), treći su bili skeptični o postojanosti te veze (Lucas, 1988.). Schumpeter (1934.) je također došao do zaključka da su usluge financijskih posrednika bitne za poticanje tehnološkoga napretka i ekonomskoga razvoja. Postoje i autori poput Donrbuscha i Reynosoa (1989.: 204) koji misle da su financijski čimbenici slični režimima vanjske trgovine i osim ako u njima ne postoje veliki poremećaji, oni nemaju nikakav utjecaj na razinu BDP-a po stanovniku. Na drugoj su strani ekonomisti koji su uvjereni ne samo da su financije važne za ekonomski rast, nego da ga one i uzrokuju.

U nastavku rada daje se prikaz novijih empirijskih istraživanja kojima se analizira utjecaj razvijenosti financijskoga sustava na gospodarski rast. Već postoji nekoliko pregleda literature o povezanosti financija i gospodarskoga rasta: Gertler (1998.) čiji se prikaz usredotočuje na mikroekonomske aspekte financija i rasta; Pagano (1993.); Levine (1997.; 2005.), Trew (2006.), Demirgüc-Kunt i Levine (2008.), Bogdan (2009.) te Bađun (2009.) koja se usredotočila na prikaz radova utjecaja bankarskoga sektora na gospodarski rast. Ovdje treba naglasiti da jedan dio tih radova analizira utjecaj financijskog posredovanja banaka, a drugi su orijentirani na utjecaj financijskog tržišta na gospodarski rast. Isto tako, neki su autori analizirali utjecaj financija na gospodarski rast i sve temeljili na linearnoj vezi između tih dviju varijabli. Upravo zbog ograničenosti prostora nije se u mogućnosti navesti sve radove koji su istraživali vezu

između financija i gospodarskoga rasta te ćemo se usredotočiti na radove koji se uzimaju značajnijima i koji su bili usmjereni prema empirijskim istraživanjima.[43]

Isto tako, ovdje se neće zasebno navoditi utjecaj financijske strukture na gospodarski rast jer su oni komplementarni.

U slijedećoj tablici dat je prikaz najčešće citiranih istraživanja na temu utjecaja razvoja fianncijskog sustava na gospodarski rast do danas.

Tablica 3.1. Prikaz odabranih dosadašnjih istraživanja o utjecaju financijskog sustava na gospodarski rast

Autori	**Uzorak i vremensko razdoblje**	**Metoda analize podataka**	**Rezultati**
Goldsmith (1969)	35 zemalja (1860-1963)	Analiza korelacijom	Istraživanje pokazuje pozitivnu vezi razvoja FS i gospodarskog rasta.
King and Levine (1993)	80 zemalja (1960-1989)	Regresija i analiza osjetljivosti	Jaka veza između financijskog razvoja i gospodarskog rasta
Demirguc-Kunt and Levine (1996)	44 zemlje (1986-1993)	Panel analiza	Potvrđeno da razvoj tržišta kapitala pozitivno utječe na gospodarski rast.
Levine and Zervos (1998)	47 zemalja (1976-1993)	Panel analiza i analiza osjetljivosti	Otkrili su da je razvoj bankarskog sektora i likvidnost na tržištu kapitala ima pozitivnu korelaciju s akumulacija kapitala, rast produktivnosti i na gospodarski rast u kratkom roku.
Levine i dr. (2000)	74 zemlje (1960-1995)	Cross sections i panel analiza	Autori su došli do spoznaje da razvoj financijskog sustava ima pozitivan utjecaj na ekonomski rast.
Sinha and Macri (2001)	8 azijskih zemalja (India, Japan, Korea, Malaysia, Pakistan, Philippines, Sri Lanka, Thailand, 1950-1997)	Grangerov test uzročnosti	Stigli su do nalaza o pozitivnom odnosu između gospodarskog rasta i razvoj financijskog sektora u Indiji, Malezija, Pakistan i Šri Lanka. S druge strane tu je dvosmjerna uzročnost između prihoda i razvoja financijskog sektora u Indiji i Maleziji; jednosmjerni uzročnost od prihoda za razvoj financijskog sektora u Japanu i Tajlandu, jednosmjerni uzročnost od razvoa financijskog sektora na prihod u Pakistanu, Filipinima, i Koreja.

[43] Za one čitatelje koje zanimaju detalji teorijskih modela opširniji pregled mogu naći u Levineovu pregledu (2005.).

Bloch and Tang (2003)	75 zemalja (1960-1990)	Analiza vremenskih serija	Otkrili su da ne postoji značajna povezanost između gospodarski rasta i razvoja financijskog sektora.
Rioja and Valev (2004)	74 zemlje (1961-1995)	Dinamička panel analiza, GMM procjenitelj	Otkrili su da je odnos između gospodarskog rasta i razvoja financijskog sektora varirala prema stupnju razvoja financijskih tržišta. Učinak je bio pozitivan u zemljama sa srednjom i visokom razinom razvijenosti financijskih tržišta, a učinak je bio nejasan u zemljama s vrlo niskom razinom razvoja financijskih tržišta.
Jeanneney i dr.. (2006)	Kina (1993-2001)	Dinamički panel model, GMM procjenitelj	Došli su do saznanja da razvoj financijskog sektora utječe na rast produktivnosti pozitivno.
Backé i dr (2007)	Zemlje središnje i istočne Europe (1993-2006)	Panel analiza	Došli su do saznanja da razvoj financijskog sektora utječe na gospodarski rast pozitivno.
Abu-Bader and Abu-Qarn (2008)	Algeria, Egypt, Israel, Morocco and Tunisia (1960–2004)	Povećani vektor autoregresije, metodologija Toda i Yamamoto	Utvrdili su jednosmjernu uzročnost od razvoja financijskog eektor na gospodarski rast za sve zemlje osim Izraela.
Caporale i dr (2009)	Bulgaria, Czech. Rep., Estonia, Hungary, Latvia, Lithuania, Poland, Romania, Slovakia, Slovenia (1994-2007)	Povećani Barrov regresijski model	Spoznali su da je bankarski sektor povećao gospodarski rast, ali da tržište kapitalata ima relativno mali utjecaj na rast.
Estrada i dr. (2010)	116 Azijskih zemalja (1987-2008)	Panel analiza	Otkrili su da je razvoj financijskog sustava utječe na gospodarski rast pozitivno.
Anwar i Nguyen (2011)	Vietnam (1997-2006)	Panel	Otkrili su da postoji pozitivna odnos između ekonomskog rasta i razvoja financijskog sustava.
Zhang i dr. (2012)	China (2001–2006)	Regresija i dinamički panel	Autori su došli do spoznaje da razvoj financijskog sektora ima pozitivan učinak na gospodarski rast.
Al-Malkawi i dr. (2012)	UAE (1974-2008)	ARDL analiza	Spoznali su da postoji negativna veza između gospodarskog rasta i razvoja financijskog sektora i također dvosmjerna uzročnost između gospodarskog rasta i razvoj financijskog sektora.
Kagochi i dr. (2013)	Afričke zemlje (1991-2007)	Panel analiza	Spoznali su da je da je jednosmjerna uzročnost od gospodarskog rasta prema razvoju bankarskog sektora i dvosmjerna uzročnost između razvoja tržišta kapitala i

			gospodarskog rasta. Istraživanje je pokazalo pozitivan učinak tržišta kapitala na gospodarski rast, a indikatori koji mjere razvoj bankarskog sektora imali su neizvjesna učinak na gospodarski rast.
Adusei (2013)	Gana (1971-2010)	Korekcija vektorski greški	Otkrio je da razvoj financijskog sektora ima negativan učinak na rast u kratkom i dugom roku.
Deidda and Fattouh (2002)	119 razvijenih zemalja i zemalja u razvoju (1960-1989)	Cross sections, prag regresije (dvije skupine zemljama: s visokim i niskim prihodima)	Ne-linearni odnos između financija i gospodarskog rasta. Financije su značajna odrednica rasta u zemljama s visokim prihodima, ali beznačajno u zemljama s niskim prihodima.
Rioja and Valev (2004a)	74 razvijenih zemalja i zemalja u razvoju (1961-1995)	Panel analiza, dinamički panel(tri regije: niske, srednje i visoke razine financijskog razvoja)	Financije imaju veliki pozitivan učinak na rast srednje razvijenih regija. Utjecaj je pozitivan, ali učinak je manji u visoko razvijenim regijama, ali nije statistički značajan u slabije razvijenim regijama.
Rioja and Valev (2004b)	74 razvijenih zemalja i zemalja u razvoju(1961-1995)	Dinamički panel(tri regije: niske, srednje i visoke razine financijskog razvoja)	Financije ima snažan pozitivan utjecaj na rast produktivnosti u razvijenim gospodarstvima. U zemljama s niskim dohotkom se učinak financija na rast proizvodnje javlja preko akumulacije kapitala.
Shen and Lee (2006)	48 razvijenih zemalja i zemalja u razvoju (1976-2001)	Panel analiza, pooled OLS	Nelinearni invertni u obliku slova "U" odnos između financija (burzovne varijable) i gospodarskog rasta; razvoj banka je bolje opisana kao slabi odnos obrnutog "U"oblika.
Ergungor (2008)	46 razvijenih zemalja i zemalja u razvoju (1980-1995)	Presjeci, 2SLS s heteroskedastičnosti -dosljedni standardu greške	Veza je nelinearna između financija (bankarski sektor) i gospodarskog rasta. Zemlje koje imaju nepopustljiv sudski sustav rastu brže kada imaju više bankocentrični financijski sustav.
Huang and Lin (2009)	71 zemlja (1960-1995)	Presjeci, regresija praga (dva režima: u zemljama s visokim i niskim prihodima)	Nelinearna pozitivna veza između financija i gospodarskog rasta. Pozitivan učinak je više izražen u zemljama s niskim dohotkom nego u zemljama s visokim dohotkom.

Cecchetti and Kharroubi (2012)	50 razvijenih zemalja i zemalja u razvoju (1980-2009)	Panel analiza, poold OSL sa standardnim greškama	Financijski sektor ima utjecaj obrnuti "U" oblik na rast produktivnosti. Razvoj financijskog sektora dovodi do rasta produktivnosti i gospodarskog rasta.
Arcand i dr. (2012)	100 razvijenih zemalja i zemalja u razvoju (1960-2010)	Presjeci i panel analiza, parametarske procjene	Financije počinju imati negativan učinak na rast proizvodnje kada se krediti privatnom sektoru dosegnu razinu 100% BDP-a.
Nahla Samargandi, Jan Fidrmuc and Sugata Ghosh (2013)	52 srednje razvijene zemlje (1980-2008)	Panel analiza, dinamički panel model	Pokazali da razvoj financijskog sustava nema pozitivan lineran utjecaj na gospodarski rast. Taj utjecaj je obrnuti „U“ oblik ako gledamo dugoročno.

Izvor: autor

Kako bi se omogućio bolji pregled radova koji se bave pitanjem utjecaja financija na gospodarski rast, organizirat ćemo ih na sljedeći način:

1. na radove koji ukazuju na pozitivnu vezu između financija i gospodarskoga rasta
2. na radove koji ne ukazuju uvijek na pozitivnu vezu između financija i gospodarskoga rasta ili upućuju na to da ta veza ne postoji
3. na radove koji utvrđuju nelinearnost između financija i gospodarskoga rasta
4. na radove koji se temelje na istraživanju utjecaja na rast prema podatcima na razini gospodarskih područja i poduzeća.

3.2. Radovi koji ukazuju na pozitivnu vezu između financija i gospodarskoga rasta

Na prvo mjesto u ovu skupinu radova svakako treba staviti Barroov rad (1991.). Međutim, manjkavost mu je u tome što u istraživanje nije uključio indikatore financijskoga posredovanja. Nakon toga nastaju radovi Roberta Kinga i Rossa Levinea (1993.; 1993.a) koji su uveli nove

indikatore koji poslije postaju standardni indikatori financijskoga razvoja: udio „novca u širem smislu u BDP-u“, udio kredita banaka u ukupnoj imovini bankarskog sektora, udio kredita privatnim poduzećima u ukupnim kreditima i udio kredita privatnom sektoru u BDP-u.

Analizirali su 30 zemalja u razdoblju od 30 godina i došli do zaključka da financijski sektor ima pozitivan utjecaj na gospodarski rast. Oni su došli do zaključka da je moguće na temelju financijskoga razvoja raditi i predviđanja gospodarskog rasta i produktivnosti. Ovakva razmišljanja trpe i odgovarajuće kritike u smislu da razvijenost financijskoga sustava može biti u pozitivnoj korelaciji s rastom jer se i financijski sustav razvija uz pozitivna očekivanja budućeg ekonomskog rasta.

Levine potom (1998.) daje više pozornosti pravnim pokazateljima kao instrumentalnim varijablama kako bi se izdvojila egzogena komponenta bankovne razvijenosti. Kada su se uključile i druge varijable koje mogu utjecati na gospodarski rast, poput monetarne i fiskalne politike, edukacije, politička stabilnost…, rezultat je ostao isti. U ovom radu došlo se do saznanja da pravni sustav i pravno okruženje utječu na bankarski sektor. Isto tako, autor ne naglašava da njegovo istraživanje ne pokazuje da ekonomski rast ne utječe na bankovni sustav. (Ovu tvrdnju ne testira, ali ipak zaključuje da razvoj bankarskog sustava utječe na gospodarski rast.).

Levine dvije godine poslije (2000.) u svoje istraživanje uvodi i neke instrumentalne varijable (pokazatelje zakonodavnog i regulatornog sustava). I u ovom istraživanju Levine pokazuje pozitivnu vezu između financija i gospodarskoga rasta i time potvrdili rezultate od prije (King i Levine 1993., kao i King i Levine 1993.a). U ovom istraživanju autori idu korak dalje i savjetuju daljnje reforme u računovodstvu koje bi ojačale pravo vjerovnika, provedbu ugovora i računovodstvenu praksu kako bi se potaknuo razvoj financijskoga posredovanja i time ubrzao financijski rast.[44]

[44] Važno je bilo ove varijable uzeti u obzir jer postoje razlike u zakonskim sustavima među pojedinim državama. Te razlike proizlaze iz zakonskih okvira na kojim je sazdan zakonodavni sustav tih zemalja (angloamerički, njemački, francuski ili skandinavski okvir). Razlike se odnose na prava vjerovnika za prikupljanje kolaterala ili likvidaciju tvrtke u slučaju neplaćanja, smjenu direktora pri reorganizaciji poduzeća, posjedovanje visokog prioriteta u odnosu na druge vjerovnike u bankrotiranoj korporaciji. Zemlje njemačkog pravnog nasljeđa imaju bolje razvijene financijske posrednike. Engleska zakonska tradicija, međutim, ima zakone koji u većem stupnju naglašavaju prava vjerovnika nego francuska i njemačka zakonska regulativa ili pak skandinavskih zemalja. Za razliku od germanskih, francusko zakonsko naslijeđe ima najslabiju kvalitetu provođenja zakona. Englezi imaju i najbolje računovodstvene standarde. Treba naglasiti da ovi zakoni imaju izravan utjecaj na funkcioniranje financijskih posrednika. Stoga, prema mišljenju ovih autora, zemlje mogu ciljati reforme koje će osigurati da kreditori imaju povjerenje da će zakonski sustav brzo, transparentno i učinkovito izvršiti njihova potraživanja od dužnika i da će vanjski investitori imati lakši pristup informacijama visoke kvalitete i usporedivosti.

Zanimljiv je rad i Odedokuna (1996.) koji također u svome istraživanju potvrđuje pozitivnu vezu između financija i rasta. U okviru svoje analize koristio se regresijom i potvrdio hipotezu za 85 % zemalja na kojima je vršio istraživanje (uzorak se sastojao od 71 zemlje u razvoju u razdoblju između 1960. i 1980.). Pozitivnu vezu između financija i gospodarskoga rasta pokazali su i Benhabib i Spiegel (2000.), a u svome istraživanju upotrijebili su iste pokazatelje za mjerenje veličine financijskoga sustava kao King i Levine 1993., odnosno 1993.a. Rezultati istraživanja koje su dobili Fink i dr. (2005.) pokazuju jaku povezanost financija i rasta, a glavni se učinak na rast ostvaruje kanalima produktivnosti. Ovdje je potrebno naglasiti da njihov rad uzima u obzir, pored bankarskoga sektora, i aktivnosti na tržištu kapitala (kapitalizacija tržišta vrijednosnica te vrijednost izdanih dužničkih vrijednosnica u omjeru s BDP-om). Pored ovih istraživanja javljala su se istraživanja koja su obuhvaćala i neke druge pokazatelje kao što su uplitanje vlada u financijski sustav (Laporta i dr., 2002.), a zaključak je takva istraživanja da je veći stupanj javnog vlasništva banaka povezan s niskom razinom bankarskoga razvoja i manjom stopom gospodarskog rasta. Također, postoje istraživanja koja su uzimala veće vremensko razdoblje (Rousseau i Watchel, 1998.), a pokazala su da financije snažno utječu na gospodarski rast, odnosno na primjeru pet visokorazvijenih zemalja dokazan je snažan utjecaj financijskog sustava na znatnu industrijsku transformaciju. *Christopoulos* i Tsionas (2004.) utvrđuju utjecaj financijskog sustava na gospodarski rast i taj se utjecaj usmjerava od financijskog sustava na gospodarski rast, no taj se utjecaj ne utvrđuje dvosmjerno i za to ne postoje dokazi.[45]

Svi su ti autori u dokazivanju hipoteza koristili različite ekonometrijske metode (vremenske serije, panel-analize, presječne *cross-section* analize) i svi su oni radili svoja istraživanja na različitim zemljama (uzorcima) i potvrdili utjecaj financija na gospodarski rast.

Postoje radovi koji su u središte svoga istraživanja stavljali tržište kapitala i vezu s gospodarskim rastom. Na temelju tih istraživanja postavlja se pitanje o tome treba li financijski sustav razvijati u smjeru razvoja banaka i drugih posrednika ili ga treba razvijati kroz tržište vrijednosnih papira. Tako će se u ovom dijelu rada dati prikaz radova kojima je temelj istraživanja bio upravo ovaj dio financijskoga posredovanja.

---

[45] Botrić i Slijepčević (2006.) analizirale su vezu između razvijenosti bankarskoga sustava i rasta BDP-a u zemljama jugoistočne Europe i pokazale da je bankarski sektor u pozitivnoj vezi s gospodarskim rastom. Bogdan (2009.) je analizirao utjecaj financijskoga sustava na tranzicijskim zemljama i ustanovio pozitivnu vezu, ali su koeficijenti u regresijama bili mali te se utjecaj financijskoga sustava na ekonomski rast ne čini signifikantnim.

Atje i Jovanović (1993.) istražili su vezu između razvijenosti tržišta dionica i gospodarskoga rasta. Istraživanje je provedeno na 40 zemalja u trajanju od 1980. do 1988 primjenom *cross-country* analize i zaključak je da je utjecaj pozitivnog predznaka. Demergüç-Kunt i Levine (1996.a, prema Demergüç-Kunt i Levine, 2001.) pokazali su da zemlje s dobro razvijenim tržištem dionica imaju dobro razvijene i ostale segmente financijskog sustava, i da je, dugoročno gledano, volatilnost povrata na dionice manja u zemljama koje imaju otvorenija kapitalna tržišta. Levine i Zervos (1996.) u svojim su istraživanjima za indikatore (u procjeni veze tržišta dionica, stope rasta i stope tehnološkog razvoja) uzeli odnos vrijednosti prodanih dionica i GDP-a i omjer između ukupne vrijednosti prodanih dionica i kapitalizacije tržišta dionica. Za indikatore rasta uzeli su ekonomski rast, rast akumulacije kapitala i rast produktivnosti. Iz navedena istraživanja došli su do zaključka da je razvoj tržišta kapitala u pozitivnoj korelaciji s budućim rastom gospodarstva, a iz toga su zaključili da se banke i tržište kapitala međusobno nadopunjuju. Wurgler (2000.) u svom je istraživanju došao do zaključka da tržište kapitala u određenim situacijama bolje vrši alokaciju sredstava od banaka dok su se u nekim slučajevima banke pokazale učinkovitijima. Bekaert i dr. (2001.) u svojim su istraživanjima također potvrdili pozivnu vezu između tržišta dionica i gospodarskog rasta.

Arsetis i dr. (2001.) pokazali su da tržišta dionica mogu pridonijeti rastu proizvoda u dugom roku, ali u manjoj mjeri nego banke. Oni zaključuju da bankocentrični financijski sustavi potiču dugoročni rast bolje od tržišnocentričnih sustava, a takvo razmatranje objašnjavaju volatilnošću tržišta dionica i njezinu utjecaju na rastuću opću nesigurnost koja rezultira neučinkovitom alokacijom resursa i pritiskom na rast kamatnih stopa te negativnim učinkom na investicije. Oni predlažu da razvoj tržišta kapitala ide usporedo s razvojem bankarskog tržišta jer se razvoj tržišta dionica može nepovoljno reflektirati na gospodarski rast ako se događa na štetu razvoja bankovnoga sustava. Calderón i Liu (2003.) analizirali su utjecaj financijskoga sustava i gospodarskoga rasta u oba smjera i zaključili da je utjecaj jači na strani financijskog razvoja nego obratno. Christopolulos i Tsionas (2004.) analizirali su deset zemalja u razvoju i pokazali pozitivan odnos financijskog sustava na gospodarski rast u dugoročnom razdoblju. Chang i Caudill (2005.) također su ukazali na pozitivnu vezu između financijskog sustava i rasta (na primjeru Tajvana), a do istih su rezultata došli i Rousseau i Wachtel (2002b.) na pet industrijaliziranih zemalja u razdoblju između 1870. i 1929. godine. Shan (2005.) je u istraživanju na jedanaest zemalja došao do zaključka da postoji malen utjecaj financijskoga razvoja na gospodarski rast.

Najia Saqib u svom radu „Impact of Development and Efficiency of Financial Sector on Economic Growth: Empirical Evidence from Developing Countries“ (2013.) opisuje analizu razvoja i učinkovitost financijskog sustava. Dokument koristi tzv. *cross-country* analizu u razdoblju između 2005. i 2009. Rezultati pokazuju da razvijen i učinkovit financijski sustav i signifikantno pozitivno utječe na gospodarski rast.

Moses Sindani u svom radu „The Impact of Financial Sector Deepening on Economic Growth in Kenya“ (2013.) također potvrđuje da razvoj financijskog sustava potiče gospodarski rast povećanjem učinkovitosti i investicijama.

Gambacorta, Yang i Tsatsaronis (2014.) istraživali su utjecaj razvoja financijskoga sustava na gospodarski rast. Prema njima i banke i tržišta kapitala povećavaju i utječu na gospodarski rast, ali do određene razine. Iznad te razine povećanje kreditiranja i tržišnog financiranja ne utječu na daljnji gospodarski rast.

Cournède, B., O. Denk and P. Hoeller (2015.), pokazuju da financije su jako važane za gospodarski rast, ali također može biti previše financija je osnovna premisa od koje polazi ovo istraživanje. Ova studija istražuje u periodu od pedeset godina na podacima za zemlje OECD-a da se dođe do odgovora na pitanje što je uloga financijskog sektora za gospodarski rast . U proteklih pedeset godina, kredit od banaka i ostalih posrednika stanovništvu i poduzećima je narasla tri puta brže nego gospodarske aktivnosti. U većini zemalja OECD-a, daljnje širenje je vjerojatno da će usporiti, a ne da će razvoj financijskog sustava pojačati rast. Više krediti privatnom sektoru usporava rast u većini zemalja OECD-a, ali više financiranja putem tržišta kapitala . Krediti imaju jači utjecaj na rast ali oni koji idu poduzećima a ne stanovništvu rezultat je ovog istraživanja.

Boris C. and Oliver D. su u svom radu “*Finance and Ecomoic Growth in OECD and G20 Countries”* iz 2015.godine pokazali ulogu financijskog razvoja i njegovog utjecaja na gospodarski rast u bivšim komunističkim zemljama središnje i istočne Europe. Zemlje iz uzorka koje su imale nerazvijen financijski sustav u komunizmu, daju interesantne nalaze veze financijskog sustava i gospodarskog rasta. Istraživanje pokazuje da krediti privatnom sektoru imaju pozitivan efekt na rast u odabranim zemljama. Isto tako, visoka inflacija može poništiti pozitivne efekte na rast u odabranim zemljama. Indikatori koji su korišteni u ovom istraživanju su krediti privatnom sektoru, kamatni *spread*, troškovi poslovanja bankarskog sektora, koncentracija.

Zaključak ovog istraživanja jest da treba biti oprezan kod analize i zaključivanja jer zemlje iz uzorka imaju relativno slabo razvijen financijski sustav i samim time slabu konkurenciju u bankarstvu što u konačnici može umanjiti efekt financijskog razvoja na gospodarski rast.
Glavni zaključak da krediti privatnom sektoru imaju pozitivan i imaju veliki utjecaj na gospodarski rast. Visoki kamatni *spread*-ovi imaju negativan utjecaj na gospodarski rast. Slijedeći zaključak jest da nato kamatna marža ne utječe na gospodarski rast a da troškovi jesu. Isto tako, visoka koncentracija banaka dovodi do slabijeg rasta (zbog visokih kamatnih *spread*-ova).

3.3. Radovi koji ne pokazuju uvijek pozitivnu vezu između financija i gospodarskog rasta ili upućuju na nepostojanje te veze

Konstatirali smo da postoje brojni radovi čiji rezultati pokazuju da financijski sustav ne utječe uvijek pozitivno na gospodarski rast. Takva su istraživanja proveli De Gregorio i Guidotti (1995.) na isti način kao King i Levine (1993. i 1993.a) i to na 98 zemalja u razdoblju od 1960. do 1985. koristeći jedan pokazatelj: udjel kredita privatnom sektoru u BDP-u. I oni su utvrdili pozitivnu vezu između financija i rasta, ali su primijetili da ona varira ovisno o regijama, vremenskom razdoblju i razini dohotka. Čak su došli i do zaključka da postoji negativna korelacija za zemlje Latinske Amerike, a kao glavni razlog autori navode uvjete neodgovarajućeg regulatornog okruženja i velike inflacije. Dimetriades i Hussein (1996.) također su proveli istraživanje utjecaja financija na rast uzevši uzorak od 16 zemalja[46] u razdoblju od 1960. do 1990. Oni su došli do zaključka da je utjecaj za različite zemlje različit te su zaključili da gospodarski rast u nekim zemljama izaziva financijski razvoj. Također, oni zaključuju da i razlike u razvijenosti financijskoga sustava mogu biti preslika različitih politika, institucionalnih razlika i njihovih različitih primjena. Beck i dr. (2000.) pokazali su da se utjecaj financijskog sustava na gospodarski rast pokazao kroz povećanje produktivnosti, a ne kroz povećanje kapitala. Shan i dr.(2001.) su koristili vremensku seriju na devet zemalja OECD-a i Kinu, no nisu potvrdili pozitivan utjecaj financija na rast. Međutim, u trima su slučajevima

[46] Kostarika, Salvador, Grčka, Gvatemala, Honduras, Indija, Koreja, Mauricijus, Pakistan, Južna Afrika, Španjolska, Šri Lanka, Tajland, Turska i Venezuela.

uočili utjecaj gospodarskog rasta na financije. Rousseau i Wachtel (2002.a) u svojim su istraživanjima pokazali da razvoj financijskoga sustava pozitivno utječe na gospodarski rast samo u slučajevima male inflacije. Moreover, Rioja i Valev (2004.a) radili su istraživanje slično Becku i dr. (2000.) i došli do zaključka da je pozitivan predznak financijskog razvoja, mjeren kroz veličinu financijskog sustava, i utjecaj na gospodarski rast evidentan samo u zemljama s visokim i srednjim dohotkom. Rioja i Valev (2004.b) u svom su istraživanju pokazali da postoji prag razvijenosti financijskoga sustava prije nego što povećanje u veličini tog sustava ima negativan učinak na gospodarski rast. Loayaza i Rancier (2002.) svojim su istraživanjima upozorili na različitost između kratkoročnog i dugoročnog utjecaja financija na rast. Oni su u panel-analizi pokazali da financije imaju negativan predznak u kratkoročnom rastu, a pozitivan u dugoročnom. Boulila i Trabelsi (2004.a) radili su istraživanja na uzorku samo jedne zemlje (Tunisa) u razdoblju od 1963. do 1987. i pokazali da financije ne utječu na gospodarski rast te zaključili da je ta veza suprotna, tj. da gospodarski razvoj utječe na razvoj financijskoga sustava.

Primijenivši analizu vremenske serije, Shan (2005.) je uradio istraživanje na jedanaest zemalja u razdoblju od 1985. do 1998. (uzimao je tromjesečne podatke) te utvrdio da financije ne uzrokuju gospodarski rast. Nasuprot tomu Zhang i Kim (2007.) u svojem su istraživanju panel-analizom na uzorku koji je bio identičan Levineu i dr. (2000) došli do potpuno suprotnih zaključaka, tj. da nema dokaza tumačenju da financije uzrokuju rast. Zapravo, došli su do zaključka da postoje znatne indikacije da gospodarski rast prethodi financijskom razvoju. Koiovu (2005.) u svojim istraživanjima na uzorku od 25 zemalja u razdoblju od 1993. do 2000. pokazuje da bankarski sektor ne promiče gospodarski rast sam po sebi. Naime, ona u svom istraživanju ne pronalazi čvrstu vezu između količine kredita privatnom sektoru i ekonomskom rastu. Naprotiv, rezultati pokazuju kauzalnost između ekonomskog rasta i rasta kredita. Mehl i dr. (2005.) također ne pronalaze činjenice koje bi ukazale na pozitivan utjecaj financija na rast zemalja jugoistočne Europe u razdoblju između 1993. i 2003.

Shen i Lee (2006.) u svojim su istraživanjima došli do zaključka da razvoj bankarskoga sektora ne utječe na gospodarski rast, odnosno da ima negativan predznak dok je razvoj tržišta dionica u pozitivnom odnosu ako se koristi varijabla prometa dionicama.[47] Na uzorku srednjoistočnih

[47] Njihovi se zaključci mogu svesti na sljedeće: 1. razvoj tržišta dionica ima pozitivan učinak na rast BDP-a *per capita* dok je utjecaj bankovnog razvoja negativan; 2. uvjetne varijable, kao što su financijska liberalizacija, visok dohodak i dobra zaštita dioničara, mogu ublažiti učinak negativnog razvoja bankarskog sustava na gospodarski rast (u zemlji koja ima visok dohodak i zaštitu dioničara razvijenost bankarskog sustava čak potiče rast); 3. uvjetne varijable (kao što su srednja razina dohotka, smještaj u Latinskoj Americi, supsaharskoj Africi i istočnoj Aziji,

zemalja i mediteranske Afrike, Boulila i Trabersi (2004.b) došli su do rezultata da gospodarski rast utječe na razvoj financija, ali ne i obrnuto. Al-Awad i Harb (2005.) uzeli su uzorak od 10 zemalja Srednjega istoka te došli do sličnih zaključaka, ali na kratkoročnoj razini. Istražujući vezu između financijskog razvoja i gospodarskog rasta Odhiambo (2008.) je, koristeći „proxi" indikatore za financijski razvoj, došao do zaključka da financijski sustav prati gospodarski rast, ali ne i obrnuto. Blanco (2009.) u svojoj studiji na uzorku Latinske Amerike u razdoblju između 1961. i 2005. dolazi do rezultata da financije ne utječu na gospodarski rast i zaključuje da je veza obrnuta. Slično su istraživanje proveli Hurlin i Venet (2008.) potvrdivši iste rezultate, tj. pozitivan utjecaj gospodarskog rasta na financijski sustav. Marcelo i Ernesto (2010.) proveli su opsežno istraživanje koje se odnosilo na pronalazak nove veze između financijskog razvoja i gospodarskog rasta te došli do rezultata da financijski razvoj statistički nema veći značaj na gospodarski rast i da je, prema njima, veličina ekonomije statistički značajna determinanta rasta.

Arcand, J.-L., E. Berkes i U. Panizza (2012) - ovaj rad ispituje da li postoji prag iznad kojeg financijski razvoj više nema pozitivan učinak na gospodarski rast. Autori su koristili različite empirijske pristupe koji pokazuju da tu doista može biti "previše" financije. Konkretno, njihovi rezultati ukazuju na to da financije počinju imati negativan utjecaj na rast proizvodnje kada se krediti privatnom sektoru dođu do 100% BDP-a. Pokazali su da su njihovi rezultati u skladu s zanemarivim efektom na financijski.

Beck, T. (2012) je u svom istraživanju pokazao da da je učinkovit financijski sustav ključno za ekonomski razvoj i rast. Financijski sustav, međutim, također je predmet ekspanzije i može biti slabo otporan na rizike što može nepovoljno utjecati na gospodarstvo. Nadalje, politička struktura društva, često unaprijed određena povijesnim iskustvom, ključno je za strukturu i razvoj financijskog sustava.

Empirijski, dugoročno financijsko produbljivanje se odnosi na brži gospodarski rast i kratkoročni kreditni bum se odnose na veće vjerojatnosti sustavnog problema u bankarstvu. Prema ovim autorima, ako imamo sustav koji funkcionira i financijske institucije i tržišta kao takva će poduprijeti razmjenu dobara i usluga i poticati dugoročne investicije i time i rast. Fokus na sve veće upravljanje je bitno ne samo za središnje banke i

bankovne i valutne krize, dobra zaštita vjerovnika i veće korupcije) pojačavaju negativne učinke bankarskog razvoja; 4. kondicionalne varijable (srednje visoka razina dohotka, smještaj u Latinskoj Americi, supsaharskoj Africi i istočnoj Aziji) naglašavaju pozitivne učinke razvoja tržišta dionica; 5. financijska liberalizacija slabi pozitivne učinke razvijenosti tržišta dionica na gospodarski rast, no uvjetne varijable (visoka razina dohotka, bankovne i valutne krize, antidirektorski indeksi, tj. indeks koji pokazuje stupanj u kojem zakoni zemlje štite prava malih dioničara, indeks korupcije i zaštita vjerovnika) nemaju učinka na razvoj tržišta dionica.

regulatorna tijela, već i za financijske institucije i njihovih odnosa s političkim i regulatornim tijelima.

Laura C, Saul D.H. and Jeffrey M. u svom istraćživanju iz 2012.godine naziva *" Financial Development and Economic Growth in Transition Economies: Empirical Evidence from the CEE and CIS Countries"*Ovo istraživanje pokazuje da su financijski sustavi bili ključni element dugoročnog rasta u OECD zemljama kao i G20 zemalja u proteklih pedeset godina ali s zaključkom da može biti „previše financija". Istraživanje pokazuje da trenutni nivo kredita kućanstvima i kredita poslovnim subjektima i daljnji njihov rast usporava gospodarski rast a ne ubrzava ga. Stav da više kredita usporava rast podržan je od nove empirijske metodologije koja iskorištava promjene u financijskoj regulaciji u različitim odabranim zemljama i vremena kao izvor egzogene varijacije financijskih veličina. Empirijska analiza ističe pet faktora koji pokazuju da više kredita usporava rast: (1) pretjerana financijska deregulacija, (2) veći rast kredita izdanih od strane banaka u odnosu na druge posrednike, (3) too-big-to-fail garancija od strane vlada za velike financijske institucije, (4) loša kvaliteta kredita i (5) nerazmjeran rast kredita kućanstvima u usporedbi s onima danim u poslovne svrhe.

Ovo istraživanje pokazuje, isto tako, da ekspanzija tržišta kapitala dovodi generalno do većeg i bržeg gospodarskog rasta.

Nekoliko je zaključaka iz ovog istraživanja a od kojih će u svrhu ovog rada biti nabrojani samo neki:[48]

- Dublji financijski razvoj, inovacije i financijska integracija su do ovog istraživanja viđenje kao donosilac bolje efikasnosti i jačeg gospodarskog rasta. Velika recesija koja je dovela do ogromnih gubitaka i povećanja nezaposlenosti u mnogim zemljama je isto tako potakla pitanja o utjecaju financija na gospodarski rast. Indikatori koji mjere financijsku veličinu, kao što su krediti i tržišna kapitalizacija su enormno porasli u promatranom razdoblju. Slično tome, strukturne financijske aktivnosti su doživjele duboku transformaciju. Jedan od primjera je ogromno prebacivanje privatnih kredita sa poslovnih namjena u hipotekarne. Ove promjene su se desile u periodu u kojem trend gospodarskog rasta usporava u promatranim zemljama.
- Ovo istraživanje revidira vezu između razvoja financijskog sustava i gospodarskog rasta u OECD zemljama kao i G20 zemljama. Za analizu je korišten panel model i to GMM procjenitelj. Isto tako, ovo istraživanje promatra efekte promjene u financijskoj strukturi i na to koji su međunarodni financijski centri imali utjecaj na gospodarske performanse.

[48] Za one koji žele vidjeti sve zaključke ovog istraživanja predlaže se čitanje članka u cijelosti.

- Vezu financija i gospodarskog rasta su promatrali kroz tri pokazatelja financijske veličine: (1) dodana vrijednost financija, (2) krediti banaka i drugih financijskih institucija privatnom sektoru i (3) tržišna kapitalizacija i sve veličine su relativne u odnosu na BDP.
- Rezultati istraživanja su pokazali da dodana vrijednost financija i krediti imaju negativan utjecaj na gospodarski rast, dok s druge strane indikator tržišna kapitalizacija pokazuje pozitivnu vezu s rastom
- Više kapitala i manje kredita bi povećalo gospodarski rast i dovodilo bi do toga da se privreda prebacuje na financiranje putem tržišta kapitala

Beck, R., G. Georgiadis and R. Straub (2014) smatraju da ekspanzija kredita ima pozitivan učinak na rast proizvodnje po stanovniku samo do određene točke. Iza tog praga utjecaj financija na rast nije statistički značajna više. Pokazali su, međutim, da je procijenjen nelinearni odnos može proizlaziti iz zanemarivanja nekih drugih čimbenika a koji se nisu razmatrali u literaturi do sada. Ti čimbenici mogu imati negativan utjecaj na rast u zrelim financijskim sustavima, a uključuju magnitudu financijskih ciklusa, i uključuju ne posredničke aktivnosti bankarskih poslovnih modela.

Law, S. H. and N. Singh (2014), u svom istraživanju daju nove dokaze o odnosu između financija i gospodarskog rasta korištenjem inovativni dinamična tehnika u analizi. Uzorak se sastoji od 87 razvijenih i nerazvijenih zemljama.

Empirijski rezultati pokazuju da postoji prag učinak u odnosu financije-rast. Konkretno, možemo vidjeti da razina financijskog razvoja je korisna za rast samo do određeni praga; iznad razine praga daljnji razvoj financija sklon je negativno utjecati na rast. Ovi rezultati pokazuju da je više financijski ne mora nužno biti dobro za gospodarski rast i vrhunac da je " optimalna " razina financijskog razvoja je važnije za brži i veći rast.

Angeles, L. (2015) u svom istraživanju pokazuje da kreditna ekspanzija je povezana s bržim gospodarskim rastom i većom pojavom financijske krize - rezultata za koji se čini da se međusobno kontradiktoran. U radu je urađen napredak za objašnjenje ovih rezultata odvajanjem kredita za privatni sektor na kredite poduzećima i kredite stanovništvu. Empirijska analiza pokazuje da su krediti poduzećima zaslužni za pozitivan učinak na rast, dok je pojava krize je uglavnom izazvana zbog kredita stanovništvu. Događaji u posljednjih deset godina, gdje je brza kreditna ekspanzija dovela do krize i vrlo malo do rasta, može se shvatiti kao promjena u sastavu kredita koji su plasirani stanovništvu.

Langfield, S. and M. Pagano (2015), u sovjem istraživanju pokazuju da europska financijska struktura je postala jako bankocentrična (u gotovo svim europskim zemljama) - daleko više nego u drugim svjetskim gospodarstvima gdje je daleko više razvijeno tržište kapitala. Ovo istraživanje pokazuje da je povećanje u smislu veličine bankarskog sustava u odnosu na tržišta kapitala povezan s više sustavnim rizikom i manje utječe na gospodarski rast, posebno tijekom krize tržišta nekretnina. U zaključku rada raspravlja se o političkom rješenju za europsku perspektivu u smislu da se smanji "pristranost prema bankama", a koja uključuju smanjenje regulatorne naklonjenosti prema bankama, dok s druge strane je potrebno poduprijeti razvoj tržišta kapitala.

3.4. Nelinearnost između financija i gospodarskoga rasta

Postoji izvjestan broj istraživača koji su radili na analizi veze između financija i gospodarskoga rasta. Tako su Berthelemy i Varoudakis (1996.) proveli istraživanje na uzorku od 95 zemalja u razdoblju od 1965. do 1985. godine. Dokazali su da razvijenost financijskog sustava nema nikakav utjecaj na rast gospodarstava s visokom početnom razinom ljudskoga kapitala i niskom razinom financijske razvijenosti (varijabla M3 u BDP-u). U njihovu modelu jedno od ravnotežnih stanja vodi u zamku siromaštva kada financijski sektor nestaje i gospodarstvo stagnira. Drugo ravnotežno stanje obilježava pozitivan endogeni rast i normalan razvoj financijskoga posredovanja. Deida i Fattouh (2002.) proveli su istraživanja prema Kingovim i Levineovim podatcima (1993., 1993.a) uz primjenu regresijskog modela s pragovima te dolaze do zaključka da u zemljama s niskim dohotkom ne postoji statistički značajna povezanost između financija i gospodarskoga rasta dok je u zemljama visokog dohotka ta veza pozitivna i visoko značajna. Favara (2003.) u svome istraživanju potvrđuje da je veza između financija i rasta nelinearna. I financijski sustav ima pozitivan učinak na rast samo na srednjim razinama financijskoga razvoja. Koristeći se modelom praga s instrumentalnim varijablama i Huang i Lin (2009.) prema podacima Levinea, Loayza i Becka (2000.) potvrđuju pozitivnu vezu između financijskoga razvoja i gospodarskoga rasta. Ta je veza izraženija u zemljama s višim dohotkom i u tim zemljama financijski razvoj ima jači učinak na akumulaciju kapitala i rast produktivnosti. Do sličnog rezultata istraživanja dolaze Masten i dr. (2008.) koji se u svojemu istraživanju

koriste razinom financijskog razvoja kao varijablom praga i pronalaze učinke praga: manje razvijene zemlje imaju više koristi od razvijanja financijskoga sektora nego razvijena gospodarstva.

Arcand i dr.(2012) rade istraživanej na 100 razvijenih zemalja i zemalja u razvoju (1960.-2010.) . na temelju ovog istraživanja dolaze do zaključka da financije počinju imati negativan učinak na rast proizvodnje kada se krediti privatnom sektoru dosegnu razinu 100% BDP-a.

Nahla Samargandi, Jan Fidrmuc and Sugata Ghosh (2013) su radili istraživanje na 57 zemalja koje su bogate naftom. Došli su do zaključka da Pokazali da razvoj financijskog sustava nema pozitivan lineran utjecaj na gospodarski rast. Taj utjecaj je obrnuti „U“ oblik ako gledamo dugoročno.

3.5. Radovi koji su temeljeni na istraživanju utjecaja na rast na podatcima na razini grana poduzeća

Rajan i Zingales (1998.) su na podatcima vremenskoga presjeka na razini industrijskih grana pokazali da industrije koje se jače oslanjaju na eksterno financiranje rastu brže u zemljama s razvijenim financijskim sustavima. Njihov se uzorak sastoji od 38 industrija u 41 zemlji u razdoblju od 1980. do 1990. Zaključili su da se učinak financijskoga razvoja primarno očituje kroz rast broja poduzeća u ekonomiji, a manje kroz rast prosječne razine postojećih poduzeća. Manning (2003.) u svojim istraživanjima otkriva da se prethodni rezultati ekonomskog rasta u azijskim zemljama ne pripisuju financijskim čimbenicima.

Beck i dr. (2000.) došli su do sličnih rezultata i njihova istraživanja pokazuju da će poduzeća puno vjerojatnije rasti po stopama koje zahtijevaju eksterno financiranje u ekonomijama u kojima je pravni sustav pogodan za razvoj aktivnog tržišta kapitala i u ekonomijama razvijenih banaka.

Demergüc-Kunt i Maksimović (2002.) na temelju podataka na razini poduzeća zaključuju da tržište kapitala i bankarski sustav različito djeluju na sposobnost poduzeća da osiguraju eksterno financiranje. Ukupna razvijenost financijskoga sustava općenito poboljšava mogućnosti

financiranja. Razvijenost tržišta kapitala vezana je uz mogućnost dugoročnog financiranja dok je razvijenost bankarskog sustava vezana uz dostupnost kratkoročnog financiranja.

Coricelli i Roland (2008.) proširuju istraživanje Rajana i Znigalesa (1998.) kako bi proučili potencijalne asimetrične učinke financijskih tržišta na gospodarski rast. Autori nisu mogli naći statistički značajan učinak razvoja financijskog sustava na rast industrije. Oni otkrivaju da financijska tržišta imaju važnu ulogu tijekom pada proizvodnje: industrije koje su relativno ovisne o vanjskom financiranju padaju relativno brže u zemljama s nerazvijenim financijskim sustavom, mjerenim udjelom kredita u BDP-u. Iz toga se zaključuje da kreditna tržišta imaju veću ulogu u ublažavanju pada proizvodnje nego u poticanju rasta, što podupire mišljenje da je učinak financijskog razvoja na rast asimetričan – kreditna su tržišta najvažnija tijekom recesija.

Analizom predstavljenih istraživanja možemo zaključiti sljedeće:

- najveća preprjeka u napretku istraživanja utjecaja financijskoga sustava na gospodarski rast jest u nepostojanju odgovarajućih podataka kojima bi se moglo ocijeniti učinkovitost u posredovanju zbog čega se možda dosad dolazilo do pogrješnih zaključaka
- dosadašnja su istraživanja ostavila prilično velik broj neriješenih pitanja, što izaziva skeptičnost prema davanju prednosti mjerama politike usmjerenima prema financijskom sustavu s ciljem uzrokovanja gospodarskoga rasta
- manje se pozornosti pridaje naglašavanju činjenici da se teško može razdvojiti pojedinačan utjecaj financijskog sustava na gospodarski rast od drugih povezanih činitelja
- u stagnirajućem gospodarstvu teško je reći što ometa rast – je li to nedostatak financijskih sredstava ili manjak poduzetništva ili nešto treće
- autori ne razlikuju financijski razvoj koji se temelji na potrošačkim kreditima od onog koji se temelji na ulaganju u proizvodnju (treba razlikovati kredite poduzećima kao indikator i kredite stanovništvu)
- gotovo svi zanemaruju mračnu stranu financija, tj. financijske krize, a ona također utječe na gospodarski rast

- ne pridaje se dovoljno važnosti razlikovanju tranzitornog rasta, koji se temelji na neodrživu dugu, i onog održivog koji se temelji na porastu proizvodnje
- važno je spoznati kada i u kojim okolnostima financijski sustav ima pozitivan utjecaj na gospodarski rast te što određuje njegovu učinkovitost u tom kontekstu.

IV. KONCEPTUALNI MODEL UTJECAJA FINANCIJSKOG SUSTAVA NA GOSPODARSKI RAST

Značenje financijskog sustava za proces za gospodarski rast i razvoj u cjelini nije jednoznačno određeno. Na jednoj strani financijskom sustavu se osporava uloga u mogućem povećanju učinkovitosti, na drugoj se, pak, strani financijskom sustavu predaje odlučujuća uloga u upravljanju procesom reprodukcije i razvoja nacionalnog gospodarstva. Bez obzira na to o kojoj grupi ekonomista se radi, nitko danas ne dovodi u pitanje važnost ekonomske politike, pri čemu se financijskom sustavu i financijskoj politici pridaje odlučniji značaj i odlučnija uloga. Sustavni pristup financijskom sustavu omogućuje i sustavnu financijsku politiku. Brz razvoj finansijskog sustava u industrijski razvijenim zemljama, a naročito u SAD-u, zahtjevao je i razvoj sustava suvremenih financijskih institucija koje su adekvatne potrebama, prije svega, investitora, a zatim i korisnika kapitala. Takav zahtjev se postavljao kao neophodan, jer je financijski sustav organiziran na konzervativan način postao kočnica daljnjeg razvoja tržišnih odnosa i financijskog sustava uopće. Reorganiziranje i prilagođavanje financijskog sustava novonastaloj situaciji i novim potrebama je bilo sporog karaktera iz mnogo razloga, od kojih je najvažniji bio razlog neizvjesnosti i rizika u poslovima sa novcem i kapitalom, što novac i kapital po prirodi stvari nose sa sobom. Tim činjenicama se može zahvaliti što su zemlje sa razvijenim financijskim sustavima obogatile svoju financijsku strukturu nizom novih, daleko fleksibilnijih i efikasnijih institucija od konzervativnih i sporo prilagodljivih financijskih organizacija. Najtipičniji predstavnici ovih efikasnih institucija na bankarsko – finansijskom tržištu su svakako mirovinski fondovi.

4.1. Polazišta i sadržajne odrednice za formiranje modela veze između financijskog sustava i gospodarskog rasta

Brojna literatura(teoretska i praktična istraživanja) govori o tome kako financijski sustav utječe na gospodarski rast, pa tako počevši već od pionira ovog razmišljanja Joseph-a Schumpetera (1934.). Naravno, prema Schumpeteru financijski sustav ima pozitivan utjecaj na gospodarski rast kao rezultat njegovog utjecaja na produktivnost i tehnološki napredak. Bagehot je istraživao vezu financijskog sustava i gospodarskog rasta već u 19 stoljeću.Ovo i slična istraživanja se posebno produbljuju 90-ih godina prošlog stoljeća. I nakon više od 30 godina istraživanja opet

ne postoji jedinstveno stajalište o međuovisnosti finanijskog sustava i gospodarskog rasta (pregled istraćivanja na ovu temu data je u prethodnom dijelu rada).
Mnoštvo relevantnih teoretskih razmatranja bilo je razvijeno nakon što se razvila endogena teorija rasta. Općenito, AK model koji se razvio iz endogene teorije rasta je otkrio tri kanala rasta kojim financijski sustav utječe na gospodarski rast. Prvi, financijski sustav ako je dovoljno razvijen može povećati produktivnost investicija. Drugi, efikasniji financijski sustav smanjuje transakcijske troškove samim time povezuje i povećava štednju sa produktivnijim investicijama. Treće, financijski sustav može značajno utjecati na depozitne kamate, ili ih povećavati ili smanjivati (Pagano, 1993.).

Greenwood i Jovanović (1990.), Levine (1991.), Bencivenga i Smith (1991.), kao i Saint-Paul (1992.) su prezentirali svoje teoretske modele po kojima efikasan financijski sustav povećava kvalitetu investicija i samim time utječe na gospodarski rast.
Štednja nije u cijelosti alocirana u investicije iz jednostavnog razloga što dio se potroši na transakcijeske troškove. Blackburn i Hung (1996.) su u svome istraživanju došli do spoznaje da financijski sustav utječe na gospodarski rast iz najmanje dva načina. Bez intermedijacije financijskog sustava svaki investitor bi morao o svome trošku provoditi monitoring što bi dovelo do povećana vremena izvršenja investicije a samim time i troškova. Ako je financijski sustav dovoljno razvijen, monitoring investicija može biti delegiran istome. U tom slučaju, transakcijski troškovi se smanjuju i veći dio štednje je alociran na investicije koje donose novi rast. Blackburn i Hung su također došli do saznanja kako jedna zemlja može pasti u zamku gdje je karakterističan slab rast i slabo razvijen financijski sustav. To se događa iz razloga što je početni tehnološki razvoj u nekoj zemlji nizak a onda i očekivani razvoj novih ideja ostaje nizak. U tom slučaju troškovi monitoringa investicija postaju previsoki za financijsku intermedijaciju da ih organiziraju i, dakako, gospodarski rast ostaje na niskoj razini. Prema endogenom modelu rasta što je veća štednja veći je i gospodarski rast.

Pored teoretskih razmatranja utjecaja financijskog sustava na gospodarski rast, postoje mnogi empirijski radovi na ovu temu. Među prvim značajnijim istraživanjima svakako treba spomenuti istraživanje King-a i Levine-a (1993.) a koji su uradili istraživanje na 80 zemalja. U ovom istraćivanju koristili su četiri indikatora: prvi pokazatelj je bio – udio likvidnih sredstava u BDP-u; drugi pokazatelj bio je udio komercijalnih banaka u odnosu na centralnu u alokaciji kredita; treći pokazatelj jest krediti privatnom sketoru u ukupnom iznosu kredita i četvrti indikator je bio udio kredita privatnom sketoru u BDP-u. U istraživanju se pokazala snažna veza svih

indikatora sa gospodarskim rastom. Kasnije je bila lavina istraživanja poput onog od Levine i Zervos-a (1996., 1998.) koji su pored bankarskog sustava promatrali i tržište kapitala. U svome istraživanju su došli do spoznaje o visokoj korelaciji između indikatora tržišta kapitala i gospodarskog rasta.
Svakako je potrebno naglasiti da je veliki broj istraživanja koja su došli do rezultata da neki indikatori nemaju dovoljnu statističku značajnost utjecaja na gospodarski rast kao i razlike u rezultatima ovisno o tome koliko su odabranje zemlje razvijene (dosegnuti stupanj razvoja kako gospodarskog, tako i financijskog sustava).

Kod razmatranja indikatora financijskog sustava postoje različita mišljenja pa tako i kritike na iste (svaki od indikatora može biti kritiziran i svaki sam po sebi nije idealan). Npr. veličina kredita privatnom sektoru ne govori o efikasnosti financijskog sustava. Povećanje kreditiranja može doći usljed kreditne ekspanzije kad se očekuje veći rast. Ali ipak većina tih istraživanja je pokazala da veličina financijskog sustava utječe na gospodarski rast. Upravo zbog ovoga zemlje s visokim dohotkom ne samo da imaju veći financijski sustav nego je to slučaj kod zemalja srednjeg i niskog dohotka, nego je i efikasnost financijskog sustava veća.
Premda ekonomisti odavna razmišljaju o utjecaju razvijenosti financijskog sustava na gospodarski rast, pregled navedenih radova navodi na zaključak da rasprava o utjecaju razvijenosti financijskog sustava na gospodarski rast još nije završila. Naizgled najlogičnije se čini da razvijen financijski sustav potiče štednju koja je važna za financiranje investicija u fizički i ljudski kapital i poticanje tehnološkog napretka, a također obavlja i još nekoliko funkcija (korporativna kontrola, olakšavanje razmjene, i dr.) kojima potiče gospodarski rast. Kao što je predstavljamo u prethodnom dijelu ovog rada, postoje naznake u korist, ali i protiv navedene teze. Premda je utjecaj financijske razvijenosti na gospodarskirast još uvijek top tema među svjetskim ekonomistima, mora se istaknuti da još nije u potpunosti određeno uzrokuje li financijski razvoj gospodarski rast ili je on posljedica gospodarskog rasta (Bogdan, 2009.).

Ekonomisti su suglasni s mišljenjem da su dva glavna kanala gospodarskog rasta akumulacija kapitala (fizičkog i ljudskog) i tehnološke inovacije, ali u ekonomskoj analizi poznata su naročito tri modela ekonomskog rasta: model rasta Solowa (1956), Mankiw-Romer, Weilov (1992.) model i AK model (Rebelo, 1991.). Uloga financijskog sustava u navedenim modelima se očituje kroz njegovu zadaću da vrši transmisiju štednje u investicije. Sva tri modela polaze od pretpostavke da je štednja jednaka investicijama. što zapravo znači da u modelu postoji perfektna financijska intermedijacija, odnosno da se štednja bez ikakvih troškova može

mobilizirati u investicije. Model rasta Solowa i Mankiw-Romer-Weil se razlikuju samo u jednoj pretpostavci – MRW – „razdvaja“ štednju na dio kojim se financira fizički kapital i na dio kojim se financira ljudski kapital, dok model Solowa ljudski kapital ignorira, pa se ni štednja ne razdvaja. Prema modelu rasta Solowa, u kojem proizvodnja ovisi o razini (fizičkog) kapitala, broju zaposlenih i proizvodnosti rada, promjena stope štednje dugoročno ne utječe na stopu rasta proizvoda po zaposlenom jer je dugoročno jednaka stopi tehnološkog napretka. Može se, dakle, iz tog modela Solowa zaključiti da dugoročno financijski sustav nema nikakav efekt na gospodarski rast. U isto vrijeme kad je izašao taj model velik broj teoretičara negirao je ulogu financijskog sustava na gospodarski rast. Primjerenije rečeno, utjecaj financijskog sustava na gospodarski rast može biti samo privremenog značaja. Što više, neki su teoretičari, poput Joan Robinson zastupali mišljenje „gdje gospodarski rast predvodi, financije slijede“, dakle da financijski sustav nema utjecaja na gospodarski rast, nego da gospodarski rast utječe na financijski sustav(Gertler, 1998.).

Funkcija mobilizacije štednje bitna je zadaća financijskog sustava jer su, s jedne strane, bez pristupa investitorima mnogi proizvodni procesi neprofitabilni, a s druge strane ona omogućuje kućanstvima posjedovanje diversificiranog portfelja i povećanje likvidnosti imovine što pridonosi efikasnijoj alokaciji resursa (Sirri i Tufano, 1995. prema Levine,1997.). Međutim, mobilizacija štednje nije jednostavna jer ju koče transakcijski troškovi prikupljanja štednje od različitih pojedinaca i informacijske asimetrije. Financijski posrednici su tu da te probleme ublaže, ali ih ne mogu eliminirati u potpunosti. Kao posljedica toga samo je jedan dio štednje iskorišten za investicije, pa preostali možemo smatrati izgubljenim zbog mnogih faktora, kao što su: aktualni troškovi posredovanja banaka, oligopolističko ponašanje, veća sklonost trošenju prikupljenih poreznih prihoda na potrošačka dobra umjesto u investicije (Gross, 2002., 16). Marco Pagano je primijenio AK model kako bi razvio model u kojem razvoj financijskog sustava dovodi do veće razine dugoročnog dohotka i dugoročne stope rasta (Pagano, 1993.a, prema Haas 2001.). U tom slučaju će stope rasta kapitala i proizvoda po zaposlenom biti dane kao razlika između stope štednje koja nije „izgubljena“ u procesu financijske intermedijacije i amortizacije. Tako se može zaključiti da razvoj financijskog sustava može poticati gospodarski rast preko manjeg udjela „izgubljene“ štednje, rasta granične proizvodnosti kapitala i stimuliranjem sklonosti štednji .

Naime, u ovom istraživanju fokus razmatranja je razvoj financijskog sustava i njegov utjecaj na gospodarski rast i neće biti promatrana povratna veza koja, dakako, može biti predmet daljnjih razrada ovog istraživanja.

Dakle u ovom istraživanju pokušat će se definirati određena grupa pokazatelja za period 1996-2011.godina. Nakon toga krenut će se u analizu pokazatelja i odradit će se njihovo grupiranje u dvije skupine indikatora i to:

- oni koji pokazuju veličinu i aktivnost financijskih sustava promatranih zemalja, i
- oni koji pokazuju efikasnost financijskih sustava promatranih zemalja

Vezu između financijskog sustava i gospodarskog rasta nije dovoljno promatrati samo preko funkcije mobilizacije štednje. Cjelovitije razumijevanje utjecaja razvijenosti financijskog sustava na gospodarski rast moguće je ako se znaju i druge funkcije koje ono obavlja. Levine (1997.) ističe šest funkcija koje obavlja financijski sustav, a to su: mobilizacija štednje, alokacija resursa, kontrola korporacija, olakšavanje upravljanja rizicima i olakšavanje trgovine roba i usluga. Svaka od navedenih funkcija može imati značajni učinak na gospodarski rast jer se preko njih može utjecati na akumulaciju kapitala i na tehnološke inovacije.

U ovom radu će se uzeti i dodatne funkcije financijskog sustava koje su u predhodnom dijelu teksta ove disertacije obrađene i upravo to daje dodatan značaj ovom istraživanju. Dodatne funckije koje ima financijski sustav a koje su u ovom radu razmatrane su: funkcija kreiranja novca i politička funkcija. Naime, općepoznato je da recimo bankarski sustav izdavanjem novih kredita multiplicira količinu novca (tzv.depozitna multiplikacija[49]) koji je u opticaju u nekom financijskom sustavu.

Ekonomsti se slažu da između financijskog razvoja i gospodarskog rasta postoji veza, no slaganje prestaje kad se postavi pitanje o naravi, smjeru i intezitetu te veze. Prije svega, neslaganje se pojavljuje pri traženju odgovora na pitanje o smjeru uzročnosti: je li financijski razvitak pokretač gospodarskog rasta (mjerenim stopama rasta po glavi stanovnika), što bismo mogli nazvati „argumentom ponude“, ili rast proizvodnje urokuje financijski razvitak, što bismo mogli nazvati „argumentom potražnje“. Ali ipak ovdje treba naglasiti da su brojna istraživanja pokazala i dokazala i jednu i drugu uzročnost. Međutim, u okviru ovog istraživanja promatrat će se uzročnost razvoja financijskog sustava na gospodarski rast.

[49] Kreditni proces u poslovnim bankama u kojem se umnožava količina depozitnog novca iznad početnog iznosa a vista depozita. Razlikuje se makromultiplikacija kao umnožavanje depozita cjelokupnog bankarskog sistema i mikromultiplikacija kao umnožavanje pojedine banke. Množitelj koji pokazuje stupanj multiplikacije zavisi od stopa likvidnosnih i obveznih rezervi i odliva depozita iz banke odnosno iz bankarskog aparata

Druga linija razmimoilaženja se ocrtava pitanjem strukture financijskog sustava. Drugim riječima, postavlja se pitanje je li struktura financijskog sustava takva da se daje akcenat na razvoj banaka ili s druge strane tržišta kapitala. Unutar ovog razmatranja opet postoje razmimoilaženja i razne studije pokazuju i potvrđuje da tome ima mjesto za daljnja pitanja koja još nemaju finalne odgovore. Ono što možemo ovdje reći, a na temelju raznih dosadašnjih istraživanja, jest to da i banke i tržišta kapitala obavljaju istu ulogu i zaključak je da će financijsku strukturu odabarati samo tržište (svejedno je kakva se financijska struktura razvija: neka odluči tržište).

U ovom radu će se razmatrati cjelokupni finanicijski sustav i njegov razvoj a nikako njegova struktura u smislu utjecaja na gospodarski rast. Upravo iz razloga sto je bankarski sektor s jedne strane i nebankarski sektor kao dio ukupnog financijskog sustava komplementaran i kao takvi će se i promatrati. Ukoliko razvojno zasotaje bilo od kojih sastavnica financijskog sustava može negativno djelovati na gospodarski rast a tom pitanju ćemo se posebno posvetiti u nastavku teksta.

4.2. Elementi modela i njihova operacionalizacija

Upravljati možemo samo onim što možemo mjeriti. Mjerenje razvitka financijskog sustava i financijske strukture dugi niz je godina bilo potisnuto u drugi plan u usporedbi s mjerenjem monetarnih i fiskalnih veličina. Nakon niza istraživanja i objavljivanja studija, a pogotovo nakon studije Raymonda Goldsmitha (1969.), narastao je interes za financijske pojave zbog mogućnošću istraživanja njihove veze s gospodarskim rastom. Unatoč tome, sustavno mjerenje i praćenje, pa i analiziranje podataka o financijskoj strukturi i financijskom razvitku započelo je tek 90.-ih godina prošlog stoljeća (Šonje, 2005.). Ovime se najviše bavio Ross Levine koji je uradio bazu podataka sa svim raspoloživim pokazateljima, kao i razni projekti Svjetske banke u okviru koje je i nastala „Financial Structure Database“.[50]

U okviru ovog istraživanja analizirati će se ukupno 21 indikator razvijenosti financijskog sustava. Svakako da niti jedan od tih indikatora sam za sebe nije idealan da bi se na temelju

[50] Jedinstvena baza podataka o financijskom razvitku koja je besplatno raspoloživa na službenim stranicama Svjetske Banke.

istog zaključilo da je financijski sustav razvijen ili nije, pa će se zaključci temeljiti na više njih. U okviru ovih pokazatelja može se zaključiti da zapravo se promatraju pokazatelji centralne banke, bankarskog sektora i nebankarskog sektora.

Ishodište za formuliranje modela utjecaja razvoja financijskog sustava na gospodarski rast pronalazi se u rezultatima dosadašnjih empirijskih i teorijskih istraživanja ali i potreba koje iz toga proizilaze. Tijekom formuliranja modela utjecaja razvoja financijskog sustava na gospodarski rast, autorova istraživačka ideja se temeljila na povezivanju pokazatelja ravoja financijskog sustava sa gospodarskim rastom, a što je dokazano u dosadašnjim istraživanjima ali u jednom drugom obliku. Naime, dosadašnja istraživanja utjecaja razvoja financijskog sustava na gospodarski rast uzimala su u prosjeku tri ili pet indikatora koji pokazuju utjecaj.

U operacionalizaciji konstrukta modela, odabrani su indikatori koji se mogu smatrati postojanim i jedinstvenim u svakom financijskom sustavu.

Analizom postojećih teorijskih saznanja i empirijskih istraživanja, a sve u cilju kako bi znanstveno istraživanje bilo cjelovito, nužno je provesti i empirijsko istraživanje, odnosno potvrditi ili opovrgnuti ispravnost sadržaja postavljenih hipoteza u odnosima između varijabli. Indikatori za obje varijable izvedeni su na temelju teorijskih promišljanja i krenulo se od endogenog modela rasta koji ima slijedeci zapis:

$$BDP_RAST_{it} = \alpha_t + \beta X_{it} + \lambda FINE_{it} + \varepsilon_{it}$$

Na lijevoj strani se nalazi zavisna varijabla odnosno stopa rasta po glavi stanovnika, a na desnoj varijabla razvoja financijskog sustava, odnosno, vektor kntrolnih varijabli βX_{it}, jedan od indikatora razvoja financijskog sustava $\lambda FINE_{it}$ i konstanta ε_{it}.

U ovom radu postavljena je nezavisna varijabla koja je definirana pokazateljima razvijenosti financijskog sustava, a koja je izračunata na temelju predhodnih empirijski verificiranih kritičkih faktora razvoja financijskog sustava. Zavisna varijabla je definirana pokazateljem gospodarskog rasta i to stopom rasta po glavi stanovnika.

4.3. Grafička formalizacija istraživanja

U ovom istraživanju krenulo se od konceptualnog modela istraživanja koji ima slijedeći oblik:

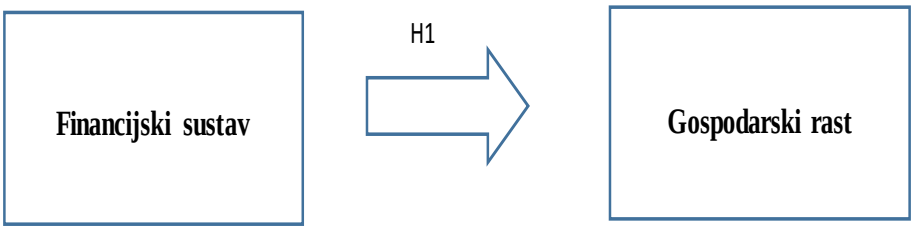

Brojna literatura (teoretska i praktična istraživanja) govori o tome kako financijski sustav utječe na gospodarski rast, pa tako počevši već od pionira ovog razmišljanja Joseph-a Schumpetera (1934.). Naravno, prema Schumpeteru financijski sustav ima pozitivan utjecaj na gospodarski rast kao rezultat njegovog utjecaja na produktivnost i tehnološki napredak. Bagehot je istraživao vezu financijskog sustava i gospodarskog rasta već u 19 stoljeću. Ovo i slična istraživanja se posebno produbljuju 90-ih godina prošlog stoljeća. I nakon više od 30 godina istraživanja opet ne postoji jedinstveno stajalište o međuovisnosti finanijskog sustava i gospodarskog rasta (pregled istraživanja na ovu temu data je u prethodnom dijelu rada).

Mnoštvo relevantnih teoretskih razmatranja bilo je razvijeno nakon što se razvila endogena teorija rasta. Općenito, AK model koji se razvio iz endogene teorije rasta je otkrio tri kanala rasta kojim financijski sustav utječe na gospodarski rast. Prvi, financijski sustav ako je dovoljno razvijen može povećati produktivnost investicija. Drugi, efikasniji financijski sustav smanjuje transakcijske troškove samim time povezuje i povećava štednju sa produktivnijim investicijama. Treće, financijski sustav može značajno utjecati na depozitne kamate, ili ih povećavati ili smanjivati (Pagano, 1993.).

Greenwood i Jovanović (1990.), Levine (1991.), Bencivenga i Smith (1991.), kao i Saint-Paul (1992.) su prezentirali svoje teoretske modele po kojima efikasan financijski sustav povećava kvalitetu investicija i samim time utječe na gospodarski rast.

Štednja nije u cijelosti alocirana u investicije iz jednostavnog razloga što dio se potroši na transakcijeske troškove. Blackburn i Hung (1996.) su u svome istraživanju došli do spoznaje da financijski sustav utječe na gospodarski rast iz najmanje dva načina. Bez intermedijacije financijskog sustava svaki investitor bi morao o svome trošku provoditi monitoring što bi dovelo do povećana vremena izvršenja investicije a samim time i troškova. Ako je financijski sustav dovoljno razvijen, monitoring investicija može biti delegiran istome. U tom slučaju, transakcijski troškovi se smanjuju i veći dio štednje je alociran na investicije koje donose novi rast. Blackburn i Hung su također došli do saznanja kako jedna zemlja može pasti u zamku gdje je karakterističan slab rast i slabo razvijen financijski sustav. To se događa iz razloga što je početni tehnološki razvoj u nekoj zemlji nizak a onda i očekivani razvoj novih ideja ostaje nizak. U tom slučaju troškovi monitoringa investicija postaju previsoki za financijsku intermedijaciju da ih organiziraju i, dakako, gospodarski rast ostaje na niskoj razini. Prema endogenom modelu rasta što je veća štednja veći je i gospodarski rast.

Pored teoretskih razmatranja utjecaja financijskog sustava na gospodarski rast, postoje mnogi empirijski radovi na ovu temu. Među prvim značajnijim istraživanjima svakako treba spomenuti istraživanje King-a i Levine-a (1993.) a koji su proveli istraživanje na 80 zemalja. U ovom istraživanju koristili su četiri indikatora: prvi pokazatelj je bio – udio likvidnih sredstava u BDP-u; drugi pokazatelj bio je udio komercijalnih banaka u odnosu na centralnu u alokaciji kredita; treći pokazatelj jest krediti privatnom sketoru u ukupnom iznosu kredita i četvrti indikator je bio udio kredita privatnom sketoru u BDP-u. U istraživanju se pokazala snažna veza svih indikatora sa gospodarskim rastom. Kasnije je bila lavina istraživanja poput onog od Levine i Zervos-a (1996., 1998.) koji su pored bankarskog sustava promatrali i tržište kapitala. U svome istraživanju su došli do spoznaje o visokoj korelaciji između indikatora tržišta kapitala i gospodarskog rasta.

Svakako je potrebno naglasiti da je veliki broj istraživanja koja su došli do rezultata da neki indikatori nemaju dovoljnu statističku značajnost utjecaja na gospodarski rast kao i razlike u rezultatima ovisno o tome koliko su odabranje zemlje razvijene (dosegnuti stupanj razvoja kako gospodarskog, tako i financijskog sustava).

Kod razmatranja indikatora financijskog sustava postoje različita mišljenja pa tako i kritike na iste (svaki od indikatora može biti kritiziran i svaki sam po sebi nije idealan). Npr. veličina kredita privatnom sektoru ne govori o efikasnosti financijskog sustava. Povećanje kreditiranja može doći usljed kreditne ekspanzije kad se očekuje veći rast. Ali ipak većina tih istraživanja je pokazala da veličina financijskog sustava utječe na gospodarski rast. Upravo zbog ovoga

zemlje s visokim dohotkom ne samo da imaju veći financijski sustav nego je to slučaj kod zemalja srednjeg i niskog dohotka, nego je i efikasnost financijskog sustava veća.

Ovo je razlog zašto će i ovo istraživanje uzeti indikatore koji nisu bili korišteni u dosadašnjim istraživanjima kao i da će se paziti u usporedbi zemalja da se uspoređuju zemlje istog nivoa razvitka.

Neimke (2003.) je istraživao utjecaj financijskog sustava na gospdarski rast zemalja u tranziciji i došao je do rezultata da je ta veza pozitivnog predznaka. Fisman (2004.) u svom istraživanju potvrđuje pozitvinu vezu između razvoja financijskog sustava i gospodarskog rasta i taj utjecaj je prisutan i na kratkoročnoj i dugoročnoj razini. U slučaju kratkoročnog rasta razvoj financijskog sustava i njegova utjecaja na gospodarski rast ima veći značaj za industrije koje imaju veća očekivanja u pogledu razvoja. Kad je riječ o dugoročnom rastu onda razvoj financijskog sustava ima veći značaj za industrije koje su do tada imale zahtjeve za veće (kapitalne) investicije. Neka istraživanja novijeg datuma nisu potvrdila ovu vezu kao što je istraživanje od Mehl, Vespro i Winkler (2005.). Oni su došli do saznanja da je ta veza negativna pa su i objasnili rezultat na način da u manje kvalitetnom financijskom okruženju ekspanzija financijskog posredništva ne potiče rast. Bogdan (2009.) je potvrdio pozitivnu vezu ali su koeficijenti u regresijama bili jako mali, te se utjecaj financijskog sustava na gospodarski rast ne čini signifikantnim.

Demerguc-Kunt, Feyen i Levine (2011.) su u svome istraživanju promatrali utjecaj bankarskog sektora i sektora tržišta kapitala na gospodarski rast. Analizom rezultata istraživanja došli su do saznanja da na većem stupnju gospodarskog razvoja tržište kapitala postaje važnije i veća je potražnja za vrijednosnicama i ulaganja u iste. Isto tako, došli su do saznanja da je devijacija sadašnje strukture financijskog sustava od optimalne strukture financijskog sustava povezana sa nižom razinom gospodarski aktivnosti u odabranoj zemlji.

Model utjecaja financijskog sustava na gospodarski rast može se prikazati grafički:

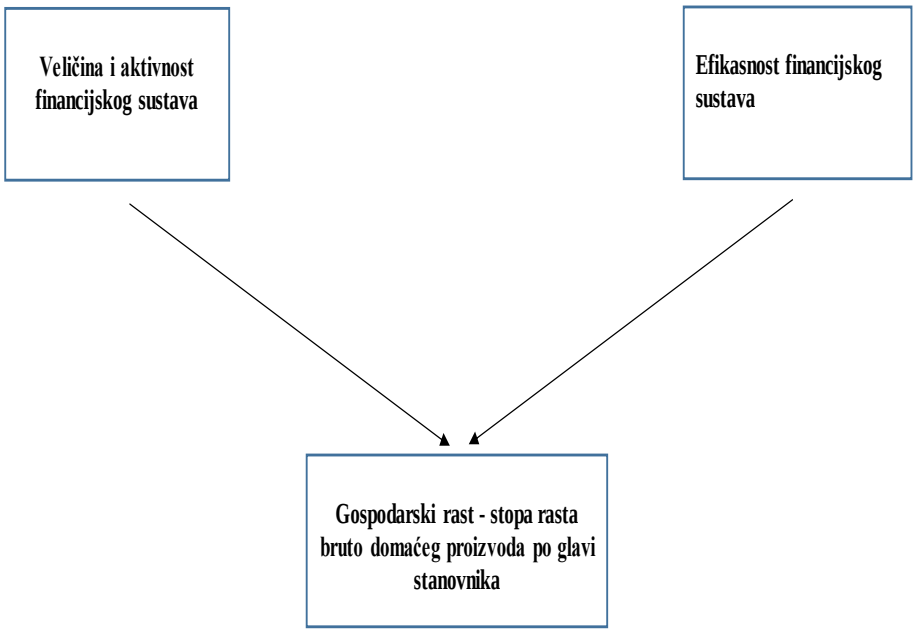

Uzimajući u obzir dosadašnja istraživanja na temu veze financijskog sustava i gospodarskog rasta, oblikovan je istraživački model prikazan grafički prethodno koji predstavlja teoretsku osnovu disertacije. Model se temelji na povezivanju, odnosno, podjeli indikatora financijskog sustava na dva dijela ili grupe i njihovog promatranja utjecaja na gospodarski rast.

U daljnjem djelu ovog rada će biti više riječi o indikatorima i njihovom grupiranju u predhodno navedene skupine ali ono što je bitno ovdje naglasiti jest da će za analizu prve pomoćne hipoteze biti jedanaest indikatora razvijenosti financijskg sustava a kod druge pomoćne hipoteze njih deset.

V. EMPIRIJSKO UTVRĐIVANJE UTJECAJA FINANCIJSKOG SUSTAVA NA GOSPODARSKI RAST

5.1. Istraživačke hipoteze

Problem, predmet i objekt istraživanja dali su konceptualni okvir istraživanja i okvir za **postavljanje temeljne hipoteze koja polazi od pretpostavke o utjecaju razvoja financijskog sustava na gospodarski rast.**

H1.: Razvoj financijskog sustava pozitivno utječe na gospodarski rast.

Tijekom razrade konstrukta za prijedlog modela istraživanja pojavila se potreba uvođenja dviju pomoćnih hipoteza koje međusobno povezuju konstrukte modela koji su građeni od indikatora i u sinergiji direktno i/ili indirektno daju doprinos temeljnoj radnoj hipotezi.

H1a.: Razvijeniji i aktivniji financijski sustavi imaju značajnu ulogu na razvoj realnog sektora gospodarstva, što pozitivno utječe na ukupan gospodarski rast.

Prva pomoćna hipoteza trebala bi pomoći u potvrdi teze u postojanju povezanosti između razvijenijih i aktivnijih financijskih sustava i njihova utjecaja na gospodarski rast. Ova će se hipoteza analizirati kroz indikatore veličine financijskog sustava i njegova odnosa s BDP-om kao i aktivnošću financijskoga sustava kroz kreditnu aktivnost. Budući da su financijski sustavi promatranih zemalja bankocentrični, posebna će se pozornost u analizi ove hipoteze dati upravo analizi veze i utjecaja bankarskog sektora na gospodarski rast.

Druga hipoteza glasi:

H1b.: Učinkovitiji i operativniji financijski sustavi omogućuju bolju alokaciju kapitala i na taj način potiču gospodarski rast.

Druga pomoćna hipoteza uvodi se kako bi se potvrdilo da su financijski sustavi, koji bolje vode troškovnu politiku, bolji i učinkovitiji u analizi određenih investicijskih zahtjeva. Na ovaj se način selektiraju bolji investicijski projekti i tako potiče gospodarski rast. Liberalniji financijski

sustavi u pogledu ulaska konkurencije pridonose boljem financijskom sustavu u pogledu novih proizvoda, tehnologija i općenito novog načina poslovanja, a sve to pozitivno utječe na gospodarstvo jedne zemlje.

Slika 5.1. Prikaz modela istraživanja i hipoteza

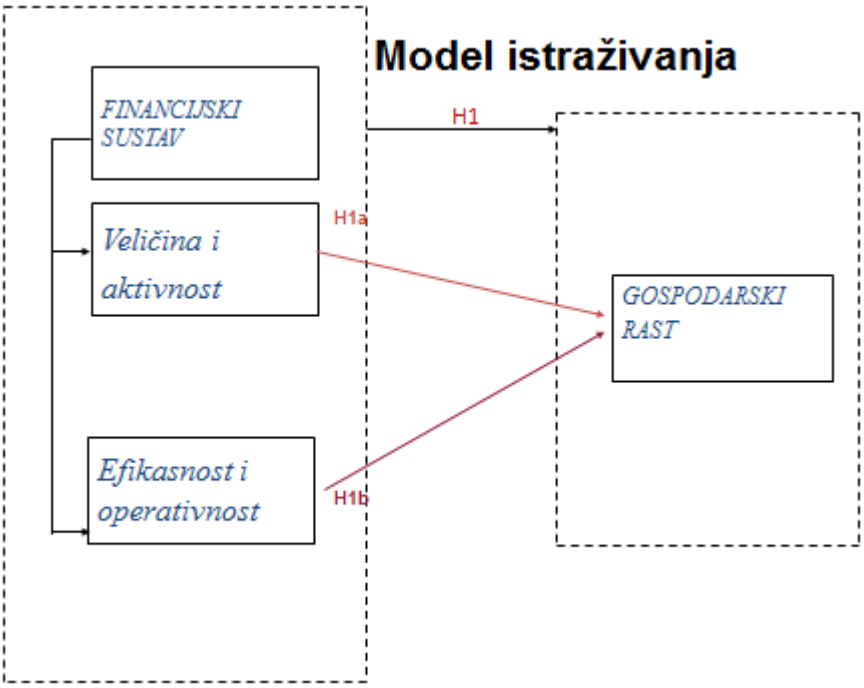

Izvor: autor

5.2. Metodološki aspekti istraživanja

U nastavku disertacije raspravlja se o ključnim metodološkim aspektima empirijskog istraživanja koji se odnose na sadržajni, prostorni i vremenski obuhvat istraživanja, instrumente istraživanja, faze istraživanja i metodologije obrade podataka.

5.2.1. Sadržajni, prostorni i vremenski obuhvat istraživanja

Slijed aktivnosti u ovom istraživanju prezentiran je na javnom razgovoru u svibnju 2015. godine u Splitu. Isprva je definiran uzorak zemalja i vremenski obuhvat istraživanja, a zatim su prikupljeni podatci i provedeno je preliminarno istraživanje na uzorku od deset indikatora razvijenosti financijskoga sustava, čiji je cilj bio verificirati operacionalizirane istraživačke konstrukte i utvrditi potencijalne probleme u formiranju istraživačkih instrumenata. U sljedećem koraku analizirani su rezultati preliminarnog istraživanja. Uslijedilo je prikupljanje podataka (indikatora) za cijeli uzorak (za sve odabrane zemlje). Nakon završetka prikupljenih podataka pristupilo se statističkoj obradi, analizi i u okviru ove disertacije prezentirani dobiveni rezultati.

Odabrane zemlje koje su obrađene ovim istraživanjem su: Albanija, Austrija, Bosna i Hercegovina, Bugarska, Crna Gora, Češka, Hrvatska, Italija, Grčka, Mađarska, Makedonija, Njemačka, Poljska, Rumunjska, Srbija, Slovačka i Slovenija. Dakle, uzorak iz ovog istraživanja sadrži 17 zemalja različite strukture i razvijenosti financijskoga sustava. Vremenski obuhvat koji je analiziran je razdoblje od 1996. do 2011. godine i analizirani su podatci na godišnjoj razini. Isto tako, kod analize se radio panel do početka financijske krize i cijeli period promatranja uzimajući u obzir i krizu a kako bi se vidio utjecaj financijske krize koja se desila u 2008.godini.

5.2.2. Instrumenti i faze istraživanja

Za izradu predložene doktorske disertacije korištene su dvije temeljne skupine metoda istraživanja i to zbog značajnih metodoloških razlika u izradi teorijskog i empirijskog dijela disertacije.

Podatci potrebni za izradu teorijskog dijela disertacije i teorijsku analizu dosadašnjih istraživanja prikupljeni su u okviru prve faze istraživanja – analize sekundarnih znanstvenih izvora – prvenstveno knjiga i članaka objavljenih u znanstvenim časopisima.

Pritom je korišten knjižni fond knjižnice Ekonomskog fakulteta u Splitu, Mostaru, Sarajevu, Beču i Zagrebu, kao i relevantne baze podataka dostupne preko interneta.

Tijekom izrade empirijskog dijela disertacije korišteni su slijedeći metodološki postupci:

- prikupljanje primarnih znanstvenih podataka iz različitih izvora IMF – WEO database, IMF – IFS database, IMF – Financial Survey Database, WB – WDI database, ECB, EBRD – EBRD transition database, središnje banke odabranih zemalja

- različite statističke metode obrade podataka (deskriptivna statistička metoda, korelacijska i regresijska analiza, panel-analiza).

Preliminarno istraživanje trebalo je potvrditi temeljne pretpostavke predloženog teorijskog modela, testirati istraživačke instrumente i tehniku provođenja istraživanja. Uzorak preliminarnog istraživanja određen je slučajnim izborom 10 indikatora za sve promatrane zemlje. Analizom rezultata preliminarnog istraživanja utvrđena je adekvatnost modela istraživanja nakon čega se pristupilo daljnjim koracima u provedbi empirijskog istraživanja, opisanim u nastavku izlaganja.

Sljedeći korak u ovom istraživanju bilo je prikupljanje svih podataka razvijenosti financijskoga sustava odabranih zemalja u utvrđenom razdoblju. Obrada podataka izvršena je uz pomoć softverskog paketa za statističku obradu podataka *SPSS.*

Slika 5.2. Protokol empirijskog istraživanja

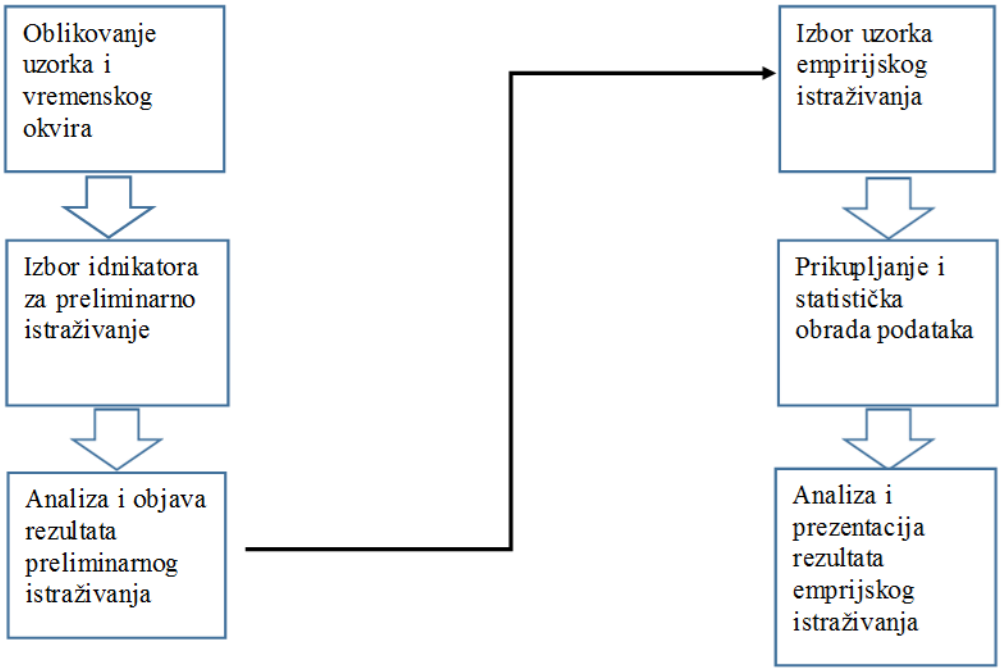

Izvor: Autor

Kao što je vidljivo iz prikaza kod ovog istraživanja prije svega oblikovan je uzorak i vremenski okvir istraživanja. Istraživanje je urađeno na uzorku od 17 zemalja i period istraživanja jest 1996.-2011.godina. Nakon toga odraženo je preliminarno istraživanje na uzorku od deset indikatora (za svaku pomoćnu hipotezu po pet). Rezultati preliminarnog istraživanja prezentirani su u Istraživačkom projektu. Nakon toga usljedilo je prikupljanje svih indikatora razvoja financijskog sustava i pristupilo statističkoj obradi i analizi istraživanja.

5.2.3. Metodologija obrade podataka

U radu su korištene induktivna i deduktivna metoda, metoda generalizacije i specijalizacije, metoda analize i sinteze, komparativna metoda i ekonometrijska metoda panel-analize. Poseban značaj u ovom radu ima ekonometrijska metoda panel-analiza koja je korištena za određivanje modela koji određuju utjecaj determinanti razvoja financijskoga sustava na pokazatelje razvoja financijskoga sustava. Prednost ove metode nad prostornom analizom i analizom vremenskih serija je u tome što sadrži vremensku i prostornu komponentu. Zavisna se varijabla mijenja po jedinkama i po vremenu pa su procjenitelji dobiveni panel-analizom precizniji. Ta je metoda robusnija u odnosu na nedostajuće podatke i korelaciju međuovisnih varijabli. Svi procijenjeni modeli analizirani su zasebno, a na kraju su komparativnom metodom uspoređeni dobiveni modeli te su određene zajedničke karakteristike svih procijenjenih modela.

5.2.4. Statističke metode istraživanja

Budući da podatci sadrže prostornu (engl. *cross-sectional data*) i vremensku komponentu (engl. *time-series data*), riječ je o panel-podatcima, a modele kojima se na adekvatan način može procijeniti utjecaj jedne ili više nezavisnih varijabli na promatranu zavisnu varijablu nazivamo panel-modelima.

5.2.4.1. Panel-modeli

Prije pojave panel-analize za analizu podataka koristila se višestruka regresija na prostornim podatcima ili vremenskim serijama. S vremenom su vremenske serije postale duže, a prostorne analize sadržavale su sve više opažanja pa su rezultati analiza postali kvalitetniji. Unatoč sve kvalitetnijim i preciznijim ekonometrijskim analizama, u empirijskim se istraživanjima pojavila potreba da podatci za analizu imaju vremensku i prostornu komponentu. Podatci koji sadrže

vremensku i prostornu komponentu neke varijable nazivaju se panel-podatci. Dakle, da bi se prikupili panel-podatci, moraju se prikupljati podatci o istim jedinkama (pojedincima, poduzećima, gradovima, državama) u određenom vremenu. Za analizu panel-podataka nije uvijek moguće korištenje obične višestruke regresije jer ne može pretpostaviti nezavisnost među opažanjima jedne jedinke u određenom vremenu. S obzirom na prirodu panel-podataka, za njihovu ekonometrijsku analizu razvijene su posebne metode i modeli.

Neovisno o složenosti modela za ekonometrijsku analizu, panel-podatci imaju razne prednosti nad jednostavnim vremenskim serijama i prostornim analizama. Razlog tomu je sve češća uporaba panel-podataka u ekonometrijskim analizama. Paneli sadrže veći broj opažanja nego prostorni podatci ili pripadajuća vremenska serija. Zavisna se varijabla mijenja po jedinkama i vremenu pa su procjenitelji dobiveni panel-analizom precizniji. Panel-podatci mogu umanjiti učinak pristranosti zbog nedostajućih podataka. Dakle, može se zaključiti da su procjenitelji u panelima robusniji na nepotpunu specifikaciju modela. Panel-podatci omogućavaju konstruiranje i testiranje kompliciranijih modela. Oni daju raznolikost podataka i smanjuju korelaciju među varijablama. Dogodi li se da su dvije varijable unutar jedne jedinke jako korelirane, a ta korelacija nije izražena među varijablama drugih individua, ta korelacija gubi značajnost. S obzirom na svojstva panel-podataka u analizi se primjenjuju različiti modeli za analizu. U ovisnosti o zavisnoj varijabli razlikuju se statički i dinamički modeli. Statički paneli dijele se na združene modele (eng. *pooled* OLS), modele s fiksnim efektom i modele sa slučajnim efektom. Navedeni modeli bit će opisani u daljnjem dijelu rada. Panel-podatci dijele se na balansirane (uravnotežene) i nebalansirane (neuravnotežene) panel-podatke. Ako su za svaku jedinku, u svakom vremenskom razdoblju, za sve varijable dostupni potrebni podatci, panel-podatci nazivaju se balansiranim panel-podatcima. Ako za neku jedinku nedostaju podatci za neku varijablu ili možda nisu dostupni podatci za određeno vremensko razdoblje, panel-podatci nazivaju se nebalansiranim panel-podatcima[51].

[51] Formule za sve panel-modele, procjenitelje i testove bit će prikazane za balansirane panel-podatke. Gotovo svi modeli, procjenitelji i testovi primjenjivi su i na nebalansiranim panel-podatcima. Također, svi programski paketi imaju mogućnost rada s nebalansiranim panel-podatcima.

5.2.4.1.1. Združeni model

Najjednostavniji panel-model je združen model, a izgleda kao:

$$y_{it} = \alpha + \beta_1 x_{it1} + \beta_2 x_{it2} + ...\beta_K x_{itK} + \varepsilon_{it};\ i = 1,...N, t = 1,...,T \tag{5.1.1}$$

N označava broj jedinki, T označava broj vremenskih razdoblja, $x_{itk}, k = 1,...K$ označava vrijednost k -te nezavisne varijable, i-te jedinke u vremenskom razdoblju t, α je konstantan član koji je jednak za sve jedinke i ne mijenja se kroz vrijeme, $\beta_1,...,\beta_K$ su parametri koje treba procijeniti. Nadalje, ε_{it} je grješka procjene i-te jedinke u vremenskom razdoblju t i pretpostavka je da su ε_{it} nezavisno i identično distribuirani po jedinkama i vremenu, sa sredinom 0 i varijancom σ_ε^2. Također se pretpostavlja da su svi x_{itk} neovisni o ε_{it} za sve i,t,k

Ovaj naizgled najjednostavniji model ima najviše ograničenja. U modelu se pretpostavlja nepostojanje vremenske korelacije među opažanjima unutar jedne jedinke. Ovakav se model rijetko pokazuje pogodnim za procjenu parametara. Da bi se ovaj model prilagodio podatcima, nad njim se vrše razne transformacije. Da bi se riješio problem korelacije opažanja unutar jedne jedinke, u model se uvodi *dummy* varijabla za svaku jedinku. Ako se za svaku jedinku uvede *dummy* varijabla, združeni OLS postaje model s fiksnim efektom. Drugi način uklanjanja korelacije unutar jedne jedinke je diferenciranje zavisnih i nezavisnih varijabli u modelu.[52]

Ponekad se združeni OLS model transformira tako da se pronađe prosječna vrijednost opažanja za svaku jedinku kao u formuli:

$$\bar{y}_i = \frac{\sum_{i=1}^{T} y_{it}}{T},\ \bar{x}_{ik} = \frac{\sum_{i=1}^{T} x_{itk}}{T},\ \bar{\varepsilon}_i = \frac{\sum_{i=1}^{T} \varepsilon_{it}}{T},\ i = 1,...,N,\ k = 1,...,K, \tag{5.1.2}$$

[52] Varijable se smiju diferencirati tek kada u programskoj potpori definiramo vremensku i prostornu komponentu panel-podataka.

Pritom je $\overline{y}_i$ prosječna vrijednost zavisne varijable *i*-te jedinke, $\overline{x}_{ik}$ je prosječna vrijednost *k*-te nezavisne varijable *i*-te jedinke, $\overline{\varepsilon}_i$ je prosječna vrijednost grješke relacije *i*-te jedinke. Dobivene vrijednosti uvrste se u jednadžbu (5.1.1). Novi model koji treba procijeniti ima sljedeći oblik

$$\overline{y}_i = \beta + \beta_1 \overline{x}_{i1} + \beta_2 \overline{x}_{i2} + \ldots \beta_k \overline{x}_{iK} + \overline{\varepsilon}_i;\ i = 1, \ldots N., \tag{5.1.3}$$

i naziva se model „između“ (eng.*between model*).[53] Procjenitelj modela (5.1.3) naziva se „između“ (eng.*between*) procjenitelj. Ovaj procjenitelj je nepristran i konzistentan, ali nije učinkovit. Model „između“ ne koristi se često za procjenu jer se gubi utjecaj vremenske komponente. Ipak, „između“ procjenitelj koristi se za izvod procjenitelja složenijih modela s boljim svojstvima.

5.2.4.1.2. Model s fiksnim efektom

Model s fiksnim efektom[54] jednostavan je linearni model u kojem se konstantni član mijenja sa svakom jedinkom, ali je konstantan u vremenu. Model s fiksnim efektom ima oblik:

$$y_{it} = \alpha_i + \beta_1 x_{it1} + \beta_2 x_{it2} + \ldots \beta_K x_{itK} + \varepsilon_{it};\ i = 1, \ldots N, t = 1, \ldots, T\ , \tag{5.1.4}$$

[53] Model “između” (eng.between model) koristi se u izvodu procjenitelja sa slučajnim efektom, samo je pogrješka relacije raspisana $\overline{y}_i = \beta + \beta_1 \overline{x}_{i1} + \beta_2 \overline{x}_{i2} + \ldots \beta_K \overline{x}_{iK} + \alpha_i + \overline{\varepsilon}_i;\ i = 1, \ldots N$; α_i predstavlja pogrješku koja je konstantna unutar jedne jedinke, $\overline{\varepsilon}_i$ predstavlja prosječnu pogrješku koja se mijenja s vremenom i jedinkama; ako je α_i koreliran s nekim x_{ik}, tada je *between* procjenitelj pristran.

[54] U ovom radu promatrat će se samo model s fiksnim efektom u kojem se konstantan član mijenja s jedinkom. Postoji model s fiksnim efektom u kojem se konstantan član mijenja s vremenom. Takav model dan je formulom: $y_{it} = \lambda_t + \beta_1 x_{it1} + \beta_2 x_{it2} + \ldots \beta_K x_{itK} + \varepsilon_{it};\ i = 1, \ldots N, t = 1, \ldots, T$. Ako model s fiksnim efektom istodobno sadrži konstantan član za svaku jedinku i konstantan član za svako vremensko razdoblje, naziva se model s dvostrukim fiksnim efektom (eng.*two way fixed effect*). Više o ovim modelima pogledati u knjizi Baltagi, B. H. (2005.) „*Econometric Analysis of Panel Data*, Third Edition. West Sussex: John Wiley and Sons, str. 33. – 34.

N označava broj jedinki, T označava broj vremenskih odrednica, $x_{itk}, k = 1,...K$ označava vrijednost k -te nezavisne varijable, i -te jedinke u vremenskom razdoblju t, α_i je konstantan član različit za svaku jedinku, a $\beta_1,...,\beta_K$ parametri su koje treba procijeniti. Nadalje, ε_{it} je grješka procjene i -te jedinke u vremenskom razdoblju t i pretpostavka je da su ε_{it} neovisno i identično distribuirani po jedinkama i vremenu sa sredinom 0 i varijancom σ_ε^2. Također se pretpostavlja da su svi x_{itk} neovisni o ε_{it} za sve i,t,k.

Model s fiksnim efektom može se zapisati uz pomoć *dummy* varijabli na sljedeći način:

$$y_{it} = \sum_{j=1}^{N} \alpha_i d_{ij} + \beta_1 x_{it1} + \beta_2 x_{it2} + ...\beta_K x_{itK} + \varepsilon_{it};\ i = 1,...N, t = 1,...,T, \tag{5.1.5}$$

Pritom je $d_{ij} = 1$, ako je $i = j$, a inače je 0. Iz formule (5.1.2.) vidi se da je za procjenu modela s fiksnim modelom potrebno procijeniti N *dummy* varijablu što je *N-1* dodatna varijabla u odnosu na združeni (eng.*pooled*) model. Metoda najmanjih kvadrata za procjenu modela s fiksnim efektom naziva se metodom najmanjih kvadrata s *dummy* varijablama (eng.*least squares dummy variables* – LSDV). Nedostatak ove metode procjene je gubitak velikoga broja stupnjeva slobode zbog procjene fiksnog efekta za svaku jedinku. Dodatno zbog procjene velikog broja *dummy* varijabli može doći do pojave multikolinearnosti među neovisnim varijablama. Model s fiksnim efektom ne može se koristiti ako u modelu postoje varijable koje ne ovise o vremenu kao što su, primjerice, spol, rasa, religija i sl. Programski paketi koji se koriste za analizu panel-modela signaliziraju multikolinearnost i tako se onemogućava procjena modela. Svojstva modela mijenjaju se s obzirom na veličinu uzorka, tj. s obzirom na broj vremenskih razdoblja i broj jedinki u uzorku. Ako je broj vremenskih razdoblja $T \to \infty$, procjenitelj fiksnog efekta za svaku je jedinku konzistentan. Ako je broj vremenskih razdoblja T fiksan, a broj jedinki $N \to \infty$, procjenitelji od $\beta_1, \beta_{2,...,}\beta_K$ su konzistentni, a procjenitelji od $\alpha_1, \alpha_2,...,\alpha_n$ nisu konzistentni. Dodavanjem novih jedinki u uzorak, bez dodavanja novih vremenskih razdoblja neće poboljšati procjenu fiksnog efekta svake jedinke.

Opravdanost uporabe modela s fiksnim efektom može se provjeriti uz pomoć uobičajenog F -testa. Formiraju se sljedeće hipoteze:

$$H_0 : \alpha_1 = \alpha_2 = ... = \alpha_N \qquad (5.1.6)$$
$$H_1 : \alpha_i \text{ nisu svi međusobno jednaki.}$$

Dakle, formira se sljedeći *F*-omjer :

$$F = \frac{(RRSS - URSS)/(T-1)}{URSS/((N-1)(F-1)-K} \approx F_{T-1,(N-1)(T-1)-K} \qquad (5.1.7)$$

RRSS predstavlja sumu kvadrata reziduala združenog (*pooled*) modela procijenjenog metodom najmanjih kvadrata, URSS predstavlja sumu kvadrata reziduala modela s fiksnim efektom procijenjenog metodom najmanjih kvadrata *dummy* varijabli.

Ako je $F < F^{\alpha}_{T-1,(N-1)(T-1)-K}$, na razini signifantnosti α (odnosno, ako je p-vrijednost veća od α) ne može se odbaciti nultu hipotezu koja tvrdi da su fiksni efekti svih jedinki međusobno jednaki nuli. Dakle, prihvati li se hipoteza H_0, može se zaključiti da je fiksni efekt nepotreban, tj. da je bolje koristiti jednostavan združeni (eng.*pooled*) model koji će imati jedan konstantan član za sve jedinke.

Ako je $F < F^{\alpha}_{T-1,(N-1)(T-1)-K}$, na razini signifikantnosti α odbacuje se nulta hipoteza da su fiksni (individualno, pojedinačno) efekti svih jedinki međusobno jednaki i zaključuje se da je model s fiksnim efektom prikladan za procjenu parametara.

Ako panel-podatci sadrže mnogo različitih jedinki, nije preporučljivo koristiti model s fiksnim efektom. Jedan je razlog tomu što se u modelu pojavljuje velik broj *dummy* varijabli, a samim time i velik broj parametara za procjenu. Drugi je razlog što programska potpora ne može procijeniti takav model. Treći je razlog što se kod procjene modela s fiksnim efektom za svaku jedinku gubi po jedan stupanj slobode. Zbog svih navedenih razloga javila se potreba za

jednostavnijim modelom koji će procjenjivati parametre $\beta_1, \beta_{2,...,}\beta_K$ iz modela s fiksnim efektom na jednostavniji način. Glavni cilj novoga modela je eliminirati pojedinačni efekt α_i transformiranjem podataka.

Uvedu li se oznake $\overline{y_i}$, $\overline{x_{ik}}$, $\overline{\varepsilon_i}$ za prosječne vrijednosti zavisne varijable, nezavisnih varijabli i grješke relacije za jedinku i, kroz t vremenskih razdoblja kao u jednadžbi (5.1.8)

$$\overline{y}_i = \frac{\sum_{i=1}^{T} y_{it}}{T}, \quad \overline{x}_{ik} = \frac{\sum_{i=1}^{T} x_{itk}}{T}, \quad \overline{\varepsilon}_i = \frac{\sum_{i=1}^{T} \varepsilon_{it}}{T}, \; i = 1,...,N, \; k = 1,...,K, \tag{5.1.8}$$

a zatim se dobivene prosječne vrijednosti svih varijabli za svaku jedinku i uvrste u jednadžbu (5.1.4), dobije se jednadžba

$$\overline{y}_i = \alpha_i + \beta_1 \overline{x}_{i1} + \beta_2 \overline{x}_{i2} + ...\beta_K \overline{x}_{iK} + \overline{\varepsilon}_i; \; i = 1,...N. \tag{5.1.9}$$

Nakon toga od jednadžbe (5.1.4) oduzme se jednadžba (5.1.9) i dobije se:

$$y_{it} - \overline{y}_i = \beta_1(x_{it1} - \overline{x}_{i1}) + \beta_2(x_{it2} - \overline{x}_{i2}) + ...\beta_K(x_{itK} - \overline{x}_{iK}) + (\varepsilon_{it} - \overline{\varepsilon}_i); \; i = 1,...N \tag{5.1.10}$$

Dobiven model (5.1.10) regresijski je model odstupanja od prosječnih vrijednosti svake jedinke i ne uključuje fiksni efekt α_i. Proces transformacija opažanja u odstupanja od prosječne vrijednosti jedinke naziva se procjenitelj fiksnog efekta . Procijenjene vrijednosti od $\beta_1, \beta_{2,...,}\beta_k$ koje dobijemo metodom najmanjih kvadrata iz transformiranog modela nazivaju se „unutar“ (eng.*within*) procjene. Procjene parametara $\beta_1, \beta_{2,...,}\beta_k$ koji se dobiju ovom metodom identične su procjenama istih parametara koji su dobiveni metodom najmanjih kvadrata indikator *dummy* varijabli. Jedina je razlika u tome što „unutar“ metoda (eng.*within* metoda) nema procjenu pojedinačnog efekta za svaku jedinku. Ako se ipak žele procijeniti pojedinačni efekti svake jedinke, procjenitelj pojedinačnog efekta dan je sljedećom formulom

$$\alpha_i = y_i - \beta_1 X_{i1} - \beta_2 X_{i2} - \ldots - \beta_k X_{ik}\,; i = 1,\ldots N\,, \tag{5.1.11}$$

Pritom su procijenjeni parametri $\beta_1, \beta_2, \ldots \beta_k$ preuzeti iz jednadžbe (5.1.10) uz pretpostavku da sve nezavisne varijable nisu korelirane s rezidualima. Procjenitelji α_i konzistentni su jedino u slučaju kada je $T \to \infty$.

Opravdanost korištenja „unutar“ modela također se može provjeriti korištenjem *F*-omjera kao u formuli (5.1.7), samo što se za URSS umjesto zbroja kvadrata reziduala modela s fiksnim efektom procijenjenog metodom najmanjih kvadrata *dummy* varijabli koristi zbroj kvadrata reziduala procijenjenih pomoću „unutar“ modela. Jedini problem od triju prije navedenih koji se ne rješava uvođenjem ovog procjenitelja jest gubitak stupnjeva slobode. Broj stupnjeva slobode kod obaju je modela jednak. Iako se ne procjenjuje konstantan član za svaku jedinku, po jedan se stupanj slobode gubi centriranjem vrijednosti varijabli jedinke oko svoje prosječne vrijednosti.

5.2.4.1.3. Model sa slučajnim efektom

Model sa slučajnim efektom[55] jednostavan je linearni model u kojem se pretpostavlja da su jedinke odabrane na slučajan način. Isto tako, pretpostavlja se da su razlike među jedinkama slučajne. Model sa slučajnim efektom ima sljedeći oblik:

$$y_{it} = \mu + \beta_1 x_{it1} + \beta_2 x_{it2} + ...\beta_k x_{itK} + \alpha_i + \varepsilon_{it};\ i = 1,...N, t = 1,...,T, \quad (5.1.12)$$

Zajednički konstantni μ je član za sve jedinke dok je α_i slučajan efekt za svaku jedinku. Pretpostavka ovog modela je da su α_i nezavisno i identično distribuirani po jedinkama sa sredinom nula i varijancom σ_α^2, $\beta_1,...,\beta_K$ parametri su koje treba procijeniti. Isto tako je pretpostavka da su ε_{it} nezavisno i identično distribuirani po jedinkama i vremenu, sa sredinom 0 i varijancom σ_ε^2. Pretpostavka modela je

$$Cov(\alpha_i, x_{itk}) = 0, k = 1,...,K \quad (5.1.13)$$

te da je

$$Cov(\alpha_i, \varepsilon_{it}) = 0, t = 1,...,T. \quad (5.1.14)$$

[55] U ovom radu promatrat će se samo model sa slučajnim efektom u kojem se slučajni efekt mijenja s jedinkom. Postoji model sa slučajnim efektom u kojem se slučajni efekt mijenja s vremenom. Takav model dan je formulom: $y_{it} = \alpha + \beta_1 x_{it1} + \beta_2 x_{it2} + ...\beta_K x_{itK} + \lambda_t + \varepsilon_{it};\ i = 1,...N, t = 1,...,T$. Ako model sa slučajnim efektom istodobno sadrži slučajni efekt za svaku jedinku, i slučajni član za svaki vremenski interval naziva se model s dvostrukim slučajnim efektom (eng.*two way fixed effect*). Više o ovim modelima pogledati u knjizi Baltagi, B. H. (2005.) *Econometric Analysis of Panel Data*, Third Edition. West Sussex: John Wiley and Sons, str. 34. – 35.

$$\boldsymbol{v_{it} = \alpha_i + \varepsilon_{it};\ \ i = 1,\ldots N, t = 1,\ldots,T} \tag{5.1.15}$$

naziva se pogrješkom relacije i sastoji se od dvaju dijelova: pojedinačne i specifične komponente. S obzirom na to da su α_i i ε_{it} međusobno neovisni, varijanca od υ_{it} je homoskedastična i iznosi

$$\boldsymbol{Var(v_{it}) = \sigma_\alpha^2 + \sigma_\varepsilon^2;\ \ i = 1,\ldots N, t = 1,\ldots,T.} \tag{5.1.16}$$

Elementi matrice varijance i kovarijance iznose

$$Cov(v_{it}, v_{js}) = \begin{cases} \sigma_\alpha^2 + \sigma_\varepsilon^2 zai = j, t = s \\ \sigma_\alpha^2 zai = j, t \neq s \\ 0 \end{cases} \tag{5.1.17}$$

Iz formule (5.1.17) može se zaključiti da će postojati korelacija između pogrješaka relacije iste jedinke u različitim vremenskim točkama, a koeficijent korelacije iznosit će:

$$p = corr(v_{it}, v_{is}) = \left\{ \begin{matrix} 1 \\ 0 \end{matrix} \frac{\delta_\alpha^2}{\delta_\alpha^2 + \delta_\varepsilon^2} \right\} \text{za } i=j,\ t=s;\ za\ i=j, \tag{5.1.18}$$

Iz dosad pokazanog može se zaključiti da metoda najmanjih kvadrata (OLS metoda) nije primjerena za procjenu modela sa slučajnim efektom. Metoda procjene koja je neosjetljiva na problem korelacije grješaka relacije iste jedinke u različitim vremenskim točkama generalizirana je metoda najmanjih kvadrata (eng.*generalized least squares* metoda – GLS).

GLS transformacijama uklanja se korelacija između pogrješaka relacije iste jedinke. U prvom koraku definira se parametar λ koji je između 1 i 0.

$$\lambda = 1 - \left[\frac{\sigma_\varepsilon^2}{\sigma_\varepsilon^2 + T\sigma_\alpha^2} \right]^{\frac{1}{2}} \tag{5.1.19}$$

Nakon toga za svaku jedinku i odredi se prosječna vrijednost varijabli kao u jednadžbi (5.1.8) i dobivene vrijednosti. Uvrštavanjem prosječnih vrijednosti u regresijsku jednadžbu dobije se „između“ (eng.*between*) model:

$$\overline{y}_i = \mu + \beta_1 \overline{x}_{i1} + \beta_2 \overline{x}_{i2} + \ldots \beta_k \overline{x}_{ik} + \overline{v}_i,\ i = 1, \ldots N\ . \tag{5.1.20}$$

Oduzme li se od jednadžbe (5.1.12) jednadžba (5.1.20) pomnožena s λ, dobije se

$$\begin{aligned} & y_{it} - y_i = \mu(1-\lambda) + \beta_1(x_{it1} - \lambda x_{i1}) + \beta_2(x_{it1} - \lambda x_{i2}) + \ldots \\ & \beta_k(x_{itK} - \lambda x_{ik}) + (v_{it} - \lambda v_i), i = 1, \ldots N \end{aligned} \tag{5.1.21}$$

Model dobiven jednadžbom (5.1.21) procijeni se metodom najmanjih kvadrata. Može se zaključiti da je GLS procjenitelj modela sa slučajnim efektom jednostavan OLS procjenitelj transformiranog modela prikazanog u jednadžbi (5.1.21). Grješke transformiranog modela prikazanog jednadžbom (5.1.21) nekorelirane su.[56] Zbog nekoreliranosti grješaka procjena OLS metodom je nepristrana.

U praksi parametar λ nikada nije poznat, ali ga se može procijeniti. Procjena parametra λ može se temeljiti na metodi fiksnog efekta (eng.pool OLS). Općenito, procjenitelj λ dan je formulom:

$$\hat{\lambda} = 1 - \left\{ 1 / \left[1 + T(\sigma_\varepsilon^2 / \sigma_\alpha^2) \right] \right\}^{\frac{1}{2}} \tag{5.2.22}$$

[56] Dokaz da se pogrješke transformiranog modela neće provoditi. Dokaz tvrdnje može se pronaći u knjizi Wooldrige, J. M. (2002.) *Econometric Analysis of Cross Section and Panel Data*, London: MIT Press, str. 259. – 260.

gdje je σ_α^2 konzistentan procjenitelj od σ_α^2, a σ_ε^2 konzistentan procjenitelj od σ_ε^2. Procjenitelji mogu biti bazirani na rezidualima modela s fiksnim efektom ili združenog (eng.*pooled*) OLS modela. GLS procjenitelj (eng.*feasible*) koji koristi λ umjesto λ naziva se procjeniteljem slučajnog efekta. Ovaj procjenitelj je konzistentan, pristran i asimptomatski normalno distribuiran kada je broj jedinki *N* velik, a vrijeme (*T*) fiksno. Svojstva procjenitelja s malim brojem jedinki *N* i dužim razdobljem nisu poznata.

Jednadžba (5.1.21) omogućava korištenje procjenitelja slučajnog efekta za procjenu združenog modela i modela s fiksnim efektom. Uvrsti li se u jednadžbu (5.1.21) $\lambda = 0$, dobije se formula (5.1.1) koja predstavlja združeni model. Ako se u jednadžbu (5.1.21) uvrsti $\lambda = 1$ dobije se formula (5.1.11) koja predstavlja „unutar“ model ili model s fiksnim efektom.

Iz svega do sada navedenog može se zaključiti da se model sa slučajnim efektom koristi kod panel podataka kod kojih je broj jedinki N velik, a vremensko razdoblje relativno kratko. Ovaj model dopušta da neovisna varijabla bude neovisna o vremenu jer je pretpostavka modela da pogrješka relacije nije korelirana ni s jednom nezavisnom varijablom.

Opravdanost korištenja modela sa slučajnim efektom provodi se uz pomoć Lagragovog multiplikatora (eng. *Lagrange multiplier test* - LM test). Ako je $\alpha_i = 0$ za svaku jedinku *i*, nema potrebe korištenja modela sa slučajnim efektom. Pretpostavka modela je ta da je $E(\alpha_i) = 0$. Pokaže li se da je i $\sigma_\alpha^2 = 0$, slučajni se efekt može isključiti iz modela.

Formiraju se sljedeće dvije hipoteze:

$$H_0 : \sigma_\alpha^2 = 0 \qquad (5.1.23)$$
$$H_1 : \sigma_\alpha^2 > 0$$

Test veličina je Breusch i Paganovog testa je:

$$LM = \frac{NT}{2(T-1)} \left\{ \frac{\sum_{i=1}^{N} \left(\sum_{t=1}^{T} \varepsilon_{it} \right)^2}{\sum_{i=1}^{N} \sum_{t=1}^{T} \varepsilon_{it}^2} - 1 \right\}, \tag{5.1.24}$$

gdje su ε_{it} reziduali združenog OLS modela. *LM*-test veličina ima *hi*-kvadrat distribuciju s jednim stupnjem slobode.

Ako je $LM < \chi^2_{(0.05,1)}$, prihvaća se nulta hipoteza kojom se pretpostavlja da je varijanca slučajnog efekta jedinki jednaka nuli. Dakle, može se zaključiti da nema heterogenosti između jedinki i da je korištenje modela sa slučajnim efektom nepotrebno.

Ako je $LM \geq \chi^2_{(0.05,1)}$, odbacuje se nulta hipoteza kojom se pretpostavlja da je varijanca slučajnog efekta jednaka nuli. Može se zaključiti da je varijanca slučajnog efekta veća od nule, tj. da postoji heterogenost između jedinki i da je model sa slučajnim efektom prikladan za procjenu parametara.

5.2.4.1.4. Problem autokorelacije

Dosadašnji su modeli pretpostavljali da je korelacija kroz vrijeme prisutna među pogrješkama relacije samo unutar jedinke. Koeficijent korelacije iznosio je

$$p(v_{it}, v_{is}) = t = \frac{\sigma_\alpha^2}{\sigma_\alpha^2 + \sigma_\varepsilon^2}, \text{ za } t \neq s \tag{5.1.25}$$

Koeficijent korelacije uvijek je bio konstantan i nije ovisio o tome koliko su vrijeme (*t*) i (*s*) međusobno udaljeni. Ova je pretpostavka ograničavajuća za ekonomske relacije kao što su ulaganje, potrošnja i sl. Kod ekonomskih relacija grješke relacije u trenutku *t* utječu najmanje na vremensko razdoblje $t+1$. Ovaj tip korelacije naziva se autokorelacija i nije uključena u pretpostavke dosadašnjih modela. Ako se prisutna autokorelacija zanemari pri procjeni modela, procijenjeni parametri bit će konzistentni, ali neučinkoviti, a standardna pogrješka procijenjenih parametara bit će pristrana.

S obzirom na to da autokorelacija uzrokuje pristranost i neučinkovitost procjenitelja, razvijeni su razni testovi za uočavanje autokorelacije među pogrješkama relacije. Za modele s fiksnim efektom postupci za utvrđivanje autokorelacije su jednostavniji. Na sreću, procjena modela s fiksnim efektom moguća je i kad su zadovoljene pretpostavke modela sa slučajnim efektom.

Najčešće korišten test za utvrđivanje autokorelacije prvog reda je Durbin-Watsonov test za panel-analizu. Zbog svoje jednostavnosti prisutan je u svim paketima za panel-analizu. Test se temelji na tome da se provjeri slijede li pogrješke relacije *AR* proces. Da bi se provjerilo postojanje autokorelacije prvoga reda, promatra se jednadžba

$$\varepsilon_{it} = \rho\varepsilon_{i,t-1} + \nu_{it} \ , \tag{5.1.26}$$

gdje su ν_{it} neovisno i identično distribuirani po jedinkama i vremenu. Ovaj test restriktivno pretpostavlja da sve jedinke imaju isti koeficijent autokorelacije ρ. Test se sastoji od sljedećih pretpostavki:

$$\begin{aligned} H_0 &: \rho = 0 \\ H_1 &: \rho \neq 0. \end{aligned} \tag{5.1.27}$$

Dakle, nultom se hipotezom pretpostavlja da ne postoji autokorelacija prvoga reda među pogrješkama relacija, a alternativnom se hipotezom pretpostavlja postojanje pozitivne ili negativne autokorelacije prvoga reda. Bhargava, Franzini i Narendanathan (1983.) predložili su sljedeću generalizaciju Durbin-Watsonove statistike:

$$dw_p = \frac{\sum_{i=1}^{N}\sum_{t=2}^{T}\left(\varepsilon_{it} - \varepsilon_{i,t-1}\right)}{\sum_{i=1}^{N}\sum_{t=1}^{T}\varepsilon_{it}} \tag{5.1.28}$$

gdje su ε_{it} reziduali procijenjenog modela s fiksnim efektom. Koristeći sličnu tehniku kao Durbin i Watson, autori testa odredili su donju i gornju granicu područja[57] u kojem nije moguće donijeti odluku o autokorelaciji prvoga reda u ovisnosti o *N*, *T* i *K*. Za razliku od Durbin-Watsonova testa za vremenske serije, područje u kojem se ne može donijeti odluku o autokorelaciji vrlo je usko, pogotovo kada je broj jedinki u panelu velik.

Osim Durbin-Watsonova testa postoji nekoliko *LM*-testova. Prvi *LM*-test utvrđuje istodobno postojanje autokorelacije prvoga reda i postojanje slučajnog efekta. Drugi *LM*-test utvrđuje autokorelaciju prvoga reda uz pretpostavku da model sadrži fiksni efekt. Treći *LM*-test utvrđuje postojanje autokorelacije prvoga reda uz pretpostavku da model sadrži slučajni efekt. (Baltagi i Li)[58]

[57] Tablicu s donjim i gornjim granicama Durbin-Watsonova testa za određene *N*, *K*, *T* vidjeti u knjizi Verbeek, M. (2005.) *A Guide To Modern Econometrics*, Second edition, London: John Wiley & Sons, str. 357.
[58] *LM*-testovi samo su navedeni jer je izračun *LM*-statistika jako dugačak i zahtijeva uporabu složenijih matematičkih alata (tenzorski produkt) i uvođenje raznih novih oznaka tako da prelazi okvire ovoga rada. Više o *LM*-testovima pogledati u knjizi Baltagi, B. H. (2005.) *Econometric Analysis of Panel Data*, Third Edition. West Sussex: John Wiley and Sons, str. 93. – 103.

5.2.4.2. Dinamički panel-modeli

5.2.4.2.1. Karakteristike dinamičkog panel-modela

Većina ekonomskih relacija je dinamičke prirode što znači da sadašnja vrijednost neke varijable ovisi o njezinim prethodnim stanjima. Dinamički panel-modeli sadrže zavisnu varijablu s pomakom od jednog ili više vremenskih intervala unatrag, ovisno o svojstvima zavisne varijable. Dinamički panel koji sadrži zavisnu varijablu s jednim vremenskim pomakom unatrag ima oblik

$$y_{it} = \mu + \gamma y_{i,t-1} + \beta_1 x_{it1} + \beta_2 x_{it2} + \ldots \beta_K x_{itK} + \alpha_i + \varepsilon_{it};\ i = 1,\ldots N, t = 1,\ldots,T \qquad (5.1.29)$$

gdje se podrazumijeva da su pogrješke relacije ε_{it} nezavisno i identično distribuirane sa sredinom 0 i varijancom σ_ε^2. Uvođenje zavisne varijable s pomakom dovodi do pojave korelacije između zavisne varijable s pomakom i α_i. Treba objasniti zašto dolazi do navedene korelacije. Naime, ako se pogleda jednadžba (26), vidi se da je y_{it} funkcija od α_i. Korelacija će postojati bez obzira na to je li α_i fiksan efekt ili slučajna pogrješka. Isto tako, ako se u jednadžbu (1) umjesto varijable y_{it} uvrsti varijabla $y_{i,t-1}$, vidi se da je i $y_{i,t-1}$ funkcija od α_i. Ako bi se zanemarila uočena korelacija i ako bi se naveden model procijenio metodom najmanjih kvadrata, OLS procjenitelj parametara bio bi pristran i nekonzistentan.

Ako se koristi procjenitelj fiksnog efekta, „untar“ (eng.w*ithin*) transformacijama će se izgubiti α_i, ali će $\left(y_{i,t-1} - \bar{y}_{i.-1}\right)$ biti korelirana s $(\varepsilon_{it} - \bar{\varepsilon}_i)$ i ako su v_{it} međusobno nekorelirane. Varijabla $\bar{y}_{i.-1}$ definira se formulom

$$\bar{y}_{i.-1} = \frac{\sum_{i=2}^{T} y_{i,t-1}}{T} \tag{5.1.30}$$

Korelacija je prisutna zbog toga što je varijabla $y_{i,t-1}$ korelirana s ε_{it}. *Within* procjenitelj će biti pristran i faktor korekcije iznosit će $\frac{1}{T}$, a konzistentnost će ovisiti o broju vremenskih intervala *T*.[59] Kiviet je (1995.) predložio korigirani „unutar“ procjenitelj koji se dobije oduzimanjem konzistentnog procjenitelja od pristranog originalnog „unutar“ procjenitelja. Dakle, koristi li se *within* procjenitelj za procjenu panel-podataka za velik broj jedinki i fiksan broj vremenskih intervala *T*, procjene će biti pristrane i nekonzistentne. Procjenitelj će biti konzistentan ako se procjenjuju podatci u kojima je vremenski interval $T \to \infty$.[60]

Procjenitelj sa slučajnim efektom također je pristran u procjeni dinamičkih panela. Varijabla $\left(y_{i,t-1} - \lambda \bar{y}_{i.-1}\right)$ bit će korelirana s varijablom $(\varepsilon_{it} - \lambda \bar{\varepsilon}_i)$. Diferenciranje je alternativan način transformiranja dinamičkog modela kako bi se izgubio individualan efekt. Anderson i Hsiao predložili su prve diferencije kako bi se uklonio α_i iz modela i predložili da se $\Delta y_{i,t-2} = \left(y_{i,t-2} - y_{i,t-3}\right)$ ili $y_{i,t-1}$ koristi kao instrument za $\Delta y_{i,t-1} = \left(y_{i,t-1} - y_{i,t-2}\right)$. Ovi instrumenti nisu korelirani s $\Delta \varepsilon_{i,t-1} = \left(\varepsilon_{i,t-1} - \varepsilon_{i,t-2}\right)$ ako $\varepsilon_{i,t}$ nisu međusobno korelirani. Procjenitelj dobiven ovom metodom instrumentalnih varijabli je konzistentan, ali ne nužno i efikasni procjenitelji.[61] Arellano i Bond (1991.) predložili su generaliziranu metodu trenutaka (eng.*generalized method of moments* – GMM) koja je učinkovitija od Anderson i Hsiao (1981.) metode.[62] U daljnjem tekstu metoda će biti detaljno objašnjena.

---

[59] Nickel, S. (1981.) „Biases in Dynamic Models With Fixed Effects“, *Econometrica*, 49, str. 1417. – 1426.
[60] Kiviet, J. F. (1995.) „On bias, *inconsistency* and effciency of various estimators in dynamic panel data models“, *Journal of econometrics*, 68, str. 53. – 78.
[61] Anderson,T. W. i Hsiao, C. (1981.) „Estimation of Dynamic Models with Error Components“, *Journal of the American Statistical Association*, 76, str. 598. – 606.
[62] Arelleanno, M. i Bond, S. (1991.) „Some Tests of Specification for Panel Dana: Monte Carlo Evidence and Aplication to Employment Equations“, *Review of Economic Studies, 58*, str. 277-297.

5.2.4.2.2. Autoregresijski dinamički panel-model

Da bismo olakšali razumijevanje metode koju su predložili Arellano i Bond (1991.), promatrat će se jednostavan autoregresijski model koji neće sadržavati nezavisne varijable. Autoregresijski model dan je jednadžbom

$$y_{it} = \gamma y_{i,t-1} + \alpha_i + \varepsilon_{it};\ i = 1,\ldots N, t = 1,\ldots,T, \tag{5.1.31}$$

gdje su ε_{it} nezavisno i identično distribuirani sa sredinom 0 i varijancom σ_ε^2 Poznato je da se u modelu javlja problem korelacije između zavisne varijable s vremenskim pomakom i α_i. Da bi se uklonio utjecaj fiksnog efekta ili slučajne varijable, jednadžba (5.1.33) se diferencira. Diferenciranjem se dobije sljedeća jednadžba:

$$y_{it} - y_{i,t-1} = \gamma\left(y_{i,t-1} - y_{i,t-2}\right) + \left(\varepsilon_{it} - \varepsilon_{i,t-1}\right);\ i = 1,\ldots N, t = 1,\ldots,T\ . \tag{5.1.32}$$

Ako se transformiran model procijeni metodom najmanjih kvadrata, procjenitelj od γ neće biti konzistentan zbog korelacije između $y_{i,t-1}$ i $\varepsilon_{i,t-1}$, čak ni kada je $T \to \infty$, a $\left(\varepsilon_{it} - \varepsilon_{i,t-1}\right)$. Slijedi *MA*[63] proces. Korelacija se jasno vidi ako jednadžbu (5.1.33) pomaknemo za jedan vremenski interval unatrag. Tada će $y_{i,t-1}$ postati zavisna varijabla te se uvrštavanjem $y_{i,t-1}$ u formulu (5.1.33) dobije jednadžba

$$\cdot\, y_{i,t-1} = \gamma y_{i,t-2} + \alpha_i + \varepsilon_{i,t-1};\ i = 1,\ldots N, t = 1,\ldots,T \tag{5.1.33}$$

[63] Više o *MA*-procesima pogledati u knjizi Enders, W. (2003.) *Applied Econometric Time Series*, Second edition, New York, Wiley and Sons, str. 48. – 99.

Iz jednadžbe (30) očito je da je i $y_{i,t-1}$ funkcija od $\varepsilon_{i,t-1}$ pa je time očito i postojanje korelacije. $t=3$ Prvo razdoblje koje se može prikazati jednadžbom (5.1.34) je $t=3$ i dobije se sljedeći izraz:

$$y_{i3}-y_{i2}=\gamma\left(y_{i2}-y_{i1}\right)+\left(\varepsilon_{i3}-\varepsilon_{i,2}\right);\ i=1,...N\ . \tag{5.1.34}$$

U ovom slučaju y_{i1} je valjan instrument za $\left(y_{i2}-y_{i1}\right)$. Jako je koreliran s $\left(y_{i2}-y_{i1}\right)$, a nije koreliran s $\left(\varepsilon_{i3}-\varepsilon_{i,2}\right)$ dok ε_{it} nisu međusobno korelirani.

Pokazat će se još što se događa za $t=4$. Uvrštavanjem $t=4$ u jednadžbu (5.1.34) dobije se

$$y_{i4}-y_{i3}=\gamma\left(y_{i3}-y_{i2}\right)+\left(\varepsilon_{i4}-\varepsilon_{i3}\right);\ i=1,...N\ . \tag{5.1.35}$$

U ovom slučaju y_{i1} i y_{i2} su valjani instrumenti za $\left(y_{i3}-y_{i2}\right)$ jer obje varijable nisu korelirane s $\left(\varepsilon_{i4}-\varepsilon_{i3}\right)$. Ako se isto postupak primjeni za razdoblje T, valjani instrumenti bit će $(y_{i1}, y_{i2,}...y_{i,T-2})$.

Poznato je da uključivanje više uvjeta intervalu povećava učinkovitost procjenitelja. Arellano i Bond predložili su da se lista instrumenata proširi dodatnim uvjetima intervala. Broj uvjeta intervala ovisi o *t*. Tako za $t=3$ postoji uvjet

$$E\left\{\left(\varepsilon_{i3}-\varepsilon_{i2}\right)y_{i1}\right\}=0\,. \tag{5.1.35}$$

Za $t=4$ postoje dva uvjeta

$$E\left\{\left(\varepsilon_{i4}-\varepsilon_{i3}\right)y_{i1}\right\}=0 \qquad (5.1.36)$$
$$E\left\{\left(\varepsilon_{i4}-\varepsilon_{i3}\right)y_{i2}\right\}=0.$$

Analogno za $t=T$ postojat će $T-2$ uvjeta

$$E\left\{\left(\varepsilon_{iT}-\varepsilon_{i,T-1}\right)y_{i1}\right\}=0 \qquad (5.1.37)$$
$$E\left\{\left(\varepsilon_{iT}-\varepsilon_{i,T-1}\right)y_{i,2}\right\}=0$$
$$\ldots$$
$$E\left\{\left(\varepsilon_{iT}-\varepsilon_{i,T-1}\right)y_{i,T-2}\right\}=0.$$

Svi navedeni uvjeti intervala mogu se iskoristiti za formiranje *GMM*-procjenitelja. Da bi se uveo *GMM*-procjenitelj za broj vremenskog intervala *T*, definira se

$$\Delta\varepsilon_i=\begin{pmatrix}\varepsilon_{i4}-\varepsilon_{i3}\\ \varepsilon_{i5}-\varepsilon_{i4}\\ \vdots\\ \varepsilon_{iT}-\varepsilon_{i,T-1}\end{pmatrix} \qquad (5.1.38)$$

kao vektor transformiranih grješaka relacije, a

$$Z_i=\begin{pmatrix}\left[y_{i1}\right] & 0 & 0\\ 0 & \left[y_{i1},y_{i2}\right] & 0\\ 0 & 0 & \left[y_{i1},y_{i2},\ldots y_{i,T-1}\right]\end{pmatrix} \qquad (5.1.39)$$

kao matrica instrumenata. Matrica Z_i je matrica tipa $(T-2)\times(T-2)$.

Skup svih uvjeta intervala može se zapisati kao

$$E\left\{Z_i^{'}\Delta\varepsilon_i\right\}=0\cdot \tag{5.1.40}$$

Da bi se izveo *GMM*-procjenitelj (procjenitelj metodom generaliziranih intervala), u izraz (5.1.43) umjesto $\Delta\varepsilon_i$ uvrste se $(\Delta y_i-\gamma\Delta y_{i,-1})$[64] te se dobije:

$$E\left\{Z_i^{'}(\Delta y_i-\gamma\Delta y_{i,-1})\right\}=0\cdot \tag{5.1.41}$$

Broj uvjeta intervala često će biti veći od broja nepoznatih koeficijenata, koeficijent γ se procjenjuje minimiziranjem kvadratne forme u oznakama odgovarajućih uvjeta intervala

$$\min_{\gamma}\left[\sum_{i=1}^{N}Z_i^{'}(\Delta y-\gamma\Delta y_{i,-1})\right]^{'}W_N\left[\sum_{i=1}^{N}Z_i^{'}(\Delta y-\gamma\Delta y_{i,-1})^{'}\right], \tag{5.1.42}$$

gdje je W_N simetrična pozitivno definitna težinska matrica. Minimum se dobije tako da se izraz (45) po γ i dobivena derivacija izjednače s nulom. Iz dobivena izraza izluči se γ i dobije se sljedeći procjenitelj:

$$\gamma_{GMM}=\left(\left(\sum_{i=1}^{N}\Delta y_{i,-1}^{'}Z_i\right)W_N\left(\sum_{i=1}^{N}Z_i^{'}\Delta y_{i,-1}\right)\right)^{-1}\times\left(\sum_{i=1}^{N}\Delta y_{i,-1}^{'}Z_i\right)W_N\left(\sum_{i=1}^{N}Z_i^{'}\Delta y_i\right)\cdot \tag{5.1.43}$$

Svojstva procjenitelja ovise o načinu na koji se odabere W_N i procjenitelj je konzistentan dok je matrica W_N pozitivno definitna. Za W_N se može odabrati matrica identiteta I. Optimalna težinska matrica W_N je ona matrica koja ima asimptotski najmanju matricu kovarijanci za

[64] Svaki $\varepsilon_{i,t}$ izrazi se pomoću $y_{i,t}$ i $\gamma y_{i,t-1}$ iz jednadžbe (5.2.33) i dobiven se izraz uvrsti u jednadžbu (5.1.42).

γ_{GMM} . Iz teorije *GMM*-procjenitelja poznato je da je optimalna težinska matrica proporcionalna inverznoj matrici skupa intervala. U ovom slučaju vrijedi da optimalna težinska matrica mora zadovoljavati jednakost.

$$\underset{N\to\infty}{p\lim} W_N = V\left\{Z_i^{'}\Delta\varepsilon_i\right\}^{-1} = E\left\{Z_i^{'}\Delta\varepsilon_i\Delta\varepsilon_i^{'}Z_i\right\}^{-1} \tag{5.1.44}$$

Općenito, *GMM*-pristup ne pretpostavlja da su ε_{it} neovisno i identično distribuirani po jedinkama i vremenu. Umjesto da se matrica optimalnih težina procijeni bez ograničenja, moguće je uključiti ograničenja koja zahtijevaju nepostojanje autokorelacije među pogrješkama relacije kao i pretpostavku homoskedastičnosti varijance. Pod pretpostavkom neovisno i identično distribuiranih grješaka relacije

$$E\left\{\Delta\varepsilon_i\Delta\varepsilon_i^{'}\right\} = \sigma_\varepsilon^2 G = \sigma_\varepsilon^2 \begin{pmatrix} 2 & -1 & 0 & & \dots \\ -1 & 2 & \dots & & 0 \\ & & \dots & & \\ 0 & & & 2 & -1 \\ 0\dots & & & -1 & 2 \end{pmatrix}. \tag{5.1.45}$$

matrica optimalnih težina može se definirati kao

$$W_N^{opt} = \left(\sum_{i=1}^{N} Z_i^{'} G Z_i\right)^{-1} \tag{5.1.46}$$

Procjenitelj koji se dobije uvrštavanjem matrice optimalnih težina W_N^{opt} iz formule (5.1.46) u formulu (5.1.43) naziva se Arellano-Bondov procjenitelj u jednom koraku i sljedećeg je oblika:

$$\gamma_{GMM} = \left(\left(\sum_{i=1}^{N} \Delta y_{i,-1}^{'} Z_i \right) W_N^{opt} \left(\sum_{i=1}^{N} Z_i^{'} \Delta y_{i,-1} \right) \right)^{-1} \cdot \left(\sum_{i=1}^{N} \Delta y_{i,-1}^{'} Z_i \right) W_N^{opt} \left(\sum_{i=1}^{N} Z_i^{'} \Delta y_i \right). \tag{5.1.47}$$

Ako se diferencirane pogrješke relacije $\Delta\varepsilon_i$ u formuli (5.1.47) zamjene s diferencijama reziduala $\Delta\varepsilon_i$ dobivenih procjenom konzistentnog Arellano-Bondova procjenitelja γ_{GMM} u jednom koraku, novi procjenitelj naziva se Arellano-Bondov procjenitelj u dva koraka.[65]

$$\gamma_{GMM} = \left(\left(\sum_{i=1}^{N} \Delta y_{i,-1}^{'} Z_i \right) W_N^{opt} \left(\sum_{i=1}^{N} Z_i^{'} \Delta y_{i,-1} \right) \right)^{-1} \cdot \left(\sum_{i=1}^{N} \Delta y_{i,-1}^{'} Z_i \right) W_N^{opt} \left(\sum_{i=1}^{N} Z_i^{'} \Delta y_i \right) \tag{5.1.48}$$

Procjenitelji u jednom ili dvama koracima asimptotski su jednaki ako su ε_{it} identični i jednoliko distribuirani sa sredinom nula i varijancom σ_ε^2.

5.2.4.2.3. Dinamički panel-model s nezavisnim varijablama

U ovom dijelu promatra se model koji osim zavisne varijable s pomakom sadrži *K* nezavisnih varijabli x_{itk}, $k = 1,...,K$. Model se može prikazati jednadžbom

$$y_{it} = \mu + \gamma y_{i,t-1} + \beta_1 x_{it1} + \beta_2 x_{it2} + ...\beta_k x_{itK} + \alpha_i + \varepsilon_{it};\ i = 1,...N, t = 1,...,T \tag{5.1.48}$$

Često se radi lakšeg zapisa umjesto jednadžbe (5.1.48) koristi matrični zapis

[65] Baltagi, B. H. (2005.) *Econometric Analysis of Panel Dana*, Third Edition. West Sussex: John Wiley and Sons, str. 137. – 139.

$$y_{it} = \mu + x_{it}^{'}\beta + \gamma y_{i,t-1} + \alpha_i + \varepsilon_{it} = 1,...N, t = 1,...,T \tag{5.1.49}$$

gdje je β vektor parametara $\beta_1,...,\beta_K$, a $x_{it}^{'}$ je vektor nezavisnih varijabli $x_{it1}, x_{it2},..., x_{itK}$.

Pretpostavka modela je da su sve x_{it} strogo egzogene varijable u smislu da su nekorelirane s bilo kojim ε_{is}. Ovaj uvjet može se zapisati kao

$$E\{x_{is}\Delta\varepsilon_{it}\} = 0, za \text{ svaki s,t} \tag{5.1.50}$$

pa se $x_{i1}^{'}, x_{i2}^{'},..., x_{iT}^{'}$, mogu dodati na listu instrumenata u diferenciranom modelu za svako vrijeme.

Često se pretpostavka striktne egzogenosti zamijeni s pretpostavkom (predeterminiranosti) što znači da su trenutna vrijednost i vrijednosti s pomakom svake nezavisne varijable nekorelirane s trenutnim vrijednostima pogrješke relacije. Ova se pretpostavka može zapisati kao

$$\begin{aligned} &E\{x_{it}, \varepsilon_{is}\} \neq 0, t < \text{s}, \\ &E\{x_{it}, \varepsilon_{is}\} = 0, \text{ inače.} \end{aligned} \tag{5.1.51}$$

Dakle, za $t = 3$ jednadžba prvih diferencija ima oblik

$$y_{i3} - y_{i2} = \gamma(y_{i2} - y_{i1}) + (x_{i2}^{'} - x_{i1}^{'})\beta + (\varepsilon_{i3} - \varepsilon_{i,2}), i = 1,..., N. \tag{5.1.52}$$

Ako je pretpostavka (5.1.51) zadovoljena, onda su za jednadžbu (5.1.52) $x_{i1}^{'}, x_{i2}^{'}$ valjani instrumenti ako nisu korelirani s $\left(\varepsilon_{i3} - \varepsilon_{i,2}\right)$.

Za $t = 4$ jednadžba prvih diferencija ima oblik

$$y_{i4} - y_{i3} = \gamma\left(y_{i3} - y_{i2}\right) + (x_{i4}^{'} - x_{i3}^{'})\beta + \left(\varepsilon_{i4} - \varepsilon_{i,3}\right), i = 1,...,N\,. \qquad (5.1.53)$$

Za jednadžbu (5.1.53) $x_{i1}^{'}, x_{i2}^{'}, x_{i3}^{'}$ valjani su instrumenti ako nisu korelirani s $\left(\varepsilon_{i3} - \varepsilon_{i,2}\right)$.

Ako se nastave nabrajati dodatni instrument za sva vremenska razdoblja, dobije se sljedeća matrica instrumenata

$$Z_i = \begin{pmatrix} \left[y_{i1}, x_{i1}, x_{i2}\right] & 0 & 0 \\ 0 & \left[y_{i1}, y_{i2}, x_{i1}, x_{i2}, x_{i3}\right] & 0 \\ 0 & 0 & \left[\; y_{i1}, y_{i2},...y_{i,T-1}, x_{i1}, x_{i2},..., x_{i,T-1} \;\right] \end{pmatrix} \qquad (5.1.54)$$

Formula za procjenitelje u jednom i dvama koracima $\begin{pmatrix} \gamma \\ \beta \end{pmatrix}$ složena je pa se u ovom radu neće navoditi.[66]

Iako su u matrici (1.5.54) pokazani svi mogući instrumenti, pri procjeni odgovarajućeg modela ne koriste se svi. Valjanost instrumenata koji se odaberu za procjenu modela testira se Sarganovim testom. Sarganov test je test koji testira valjanost instrumentalnih varijabli. To je test za preidentifikaciju ograničenja. Uvođenjem svake nove instrumentalne varijable dodaje se novi uvjet (ograničenje) koji mora biti zadovoljen. Hipoteza koja se testira je da su odabrane instrumentalne varijable nekorelirane s rezidualima. Ako se prihvati nulta hipoteza, svi uvjeti

[66] Više o procijenitelju, izvor formule i sl. pogledati u djelu Baltagi, B. H. (2005.), *Econometric Analysis of Panel Data*, Third Edition. West Sussex: John Wiley and Sons, str. 139. – 140.

trenutka zadovoljeni su i svi se navedeni instrumenti prihvaćaju. Uvođenjem dodatnih instrumentalnih varijabli dobiva se na učinkovitosti procjenitelja, ali procjenitelj postaje pristran. Dakle, treba odabrati optimalan broj instrumenata kako bi se zadovoljila nulta hipoteza Sarganova testa i da ne postoji korelacija prvog i drugog reda među rezidualima.

5.3. Rezultati empirijskog istraživanja

Rezultati ovog istraživanja najprije će prikazati analizu svih zemalja za cijelo razdoblje promatranja a potom za razdoblje prije krize kako bi se analizirao utjecaj financijskog sustava na gospodarski rast i u doba krize. Za svaku zemlju kontrolne varijable obuhvaćaju OPENESS, SAVINGS i RISK. U analizi će biti prikazan cijeli put analize do odabira odgovarajućeg panela koji će dati rezultate ovog istraživanja i na osnovu kojih će se donositi određeni zaključci.

5.3.1. Odabrane zemlje središnje, istočne i jugoistočne Europe

Za empirijsku analizu odabrano je 17 zemalja središnje, istočne i jugoistočne Europe. Odabrane zemlje prikazane su u sljedećoj tablici:

Tablica 5.1. Odabrane zemlje središnje, istočne i jugoistočne Europe

1. Albanija: ALB_ 2. Austrija: AUT_ 3. Bosna i Hercegovina: BIH_ 4. Bugarska: BUL_ 5. Hrvatska: CRO_ 6. Češka: CZK_ 7. Njemačka: GER_ 8. Grčka: GRE_ 9. Mađarska: HUN_	10. Italija: ITA_ 11. Makedonija: MAC_ 12. Crna gora: MNE_ 13. Poljska: POL_ 14. Rumunjska: ROM_ 15. Srbija: SER_ 16. Slovačka: SVK_ 17. Slovenija: SLO_

Ovaj uzorak odabranih zemalja interesantan je u ovom istraživanju zato što uzima u obzir zemlje s različitim stupnjem razvijenosti financijskoga sustava. Ali prije svega potrebno je naglasiti i nekoliko povijesnih činjenica za sve odabrane zemlje, što slijedi u nastavku teksta.

Do početka devedesetih neke od navedenih zemalja nisu postojale kao samostalne države. Raspadanjem SFRJ 1991. godine nastale su države Slovenija, Hrvatska i Bosna i Hercegovina, 1992. osamostalila se i Makedonija, a od 2006. došlo je do razdvajanja Srbije i Crne Gore.

Većina odabranih zemalja ušla je u Europsku uniju ili je u pregovorima za ulazak. U Europsku uniju 2004. ušle su Češka, Mađarska, Poljska, Slovačka i Slovenija dok su 2005. članstvo u Europskoj uniji dobile Rumunjska i Bugarska. Hrvatska ulazi u EU 2012. Kandidati za ulazak

u EU su Makedonija, Srbija i Crna Gora.

Nadalje, devedesetih godina prošloga stoljeća sve su te zemlje prošle proces transformacije iz socijalističkog u kapitalistički sustav, odnosno usmjerile su se prema tržišnoj ekonomiji. Ipak, važno je naglasiti da su zemlje bivše Jugoslavije prošle i ratna zbivanja i nisu u pravom smislu riječi prošle proces transformacije iz planske prema tržišnoj ekonomiji pa i danas nakon dva desetljeća postoje razmišljanja da je onaj bivši sustav u mnogočemu bio bolji. Jedan od razloga takvu razmišljanju je pretvorba (privatizacija)[67], no taj proces nije predmet ove disertacije i neće biti posebno elaboriran.

Zastoj u razvoju bio je obilježen nultim ili čak negativnim stopama ekonomskoga rasta punih 10 godina (između 1980. i 1990. godine). Državno je vlasništvo tada negiralo poduzetništvo i privatnu inicijativu, a bez njih je bilo teško ostvariti kontinuiran proces inovacija i tehnoloških promjena.

U početku su zemlje iskusile oštar pad ekonomskoga rasta koji je nerijetko bio praćen i drugim makroekonomskim nestabilnostima poput hiperinflacije i tečajne krize. Rast koji je nastupio nakon provedbe stabilizacijskih programa većinom je generirala povećana osobna potrošnja koja je u situaciji otvaranja tržišta pogodovala rastu uvoza. Vanjska nekonkurentnost tranzicijskih ekonomija rezultirala je stagniranjem izvoza i dovela države do visokih trgovinskih deficita. Spomenuti deficiti trgovinske bilance kompenzirani su rastućim vanjskim zaduženjem ili priljevom direktnih stranih investicija koje su samo označavale promjenu vlasničke strukture. U zemljama dolazi do privatizacije državnoga sektora, liberalizacije cijena, tržišnoga otvaranja i reforme bankarskoga sustav. (Usp. Vukoja, 2008.)

Razvoj tržišta kapitala bio je prekinut tijekom socijalističke vlasti. Tijekom devedesetih godina u svim zemljama dolazi do oživljavanja financijskih tržišta, u prvom redu tržišta dionica. Razvoju tržišta dionica doprinosi i proces tranzicije. Premda se tržišta dionica kontinuirano

[67] Prijelomna etapa tržišne transformacije je u procesu privatizacije. Ona se i spomenutim zemljama odvijala putem različitih modela, no svugdje je imala isto značenje – predstavljala je svojevrsnu barijeru pokušajima održanja ili uspostave tržišnih monopola. Tako je u Poljskoj primijenjen tzv. mješoviti privatizacijski model. Dugoročni plan privatizacije i kontrola tržišta kapitala preko državnih investicijskih fondova i inozemnih menadžera rezultirali su konzistentnim procesom privatizacije u kojem su osobito velika poduzeća postupno nakon restrukturiranja ulazila na tržište kapitala. Karakteristika mađarskog modela privatizacije je nepostojanje podjele kapitala za razliku od Slovačke i Češke u kojima je primijenjen model tzv. vaučerske-kuponske prezentacije. U Slovačkoj se on poslije zamjenjuje modelom „slučaj po slučaj“. U Sloveniji se provodio „kompromisni model privatizacije“, dok se hrvatski privatizacijski model razvijao etapno, putem pretvorbe i privatizacije. U Hrvatskoj on započinje 1991. godine te obuhvaća 3.600 društvenih poduzeća ukupne procijenjene vrijednosti cca 20 milijardi USA $. (Potrebno je naglasiti da to nije bila ukupna vrijednost nacionalnog proizvodnog kapitala!) Za dobivanje ove veličine posljednjem iznosu potrebno je pridodati 30 – 40 milijuna USA $ procijenjene vrijednosti ostataka nacionalnog proizvodnog kapitala.

razvijaju, može se zaključiti da je još uvijek riječ o malim tržištima. (Usp. Bogdan, 2008.)
Osobito značenje u procesu privatizacije ima privatizacija banaka. Tako je bilo i u Hrvatskoj. Predtranzicijsko razdoblje opteretilo je banke nepovoljnom strukturom kapitala i velikim udjelom rizičnih potraživanja. Sve je to posljedica selektivne monetarno-kreditne politike kada su banke poslovale pod političkim pritiscima. Glavne karakteristike bankarskoga sustava u drugoj polovici 90-ih njegova je blokada, nelikvidnost, stečajevi dijela industrije, sanacija banaka te na kraju njihova prodaja inozemnim vlasnicima. Uz spomenuto upravo su restriktivna monetarno-kreditna politika, nekompletna politika javnog duga kao i nerazvijeni instrumenti sekundarnog tržišta dodatno produbili krizu u bankarskom sustavu.

S obzirom na to da je došlo do reformi u bankarskom sustavu, oživljavanja tržišta kapitala, tržišne otvorenosti i financijske otvorenosti, može se zaključiti da se zemlje središnje i istočne Europe financijski razvijaju. Razvoj financijskog sustava promatranih zemalja ima posebnu težinu jer osim restrukturiranja bankarskih posrednika, koji se prilagođavaju tržišnom gospodarstvu, dolazi do izgradnje nepostojećih dijelova bankarskog sustava kao što su tržište kapitala i nebankarski posrednici. Unatoč različitim rezultatima u razvoju tržišta kapitala u financijskim sustavima još uvijek dominiraju banke te su financijski sustavi i dalje bankocentrični.
Ako bi se, primjerice, uspoređivali bankarski sustav Hrvatske i Mađarske, može se zaključiti da su Mađarske banke nešto slabije razvijene u odnosu na hrvatske premda je sustav s udjelom stranih banaka u ukupnoj aktivi od gotovo 90 % podjednako internacionaliziran kao i hrvatski. Fondovi imaju malo veći udjel u financijskom sustavu nego u Hrvatskoj, no ta razlika nije značajna na ovom stupnju razvijenosti financijskog sustava. Razlika se uglavnom može objasniti time da su u Mađarskoj prije osnovani dobrovoljni mirovinski fondovi. Međutim, fondovi rizičnog kapitala puno su aktivniji nego u Hrvatskoj.
Kao i u Hrvatskoj, otvoreni fondovi uglavnom ulažu u državne obveznice i ne ostvaruju posebno atraktivne povrate. Premda je promet na budimpeštanskoj burzi (ovisno o godini) 5 – 10 puta veći nego na zagrebačkoj burzi, dionice nisu atraktivna imovina za mađarske ulagače. To se može objasniti s naglim padanjem cijena i nedovoljnim financijskim bogatstvom Mađara (zbog čega se preferiraju klasični oblici štednje kao i u gotovo svim odabranim zemljama u ovoj disertaciji).
Ni nakon spektakularnog uvrštenja velikih mađarskih poduzeća na burzu i postizanja za tranzicijske zemlje fantastičnog omjera prometa dionicama i BDP-a, Mađari nisu postali veliki dioničari. Tržište su pokretali strani investitori koji su bili i ostali najvažniji dioničari na tom

tržištu.

Slučaj Mađarske jasno pokazuje kako uvrštenje velikih poduzeća na burzu može stvoriti jedno od najlikvidnijih tržišta, ali da takav razvoj događaja još uvijek ne mora stvoriti stabilnu strukturu domaćih investitora. Iskustvo susjeda jasno potvrđuje korelaciju između liberalizacije optjecaja kapitala i razvoja dioničarskog tržišta, no daljnje razvojne perspektive tržišta kapitala i dalje su upitne. Isto tako, razlika između Hrvatske i Mađarske je i u tome što je Mađarska uvrstila sve svoje velike državne tvrtke, a Hrvatska to nije uradila. Upravo je to bio i razlog zašto je Mađarska postigla višestruko veću tržišnu likvidnost pa se čvrsta korelacija između inozemnih ulaganja i rasta financijskoga portfelja mogla uspostaviti nekoliko godina prije nego u Hrvatskoj. Premda nešto veća od Hrvatske, Mađarska je prema globalnim financijskim mjerilima podjednako mala i otvorena kao i Hrvatska te suočena s temeljnom dilemom o financijskom razvoju.

Naime, na nižim razinama razvoja, dok privatna financijska imovina još ne doseže velike vrijednosti, moguće je imati nerazvijeno tržište kapitala i prepreke za međunarodne tokove kapitala. Dok je kapital u zemlji rijedak, nije teško pronaći mjesta gdje će donijeti visoke povrate. Ali kako rastu fianancijske imovine , a kapital postaje dostupniji, teže je pronaći dobre prilike za ulaganja. U takvim uvjetima temeljna dilema financijske politike postaje sve izraženija: ili će se razvijati domaće tržište kapitala i pružiti nove prilike za ulaganja u vidu raznih vrijednosnih papira, ili će se otvoriti vrata za odljev kapitala u inozemstvo i dati mogućnost ostvarivanja povrata na drugim, propulzivnijim tržištima. Tempo rasta financijskih imovina u Hrvatskoj, uz slabo dioničko tržište, pokazuje kako možda nismo daleko od trenutka aktuelnosti te dileme. Nema dileme, ako tržište ostane aktivno kako je to danas, novac će ići na druga tržišta gdje može ostvariti veće prinose.

5.3.2. Deskriptivna analiza

Kako je i u prethodnom dijelu ove disertacije navedeno, ovo je istraživanje provedeno na 17 odabranih zemalja. Istraživanje je provedeno u razdoblju od 1996. do 2011.godine. Postavlja se pitanje zašto je odabrano ovo razdoblje promatranja?

Naime, većina zemalja iz uzorka se osamostalila do početka ovoga istraživanja. Na žalost, na prostoru bivše Jugoslavije dogodio se razoran rat i zemlje koje su nastale raspadom Jugoslavije nisu proživjele u pravom smislu riječi proces transformacije ekonomije u tržišni režim.

Isto tako, od početne godine ovog istraživanja dostupni su i podatci o razvijenosti financijskih sustava odabranih zemalja. Dakako, za pojedine zemlje neki podatci nedostaju, ali to nije narušilo sam proces analize i zaključaka koji se mogu donijeti. Primjerice, Srbija i Crna Gora nemaju pojedinačne podatke jer su se one odvojile tek 2006. godine. U ovom istraživanju podatci su za te dvije zemlje analizirani do 2006. godine kao zajednički podatci, a od 2006. godine za svaku zemlju zasebno.

U empirijskoj analizi bit će analizirana dvadeset jedna varijabla koja pokazuje razvijenost financijskoga sustava za svaku zemlju iz uzorka i sve korištene varijable sadržat će podatke na godišnjoj razini.

Indikatori koji su korišteni u analizi (kao i njihove oznake) su sljedeći:

H1a pokazatelji:

1. razlika aktivne i pasivne kamate (kamatna marža): _INTERESTSPREAD
2. udio ukupne novčane mase u BDP-u: _BMONEYINGDP
3. udio aktive središnje banke u BDP-u: _CBAGDP
4. udio aktive bankarskog sektora u BDP-u: _DBAGDP
5. udio aktive nebankarskog sektora u BDP-u: _OFAGDP
6. udio kredita bankarskog sektora privatnom sektoru u BDP-u: _BANKCREDINGDP
7. udio kredita privatnom sektoru u ukupnoj aktivi bankarskog sektora: _PCRDDBA
8. ukupan udio kredita privatnom sektoru u BDP-u: _PRIVCREDINGDP
9. udio aktive životnih osiguravajućih društava u BDP-u: _INSLIFE
10. udio ukupne aktive osiguravajućih društava u BDP-u: _INSNONLIFE.

H1b pokazatelji:

1. udio općih troškova (režijskih) u ukupnoj aktivi bankarskog sektora: _OVERHEAD
2. udio neto prihoda banaka u ukupnoj aktivi koju donosi kamata: _NETINTMARGIN
3. udio NPL u ukupnim kreditima bankarskog sektora: _NPLINTOTAL
4. omjer tržišne kapitalizacije i BDP-a: _MARKTCAPINGDP
5. omjer ukupne tržišne realizacije i BDP-a: _TRADSTOCKVALINGDP
6. brzina prometa ili obrtaj koji predstavlja omjer prometa i tržišne kapitalizacije: _MARKTTURNRATIO

7. broj uvrštenih poduzeća na tržištu kapitala ukupno: _LISTEDCOMP
8. koncentracija: _CONCENTRATION
9. udio aktive stranih banaka u ukupnoj aktivi bankarskog sektora: _FBA_TBA
10. broj stranih banaka u ukupnom broju banaka:_FBNO_TBNO
11. udio banaka u vlasništvu države u ukupnom bankarskom sektoru: _SOEBANKSHARE.

Kao što je vidljivo iz popisa indikatora, u ovom je istraživanju korišten 21 indikator. Svi su indikatori promatrani na godišnjoj razini.

Prvi pokazatelj koji je analiziran jest *razlika između aktivne i pasivne kamatne stope* (kamatna marža) _NETINTERESTMARGIN. Ovaj pokazatelj objašnjava koliko je profitabilan financijski sustav, odnosno bankarski sustav. To je zapravo profitna marža u bankarskom sektoru i što je on veći, to je bankarski sektor profitabilniji.
Interesantno je zamijetiti da je taj pokazatelj 1996. godine u Bugarskoj bio na razini iznad 200 %, u Hrvatskoj i Bosni i Hercegovini oko 18 %, u Rumunjskoj nešto ispod 18 % dok je u ostalim zemljama bio u rasponu između 5 % i 10 %. Naravno, zemlje središnje Europe, kao što su Njemačka i Austrija, imale su te pokazatelje ispod 5 % . Taj je pokazatelj s vremenom bivao sve manji i u zemljama istočne i jugoistočne Europe.
Udio ukupne novčane mase u BDP-u - Kako i sam naziv kaže, _BMONEYINGDP indikator pokazuje kolika je ukupna novčana masa u jednom financijskom sustavu ili gospodarstvu jedne zemlje u odnosu na BDP. Bitno je naglasiti da je novčana masa u svim zemljama značajno veća u krajnjoj godini ovog istraživanja nego u početnoj. On obuhvaća ukupan dio pasive (eng.*liabillities*) u bankarskom sektoru u BDP-u. Po svom karakteru to je najširi mogući indikator razvijenosti financijskog posredništva i navedeni indikator predstavlja mjeru financijske dubine i na taj način cjelokupnu veličinu bankarskog sektora. (Usp. Beck, Demerguc-Kunt i Levine, 2001.)

Udio aktive Centralne Banke u BDP-u _CBAGDP je indikator koji predstavlja potraživanja središnje banke od domaćeg nefinancijskog sektora u BDP-u. Ovaj indikator pokazuje veličinu financijskog potraživanja u koji ne ulaze depozitne banke. Interesantno je zamijetiti da ovaj indikator u svim zemljama pada, ali je to i normalno kada se uzme u obzir koliki je rasta bankarskog sektor pa time i njegova udjela u BDP-u. Tako je u Mađarskoj taj udio pao s 45 % u 1996. godine na 0,75 % u 2011.godini. Ovo zapažanje važi za sve zemlje osim Njemačke i

Austrije gdje se taj udio zadržao na istoj razini. Austrija je tako imala taj pokazatelj 1996. godine na vrijednosti od 0,41 %, a 2011. godine na vrijednosti od 1,44 %.

Indikator koji također mjeri apsolutnu veličinu financijskoga sektora jest udio aktive bankarskoga sektora u BDP-u: _ DBAGDP. Ovaj pokazatelj govori kolika su potraživanja bankarskoga sektora od realnog sektora u odnosu na BDP. Ovdje je interesantno zamijetiti rast ovog udjela u gotovo svim zemljama osim u Bugarskoj, Češkoj, Mađarskoj i Poljskoj gdje je ovaj udjel pao. Bankarstvo je nabolje razvijen segment u svim odabranim zemljama, ali je u ovim zemljama njegova uloga još uvijek mala ako se uzme u obzir odnos imovine banaka prema BDP-u. U Poljskoj je taj odnos bio 27,17 % u 1996. godini da bi se smanjio na 14,10 % u 2011. Isti je slučaj i s Mađarskom gdje je taj udjel iz 1996. godine s 33,39 % pao na 16,53 % u 2011.godini.

Ipak, banke imaju jaku poziciju koja je izgrađena na čvrsto ukorijenjenoj navici javnosti da drži novac u banci i na stečenu povjerenju u bankarski sustav. Ali, isto tako, mnogi se Poljaci još uvijek ne odlučuju za korištenje bankarskih proizvoda i smatra ih se tradicionalistima. Tako svega 45 % populacije (starije od 15 godina) ima otvoren račun u banci u usporedbi s 87 % u Sloveniji, 94 % u Austriji te 99 % u Njemačkoj. Slična je situacija i s ostalim zemljama istočne i jugoistočne Europe, a razlog tomu je da velik dio populacije ima vrlo ograničene prihode, nestabilnost zakonske i političke situacije i velik je broj ljudi zaposlen u poljoprivrednom sektoru koji je uglavnom siromašan, a njihova su radna mjesta daleko od najbliže banke pa se radije odlučuju za gotovinu.

Udio općih troškova (režijskih) u ukupnoj aktivi bankarskoga sektora Pokazatelj _OVERHEAD opisuje uspješnost vođenja banke na nekom tržištu ili u nekom financijskom sustavu. Naime, ako banke dobro upravljaju troškovima, bit će i učinkovitije u obavljanju svojih temeljnih funkcija, odnosno imat će veću mogućnost plasmana kredita. Ovaj pokazatelj jedan je od ključnih pokazatelja poslovanja jedne banke u financijskom sustavu jedne zemlje. Budući da je riječ o novijem pokazatelju, podatci za ovo istraživanje u odabranim zemljama počinju se pratiti već od 2000. godine. Zamjetno je da je ovaj pokazatelj u Srbiji bio najveći kada gledamo presjek s 2011. godinom i prelazi 16 %, što pokazuje neučinkovitost upravljanja troškovima na tom tržištu. Optimalne bi vrijednosti trebale iznositi 1 – 2 %.

Udio neto prihoda banaka u ukupnoj aktivi koji donosi kamata _NETINTMARGIN pokazatelj je koji ukazuje na strukturu prihoda bankarskoga sektora u ukupnoj aktivi. Naime, dva su temeljna izvora prihoda poslovanja banke: prihodi od kamate i ostali nekamatni prihodi (različite naknade). Interes svake banke je da je udjel nekamatnih prihoda što veći jer on nosi i

glavni dio profita jer nemaju visoke troškove koji su izravno povezani s tim prihodima. Međutim, nije dobro da banke grade svoju profitabilnost samo na naknadama u smislu da su manje usredotočene na prihode iz plasmana kredita. Zanimljivo je primijetiti da u zemljama središnje Europe, koje su duže u EU, ovaj pokazatelj iznosi između 1 i 2 % dok u zemljama istočne i jugoistočne Europe ovaj pokazatelj iznosi više od 5 %, što je veliko troškovno opterećenje na tim tržištima i dovodi do toga da se poduzeća vrlo rijetko odlučuju za investicije jer nisu profitabilne s tako visokim kamatnim maržama.

Udio NPL u ukupnim kreditima bankarskog sektora Pokazatelj _NPLINTOTAL daje podatke o tome koliko bankarski sektor dobro upravlja portfeljom, odnosno koliko je taj portfelj u bilanci „toksičan“. Svjedoci smo da je ovaj pokazatelj do prije krize u zemljama istočne i jugoistočne Europe imao vrijednost do nekih 7 %, a u odabranim zemljama središnje Europe (Njemačka, Austrija) ne više od 2 %. U 2011. godini taj postotak nije bio veći od 5 %, što pokazuje koliko je koji financijski sustav zdrav. Primjerice, u Crnoj Gori se u 2011. godini ovaj pokazatelj kretao oko 23 %, u BiH 18 % dok je u Hrvatskoj taj postotak bio nešto malo manji.
Omjer tržišne kapitalizacije i BDP-a (_ MARKTCAPINGDP), *omjer ukupne tržišne realizacije i BDP-a* (_ TRADSTOCKVALINGDP), *omjer ukupne tržišne realizacije i BDP-a* (_TRADSTOCKVALINGDP) i *broj uvrštenih poduzeća na tržištu kapitala ukupno* (_LISTEDCOMP) pokazatelji su koji ukazuju na nominalnu sliku razvitka tržišta kapitala, odnosno ukazuju na nominalnu sliku razvijenosti tržišta kapitala. *Omjer ukupne tržišne realizacije i BDP-a* (_ TRADSTOCKVALINGDP) i *brzina prometa ili obrtaj*, odnosno *omjer prometa i tržišne kapitalizacije* (_ MARKTTURNRATIO) mjere likvidnost tržišta, tj. tržišnu aktivnost. Moguće je da neka tržišta imaju razmjerno visoku kapitaliziranost uz razmjerno velik broj uvrštenih poduzeća, ali da pritom promet dionicama (likvidnost) bude malen. Primjerice, ako iz nekog razloga neka zemlja donese zakon o prisilnom uvrštenju dionica na tržište kapitala, naglo će porasti i tržišna kapitalizacija i broj uvrštenih poduzeća. Međutim, likvidnost se, barem u početku, vjerojatno neće bitno promijeniti. Isto tako, u zemljama u razvoju čest je slučaj bio da su dionice velikih poduzeća uvrštene i na lokalnu i na neku veliku burzu u jednom od velikih međunarodnih centara. Neke lokalne burze prikazuju ukupnu tržišnu kapitalizaciju premda se velika većina prometa tom dionicom odvija na inozemnoj burzi. Stoga su svi pokazatelji koji uključuju tržišnu kapitalizaciju manje pouzdani od pokazatelja prometa. Premda i kod prometa može postojati problem dvostrukog brojanja, općenito se smatra da je omjer burzovnog prometa dionicama i BDP-a najbolji pokazatelj razvijenosti tržišta. Isto tako, u mnogim je istraživanjima

potvrđeno da od svih pokazatelja na rast BDP-a najjače utječe upravo likvidnost tržišta. (Usp. Russoeau i Wachtel, 1998., 2000.; Levine i Zevros, 1998.)
Isto tako, važno je ukazati na razliku između kapitalizacije tržišta dionica i kapitalizaciju tržišta obveznica. Zbrojna kapitalizacija može zavarati. Rast tržišta, kao posljedica rasta broja uvrštenih obveznica i njihova prometa, ne mora značiti da se u financijskoj strukturi događaju bitne promjene. Neposredan plasman dužničkih instrumenata na tržište može značiti da neka poduzeća (u pravilu veća) zamjenjuju bankarsko financiranje emisijom obveznica radi širenja baze investitora i smanjivanja ovisnosti o bankama. Drugi razlog tomu može biti diverzifikacija financijske strukture u kojoj će biti zastupljeni svi financijski instrumenti kako bi se smanjili rizici financiranja povezani s tržištima pojedinih instrumenata. Kada rast poduzeća dosegne razinu na kojoj se isplati izdati komercijalne zapise ili obveznice, ta vrsta prikupljanja financijskih sredstava nastaje kao komplement bankarskom kreditu. Premda su takvi pomaci pozitivni, oni ne donose značajne kvalitativne promjene u financijskoj strukturi. Dužnički instrumenti znače da je rok dospijeća kraći dok su spremnost investitora na rizik i praćenje informacija o poduzeću manji nego kod vlasničkih instrumenata. Razvoj tržišta vlasničkih financijskih instrumenata jače utječe na kvalitetu alokacije kapitala i ulaganja nego razvoj tržišta dužničkih instrumenata. Upravo je to razlog zašto razvoju tržišta vlasničkih financijskih instrumenata treba pridavati veću pozornost.

Nadalje, indikatori koji pokazuju konkurentnost i otvorenost financijskoga sustava u pogledu ulaska stranih investitora u kapital banaka su sljedeći: *koncentracija* (_CONCENTRATION), *udio aktive stranih banaka u ukupnoj aktivi bankarskog sektora* (_FBA_TBA), *broj stranih banaka u ukupnom broju banaka* (_FBNO_TBNO) i *udio banaka u vlasništvu države u ukupnom bankarskom sektoru* (_SOEBANKSHARE). Pokazatelj koncentracije pokazuje moć četiriju ili više banaka na nekom bankarskom tržištu ili u nekom financijskom sustavu. Poznato je da visoka koncentracija vodi k većoj cijeni kapitala na tržištu i samim tim većim maržama za bankarski sektor, što povećava trošak investicija i daljnji razvoj realnog sektora. Ostali pokazatelji ukazuju na to koliko je jedan financijski sustav bio otvoren za strane investitore, odnosno koliko je vlada dopustila stranim bankarskim grupacijama da postane njegov suvlasnik ili vlasnik bankarskog sustava. S dolaskom stranih investitora u domaći bankarski sektor povećava se njegova konkurentnost i širi se ponuda proizvoda s tržišta s kojih dolaze.
U svijetu liberaliziranih globalnih financija novac i domaći novčani supstituti nisu više jedini izvor financiranja kreditnoga portfelja. Pristup inozemnim izvorima sredstava (krediti matica, sindicirani zajmovi, prodaje aktive,...) oslabljuje korelaciju između novčanoga dijela bankarske

pasive i kreditnoga dijela bankarske aktive čime se otvara prostor za relativno autonomno kretanje kredita privatnom sektoru i njihov jednako autonoman utjecaj na gospodarski rast (Šonje, 2005.).[68]

Ovdje se posebno treba usredotočiti na utjecaj inflacije te kod korištenja pokazatelja voditi računa o tome jesu li isti deflacionirani. Inflacija ima snažan utjecaj na vrijednosti indikatora koji u brojniku mjere stanje financijske imovine na kraju godine. U nazivniku pokazatelja je BDP koji predstavlja optjecaj koji se ostvaruje tijekom čitave godine. Formula koja minimizira inflacijske utjecaje na vrijednosti indikatora izgleda jeo (vidi Demerguc-Kunt, Levine, 2001.):

$$\frac{0.5 * \left(\frac{FD_t}{CP_{e,t}} + \frac{FD_{t-1}}{CPI_{e,t-1}} \right)}{\frac{GDP_t}{CPI_{a,t}}}$$

pri čemu je e kraj razdoblja (*end*), a a prosjek razdoblja (*average*). FD se odnosi na određeni indikator financijskoga razvoja, a CPI je indeks potrošačkih cijena. Ovako definiran omjer financijskoga razvitka uklanja utjecaj inflacije koji se očituje u razlici između inflacije mjerene „prosjek na prosjek“ u odnosu na inflaciju mjerenu „kraj na kraj“ godine. Dosadašnja istraživanja pokazuju da te razlike mogu biti značajne u uvjetima visoke i rastuće inflacije.

[68] U ovom se slučaju pod autonomnošću podrazumijeva utjecaj u kratkom roku.

5.3.3. Izbor odgovarajućeg panel-modela i interpretacija panel-analize

Za dokazivanje prve istraživačke hipoteze započinje se s provjerom koje su od skupa nezavisnih varijabli visoko korelirane. Naime, ne može se očekivati da će svih 10 nezavisnih varijabli, uz dodatne kontrolne varijable, biti statistički značajne pri čemu postoji opasnost da će predznaci varijabli biti pogrješni kao posljedica multilkolinearnosti koja je prisutna onda kada ima puno nezavisnih varijabli. Na temelju korelacijske matrice za izabran skup nezavisnih varijabli utvrđuje se između kojih postoji visoka povezanost:

Tablica 5.2. Korelacijska matrica za odabran skup varijabli za prvu pomoćnu hipotezu

```
interest         money      bankcred        cbagdp        dbagdp
        1.0000       -0.0499       -0.0305        0.1136       -0.0777  interest
                      1.0000        0.7200        0.0772        0.5224  money
                                    1.0000       -0.0211        0.9305  bankcred
                                                  1.0000       -0.1785  cbagdp
                                                                1.0000  dbagdp

       pcrddba      privcred       inslife    insnonlife
       -0.0452       -0.0971       -0.1400        0.6406  interest
       -0.3939        0.4849        0.3656        0.0160  money
        0.1154        0.9354        0.7580        0.2630  bankcred
       -0.4637       -0.2967       -0.1607       -0.2606  cbagdp
        0.3270        0.9085        0.7497        0.2472  dbagdp
        1.0000        0.2888        0.1418        0.2760  pcrddba
                      1.0000        0.7566        0.3501  privcred
                                    1.0000        0.2908  inslife
                                                  1.0000  insnonlife

? corr interest money bankcred cbagdp dbagdp pcrddba privcred inslife insnonlife
growth

Correlation Coefficients, using the observations 1:01 - 17:16
(missing values were skipped)

      interest         money      bankcred        cbagdp        dbagdp
        1.0000       -0.0499       -0.0305        0.1136       -0.0777  interest
                      1.0000        0.7200        0.0772        0.5224  money
                                    1.0000       -0.0211        0.9305  bankcred
                                                  1.0000       -0.1785  cbagdp
                                                                1.0000  dbagdp

       pcrddba      privcred       inslife    insnonlife        growth
       -0.0452       -0.0971       -0.1400        0.6406       -0.2201  interest
       -0.3939        0.4849        0.3656        0.0160       -0.1633  money
        0.1154        0.9354        0.7580        0.2630       -0.3160  bankcred
       -0.4637       -0.2967       -0.1607       -0.2606        0.0266  cbagdp
```

```
        0.3270        0.9085        0.7497        0.2472       -0.3200  dbagdp
        1.0000        0.2888        0.1418        0.2760       -0.0092  pcrddba
                      1.0000        0.7566        0.3501       -0.1795  privcred
                                    1.0000        0.2908       -0.2534  inslife
                                                  1.0000       -0.2469  insnonlife
                                                                  1.0000  growth
? smpl kriza=0 --restrict
Full data set: 272 observations
Current sample: 1:01 - 17:12 (n = 204)

? corr interest money bankcred cbagdp dbagdp pcrddba privcred inslife insnonlife
growth

Correlation Coefficients, using the observations 1:01 - 17:12
(missing values were skipped)

      interest         money      bankcred        cbagdp        dbagdp
        1.0000       -0.0130       -0.0140        0.1000       -0.0803  interest
                      1.0000        0.6881        0.1267        0.6967  money
                                    1.0000       -0.0041        0.9574  bankcred
                                                  1.0000       -0.1918  cbagdp
                                                                  1.0000  dbagdp

       pcrddba      privcred       inslife    insnonlife        growth
       -0.0762       -0.0738       -0.1505        0.6558       -0.3227  interest
       -0.3465        0.3984        0.4236        0.0487       -0.1027  money
        0.1287        0.9259        0.7728        0.2730       -0.2319  bankcred
       -0.5190       -0.3041       -0.1861       -0.2695       -0.0446  cbagdp
        0.2002        0.9526        0.8066        0.2486       -0.2666  dbagdp
        1.0000        0.4262        0.2767        0.3959       -0.0761  pcrddba
                      1.0000        0.8007        0.3671       -0.0747  privcred
                                    1.0000        0.2698       -0.2669  inslife
                                                  1.0000       -0.3220  insnonlife
                                                                  1.0000  growth
```

Pod regresijskom dijagnostikom, odnosno testiranjem nedovoljne specifikacije modela (eng.*misspecification tests*) podrazumijeva se testiranje autokorelacije i heteroskedastičnosti.

Nakon što je odabran prikladan model, ide se na ispitivanje autokorelacije koja je prikazana u prethodnom dijelu teksta. U ekonomiji se pod tim pojmom podrazumijeva serijska korelacija između slučajnih grješaka različitih razdoblja. Budući da su podatci na godišnjoj razini, u ovom se radu promatra autokorelacija prvoga reda.

Kako će se vršiti analiza u ovom radu? Uslijedit će nekoliko koraka:

1. Najprije će se procijeniti, odnosno, izvršiti testiranje autokorelacije za pojedine skupine zemalja.
2. Budući da podatci sadrže prostornu komponentu (engl. *cross-sectional data*) i vremensku komponentu (engl. *time-series data*) riječ je o panel-podatcima, a modeli kojima se na adekvatan način može procijeniti utjecaj jedne ili više nezavisnih varijabli na promatranu zavisnu varijablu su panel-modeli.

Više je panel-modela koji se mogu koristiti kao, primjerice, združeni panel (engl. *pooled panel*), statički panel-model (s fiksnim ili slučajnim efektom) ili dinamički panel-model. (Usp. Baltagi, 2009.) Naime, empirijska su istraživanja pokazala da se opravdanost korištenja odgovarajućeg panel-modela temelji na odnosu prostorne i vremenske komponente, a prikladnost samog modela temelji se na dijagnostičkim testovima kao npr. Hausmanov test, Sarganov test, test Lagrangeova multiplikatora i sl. (usp. Wooldridge, 2010.) S obzirom na vremensku komponentu panel- podatka vrijednosti nezavisnih varijabli u modelu mogu se pojaviti s vremenskim pomakom (*t-1*). Općenito, u proširenom ekonometrijskom modelu mogu se uključiti kontrolne varijable kao dodatni članovi. Pritom treba voditi računa o načelu parsimonije jer uključivanje dodatnih varijabli smanjuje broj stupnjeva slobode uz nepromijenjenu veličinu uzorka. Opasnost od gubitka u stupnjevima slobode je nepouzdanost t-testa kojim se testira značajnost procijenjenih koeficijenata koji se pojavljuju u jednadžbi panel-modela. Dakle, načelo parsimonije zahtijeva što manji broj parametara koji se procjenjuju uz zadovoljavajuću prikladnost modela kao cjeline.

Iz navedena razloga potrebno je u prvoj fazi istraživanja izabrati koje će se nezavisne varijable uključiti u model. Naime, zbog velikog broja nezavisnih varijabli nije opravdano sve istodobno uključiti u model. Uključivanje varijabli koje zapravo nisu relevantne uzrokuje pristranu procjenu preostalih varijabli u modelu. Isto tako, isključivanje onih varijabli koje su zapravo relevantne može uzrokovati neučinkovite procjene standardnih pogrješaka. Rješenje ovog problema sastoji se u izboru neovisnih varijabli koje se međusobno nekorelirane. Ako su nezavisne varijable visoko korelirane, pojavljuje se problem multikolinearnosti, tj. narušena je temeljna pretpostavka ekonometrijskog modela. Posljedice multikolinearnosti nerealno su visoke standardne pogrješke procjena regresijskih koeficijenata, tj. nerealno male vrijednosti t-

testova te donošenje pogrješnog zaključka o značajnosti pojedinih varijabli u modelu koji se procjenjuje. Dakle, da bi se izbjegao problem multikolinearnosti iz skupa neovisnih varijabli izabrat će se one koje nisu visoko korelirane. Na taj će se način uvažiti i načelo parsimonije te će se izbjeći opasnost od velikog gubitka u stupnjevima slobode. Kao kriterij u utvrđivanju multikolinearnosti koristi se Kleinov kriterij, odnosno kada između nezavisnih varijabli koeficijent korelacije po apsolutnoj vrijednosti iznosi više od 0,7. U tom slučaju postoji ozbiljan problem multikolinearnosti zbog čega se ispituje korelacijska matrica.

Model s fiksnim efektom je jednostavni linearni model u kojem se konstantan član mijenja sa svakom jedinicom promatranja, ali je konstantan u vremenu. Model s fiksnim efektom definira se:

$$y_{it} = \alpha_i + \beta_1 x_{it1} + \beta_2 x_{it2} + \cdots + \beta_K x_{itK} + \varepsilon_{it;}$$

$$i = 1, \dots N, t = 1, \dots, T$$

Pritom N označava broj jedinica promatranja, T označava broj razdoblja, x_{itk}, $k = 1, \dots K$ označava vrijednost k-te nezavisne varijable, i-te jedinice promatranja u razdoblju t. Parametar α_i je konstantan član različit za svaku jedinicu promatranja dok su $\beta_1, \dots, \beta_k$ parametri koje treba procijeniti. Nadalje, ε_{it} je grješka procjene i-te jedinice promatrana u trenutku t i pretpostavlja se da su ε_{it} neovisno i identično distribuirane slučajne varijable po jedinicama promatranja i vremenu sa sredinom 0 i varijancom σ_ε^2. Također se pretpostavlja da su svi x_{itk} neovisni s ε_{it} za sve i, t, k.

Opravdanost uporabe modela s fiksnim efektom može se testirati uz pomoć uobičajenog F-testa. Ako je pripadajuća vrijednost F-testa manja od odgovarajuće teorijske vrijednosti F-testa na razini signifikantnosti α, zaključuje se da je model s fiksnim efektom neadekvatan, tj. da je primjerenije koristiti združeni model. Ako je pripadajuća vrijednost F-testa veća od odgovarajuće teorijske vrijednosti F-testa na razini signifikantnosti α, zaključuje se da je model s fiksnim efektom prikladniji za korištenje u predmetnom istraživanju.

Opravdanost korištenja modela sa slučajnim efektom provodi se uz pomoć testa Lagrangeova multiplikatora (engl. *lagrange multiplier test* – LM). *LM*-test temelji se na hipotezi da je varijanca članova *u* jednaka nuli, a test veličina je hi-kvadrat vrijednost s jednim stupnjem slobode.

Primjenjivost pojedinog modela između dvaju navedenih utvrdit će se uz pomoć Hausmanova testa.

Često se postavlja pitanje je li u empirijskim analizama bolje koristiti model s fiksnim efektom ili model sa slučajnim efektom. Jednoznačan odgovor ne postoji jer uporaba modela ovisi o prirodi podataka. Prednosti modela sa slučajnim efektom su sljedeće:

- na temelju modela sa slučajnim efektom može se procijeniti utjecaj varijabli koje su neovisne o vremenu (engl. *time-invariant*);
- procjene slučajnog efekta dobivaju se *GLS*-metodom, a procjene fiksnog efekta dobivaju se *OLS*-metodom, što podrazumijeva da će u velikim uzorcima procjene slučajnog efekta imati manju varijancu i time biti učinkovitije.

Osim prethodno navedenih prednosti modela sa slučajnim efektom, model ima i svoje nedostatke. Ako je slučajna pogrješka α_i korelirana s bilo kojom nezavisnom varijablom, *GLS*-procjenitelji parametara modela su pristrani i nekonzistentni. U tom slučaju bolje je primijeniti model s fiksnim efektom jer su procjenitelji parametara u modelu s fiksnim efektom konzistentni bez obzira na prisutnost spomenute korelacije. Procjenitelji su konzistentni jer se primjenom transformacija „unutar“ jedinica promatranja eliminira slučajni efekt α_i. Prema tome, prednost procjenitelja parametara u modelu s fiksnim efektom je konzistentnost procjene u slučaju kada postoji korelacija između slučajne komponente grješke relacije α_i i neovisnih varijabli.[69]

Hausman je predložio test kojim se uspoređuju procijenjeni koeficijenti modela s fiksnim efektom i modela sa slučajnim efektom. Hausmanov test temelji se na činjenici da su oba procjenitelja konzistentna ako ne postoji korelacija između α_i i neovisnih varijabli x_{itk}. Ako su

[69] Aljinovic, Z. i dr., *Matematički modeli u analizi hrvatskog financijskog tržišta*, Ekonomski fakultet Split, Split, 2012., str. 194.

oba procjenitelja konzistentna, u velikim će uzorcima procjene konvergirati pravoj vrijednosti parametra $ß_k$, k = 1,…, K. Isto tako, u velikim uzorcima procjene modela s fiksnim efektom neće se značajno razlikovati od procjena modela sa slučajnim efektom. S druge strane, u slučaju da korelacija između slučajne grješke α_i i neovisnih varijabli x_{itk} postoji, procjenitelj slučajnog efekta je nekonzistentan, a procjenitelj fiksnog efekta je i dalje konzistentan[70].

Hausmanov test temelji se na razlici procjena parametara s fiksnim i sa slučajnim efektom. Test veličina definira se kao:

$$H = (\hat{\beta}_{FE} - \hat{\beta}_{RE})'[\widehat{Cov}(\hat{\beta}_{FE}) - \widehat{Cov}(\hat{\beta}_{RE})]^{-1}(\hat{\beta}_{FE} - \hat{\beta}_{RE})$$

pri čemu je $\hat{\beta}_{FE}$ vektor procijenjenih parametara modela s fiksnim efektom, $\hat{\beta}_{RE}$ je vektor procijenjenih parametara modela sa slučajnim efektom, $\widehat{Cov}(\hat{\beta}_{FE})$ je matrica varijanci i kovarijanci vektora procijenjenih parametara modela s fiksnim efektom, a $\widehat{Cov}(\hat{\beta}_{RE})$ je matrica varijanci i kovarijanci vektora procijenjenih parametara modela sa slučajnim efektom. *H*-test veličina ima hi-kvadrat distribuciju s*K* stupnjeva slobode pri čemu je *K* broj procijenjenih parametara u modelu.

Ako je vrijednost testne veličine *H* manja od X_α^2 za zadanu razinu signifikantnosti α, ne odbacuje se hipoteza kojom se pretpostavlja da slučajna grješka nije korelirana ni s jednom neovisnom varijablom. Nadalje, u tom su slučaju oba procjenitelja $\hat{\beta}_{FE}$ i $\hat{\beta}_{RE}$ konzistentna.

Ako je vrijednost testne veličine *H* veća od X_α^2 za zadanu razinu signifikantnosti α, odbacuje se hipoteza kojom se pretpostavlja da slučajna grješka nije korelirana ni s jednom neovisnom varijablom, tj. zaključuje se da postoji korelacija između barem jedne neovisne varijable i slučajnog efekta α_i. Procjenitelj slučajnog efekta $\hat{\beta}_{RE}$ nije konzistentan pa se za procjenu modela koristi procjenitelj fiksnog efekta.

[70]Aljinovic, Z. i dr., *Isto*, str. 195.

Dinamički panel-model koji će se koristiti u ovoj analizi ima slijedeći zapis:

$$y_{it} = a + y_{it-1} + \beta_1 x_{it1} + \beta_2 x_{it2} + \cdots + \beta_K x_{itK} + \varepsilon_{it;}$$

$$i = 1, \dots N, t = 1, \dots, T$$

Arellano (1989.) pokazao je da za procjenu dinamičkog modela procjenitelj parametara modela , koji kao instrumentalne varijable koristi diferencije umjesto varijabli s vremenskim pomakom, ima veliku varijancu, što znači da nije učinkovit procjenitelj.

Stoga su Arellano i Bond (1991.) predložili korištenje generalizirane metode trenutka (engl. *generalized method of moments* – GMM) koja je učinkovitija od Andersonove i Hsiaove metode. Poboljšanje Arellanova i Bondova procjenitelja predložili su Arellano i Bover (1995.), a naknadno su ga nadogradili Blundell i Bond (1998.).

Valjanost instrumenata koji se odaberu za procjenu modela testira se Sarganovim testom. Sarganov test (za ovaj se test ponekad koristi naziv Sargan-Hansenov test ili samo Hansenov test) je test za preidentifikaciju ograničenja. Uvođenjem svake nove instrumentalne varijable dodaje se novi uvjet (ograničenje) koji mora biti zadovoljen. Hipoteza testa je da su odabrane instrumentalne varijable nekorelirane s rezidualima. Ako se hipoteza ne odbacuje, svi su uvjeti vremena zadovoljeni i svi su navedeni instrumenti valjani. Ako se hipoteza odbaci, neki su od instrumenata korelirani s rezidualima, tj. u modelu postoji problem endogenosti. Uvođenjem dodatnih instrumentalnih varijabli dobiva se na učinkovitosti procjenitelja, ali procjenitelj postaje pristran. Dakle, treba odabrati optimalan broj instrumenata da se nulta hipoteza Sarganova testa ne odbaci, a da se istodobno znatno ne poveća pristranost procjenitelja.

Osim Sarganova testa u empirijskim se istraživanjima provode još i dva dijagnostička testa o autokorelaciji među prvim diferencijama rezidualnih odstupanja. Testovi se nazivaju *m1* i *m2*. Nultom hipotezom *m1* testa pretpostavlja se nepostojanje autokorelacije prvog reda među prvim diferencijama reziduala, a nultom hipotezom *m2* testa pretpostavlja se nepostojanje autokorelacije drugog reda među prvim diferencijama reziduala.

Međutim, postojanje autokorelacije drugoga reda ili višega reda upućuje na probleme pri specifikaciji modela, tj. pokazuje da neki od uvjeta koji se odnose na vrijeme nisu zadovoljeni.

(Vidi Hunag, 2006.) Dakle, rezultati *m2* testa također mogu ukazati na valjanost odabranih instrumenata.

Uz postojanje autokorelacije prvoga reda među prvim diferencijama reziduala procjene parametara su konzistentne.

Ako pak postoji korelacija drugoga reda među prvim diferencijama reziduala, procjene parametara su nekonzistentne. (Vidi Arellano i Bond, 1991.)

Nadalje, u slučaju kada je autoregresijski koeficijent blizu 1, pokazalo se da vrijednosti zavisne varijable s vremenskim pomakom nisu dobri instrumenti za model u prvim diferencijama te se svojstva procjenitelja pogoršavaju, tj. raste pristranost procjenitelja i smanjuje se učinkovitost.

U daljnjem dijelu teksta bit će opisan proces odabira pravog modela analiza utjecaja financijskog sustava na gospodarski rast.

Tablica 5.3. A. Procijenjeni panel-modeli s fiksnim efektom za cijelo razdoblje promatranja

GROWTH	model 1	model 2	model 3	model 4	model 5	model 6
CONSTANT	3,9703**	3,4363*	3,8236**	-1,1838	7,3421***	-0,9410
INTER_SPREAD	-0,0698***	-0,0741***	-0,0439***	-0,0514**	-0,1972***	-0,1401**
MONEY/GDP	0,0394	0,0469	0,0149	-0,0499	-0,0865	-0,0851
BANKCRED/GDP	-0,1175***	-0,0912*	-0,0908***	-0,0776**	-0,1004**	-0,1027**
PCRDDBA	0,0346***	0,0367***	0,0443***	0,0353***	0,0218*	0,0300**
INS_NONLIFE	0,7881	0,7567	-	0,3640	0,4041	0,4999
INS_LIFE	-	-	0,7151	-	-	-
PRIVCRED	-	-0,0307	-	-	-	-
kontrolne varijable						
OPENESS	-	-	-	0,0824***	0,0428	0,0683
SAVINGS	-	-	-	-	-	0,2721***
RISK	-	-	-	-	0,2059**	0,1398
pokazatelji prikladnosti modela						
Broj opažanja	155	155	150	155	97	97
Br. parametara	6	7	6	7	8	9
Korigirani R^2	0,2653	0,2609	0,2621	0,3357	0,4230	0,4672
F-test	2,8906	2,4247	1,6996	4,4919	2,5813	3,5005
p-vrijednost	0,0019	0,0088	0,0795	0,0000	0,0186	0,0025

Izvor: izračun autora

Tablica 5.4. B. Procijenjeni panel-modeli s fiksnim efektom za razdoblje prije krize

GROWTH	model 1	model 2	model 3	model 4	model 5	model 6
CONSTANT	2,7240	1,8989	1,5498	-1,2320	9,0876***	-0,4337
INTER_SPREAD	-0,0816***	-0,0832***	-0,0589***	-0,0648**	-0,3626***	-0,3367***
MONEY/GDP	0,0611	0,0662	0,0351	-0,0091	-0,0792	-0,11278
BANKCRED/GDP	-0,0928**	-0,0718	-0,0507	-0,0473	-0,0064	0,0135
PCRDDBA	0,0276	0,0368	0,0447*	0,0211	-0,0268	-0,0299
INS_NONLIFE	0,8115	0,7669		0,2941	1,1749	2,5198**
INS_LIFE	-	-	0,8315	-	-	-
PRIVCRED	-	-0,0275	-	-	-	-
kontrolne varijable						
OPENESS	-	-	-	0,0664**	0,0127	0,0358
SAVINGS	-	-	-	-	-	0,3524***
RISK	-	-	-	-	0,3084***	0,2014***
pokazatelji prikladnosti modela						
Broj opažanja	118	118	113	118	73	73
Br. parametara	6	7	6	7	8	9
Korigirani R^2	0,2443	0,2381	0,2448	0,2838	0,5470	0,6248
F-test	1,4264	1,3730	1,0624	2,0624	1,7016	3,7814
p-vrijednost	0,1727	0,1974	0,3997	0,0300	0,1266	0,0019

Izvor: izračun autora

Analiza je započeta na temelju procjenitelja fiksnog efekta (engl. *fixed effect estimator* – FE), tj. panel-modela s fiksnim efektom. U empirijskim analizama uobičajeno je započeti analizu s FE procjeniteljem kao osnovni model pretpostavljajući da se konstantan član α_i mijenja sa svakom jedinicom promatranja, ali je konstantan u vremenu. Taj konstantan član α_i specifičan je za svaku zemlju. Ako su konstantni članovi α_i približno jednaki za sve zemlje zajedno, može se zaključiti da je združeni panel model prikladniji (engl. *pooled panel model*). Naime, test kojim se testira da su članovi α_i jednaki za sve zemlje je *F*-test. U tablicama 5.3. A. i 5.4.B. polazi se od različitih panel-modela s fiksnim efektom s obzirom na različite neovisne i

kontrolne varijable te s obzirom na razdoblje promatranja (cijelo razdoblje promatranja naspram razdoblja prije krize). Dakle, u prvoj fazi empirijskog istraživanja procijenjeni su prvo panel-modeli s fiksnim efektom koji će se onda uspoređivati s ostalim panel-modelima da bi se mogao donijeti zaključak o izboru „boljeg“ modela. U tablicama 5.3. A i 5.4. B osim procijenjenih koeficijenata i *F*-testa te pripadajuće p-vrijednosti istaknut je broj opažanja i broj parametara koji se procjenjuju u određenu modelu. Procijenjeno je šest različitih panel-modela s fiksnim efektom u cijelom razdoblju promatranja i istih tih šest modela u razdoblju prije krize. Zavisna varijabla uvijek je ista, a to je rast BDP-a, dok je broj neovisnih varijabli različit (6 – 9). Za očekivati je da sve neovisne varijable u modelu neće biti statistički značajne.[71]

U tablici 5.3. A vidi se da jedino model 3 s fiksnim efektom nije prikladan jer se s obzirom na p-vrijednost 0,0795 pripadajućeg F-testa ne može odbaciti nulta hipoteza da sve zemlje imaju jednake specifičnosti, tj. članove α_i. Mijenjajući nezavisne varijable u modelima 1, 2, 4, 5 i 6 može se zaključiti da su kamatna marža, udio kredita bankarskog sektora privatnom sektoru u BDP-u te udio kredita privatnom sektoru u ukupnoj aktivi bankarskog sektora statistički značajni bez obzira na to koje kontrolne varijable koristili u cijelom razdoblju promatranja. Značajnim se ne pokazuju varijable: udio ukupne novčane mase u BDP-u, udio aktive životnih te neživotnih osiguravajućih društava. Naime, varijabla udjela aktive u bankarskom sektoru nije mogla biti uključena u model jer je ona upravo visoko korelirana s većinom drugih neovisnih varijabli. Posljedica toga može biti ozbiljan problem multikolinearnosti. Dakle, na temelju rezultata iz tablice 5.3. A zaključuje se da je utjecaj kamatne marže na BDP negativan i statistički značajan dok je utjecaj kredita privatnom sektoru u postotku BDP-a negativan, a udio tih istih kredita u ukupnoj aktivi bankarskoga sektora pozitivan i statistički značajan. Negativan utjecaj kamatne marže na rast BDP-a može se objasniti i nije ništa novo, odnosno i u dosadašnjim se istraživanjima dolazilo do sličnih rezultata.

Jako je zanimljiv zaključak da krediti privatnom sektoru imaju negativan utjecaj na rast ako se izražavaju kao udjel u BDP-u dok imaju pozitivan utjecaj na rast ako se izražavaju kao udjel u ukupnoj aktivi bankarskoga sektora. Od kontrolnih varijabli uglavnom se pokazuje da značajnu ulogu ima štednja (onda kada su sve tri kontrolne varijable u uključene u model). Nije imalo

[71] Oznaka (***) pokazuje da je procijenjeni parametar statistički značajan na razini signifikantnosti od 1 %, oznaka (**) pokazuje da je procijenjeni parametar statistički značajan na razini signifikantnosti od 5 % dok oznaka (*) pokazuje da je parametar statistički značajan na razini signifikantnosti od 10%.

smisla procjenjivati panel-model s više od tri kontrolne varijable zbog prevelikog broja parametara, a time onda i zbog gubitka u stupnjevima slobode. U razdoblju prije krize pokazuju se prikladnima modeli 1, 2, 3 i 5 dok je varijabla kamatna marža ostala statistički značajna s negativnim predznakom. Međutim, osim panel-modela s fiksnim efektom potrebno je procijeniti i panel-modele sa slučajnim efektom, tj. koristeći procjenitelj slučajnog efekta (engl. *random effect estimator* – RE). Prilikom korištenja *RE*-procjenitelja primjenjuju se dva dijagnostička testa: *LM*-test i Hausmanov test. *LM*-testom provjerava se je li model sa slučajnim efektom bolji od združenog panel-modela dok se Hasumanovim testom testira je li panel model sa slučajnim efektom bolji od modela s fiksnim efektom. Rezultati tih testova kao i procijenjeni parametri dani su u tablicama 5.5. A i 5.6. B. (cijelo razdoblje promatranja i razdoblje prije krize). Važno je istaknuti da modeli 5 i 6 nisu mogli biti procijenjeni zbog prevelikog broja parametara i zbog velikog gubitka u stupnjevima slobode. Zato se u ekonometriji nastoji poštivati načelo parsimonije, tj. u model uključiti što manje parametara, a da je model prikladno reprezentativan.

Tablica 5.5. A Procijenjeni panel-modeli sa slučajnim efektom za cijelo razdoblje promatranja (model 5 i 6 nije bilo moguće procijeniti zbog nedovoljnog broja stupnjeva slobode)

GROWTH	model 1	model 2	model 3	model 4	model 5	model 6
CONSTANT	3,2505**	1,4018	2,0739	2,778*		
INTER_SPREAD	-0,0417*	-0,0727***	-0,0469***	-0,0356		
MONEY/GDP	0,0741***	0,0877***	0,0838***	0,0554*		
BANKCRED/GDP	-0,0828***	-0,0190	-0,0913***	-0,0818***		
PCRDDBA	0,0157	0,0335***	0,0242**	0,0181		
INS_NONLIFE	-0,2018	0,3859	-	-0,3157		
INS_LIFE	-	-	0,4081	-	-	-
PRIVCRED	-	-0,1004***	-	-	-	-
kontrolne varijable						
OPENESS	-	-	-	0,0135		
SAVINGS	-	-	-	-	-	
RISK	-	-	-	-		
pokazatelji prikladnosti modela						
br. opažanja	155	155	150	155		
br. parametara	6	7	6	7		
LM-test	1,9048	0,4789	1,1898	2,7166		
p-vrijednost	0,1675	0,4889	0,2754	0,0993		
Hausmanov test	25,1432	11,3475	20,9786	39,4548		
p-vrijednost	0,0001	0,0782	0,0008	0,0000		

Izvor: izračun autora

Tablica 5.6. B. Procijenjeni panel-modeli sa slučajnim efektom za razdoblje prije krize (model 5 i 6 nije bilo moguće procijeniti zbog nedovoljnog broja stupnjeva slobode)

GROWTH	model 1	model 2	model 3	model 4	model 5	model 6
CONSTANT	4,0306**	2,5337	1,8484	3,7036**		
INTER_SPREAD	-0,0581***	-0,0637***	-0,0632***	-0,0563**		
MONEY/GDP	0,0723***	0,0836***	0,0909***	0,0611*		
BANKCRED/GDP	-0,0528**	-0,0343	-0,0491**	-0,0512**		
PCRDDBA	-0,0054	0,0135	0,0149	-0,0063		
INS_NONLIFE	-0,0471	0,0444	-	-0,1053		
INS_LIFE	-	-	-0,3423	-	-	-
PRIVCRED	-	-0,0394	-	-	-	-
kontrolne varijable						
OPENESS	-	-	-	0,0097		
SAVINGS	-	-	-	-	-	
RISK	-	-	-	-		
pokazatelji prikladnosti modela						
br. opažanja	118	118	113	118		
br. parametara	6	7	6	7		
LM-test	0,0011	0,0167	0,4086	0,0398		
p-vrijednost	0,9730	0,8972	0,5226	0,8419		
Hausmanov test	9,8485	9,0146	7,6671	15,0738		
p-vrijednost	0,0796	0,1727	0,1756	0,0197		

Izvor: izračun autora

U cijelom razdoblju promatranja model broj 2 sa slučajnim efektom pokazuje se prikladnim jer se s obzirom na *p*-vrijednost Hasumanova testa hipoteza se ne odbacuje (*p*-vrijednost = 0,0782). U modelu 3 tablica 5.5. A. pokazuje se značajnim u smislu kamatne marže (negativan utjecaj), udjela ukupne novčane mase u BDP-u (pozitivan utjecaj) te ukupnog udjela kredita privatnom sektoru u BDP-u (pozitivan utjecaj). U razdoblju prije krize svi modeli sa slučajnim efektom

pokazuju se prikladnima osim modela 4 (tablica 5.6. B.). Rezultati dobiveni modelima *RE* konzistentni su s modelima *FE*, no jedina je razlika u tome što je u modelima sa slučajnim efektom još značajna varijabla u smislu ukupne novčane mase u BDP-u (pozitivan utjecaj na gospodarski rast). U dosadašnjim razmatranjima analizirali su se *FE* i *RE* procjenitelji panel-modela s približno konzistentnim rezultatima te se mogao steći dojam koje su to varijable statistički značajne, a koje nisu statistički značajne. Međutim, da bi se došlo do još konzistentnijih rezultata, dodatno je primijenjen dinamički panel-model koji uz već definirane nezavisne varijable koristi zavisnu varijablu s vremenskim pomakom.

Naime, očekuje se da je gospodarski rast autokorelirana varijabla, tj. gospodarski rast u tekućem razdoblju ovisi o gospodarskom rastu iz prethodnoga razdoblja. Pozitivna autokorelacija je više pravilo nego iznimka kod ekonomskih vremenskih nizova. Stoga je procijenjeno šest dinamičkih panel- modela u cijelom razdoblju promatranja (tablica 5.7. A.) i u razdoblju prije krize (tablica 5.8.B.). Pri tome su korišteni uobičajeni dijagnostički testovi kao što je test autokorelacije prvoga i drugoga reda ili pak Sarganov test. *P*-vrijednosti navedenih testova trebale bi biti veće od teorijske razine signifikantnosti (0,05). Rezultati procijenjenih parametara, kao i *p*-vrijednosti navedenih dijagnostičkih testova, prikazani su u tablicama 5.7. A i 5.8. B.

Tablica 5.7.A. Procijenjeni dinamički panel-modeli za cijelo razdoblje promatranja (sustav *GMM*- procjenitelj)

GROWTH	model 1	model 2	model 3	model 4	model 5	model 6
CONSTANT	4,3378***	2,4836*	1,6078*	1,0439	0,2494	3,0612**
GROWTH(-1)	0,3254***	0,2904***	0,2809***	0,2631***	0,2655***	0,2388***
INTER_SPREAD	-0,1308***	-0,1249***	-0,1215***	-0,1068***	-0,1130***	-0,0781*
MONEY/GDP	0,0409	0,0501*	0,0561**	0,0307	0,0225	-
BANKCRED/GDP	-0,0644***	-0,0161	-0,0173	0,0048	0,0006	0,0195
PCRDDBA	0,0173	0,0278***	0,0309***	0,0329***	0,0348***	-
INS_NONLIFE	-0,9421***	-0,3046	-	-0,6583*	-0,7173*	0,8564*
INS_LIFE	-	-	0,3518	-	-	-
PRIVCRED	-	-0,0664***	-0,0721**	-0,0879***	-0,0826***	-0,0763***
kontrolne varijable						
OPENESS	-	-	-	0,0238***	0,0218***	-
SAVINGS	-	-	-	-	0,0766*	0,0518*
RISK	-	-	-	-	-	0,2069
pokazatelji prikladnosti modela						
br. opažanja	145	145	142	145	145	119
br. parametara	7	8	8	9	10	8
AR(1)	0,0152	0,0176	0,0171	0,0216	0,0230	0,0286
AR(2)	0,4331	0,5059	0,5183	0,5238	0,5098	0,2854
Sargan test	0,4743	0,5044	0,5989	0,4451	0,2927	0,1498
Wald test	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000

Izvor: izračun autora

Tablica 5.8.B. Procijenjeni dinamički panel-modeli za razdoblje prije krize (sustav *GMM*-procjenitelj)

GROWTH	model 1	model 2	model 3	model 4	model 5	model 6
CONSTANT	3,4539***	1,2927	0,2525	0,4452	-1,5063	3,3187***
GROWTH(-1)	0,5693***	0,5358***	0,5289***	0,5303***	0,4998***	0,4222***
INTER_SPREAD	-0,1636***	-0,1614***	-0,1545***	-0,1549***	-0,1586***	-0,0923***
MONEY/GDP	0,0189	0,0364	0,0459*	0,0218	0,0203	-
BANKCRED/GDP	-0,0261	0,0010	0,0004	0,0193	0,0179	-0,0274
PCRDDBA	0,0303	0,0546	0,0385	0,0595	0,0734**	-
INS_NONLIFE	-1,5332***	-1,3367**	-	-1,5334**	-1,4677***	-0,1515**
INS_LIFE	-	-	-0,2432	-	-	-
PRIVCRED	-	-0,0544	-0,0572	-0,0740	-0,0886	0,0031
kontrolne varijable						
OPENESS	-	-	-	0,0134	0,0106	-
SAVINGS	-	-	-	-	0,1013*	0,0593*
RISK	-	-	-	-	-	0,1802
pokazatelji prikladnosti modela						
br. opažanja	107	107	104	107	107	93
br. parametara	7	8	8	9	10	8
AR(1)	0,0132	0,0140	0,0172	0,0139	0,0141	0,0737
AR(2)	0,5590	0,6553	0,6451	0,6698	0,6425	0,9756
Sargan test	0,9329	0,9099	0,9478	0,9083	0,5658	0,0692
Wald test	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000

Izvor: izračun autora

Svi dinamički panel-modeli procijenjeni su *GMM*-procjeniteljem. U svim se modelima pokazuje značajna varijabla s vremenskim pomakom, odnosno *growth (t-1)* što potvrđuje da su dinamički panel- modeli opravdano upotrijebljeni u ovom istraživanju.

Panel-model sa slučajnim efektom i panel-model s fiksnim efektom zanemaruju autokoreliranost gospodarskog rasta kroz vrijeme. Dijagnostički testovi pokazuju da su svi dinamički panel- modeli prikladni te pokazuju da kamatna marža ostaje statistički značajna i negativnog predznaka. Za razliku od statičkih panel-modela, dinamički panel-modeli pokazuju da je varijabla udjela ukupne aktive osiguravajućih društava u BDP-u statistički značajna u cijelom razdoblju promatranja i u razdoblju prije krize. Ono što je važno istaknuti u dinamičkim panel- modelima je to što je u cijelom razdoblju promatranja varijabla udjela kredita privatnom sektoru u BDP-u statistički značajna i pozitivnog predznaka dok je u razdoblju prije krize ona zapravo nesignifikatna.

Kao što je vidljivo iz tablica kontrolne varijable koje su korištene u ovom istraživanju su otvorenost, štednja i rizik zemlje (OPENESS, SAVINGS, RISK). Varijabla SAVINGS mjerio udio bruto domaće štednje u BDP-u dok varijabla OPENESS predstavlja otvorenost jednog gospodarstva i varijabla RISK predstavlja rizik zemlje.

Isto tako, u analizi je (kako je vidljivo iz tablica) u testiranju hipoteza za varijablu uzet i BDP t-1. BDPt-1 prikazuje vrijednost bruto domaćeg proizvoda u vremenu t-1 tj u predhdonom vremenu a kako se ovdje radi o godišnjim podatcima onda je riječ o BDP-u iz predhodne godine. Navedene varijable su preuzete iz *Wolrd Development Indicators* (WDI) koje objavljuje Svjetska banka. Premda se podatci iz različitih baza mogu naći i za kraće periode od godinu dana, ograničenost velike većine varijabli iz ovog istraživanja kao i kontrolnih varijabli koje su uvrštene u model su na godišnjoj razini. Upravo je ovo i razlog zašto su onda u analizi hipoteza korišteni podatci na godišnjoj razini.

Model koji se testirao u ovom radu ima zapis u slijedećem obliku:

$$GDP_GROWTH_{it} = \alpha_i + \beta X_{it} + \gamma FINANCE_{it} + \varepsilon_{it},$$

gdje sa X označavamo vektor kontrolnih varijabli u samom modelu, a sa FINANCE jedan od indikatora razvijenosti financijskog sustava. Varijabla GDP_GROWTH je definiran kao razlika razine bruto domaćeg proizvoda iu periodu *t* i u periodu *t-1*.

Prema AK modelu, prihvaća se da štednja (SAVINGS) pozitivno utječe na gospodarski rast. Model Solowa također ističe pozitivnu vezu između štednje i rasta dohotka, ali je taj zaključak valjan samo u kratkom roku, odnosno dugoročno u modelu Solowa stopa štednje ne utječe na gospodarski rast. Potrebno je mnogo godina (preko 50) da bi se postigli dugoročni učinci povećanja stope štednje, pa kao rezultat slijedi da porast stope štednje ima privremen pozitivan utjecaj na stopu rasta. U ovom istraživanju vremenska serija je relativno kratka i očekivano je da je pozitivna veza između promjene varijable SAVINGS i BDP_GROWTH.

Kao i kod prve istraživačke hipoteze za dokazivanje druge istraživačke hipoteze započinje se s provjerom koje od skupa nezavisnih varijabli su visoko korelirane. Naime, ne može se očekivati da će svih 11 nezavisnih varijabli, uz dodatne kontrolne varijable, biti statistički značajne, pri čemu postoji opasnost da će predznaci varijabli biti pogrešni kao posljedica multilkolinearnosti koji je prisutan onda kada ima puno nezavisnih varijabli. Na temelju korelacijske matrice za izabrani skup nezavisnih varijabli utvrđuje se između kojih postoji visoka povezanost:

Tablica 5.9. Korelacijska matrica za izabrani skup nezavisnih varijabli za drugu pomoćnu hipotezu

fba_tba	fbno_tbno	soebankshare	overhead	
1,0000	0,9261	-0,6359	0,0789	fba_tba
	1,0000	-0,7080	0,0080	fbno_tbno
		1,0000	0,2736	soebankshare
			1,0000	overhead

netmargin	markcap	tradstock	
0,2939	-0,1201	-0,4001	fba_tba
0,1899	-0,0426	-0,3042	fbno_tbno
0,1317	-0,0881	-0,0290	soebankshare
0,6629	-0,2010	-0,3309	overhead
1,0000	-0,3145	-0,4596	netmargin
	1,0000	0,6119	markcap
		1,0000	tradstock

Prema gornjoj trokutastoj korelacijskoj matrici zaključuje se da su varijable npr. *markcap* i *tradstock* visoko korelirane (koeficijent korelacije iznosi 0,6119) što znači da obje ne mogu istovremeno biti uvrštene u model. Također se zaključuje da su visoko korelirane varijable netmargin i overhead (0,6629) što također znači da obje te varijable ne mogu istovremeno biti

uvrštene u model. Na taj način će se procijeniti više modela s različitim kombinacijama nezavisnih varijabli vodeći računa koje varijable ne bi smjele biti istovremeno uvrštene u model, a da se pri tome poštuje načelo parsimonije. Budući da se na temelju prethodnih rezultata istraživanja u prvoj hipotezi zaključuje da je varijabla growth vremenski autokorelirana, tj. da rast u tekućem razdoblju, između ostalog, ovisi i o rastu iz prethodnog razdoblja, tj. s vremenskim pomakom $(t-1)$ u nastavku će se analizirati isključivo dinamički panel modeli. Također će se promatrati cijelo razdoblje i razdoblje prije krize.

Iz svega navedenog procijenjeno je 14 modela s različitim kombinacijama nezavisnih varijbli i istih ti 14 modela za razdoblje prije krize. To je sveukupno 24 modela. Kombinacije nezavisnih modela su slijedeće:

1) concentration soebankshare netmargin marktturn tradstock nplintotal listed
2) concentration soebankshare overhead marktturn tradstock nplintotal listed
3) concentration fba_tba netmargin marktturn tradstock nplintotal listed
4) concentration fbno_tbno netmargin marktturn tradstock nplintotal listed
5) concentration fba_tba fbno_tbno netmargin marktturn tradstock nplintotal listed
6) concentration fbno_tbno overhead marktturn tradstock nplintotal listed
7) concentration fba_tba overhead marktturn tradstock nplintotal listed
8) concentration fbno_tbno netmargin marktturn markcap nplintotal listed
9) concentration soebankshare netmargin marktturn markcap nplintotal listed
10) concentration soebankshare netmargin marktturn markcap nplintotal listed risk1
11) concentration soebankshare netmargin marktturn markcap nplintotal listed risk1 open1
12) concentration soebankshare netmargin marktturn markcap nplintotal listed risk1 savings
13) concentration soebankshare netmargin marktturn markcap nplintotal listed risk1
14) concentration soebankshare netmargin marktturn markcap nplintotal listed savings

U slijedećim tabličnim prikazima bit će prikazani neki od modela dok ostale može se pogledati u zadnjem dijelu disertacije gdje su priloženi izračuni.

Tablica 5.9.A. Procijenjeni dinamički panel modeli za cijelo razdoblje promatranja (sistem GMM procjenitelj)

GROWTH	Model 1	Model 2	Model 3	Model 4	Model 5	Model 6
CONSTANT	-2,0407*	-1,0737	-2,0525*	-2,5327**	-7,3523***	-5,0378**
GROWTH(-1)	0,2255***	0,2897***	0,2303***	0,2137***	0,1343*	0,2154***
CONCENTRATION	0,0276*	0,0404***	0,0287	0,0296**	0,0431***	0,0284*
FBA_TBA	-	-	0,0697***	-	-	-
FBNO_TBNO	-	-	-0,1255***	0,0043	-	-
SOEBANKSHARE	-0,0028	-0,0036	-	-	0,0551*	-0,0007
OVERHEAD	-	0,3986**	-	-	-	-
NETMARGIN	0,8956***	-	0,7519***	0,8474***	0,9383***	0,9349***
MARKCAP	-	-	-	0,01721*	0,0241**	0,0225**
MARKTURN	0,0019**	0,0022**	0,0016*	-	0,0069	0,0018*
TRADSTOCK		-0,0111	0,0195	-	-	-
NPLINTOTAL	-0,1297**	-0,1247	-0,1258**	-0,1311**	-0,0687	-0,1034
LISTED	-0,0004*	0,0001	-0,0003	-0,0003*	-0,0003	-0,0003
Kontrolne varijable						
OPENESS	-	-	-	-	0,0115	-
SAVINGS	-	-	-	-	-	0,1095
RISK	-	-	-	-	0,0525	-
Pokazatelji prikladnosti modela						
Broj opažanja	168	168	168	168	91	168
Br. parametara	7	9	10	8	11	10
AR(1)	0,0018	0,0019	0,0024	0,0019	0,0177	0,0018
AR(2)	0,9394	0,8842	0,8734	0,6042	0,6270	0,3903
Sargan test	0,0285	0,0483	0,0385	0,0251	0,6862	0,0375
Wald test	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000

Izvor: Izračun autora

Svi dinamički panel-modeli procijenjeni su *GMM*-procjeniteljem. U svim se modelima pokazuje značajna varijabla s vremenskim pomakom, odnosno *growth (t-1)* što potvrđuje da su dinamički panel- modeli opravdano upotrijebljeni u ovom istraživanju.

Ukoliko analiziramo podatke iz tablice 5.9.A može se zaključiti da indikator CONCETRATION pozitivan i statistički značajno utječe na gospodarskir rast ali je vrijednost mala odnosno njegov utjecaj je mali. Isto tako pozitivnu i statistički značajnu vezu pokazuju i indikatori OVERHEAD, MARKTURN, TRADSTOCK, MARKCAP. Indikator NPLINTOTAL ima statistički značajan utjecaj na gospodarski rast ali je njegov predznak negativan.

Statistički značajan i jak utjecaj ima indikator NETINMARGIN. Indikator LISTED ima vrlo mali utjecaj i on je negativnog predznaka i u određenim modelima nije statistički značajan. Dakle, generalno iz tablice i nakon analize može se zaključiti da ukoliko se financijska razvijenost mjeri indikatorima razvoja financijskog tržišta (LISTED, MARKTURN, TRADSTOCK, MARKCAP), tada se veza između financijskog razvoja i gospodarskog rasta pokazuje statistički nesignifikantnom a što je bilo realno za očekivati jer se u ovim zemljama financijska tržišta još nisu značajno razvila.

Tablica 5.10.B. Procijenjeni dinamički panel modeli za razdoblje prije krize (sistem GMM procjenitelj)

GROWTH	Model 1	Model 2	Model 3	Model 4	Model 5	Model 6
CONSTANT	3,2436*	2,9481	0,5731	1,5165	0,3491	1,1619
GROWTH(-1)	0,4124***	0,3575**	0,3386**	0,3636***	0,3457***	0,3601***
CONCENTRATION	-0,16211	-0,0219	-0,0072	0,0043	2,3996	0,0041
FBA_TBA	-	-	-	-	-	-
FBNO_TBNO	-	0,0299	0,0405*	-	-	-
SOEBANKSHARE	-0,0088	-	-	0,0021	0,0032	-0,0001
OVERHEAD	-	-	-	-	-	-
NETMARGIN	0,3909*	0,3276	0,4733**	0,4067*	0,3621*	0,4331
MARKCAP	-	-	0,0119	0,0336**	0,0338**	0,0344*
MARKTURN	0,0015**	0,0018***	0,0016	-	-0,0192*	-0,0223**
TRADSTOCK	-0,0182*	-0,0143	-	-	-	-
NPLINTOTAL	-0,0782	-0,0771	-0,0689	-0,0425	-0,0148	-0,0398
LISTED	-0,0001	-0,0001	-0,0001	-0,0002	-4,6993	-0,0002
Kontrolne varijable						
OPENESS	-	-	-	-	0,0116	-
SAVINGS	-	-	-	-	-	0,0163
RISK	-	-	-	-0,0372	-0,0196	-0,0303
Pokazatelji prikladnosti modela						
Broj opažanja	108	108	108	62	62	62
Br. parametara	9	9	9	9	11	11
AR(1)	0,0036	0,0033	0,0037	0,0640	0,0659	0,0631
AR(2)	0,4341	0,4774	0,5524	0,1850	0,1863	0,1953
Sargan test	0,4597	0,4775	0,4279	0,2112	0,2215	0,2238
Wald test	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000

Izvor: izračun autora

Kao što je već predhodno rečeno ovdje se odmah prišlo panel analizi i to dinamički panel model kao što je to urađeno i za prvu hipotezu. Kao i u analizi prve hipoteze koristile su se iste kontrolne varijable (OPENESS, SAVINGS, RISK).

Ukoliko analiziramo tablicu 5.10.B , odnosno razdoblje prije krize može se zaključiti slični efekti odnosno pokazatelji i predznaci kao i u promatranom razdoblju. Razlika koja postoji u periodu prije krize jest ta što je utjecaj nešto slabiji a za neke indikatore taj utjecaj je prepolovljen (npr. ako promatramo indikator NETINMARGIN). Isto tako, pozitivan je utjecaj i indikatora OVERHEAD na gospodarski rast.

Dakle, može se zaključiti da u tranzicijskim zemljama gdje su manje razvijeni financijski sustavi i samim time manje efikasni više potiču rast. Navedeni zaključak je krajnje iznenađujući ali moguća obrazloženja možemo naći u Rajan i Zingales, (2003) i Rajan i Zingales (2007) gdje je potvrđeno da je pojedinim interesnim skupinama za održavanje svoje pozicije ne odgovara razvoj financijskog sustava. Objavljeno je jedno istraživanje iz 2015.godine (Sahay i dr.) gdje se pokazalo da opada utjecaj razvoja financijskog sustava na gospodarski rast što su financijski sustavi razvijeniji (kao što je primjer Švicarske i Japana).

S druge strane, zemlje u tranziciji koje imaju nerazvijene financijske sustave ili bolje rečeno koje imaju financijske sustave u razvoju i koji potiču gospodarski rast.

Ono što je sasvim sigurno za sve zemlje iz uzorka jest to da veća financijska efikasnost (mjerena OVERHEAD i NETINTMARGIN) utječe pozitivno na gospodarski rast a kao što je predhodno rečeno neke od varijabli nemaju statističku značajnost ili je njihov utjecaj slab.

Ovim istraživanjem je potvrđena kompatibilnost s istraživanjima Koivu (2002.) i Bogdan (2009.) da je NETINTMARGIN najprihvatljivija varijabla za mjerenje financijskog razvoja.

Na temelju izloženog se može prihvatiti da druga pomoćna hipoteza se može prihvatiti odnosno učinkovitiji i operativniji financijski sustavi omogućuju bolju alokaciju kapitala i na taj način potiču gospodarski rast.

Ovdje je, isto tako, važno napomenuti da su za analizu i dokazivanje obje pomoćne hipoteze korišteni originalni podatci i u slučaju logaritmiranja podataka isti ne potvrđuju vezu između razvoja financijskog sustava i gospodarskog rasta.

VI. ZAKLJUČNA RAZMATRANJA

6.1. Sažetak rezultata empirijskog istraživanja i rasprava

Zemlje središnje, istočne i jugoistočne Europe (odabrane zemlje) načinile su značajan napredak u transformaciji njihovih financijskih sustava. Zemlje iz uzorka koje su od početka članice EU-a već su prošle tu transformaciju dok su ostale zemlje taj proces započele devedesetih godina prošloga stoljeća, a u nekim traje i danas. Ostvareni su značajni pomaci u privatizaciji i transformaciji državnih banaka, sanaciji problematičnih banaka, osnivanju novih domaćih i stranih banaka, napredak u pravnom, supervizijskom i regulatornom okruženju. Neminovno je da globalizacija ima ogroman utjecaj na razvoj financijskih sustava promatranih zemalja, a što svakako ima i makroekonomske implikacije. Sve je to utjecalo i na definiranje i određivanje strukture financijskih sustava promatranih zemalja. U većini zemalja završio je proces rekonstrukcije financijskih sustava, a poglavito bankarskoga dijela kao najzastupljenijeg u svim financijskim sustavima promatranih zemalja.

U teorijskim okvirima financijski sustav može pridonijeti gospodarskom rastu na nekoliko načina:

- poticanjem akumuliranja fizičkog i ljudskog kapitala

- alociranjem kapitala u najproduktivnije investicije

- smanjenjem količine resursa koji se troše u procesu posredovanja između štediša i osoba koje žele unajmiti novac.

U ciljevima ovoga rada postavljeno je ishodišno pitanje zašto neke zemlje imaju financijske sustave koji potiču rast, a druge ne. Dakle, prije svega bitno je saznati i istaknuti kada i u kojim okolnostima financijski sustav ima pozitivan utjecaj na gospodarski rast i što to definira njegovu učinkovitost u tom kontekstu. Banke ne djeluju u neutralnom okruženju, nego su dio financijskoga i društvenoga sustava zemlje. U takvu sustavu država ima važnu ulogu te je podložna mnogim političkim i ekonomskim utjecajima. Posljednja financijska kriza daje

dodatne dokaze da je potrebno više pozornosti predati kompleksnom međuodnosu države i banaka, osobito u situacijama državnih i tržišnih neuspjeha. Financijski sustav je interesantan za istraživanje kada je riječ o njegovu utjecaju na gospodarski rast, što potvrđuju i dosadašnja istraživanja. Dosadašnja istraživanja razvoja financijskoga sustava i njegove prilagodbe dokazuju da država značajan utjecaj. Međutim, u manje razvijenim zemljama bankari uobičajeno imaju snažan utjecaj na vlade i regulatore zbog čega dolazi do toga da regulatori štite interese bankara i banaka i ne promiču opće društveno blagostanje.

Fenomen gospodarskog rasta, pozitivne promjene na razini proizvodnje dobara i usluga je delikatan fenomen. Velik broj čimbenika i njihova interakcija utječu na gospodarski rast i konvencionalna ekonomija podupire stajalište da su rad i kapital zemlje glavni pokretači rasta. Nove teorije rasta dodaju njima i tehnološke promjene kao izvor promjena u proizvodnoj funkciji.

U novije vrijeme prepoznata je važnost razvoja i razvijenosti financijskoga sustava[72] pa je i ovo istraživanje urađeno u tom smjeru. Kao rezultat istraživanja u posljednjih tridesetak godina velik broj istraživanja proizišao je iz analiza reformi financijskih sustava i većina njih potvrđuje postojanje veze između realnog i financijskog sektora i ukupnog razvoja gospodarstva.

Dakle, nastao je niz istraživanja (teorijska i empirijska) iz kojih su proizišle mnoge studije u kojima se istraživao uzrok gospodarskog rasta. Na žalost, do danas uloga razvoja financijskog sustava na gospodarski rast nije dovoljno istražena, a posebno u zemljama u razvoju. Upravo se u tom dijelu ovoga istraživanja vodila briga o tome da je odabran uzorak razvijenih zemalja i onih koje su nedavno prošle proces tranzicije. Temeljni razlog takva odabira jest taj što se želi u istom razdoblju analizirati utjecaj i vršiti usporedba, ali će se analizirati i utjecaj reformi zemalja koje su prošle transformaciju. Dakle, ovo je istraživanje rađeno zato da bi se upotpunila ta praznina dosadašnjih istraživanja i pokušao dati odgovor na neka pitanja na koja dosad nije bilo odgovora.

Ono što su dosadašnja istraživanja potvrdila na određenim indikatorima razvijenosti financijskoga sustav jest da razvoj financijskog sustava vodi prema većem rastu. Uobičajeno je da razvoj financijskih usluga kroz bolju mobilizaciju štednje i veću alokaciju kredita dovodi do većeg rasta investicija i vodi prema učinkovitijoj alokaciji kapitala. Veći krediti u svim

[72] Vidjeti Goldsmith (1969.), Hicks (1996.), Levine (1993.), Loayaza i Beck(2000.), Christodoulou i Tsinas (2004.), Kuan Ashad i dr.(2005.).

promatranim zemljama uzrokuju veći gospodarski rast i kratkoročno i dugoročno. To sugerira da se hipoteza o razvoju financijskog sustava koji utječe na gospodarski rast prihvaća u svim slučajevima. Taj je utjecaj u nekim zemljama veći, a u nekima manji, što ovisi o razini razvijenosti kao i to gdje su alocirani krediti.[73]

Pozitivan koeficijent *R* pokazuje pozitivan utjecaj na rast. Negativan koeficijent kamatne stope je nesignifikantan što je i stav škole koju zastupaju McKinnon (1973.) i Shaw (1973.). Oni smatraju da je koeficijent *R* pozitivno koreliran sa štednjom u razvijenim zemljama jer pozitivan efekt supstitucije pobija negativan efekt prihoda.

U disertaciji se, kako se može vidjeti u prethodnom dijelu teksta, daje kratak povijesni pregled dosadašnjih istraživanja o utjecaju razvoja financijskoga sustava na gospodarski rast. Istraživanje je u promatranim zemljama pokazalo respektabilnu razinu reformi koje su postignute u svim zemljama. Pokazalo se da razvoj NPL-a (udio loših kredita u ukupnim kreditima)posebno u doba financijske krize značajno usporio daljnji razvoj financijskoga sustava, a time i njegovu kontribuciju gospodarskom rastu. Isto tako treba istaknuti da pokazatelj kreditiranja privatnog sektora ne raščlanjuju te kredite poduzećima (pravnim osobama) i privatnim osobama zbog nedostatka statistike koja bi vodila evidenciju na taj način.

Reforme financijskih sustava većine promatranih zemalja utjecale su na razvoj financijskoga sustava i na gospodarski rast i vrlo je bitno da se nastavi s daljnjim reformama. Naime, razvoj financijskog sustava će i dalje jačati što će pridonijeti boljoj alokaciji resursa i većem gospodarskom rastu. Povećavanje konkurencije i kreiranje profitabilnog financijskog sustava otvorit će taj financijski sustav međunarodnoj konkurenciji.

Nadalje, pri analizi rezultata istraživanja rast depozita s manjom kamatnom stopom, pa i negativnom, u nekim europskim zemljama sugerira da se upotrijebe i drugi financijski instrumenti i tako povećaju aktivnosti na tržištu kapitala. Treba istaknuti da razvijenije zemlje imaju veće mogućnosti investiranja na tržištu kapitala, no mora se raditi na tome da se ta razina

[73] Jedno istraživanje koje su proveli Irang i Teng 2006. godine na kineskom financijskom sustavu pokazuje da njihove banke (koje su u većini u državnom vlasništvu) alociraju veliku većinu kredita javnim poduzećima. Te banke rade svoj posao posve drukčije od većine privatnih banaka. Najveći problem koji se javlja kao rezultat takva financiranja je razmjerno velik udjel NPL-a u ukupnim kreditima, ali oni ne odustaju od takvog modela financiranja i na taj način se potiču velike infrastrukturne projekte koji u dugoročnom razdoblju donose pozitivne rezultate na rast.

razvijenosti dosegne.

U ovom istraživanju je pokazana bolja otpornost razvijenih ekonomija od onih manje razvijenih. To se, primjerice, vidi na primjeru Njemačke i Austrije, s jedne strane, i zemalja koje su nedavno ušle u EU ili su u procesu pristupanja. Vidi se i ogroman pomak u ovim zemljama u smislu reforme i razvoja financijskog sustava što će vrlo vjerojatno dovesti do značajnijih rezultata u budućnosti u pogledu njegova utjecaja na gospodarski rast. Napravljen je i značajan pomak u smislu supervizije i regulacije što je dovelo do poboljšanja performansi financijskoga sustava. Vjerovalo se da će proces transformacije (privatizacije banaka i stvaranja, odnosno osnivanja novih privatnih banaka) trajati dulje, no zabilježen je ogroman napredak već u prvom desetljeću transformacije. Nakon proteklog razdoblja može se reći da su financijski sustavi većine promatranih zemalja daleko od savršeno razvijenog. Međutim, postoji protržišna orijentacija, što je pravilo u svim promatranim zemljama, a ne iznimka.

Razlike koje postoje između promatranih zemalja u smislu razvijenosti financijskoga sustava i oni se uglavnom razlikuju ovisno o veličini zemlje i vremena početka transformacije. Manje zemlje su zatvorenije i proces prilagodbe je sporiji. Neke su zemlje vodile strategiju čuvanja bankarskoga sektora u državnom vlasništvu, ali se to u financijskoj krizi pokazalo pogubnim za njih i sve su se suočile s problemom nedostatka kapitala (kapitalne adekvatnosti). U takvim se situacijama manje ponude u domaćem financijskom sustavu posezalo za međunarodnim izvorima. Na temelju analize trenutnoga stanja potrebno je u zemljama istočne i jugoistočne Europe poticati ulazak velikih institucionalnih investitora kako bi se razvilo tržište kapitala. Time bi se poradilo na ponudi financijskih proizvoda što bi olakšalo provođenje određenih investicijskih poduhvata koje dotad nije bilo moguće realizirati zbog nedostatka kapitala. Kako je i Levine (2005.) istaknuo, bitno je da postojeći razvoj i rad budu usmjereni na to da se razvija financijski sustav, ali i da se radi na strukturama gospodarskoga rasta, što će pridonijeti znatno boljim rezultatima. Razvoj tehnologija svakako da će potaknuti gospodarski rast, ali razvoja tehnologija nema bez razvoja financijskoga sustava.

Nekoliko je razloga zašto utjecaj financijskoga sustava nije jači na gospodarski rast u odabranim zemljama. Jedan od razloga je institucionalno okruženje i kvaliteta institucija uključujući i pravni sustav s birokracijom te zakonodavstvo (posebno ono vezano za imovinsku problematiku). To je u slabije razvijenim zemljama na nižoj razini kvalitete. Zato se smanjuju poslovne aktivnosti i investicije pa je gospodarski rast nedostatan. Isto tako, u tim se zemljama

infrastrukturni projekti provode smanjenim intenzitetima.

Iako je financijski sustav dobro razvijen u posljednjih 25 godina, još je nedovoljno razvijen da bi značajnije utjecao na gospodarski rast. Dakle, u ovom je slučaju potrebno nastaviti s aktivnostima poput daljnjeg poboljšanja razvoja financijskoga sustava, daljnjim vladinim potporama u razvoju financijskog sustava i poticanju razvoja konkurencije te investirati u ljudski kapital i stvoriti bolju zakonsku regulativu.

Nadalje, analiza prikupljenih podataka o razvijenosti financijskoga sustava promatranih zemalja pokazuje da razvoj financijskog sustava ima dugoročniji utjecaj na gospodarski rast u promatranu razdoblju. Razvoj financijskog sustava u odabranim zemljama dovodi do rasta investicija i rasta ukupne akumulacije kapitala. Upravo je to razlog kako treba razvijati politike koje potiču daljnji razvoj financijskoga sustava što će, u konačnici, utjecati na rast investicija i na gospodarski rast.

Kao što je već spomenuto u prethodnom dijelu teksta, u promatranim zemljama odrađen je ogroman posao u reformi financijskog sustava, a poglavito bankarskog kao dominantnog. Ulazak velikih stranih banaka i ogroman pomak u bankarskoj superviziji, kao i makroekonomska stabilnost, rezultirao je razvojem mnogih prednosti u bankarskom sektoru. Međutim, postoji ogroman prostor za unaprjeđenje i razvoj nebankarskog sektora kao i tržišta kapitala.

Kada je riječ o financijskom sustavu, bankarski sustav, kao njegov podsustav, ne bi smio biti jedini koji treba poticati gospodarski rast. Zbog toga je potreban uravnotežen razvoj financijskoga sustava kako bi se omogućio stabilan i dugoročan gospodarski rast. Međutim, bankarski sustav kao dio financijskog sustava ne bi trebao biti razvijeniji u odnosu na ekonomiju. Zato razvoj bankarskog sustava ne bi trebao biti izdvojena sastavnica, već usporedna i komplementarna sastavnica sa svim relevantnim čimbenicima financijskoga sustava koji pokreće gospodarski rast jedne zemlje. Dakle, svima onima koji rade na politikama predstoji zahtjevan posao kako bi se u zemljama odabranima za ovo istraživanje uravnotežio razvoj financijskog sustava s gospodarskim rastom.

6.2. Doprinosi i implikacije rezultata istraživanja

6.2.1. Teorijski doprinosi i implikacije istraživanja

Razni svjetski autoriteti u području financijskog sustava koji analiziraju njegov razvoj i utjecaj na gospodarski rast, dali su ogroman doprinos u razumijevanju te problematike.

Kod određenja pojma financijskoga sustava u literaturi se nalaze različite definicije, a svima je njima zajedničko određenje da financijski sustav čine valuta, platni sustav, financijska tržišta, skup financijskih institucija te institucije koje reguliraju i nadziru njihov rad. U središtu ovoga istraživanja je razvoj financijskoga sustava te je u tom smjeru uz pomoć 21 indikatora rađena analiza razvijenosti financijskih sustava odabranih zemalja.

Većina ekonomista suglasna je da su dva temeljna kanala gospodarskoga rasta: akumulacija kapitala (fizičkoga i ljudskoga) i tehnološke inovacije. U ekonomskoj analizi poznato je mnoštvo modela rasta, no sagledavamo li financijski sustav u tom kontekstu, onda su interesantna tri: Mankiw-Romer-Weilov iz 1992., Solowljev model rasta iz 1956. i tzv. *AK*-modeli. (Usp. Rebelo, 1992.)

Ovim je modelima imanentna analiza utjecaja razvoja financijskoga sustava i njegova utjecaja na gospodarski rast kroz transmisiju štednje u investicije. Upravo je funkcija mobilizacije štednje jedna od najvažnijih funkcija koje financijski sustav obavlja u jednom gospodarskom sustavu. Međutim, ovdje treba napomenuti da analizirati utjecaj financijskoga sustava samo kroz funkciju štednje nije dovoljno i potrebno je odraditi analizu i na ostalim funkcijama, što je u ovoj disertaciji i napravljeno. Kako bismo bismo dobili cjelovitiju sliku o utjecaju financijskog sustava na gospodarski rast, potrebno je promatrati i njegove druge funkcije koje obavlja. Više riječi o funkcijama financijskoga sustava može se vidjeti u odjeljku „Financijski sustav“ i svaka od navedenih funkcija može imati značajan utjecaj na akumulaciju kapitala i tehnološke inovacije.

Financijski sustavi promatranih zemalja podložni su promjenama zbog promjena zakonskih okvira i političkih promjena te je na taj način stvorena razlika u zakonskoj tradiciji i različitost

u bogatstvu proizvodnih resursa uslijed kojih se kreiraju različite političke i institucionalne strukture. Upravo sve to određuje financijske sustave, a zbog čega se oni upravo i razlikuju u promatranim zemljama.

Sva dosadašnja istraživanja na temu utjecaja financijskoga sustava na gospodarski rast pokazuju da postoji veza, ali iz tih je istraživanja proizišlo dosta pitanja na koja treba dati odgovore. Najznačajnija istraživanja u današnje vrijeme vodi Ross Levine koji je o ovoj temi objavio desetine radova. Zaključak ovog istraživanja jest potreba da se i dalje radi na razvoju financijskih sustava te da se posebna pozornost treba posvetiti determinantama razvoja financijskoga sustava. Razvoje financijskog sustava treba podrediti razvoju ekonomija i prilagoditi se promjenama koje se događaju intenzivno. Današnje su promjene sve vidljivije, zahtjevnije i dinamičnije.

6.2.2. Empirijski doprinosi i implikacije istraživanja

Model se sastoji od dviju varijabli koje su definirane kao *nezavisna varijabla* (financijski sustav) i *zavisna varijabla* (gospodarski rast).
Na slici 6.1. prikazan je istraživački model koji je rezultat pregleda prethodnih istraživanja i vlastitog modeliranja pri čemu su specificirane i mjerene veličine (vrijednosti čimbenika izlučenih tijekom empirijskoga istraživanja).

Slika 6.1. Rekapitulacija istraživačkog modela

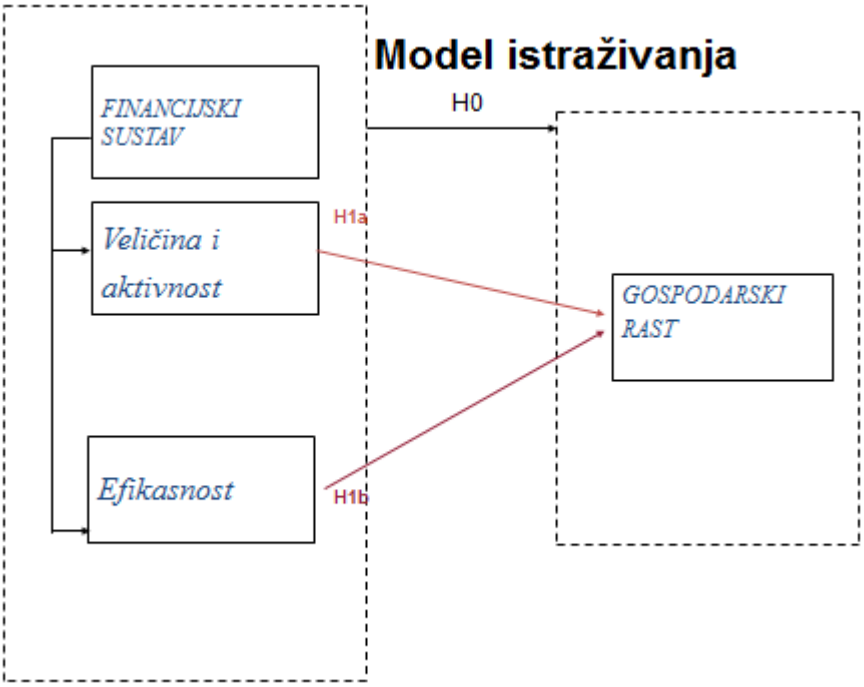

nezavisna varijabla *zavisna varijabla*

Mjereni indikatori koji se koriste za nezavisnu varijablu:

1. razlika aktivne i pasivne kamate (kamatna marža): _INTERESTSPREAD
2. udio ukupne novčane mase u BDP-u: _BMONEYINGDP
3. udio aktive središnje banke u BDP-u: _CBAGDP
4. udio aktive bankarskoga sektora u BDP-u: _DBAGDP
5. udio aktive nebankarskoga sektora u BDP-u: _OFAGDP
6. udio kredita bankarskoga sektora privatnom sektoru u BDP-u: _BANKCREDINGDP
7. udio kredita privatnom sektoru u ukupnoj aktivi bankarskoga sektora: _PCRDDBA
8. ukupan udio kredita privatnom sektoru u BDP-u: _PRIVCREDINGDP
9. udio aktive životnih osiguravajućih društava u BDP-u: _INSLIFE
10. udio ukupne aktive osiguravajućih društava u BDP-u: _INSNONLIFE
11. udio općih troškova (režijskih) u ukupnoj aktivi bankarskoga sektora: _OVERHEAD
12. udio neto prihoda banaka u ukupnoj aktivi koje donosi kamata: _NETINTMARGIN
13. udio NPL u ukupnim kreditima bankarskog sektora: _NPLINTOTAL
14. omjer tržišne kapitalizacije i BDP-a: _ MARKTCAPINGDP

15. omjer ukupne tržišne realizacije i BDP-a: _ TRADSTOCKVALINGDP
16. brzina prometa, ili obrtaj, koji predstavlja omjer prometa i tržišne kapitalizacije: _MARKTTURNRATIO
17. broj uvrštenih poduzeća na tržištu kapitala ukupno: _LISTEDCOMP
18. koncentracija: _CONCENTRATION
19. udio aktive stranih banaka u ukupnoj aktivi bankarskoga sektora:_FBA_TBA
20. broj stranih banaka u ukupnom broju banaka: _FBNO_TBNO
21. udio banaka u vlasništvu države u ukupnom bankarskom sektoru: _SOEBANKSHARE.

Za zavisnu varijablu koristio se indikator stope gospodarskoga rasta po glavi stanovnika, ali se on ujedno koristio i kao indikator u nezavisnoj varijabli s pomakom vremena, odnosno za promatrano vrijeme *t-1* (stopa gospodarskoga rasta po glavi stanovnika iz prethodnog razdoblja).

Ukratko, analizirajući empirijski dio ove disertacije za svaku pomoćnu hipotezu možemo zaključiti:

H.1a.: Razvijeniji i aktivniji financijski sustavi imaju značajnu ulogu na razvoj realnog sektora gospodarstva što pozitivno utječe na ukupan gospodarski rast je *prihvaćena*.

Statističkom analizom pomoćne hipoteze H.1a prihvaćene su sadržajne pretpostavke analizirane hipoteze. Ova se hipoteza prihvaća i dinamičkom je panel-analizom dokazan utjecaj razvijenijih i aktivnijih financijskih sustava na gospodarski rast.

H.1b.: Učinkovitiji i operativniji financijski sustavi omogućuju bolju alokaciju kapitala i na taj način potiču gospodarski rast je *prihvaćena*.

Kao i kod prethodne pomoćne hipoteze, kod druge pomoćne hipoteze H.1b prihvaćene su sadržajne pretpostavke analizirane hipoteze. Korištena je ista statistička metoda, odnosno druga pomoćna hipoteza potvrđena je dinamičkom panel-analizom.

Na kraju, može se reći da je ovo istraživanje analizirajući razvoj financijskog sustava i njegov utjecaj na gospodarski rast potvrdilo hipotezu da taj utjecaj postoji i da je pozitivnog predznaka. Korišteni su godišnji podatci za razdoblja 1996. – 2011.godina na 17 odabranih zemalja. Budući da prikupljeni podatci sadrže i vremensku i prostornu komponentu, za analizu je korištena panel-analiza. Glavni je zaključak da su indikatori razvoja financijskoga sustava uglavnom pozitivno korelirani s gospodarskim rastom. Kamatna stopa i krediti privatnom sektoru pokazuju negativan utjecaj, što potvrđuju i prethodna istraživanja (usp. De Gregorio i Guidotty, 1995.; Beck i Levine, 2002.) u kojima su, doduše, korištene nešto drukčije tehnike istraživanja i godišnji podatci za odabrane zemlje.

6.3. Ograničenja provedenog istraživanja i preporuke za daljnja istraživanja

Tijekom provođenja istraživanja i analize podataka, u konkretnu istraživanju, ukazala su se određena ograničenja koja su mogla utjecati na donošenje induktivnih zaključaka. Prije svega ogroman je problem bio pronalazak indikatora razvijenosti financijskog sustava i to ne samo za zemlje u posttranziciji nego i za zemlje koje imaju razvijene financijske sustave poput Njemačke i Austrije.

Istraživanje je provedeno, između ostaloga, na području bivše Jugoslavije gdje se netom prije početka istraživanja okončao rat, a ogromne i nesagledive posljedice znatno su utjecale na daljnji razvoj gospodarstva novonastalih zemalja. Dakle, te zemlje nisu prošle tranziciju iz komunističkog u kapitalističko društvo, poput nekih zemalja koje su time bile u prednosti u pogledu i razvijenosti financijskih sustava te u razvijenosti gospodarstava. Do danas veći je dio tih zemalja ušao u EU i one su u tom pogledu morale prilagoditi zakonodavstvo koje regulira financijski sustav. Dakle, zemlje su morale proći proces usklađivanja zakonodavstva sa pravnom stečevinom EU-a te su te promjene utjecale na rezultat ovog istraživanja počevši od promjena u regulativi pravnoga oblika i financijskih performansi koje su rezultat poslovnih postupanja u skladu s izmijenjenim financijskim propisima.
Budući istraživački zadatci zahtjevaju provođenje istraživanja u više država zajedničkog poslovnog okruženja. Istraživanje je potrebno provesti i nakon što zemlje iziđu iz financijske krize i tada usporediti podatke s razvijenim zemljama.

Poželjno je istraživanje napraviti na većem broju indikatora, a isto je tako potrebno neke indikatore nužno je raščlaniti. Trebalo bi u analizi koristiti i analizirati privatne kredite i to prema poduzećima. Na žalost, većina financiranja u doba krize plasirana je vladama, nebankarskim financijskim institucijama i s aspekta ročnosti kredita rađena su kratkoročna financiranja za poduzeća.

Treba imati na umu da je glavna hipoteza u ovom radu : „ financijski sustav utječe na gospodarski rast“ i da su odabrane zemlje one koje su već dugi niz godina članice EU ali i one koje su u promatranom periodu to postale. Međutim, u radu nije razmatrano institucionalno naslijeđe pojedinih zemalja. Dakako, postoje radovi koji su isticali utjecaj institucionalnog nasljeđa i usuglašeni su u stavu da je financijski sustav razvijeniji u zemljama koje imaju britanski i/ili njemački pravni okvir. U tranzicijskim zemljama je razvoj financijskog sustava bio zapostavljen, a prije uvođenja kapitalizma zemlje su bile na niskom stupnju gospodarskog razvoja, tako da ni financijski sustav nije mogao biti razvijen premda je većina njih u Europi u znatnoj mjeri usvojila njemačku pravnu regulativu. Stoga bi u narednim istraživanjima trebalo uzeti u obzir i institucionalno naslijeđe te razmotriti ulogu povijesnih faktora.

Potrebno je unaprijediti praćenje i mjerenje indikatora razvijenosti financijskog sustava kao što su determinante financijskog sustava.

S obzirom na rezultate ovoga istraživanja za zemlje koje su promatrane u ovom istraživanju (tranzicijske) može se reći da je puno napravljeno u razvoju financijskoga sustava, ali i da ga je potrebno i dalje razvijati. Početno razdoblje promatranja bilo je obilježeno slabom razvijenošću i konkurentnošću banaka kao najzastupljenijeg sektora u financijskim sustavima promatranih zemalja. Bilo je interesantno vidjeti kako razvoj financijskoga sustava utječe na gospodarstva tih zemalja samim razvojem financijskog sustava u smislu njegova rasta, povećanja efikasnosti i povećanja konkurentnosti.

Kako je u prethodnom dijelu disertacije prezentirano, za analizu su se koristili različiti indikatori razvijenosti financijskoga sustava jer ne postoji jedan indikator koji bi primjereno mjerio razvijenost financijskog sustava. U novijim istraživanjima pokušava se stvoriti indeks indikatora i u tom smjeru treba razrađivati i unaprjeđivati buduća istraživanja.

Buduća istraživanja o utjecaju razvoja financijskoga sustava na gospodarski rast trebala bi poboljšati samu svijest o važnosti poticanja razvoja financijskoga sustava jer se time poboljšava i pospješuje njegov utjecaj na gospodarski rast ali i na financijsku stabilnost.

VII. POPIS LITERATURE

1) Abu-Bader, S., & Abu-Qarn, A. S. (2008). Financial development and economic growth: Empirical evidence from Six MENA countries. Review of Development Economics, 12(4), 803-817.

2) Adusei, M. (2013). Financial development and economic growth: Evidence from Ghana. International Journal of Business and Finance Research, 7(5), 61-76.

3) Al-Avad, M., i Harb, N., „ Financial development and economic growth in the Middle East.“ *Applied Financial Economics,* 2005., 15(15), 1041.-1051.

4) Al-Malkawi, H. A. N., Marashdeh, H. A., & Abdullah, N. (2012). Financial development and economic growth in the UAE: Empirical assessment using ARDL approach to co-integration. International Journal of Economics and Finance, 4(5), 105-115.

5) Aghion, P., Caroli, E. i Garcia-Penalosa, C., „ Indequality and economic Growth:Perspective of The New Growth Theories“, *Journal of Economic Literature, Vol. 37, No 4.*1999.,1615.-1660.

6) Aghion, P., and Peter Howitt, „The Economics of Growth“, The MIT Press, 2009.

7) Anwar, S., & Nguyen, L. P. (2011). Financial development and economic growth in Vietnam. Journal of Economics and Finance, 35, 348-360.

8) Arcand, J. L., Berkes, E.,Panizza, U., 2012.Too much finance? IMF Working Paper 12/161.

9) Arestis, Philip, Panicos Demetriades i Kul Luintel.“Financial Development and Economic Growth.“ *Jurnal of Money Credit and Banking Vol 33, No.1,* 2001.: 16.-41.

10) Asli Demergüç- Kunt, i Ross Levine.“ Financial Structure and Economic growth, a cross-country comparasion of banks, markets, and development“. The MIT, 2001.

11) Atje, Raymond i Bojan Jovanović. „Stock Markets and Development.*“ European Economic Review, Vol. 37, Nr.2-3,* 1993.:632.-640.

12) Ayres, U. Robert, „ Theories of Economic Growth“, Center for the Management of Envoromental Resources INSEAD Fontaineblau, France, 1997.

13) Backé, P., Égert, B., & Walko, Z. (2007). Credit growth in Central and Eastern Europe revisited. Focus on European Integration, 2, 69-77.

14) Bađun, Marijana. „ Kvaliteta javnog upravljanja i ekonomski rast, Hrvatska u kontekstu pridruzivanja EU“, Magistarski rad, zagreb, 2005.

15) Bađun, Marijana.“ Financijsko posredovanje banaka i ekonomski rast:pregled empirijskih istraživanja.“ *Financijska teorija i praksa 33(2),* 2009.:119.-151.

16) Baro, R.J. i Sala-i- Martin, X, „Economic Growth“, New York, 1995, McGraw-Hill.

17) Beck, T., Levine R. i Loayza N., „ Finance and the Sources of Growth“, World Bank, 1999.

18) Beck, Torsten. „The Econometrics of Finance and Growth.“ *Policy Research Working Paper No. 4608. Washington World Bank,* 2008.

19) Beck, Z., „ The role of finance in economic growth:benefits, risks and politics“, European Banking Center Discussion Paper, 2011.

20) Beck, Torsten. „The Econometrics of Finance and Growth.“ *In Patterson, K. Mills, T.(Eds.) The Palgrave Handbook of Econometrics, Vol.2, Palgrave, Basinstkocke,* 2009., 1180-1212.

21) Beck, Thorsten, Asli Demergüç- Kunt, „Financial Institutions and Markets Across Countries and over Time: Data and Analysis. World Bank Policy Research Working Paper No. 4943. http//sitersources.worldbank.org/INTES/Resources/469232-1107449512766/FinStructure_2007_v2.2.xls.

22) Beck, Thorsten, Asli Demergüç- Kunt, i Ross Levine. „The Financial Structure Data-base“ U *Financial Structure and Economic Growth: A Cross-Country comparation of Banks, Markets and Development,* autor Asli Demergüç- Kunt i Ross Levine(ur.), 17.-80, The MIT Press, 2001.

23) Beck, Thorsten, Asli Demergüç- Kunt, Ross Levine, i Vojislav Maksimovic., „The Financial Structure Data-base“ U *Financial Structure and Economic Growth: A Cross-Country comparation of Banks, Markets and Development,*autor Ros& Demergüç- Kunt , 189.-241., The MIT Press, 2001.

24) Benhabib, Jess, i Mark Spiegel. „The Role of Financial Development in Growth and Investment.“ *Journal of Economic Growth vol 5,* 2000: 341.-360.

25) Benigno V. Diaz, „Economic Growth Theory, Empirics adn Policy“, UK, 1999.

26) Blanco, L., „The finance-growth link in Latin America.“, *Southern Economic Journal,* 2009., 76(1), 224.-248.

27) Blanchard, O., „ MAKROEKONOMIJA“, Mate, Zagreb, 2007.

28) Bloch, H., & Tang, S. H. K. (2003). „*The role of financial development in economic growth“,* Progress in Development Studies, 3(3), 243-251.

29) Bogdan, Željko, Pregled Istraživanja o vezi između razvijenosti financijskog sustava i gorpodarskog rasta: pregledni rad, UDK:303.09<336.7:330.35>(4-69)

30) Bogdan, Željko, „Makroekonomksi učinci i razvoj financijskog sustava u tranzicijskim zemljama.“, Doktorska disertacija, Zagreb, 2009.

31) Bahovec, V.,Erjavec N. (Urednici). (2015). Statistika. Zagreb: Element.

32) Bahovec, V., Erjavec N. (Urednici). (2015). Pregled formula iz Statistike. Zagreb: Element.

33) Boyd, Derick, „ W.Arthur Lewis´s Theory of Economic Growth: a Review with 50 years of Foresight, University of East London, 2007.

34) Botrić, Valerija, i Sunčana Slijepčević.“Banking Sector and Economic Growth“-Evidenc from SEEC-7“, „*3th International Conference: An Enterprises Odyssey:Integration or Desintegration, 15.-17. Lipanj 2006*. Sveučilište u Zagrebu, Ekonomski Fakultet, 2006.

35) Boulila, G. i Trabelsi, M., „Fiancial Development andlong run growth:Evidence from Tunisia: 1962.-1997.“ *Savings and Development Qouarterly Review 3,* 2004.a., 289.-314.

36) Boulila, G. i Trabelsi, M., „ The causality issue in the finance and growth nexus:empirical evidence from Middle East and North African countries.“ *Review of Middle East Economic and Finance,* 2004.b., 2(2): 123.-138.

37) Calderon, C., Liu, L. , „The direction of causality between fianncial development and economic growth.“*Journal of Development Economics,* 2003., 72(1), 321.-334.

38) Caporale, G. M., Rault, C., Sova, R., & Sova, A. (2009). Financial development and economic growth: Evidence from ten new EU members. Economics and Finance Working Paper Series No. 09-37.

39) Carlin, Wendy, i Colin Mayer.“Finance, Investment and growth.“ *Jurnal of Financial Economics Vol 69,* 2003: 191.-226.

40) Cecchetti, G., Kharroubi, E., 2012. Reassessing the impact of finance on growth. BIS Working Papers No. 381, Bank for International Settlements

41) Chang, T. i Caudil, S.B., „Financial development and economic growth: the case of Taiwan.“, *Applied Economics,* 2005, 37(12), 1329.-1335.

42) Cerovac, S. i Petrovic, S., „ Growth Decomposition Analysis: The Application of The Growth Accounting Approach in the Case of Croatia (neobjavljena publikacija 2008.).

43) Christopoulos, D. K., Tsianos, E.G., „ Financial development and economic growth:Evidence from panel unit root and cointegration tests.“ *Journal of Development Economics,* 2004, 73, 55.-74.

44) Dalić, Martina.“Usporedna analiza hrvatskog financijskog sustava i financijskih sustava naprednih tranzicijskih zemalja.“ Privredna kretanja i ekonomska politika br.92, 2002., 27.-52.

45) Deida, L., i B. Fattouh. „Non-linearity between Finance and Growth.“ *Economic Letters 74(3), 2002.:339-345.*

46) De Long, J. Bradford, „ A Short Review of Economic Growth: Theries and Policies, University of Califrnica at Berkly, and National Bureau of Economic Research, 1996.

47) Demetriades, Panicos, i K.Hussein.“Does financial development cause economic growth? Time-series evidence from 16 countries.“ Jurnal of development Economics 51(2), 1996.:387-411.

48) Demergüç- Kunt, Asli, i Ross Levine.“ Bank -Based and Market –Based Financial System.“ U *Financial Structure and Economic Growth*, autor Asli Demergüç- Kunt i Ross Levine(ur), 81.-140. MIT Press, 2001

49) Demergüç- Kunt, Asli, i Vojislav Maksimović. „Stock Market Development and Financial choices of the Firms.“ *World Bank Economic Review 10(2), 1996.a:341-370.*

50) Demergüç- Kunt, A. Feyen, E. i Levine, R., “ The Evolving Importance of Banks and Securities Markets“, The Worls Bank, 2011.

51) Dushku, E., „Financial Development and Economic Growth: The Albanian Case“, Bank of Albania, 2007.

52) Eaton, J., Kortum, S. (1996). “Trade in ideas: Patenting and productivity in the OECD”. Journal of International Economics 40, 251–278.

53) Ercegovac, R., Financijske pretpostavke ekonomskog rasta u tranzicijskim ekonomijama“, Zbornik radova Pravnog fakulteta u Splitu, 2002., Vol.39, br. 3.-4., 491-502.

54) Ergungor, O. E., 2008. Financial system structure and economic growth: structure matters. International Review of Economics and Finance 17(2), 292–305

55) Estrada, G., Park, D., & Ramayandi, A. (2010), Financial development and economic growth in developing Asia, Asian Development Bank Economics Working Paper Series No. 233.

56) Fisman, R. i Love, I., „ Financial Development and Growth in the Short- and Long-Run, The World Bank Policy Research Working Paper 3319, 2004.

57) Frederic S.Mishkin i Stanley G. Eakins. „Financijska Tržišta i Institucije“, MATE Zagreb, Zagreb, 2003.

58) Gene M. Grossman & Alan B. Krueger, 1994. "Economic Growth and the Environment," NBER Working Papers 4634, National Bureau of Economic Research, Inc

59) Greenwood, Jeremy, i Bojan Jovanović.“ Financial Development, growth and Distribution of Income.“ *Jurnal of Political Economy No 98, part 1,* 1997:1076.-1107.

60) Grossman, G.M. & Helpman, E.,“Inovation and growth in Global Economie“, Camridge, MIT Press, 1991.

61) Grossman, G.M. & Helpman, E., "Endogenous, Innovation in the Theory of Growth," Papers 165, Princeton, Woodrow Wilson School - Public and International Affairs,1993.

62) Haas, R.T.A. de. „Financial Development and economic Growth in Transition Countries.“ *Netherlands Central Bank, Directorate supervision no 35,* 2001.

63) Hadžiahmetović, A.,“ Ekonomija Evrope“, Sarajevo, 2005.

64) Hamid Ali Shah, S. i Shah, A., „ The assosiation between financial development and economic development: A review“, African Journal of Business Management, Vol. 5., pp.13428.-13434., 2011.

65) Hartmann, Philipp i sur., „ The Performance of The European Financial System“, ECB and CEPR, 2006.

66) Helpman, El., „The Mistery of Economic Growth“, Academic Fundation,New Delhi, 2005

67) Heinz, D. Kurz & Slavadori, N., „ Theorise of Economic Growth – Old and New“, Jurnal of Political Economy No 102, 2005.

68) Howitt, P. (2000). “Endogenous growth and cross-country income differences”. American Economic Review 90, 829–846.

69) Huang, Ho-Chuan, i Shu-Chin Lin. „Non-linear finance-growth nexus: a treshold with instrumental variable approach.“ *Economic of Transition Volume* 17(3), 2009.:439.-446.

70) Hurlin, C., i Venet, B., „ Financial development adn growth: A re-examination using a panel Granger causality test.“, Working paper Halshs, 2008., 00319995_vl.

71) Japelli, Tullio, i Marco Pagano. „ Saving, growth and Liquidity Constraints.“*Quarrterly Journal of economics,* 1994.,1. izd.:83.-109.

72) Jeanneney, S. G., Hua, P., & Liang, Z. (2006). Financial development, economic efficiency, and productivity growth: evidence from China. Developing Economies, 44, 27-52.

73) José, De Gregorio.“ Financial Integration, Financial Development and Economic Growth.“, Estudios de Economia, Vol.26-No.2, Diciembre 1999. Págs.137-161.

74) Kagochi, J. M., Al Nasser, O. M., & Kebede, E. (2013). Does financial development hold the key to economic growth? The case of Sub-Saharan Africa. Journal of Developing Areas, 47(2), 61-79.

75) Karima, S. i Kenneth, H., „ Does Financial Development Affect Growth?“, Journal of Applied Economics, Warwick University, 2007.

76) King, Robert, i Ross Levine. „Finance, Entrepreneurship and Economic Development.“ Jurnal of Monetary Economics, 1993.,3 izd.:717-738.

77) King, R. i Levine, R. „ Financial Indicators and Growth in Cross Section of Countries“, The World Bank, 1992.

78) King, R. i Levine, R. „Finance and Growth: Schumpeter Might Be Right.“ *Quarterly Journal of Economics, vol 108,* 1993.b:717.738.

79) Kortum, S. (1997). “Research, patenting, and technological change”. Econometrica 65, 1389–1419.

80) Koivu, Tuuli. „ Do eficient banking sector accelerate economic growth in transition countries? BOFIT *Discussion Papers No*.14, 2002.

81) Koivu, T., „ Does fianncial sector development afect economic growth in transition countries?“, BOFIT seminar, 2002.

82) Krueger, Anne, O., „ The Crucial Role of Financial Intermediation for Rapid Growth“, 3th International Derivatives and Financial Market Conference, Brazil, 2007.

83) La Porta, R., Lopez-de-Silanes, F. I Shleifer, A., „Guvernment ownership of comercial banks. Journal of Finance, 2002., 57(1), 265.-301.

84) Lederman, D., Saenz, L. (2003). “Innovation around the world: a cross-country data base of innovation indicators”.Unpublished paper. Office of the Chief Economist for LCR, The World Bank, Washington, DC

85) Levine, Ross., Finance and Growth: Theory and Evidnece.“ U Handbook of Economic Growth, autor philipe Aghion i Steven Durlauf. The Netherlands Elsevier science, 2005.

86) Levine, Ross, i Sarah Zervos.“Stock Markets, Banks and Economic Growth.“ *World Bank Policy Research Working Paper, No 1690.*, 1996.

87) Levine, Ross, Loayza, Norman, i Beck, Thorsten.“Financial Intermediation and Growth:Causality and Couses.“ *World Bank Policy Research Working Paper 2059.,* February 1999.

88) Loayza, N. I Ranciere, R. , „Financial Fragility, Financial Development, and Growt.“ Banco Central de Chile, 2002., Working Paper, 145.

89) Madura, J., „Financial Institutions and Markets.“, Thomson, Mason, Ohio, 2008.

90) McLeod Darril, „ Three Models of Growth and development“ , Fordham University, 2009.

91) McClave T.J. et al. (2008). Statistics for Business and Economics. 10. izdanje. Upper Saddle River: Prentice-Hall International.

92) Mehl, Arnaud, Christina Vespro, i Adalbert Winkler. „The finance-growth nexus and financial sector enviroment: new evidence from Southeast Europe.“ *Financial Development, Integration and Stability in Central, Eastern and South-Eastern Europe.* Wien: austrian National Bank, 2005.

93) Mervar, A. „ ESEJ O NOVIJIM DOPRINOSIMA TEORIJI EKONOMSKOG RASTA“, Ekonomski pregled, 54(3-4)369-392, 2003.

94) Neimke, Markus. „ Financial Development and Economic Growth in Transition Countries.“ *IEE Working Papers 173,* 2003.

95) Newbold P. et al. (2007). Statistics for Business and Economics. 6th Ed. Upper Saddle River: Prentice-Hall International.

96) Odhiambo, N. W., „Financial development in Kenya: A dynamic test of the finance-led growth hypothesis.“ *Economic Issues,* 2008, 13(2), 21.-36.

97) Osinski, D., „ The Relationship Between Financial Development and Economic Growth in Transition Countries“, National University of Kyiv- Mohyla Academy, 2000.

98) Parente, S.L., Prescott, E.C. (2005). “A unified theory of the evolution of international income levels”. In: Aghion, P., Durlauf, S.N. (Eds.), Handbook of Economic Growth, vol. 1A. Elsevier, Amsterdam. This volume, Chapter 21.

99) Pagano, Marco.“ Financial Markets and Growth: An Overview.“*Europian Economic Review,* 1993.a:613.622.

100) Petrakos, D. i Arvanitidis, P., „ determinants of economic growth: the experts view“, Department of Planning and regional devepoment; department of economics, University of Thessaly, Greece

101) Pritchett, L. (1997). “Divergence, big time”. Journal of Economic Perspectives 11 (Summer), 3–17.

102) Pritchett, L. (2005). “Does learning to add up add up? The returns to schooling in aggregate data”. In: Handbook of Education Economics.

103) Prljača, N. i Muhić, B., „ Harrod-Domarov model rasta“, Ekonomski fakultet u Sarajevu, Univerzitet Sarajevo, 2009.

104) Rajan, Raugharm i Luigi Zingales.“ Financial Dependence and Growth.“ *The american Economic Review, Vol.88.* 1996.:559.-586.

105) Rioja, F. I Valev, N., „ Finance and the sources of growth at various stage of economic development.“ *Economic Inquiry,* 2004.a., 42(1), 127.-40.

106) Rioja, F. I Valev, N., „ does one size fit all?“, A reexamination of the finance and growth relationship. *Journal of Development Economics,* 2004.b., 74(2), 429.-47.

107) Rispens, K.E. Richard. „ Modern economic Growth Theories and a „Miracle“ of The East Azian Tigers“, Eramus University Amsterdam, 2009.

108) Rivera-Batiz, Luis A & Romer, Paul M, "Economic Integration and Endogenous Growth," The Quarterly Journal of Economics, MIT Press, vol. 106(2), pages 531-55,1991.

109) Roger Leroy Miller i David D. VanHoose. „ Moderni novac i bankarstvo“. MATE Zagreb, Zagreb, 1997.

110) Romer, M. Paul, „ Increasing returns and new development in theory of growth“, in W.A.Barnett, B. Cornet adn C. d'Aspermont (eds), *equilibrium Theory and Applications,* Cambridge, Cambridge University Press, 1991., 83.-110.

111) Romer, M. Paul, „ The origins of endogenus growth“, *journal of economic Perspectives,*1994., 3.-22.

112) Romer, M. Paul, „Economic Growth“, from *The Concise Encyclopedia of Economics, David R.Henderson, ed. Liberty Fund, Reprinted by premission of the copyright holder,* 2007.

113) Roussau, Peter, i Richard Sylla.“ Financial Systems, Economic Growth, and Globalization.“ *NBER Working Paper, No.8323,* 2001.

114) Rousseau, P., i Wachtel, P., „Inflation thresholds and the finance-growth nexus, journal of International Money and Finance“, 21(6), 2002.a., 777.-793.

115) Rousseau, P., i Wachtel, P., „Financial intermediation and economic perfomance:historical evidence from five industrialized countries.“ *Journal of Money, Credit and Banking,* 2002.b., 30(4), 657.-658.

116) Rousseau, P., i Wachtel, P.,“What is happening to the impact of financial deeping on economic growth?“, Department of economics, Vanderbilt University, 2009., Working Paper No.09-W15.

117) Saber, A. Mahmud, „ Economic Growth“, Johns Hopkins University, 2011.

118) Sahay, R. and others, „Rethinking Financial Deepening, Stability and Growth in Emerging Markets”, IMF Stuff Discussion note, May 2015

119) Salvadori, N.“the Theory of Economic Growth: A classical Perpective“, university of Pisa, Italy.

120) Sala-i-Martin, X., „Lecture notes od economic growth(II)“, Fife prototype models of endogenus growth, NBER working paper, 1990., p. 3564.

121) Shan, J., „ Does financial development lead economic growth?“ A vector auto-regression appraisal, *Applied Economics*, 2005., 37(12), 1353.-1367.

122) Shan, J., Morris, A., Sun, F., „The direction of causality between financial development and economic growth. An egg-and-chicken problem?*Review of International Economic,* 2001., 9(3), 443.-454.

123) Shen, C. H., Lee, C. C., 2006. Same financial development yet different economic growth – why? Journal of Money, Credit and Banking 38(7), 1907–1944.

124) Sinha, D., & Macri, J. (2001). Financial development and economic growth: The case of eight Asian countries, Economia Internazionale, 54(2), 219-234

125) Solow, M. Robert, „A contribution to the Theory of Economic Growth“, *The Quarterly Journal of Economics,* Vol.70, No 1. (Feb., 1956), pp.65-94.

126) Solow, M. Robert, „The Neoclassical theory of growth and distribution“, *Banca Nacionale del Lavoro Quarterly Review,* 2000.a, 53.

127) Šonje(ur.), Velmir. „*Veza koja nedostaje-kako povezati razvitak tržišta kapitala i gospodarski rast“.* Arhivanalitika Zagreb, 2005.

128) Šonje, Velimir.“Financijski razvitak i gospodarski rast.“ *Privredna kretanja i ekonomska politika* br.73, 1999.:241-280

129) Šošić, I. (2006). Primijenjena statistika. II. izdanje. Zagreb: Školska knjiga.

130) Thorsten, Beck, Demergüç- Kunt, A. I Levine R., “ A New Database on Financial Development and Structure.“, *World Bank Policy Research Working Paper,* June 1999.

131) Thorsten, Beck, Demergüç- Kunt, A. I Levine R., “ Financial Institutions and Markets across Countries and ower Time“, The World Bank, 2009.

132) The World Bank: Croatian´s EU Convergence Report: Reaching and Sustaining higher Rates of Economic Growth Financial Theori and Practise 33(3) 367-371, 2009.

133) World Bank, http://www.wds.worldbank.org/external/default/WDSContentServer/IW3P/IB/2008/04/24/000158349_20080424160616/Rendered/PDF/WPS4608.pdf.

134) Zhang, J., Wang, L., & Wang, S. (2012). Financial development and economic growth: Recent evidence from China. Journal of Comparative Economics, 40, 393-412.

Web izvori:

IMF, WEO Database: http://www.imf.org

IMF, IFC Database: http://www.imf.org

IMF, Financial Survey Database: http://www.imf.org

WB, WDI Database: http://data.worldbank.org/

EBRD, EBRD Transition Databese: http://ebrd.com

Centralne Banke Odabranih zemalja:

Centralna banka Albanije: http://www.bankofalbania.org/

Centralna Banka Austrije: http://www.oenb.at

Centralna Banka Bosne i Hercegovine: http://www.cbbih.ba

Bugarska Narodna Banka: http://www.bnb.bg

Hrvatska Narodna Banka: http://www.hnb.hr

Češka Narodna Banka: http://cnb.cz

Njemačka Centralna Banka: http://bundesbank.de

Grčka Centralna Banka: http://www.bankofgreece.gr

Mađarska Centralna Banka: http://www.mnb.hu/

Centralna Banka Italije: http://www.bancaditalia.it/

Narodna Banka Makedonije: http://www.nbrm.gov.mk/

Centralna Banka Crne Gore: http://www.cb-mn.org/

Poljska Narodna Banka: http://www.nbp.pl/

Narodna Banka Rumunije: http://www.bnro.ro/Home.aspx

Narodna Banka Srbije: http://nbs.rs

Narodna Banka Slovačke: http://www.nbs.sk/sk/titulna-stranka

Centralna Banka Slovenije: http://www.bsi.si/

Europska Centralna Banka: http://www.ecb.int

VIII. POPIS TABLICA

1. Tablica 2.1. Pregled osnovnih grupa modela endogenog rasta.....54
2. Tablica 2.2. Prikaz bankarskoga sustava u prvom desetljeću tranzicije.....88
3. Tablica 2.3. Prikaz bankarskoga sustava u drugom desetljeću tranzicije.....89
4. Tablica 3.1. Prikaz odabranih dosadašnjih istraživanja o utjecaju financijskog sustava na gospodarski rast……..102
5. Tablica 5.1. Odabrane zemlje središnje, istočne i jugoistočne Europe.....154
6. Tablica 5.2. Korelacijska matrica za odabran skup varijabli za prvu pomoćnu Hipotezu.....164
7. Tablica 5.3. A. Procijenjeni panel-modeli s fiksnim efektom za cijelo razdoblje promatranja.....172
8. Tablica 5.4. B. Procijenjeni panel-modeli s fiksnim efektom za razdoblje prije krize.....173
9. Tablica 5.5. A. Procijenjeni panel-modeli sa slučajnim efektom za cijelo razdoblje promatranja.....176
10. Tablica 5.6. B. Procijenjeni panel-modeli sa slučajnim efektom za razdoblje prije krize.....177
11. Tablica 5.7.A. Procijenjeni dinamički panel-modeli za cijelo razdoblje promatranja (sustav *GMM*- procjenitelj).....179
12. Tablica 5.8.B. Procijenjeni dinamički panel-modeli za razdoblje prije krize (sustav *GMM*-procjenitelj).....180
13. Tablica 5.9. Korelacijska matrica za odabrani skup nezavisnih varijabli za drugu pomoćnu hipotezu.....182
14. Tablica 5.9.A. Procijenjeni dinamički panel modeli za cijelo razdoblje promatranja (sistem GMM procjenitelj).....184
15. Tablica 5.10.B. Procijenjeni dinamički panel modeli za razdoblje prije krize (sistem GMM procjenitelj).....186

IX. POPIS GRAFIKONA

1. Grafički prikaz 2.1. Prikaz bankarskih kredita kao udio u BDP-u promatranim zemljama 1996. i 2011. Godine.....70
2. Grafički prikaz 2.2. Usporedba udjela aktive stranih banaka u ukupnoj aktivi bankarskog sektora u 1996. i 2011.godini.....92
3. Grafički prikaz 2.3. Usporedba provedbe reformi bankarskoga sektora u 1996. i 2011. Godini.....94
4. Grafički prikaz 2.4. Usporedba provedbe restrukture financijskoga sustava u 1996. i 2011. Godini.....94
5. Grafički prikaz 2.5. Odabrane zemalje za 1996. i 2011. god. krediti privatnom sektoru/BDP u %.....96

X. POPIS SLIKA

1. Slika 2.1. Financijski sustav i optjecaj sredstava.....14
2. Slika 2.2. Teoretski pristup financijskom sustavu i gospodarskom rastu.....64
3. Slika 5.1. Prikaz modela istraživanja i hipoteza.....128
4. Slika 5.2. Protokol empirijskog istraživanja.....131
5. Slika 6.1. Rekapitulacija operacionaliziranog istraživačkog modela.....199

XI. PRILOG 1

Panel analiza empirijskog istraživanja (Ispis iz programa statističke analize)

Rezultati za prvu pomoćnu hipotezu

```
gretl console: type 'help' for a list of commands
? corr interest money bankcred cbagdp dbagdp pcrdba privcred inslife insnonlife
'pcrdba' is not the name of a variable
? corr interest money bankcred cbagdp dbagdp pcrddba privcred inslife insnonlife

Correlation Coefficients, using the observations 1:01 - 17:16
(missing values were skipped)

      interest         money      bankcred        cbagdp        dbagdp
        1.0000       -0.0499       -0.0305        0.1136       -0.0777  interest
                      1.0000        0.7200        0.0772        0.5224  money
                                    1.0000       -0.0211        0.9305  bankcred
                                                  1.0000       -0.1785  cbagdp
                                                                1.0000  dbagdp

       pcrddba      privcred       inslife    insnonlife
       -0.0452       -0.0971       -0.1400        0.6406  interest
       -0.3939        0.4849        0.3656        0.0160  money
        0.1154        0.9354        0.7580        0.2630  bankcred
       -0.4637       -0.2967       -0.1607       -0.2606  cbagdp
        0.3270        0.9085        0.7497        0.2472  dbagdp
        1.0000        0.2888        0.1418        0.2760  pcrddba
                      1.0000        0.7566        0.3501  privcred
                                    1.0000        0.2908  inslife
                                                  1.0000  insnonlife

? corr interest money bankcred cbagdp dbagdp pcrddba privcred inslife insnonlife
growth

Correlation Coefficients, using the observations 1:01 - 17:16
(missing values were skipped)

      interest         money      bankcred        cbagdp        dbagdp
        1.0000       -0.0499       -0.0305        0.1136       -0.0777  interest
                      1.0000        0.7200        0.0772        0.5224  money
                                    1.0000       -0.0211        0.9305  bankcred
                                                  1.0000       -0.1785  cbagdp
                                                                1.0000  dbagdp

       pcrddba      privcred       inslife    insnonlife        growth
       -0.0452       -0.0971       -0.1400        0.6406       -0.2201  interest
       -0.3939        0.4849        0.3656        0.0160       -0.1633  money
        0.1154        0.9354        0.7580        0.2630       -0.3160  bankcred
       -0.4637       -0.2967       -0.1607       -0.2606        0.0266  cbagdp
        0.3270        0.9085        0.7497        0.2472       -0.3200  dbagdp
        1.0000        0.2888        0.1418        0.2760       -0.0092  pcrddba
                      1.0000        0.7566        0.3501       -0.1795  privcred
                                    1.0000        0.2908       -0.2534  inslife
                                                  1.0000       -0.2469  insnonlife
                                                                1.0000  growth

? smpl kriza=0 --restrict
```

```
Full data set: 272 observations
Current sample: 1:01 - 17:12 (n = 204)

? corr interest money bankcred cbagdp dbagdp pcrddba privcred inslife insnonlife
growth

Correlation Coefficients, using the observations 1:01 - 17:12
(missing values were skipped)

      interest         money      bankcred        cbagdp        dbagdp
        1.0000       -0.0130       -0.0140        0.1000       -0.0803  interest
                      1.0000        0.6881        0.1267        0.6967  money
                                    1.0000       -0.0041        0.9574  bankcred
                                                  1.0000       -0.1918  cbagdp
                                                                1.0000  dbagdp

       pcrddba      privcred       inslife    insnonlife        growth
       -0.0762       -0.0738       -0.1505        0.6558       -0.3227  interest
       -0.3465        0.3984        0.4236        0.0487       -0.1027  money
        0.1287        0.9259        0.7728        0.2730       -0.2319  bankcred
       -0.5190       -0.3041       -0.1861       -0.2695       -0.0446  cbagdp
        0.2002        0.9526        0.8066        0.2486       -0.2666  dbagdp
        1.0000        0.4262        0.2767        0.3959       -0.0761  pcrddba
                      1.0000        0.8007        0.3671       -0.0747  privcred
                                    1.0000        0.2698       -0.2669  inslife
                                                  1.0000       -0.3220  insnonlife
                                                                1.0000  growth

? smpl full
Full data range: 1:01 - 17:16 (n = 272)

? panel growth interest money bankcred pcrddba insnonlife
You must include a constant in this sort of model
? panel 0 growth interest money bankcred pcrddba insnonlife
You must include a constant in this sort of model
? panel growth 0 interest money bankcred pcrddba insnonlife

Model 4: Fixed-effects, using 155 observations
Included 12 cross-sectional units
Time-series length: minimum 3, maximum 16
Dependent variable: growth

               coefficient   std. error   t-ratio   p-value
  -------------------------------------------------------
  const         3.97033      1.74735       2.272    0.0246  **
  interest     −0.0698021    0.0260846    −2.676    0.0084  ***
  money         0.0393671    0.0419031     0.9395   0.3491
  bankcred     −0.117506     0.0341434    −3.442    0.0008  ***
  pcrddba       0.0346246    0.0127991     2.705    0.0077  ***
  insnonlife    0.788119     0.645532      1.221    0.2242

Mean dependent var   3.381660   S.D. dependent var   3.703408
Sum squared resid    1390.512   S.E. of regression   3.174299
R-squared            0.341659   Adjusted R-squared   0.265330
F(16, 138)           4.476118   P-value(F)           4.34e-07
Log-likelihood      −389.9706   Akaike criterion     813.9412
Schwarz criterion    865.6795   Hannan-Quinn         834.9562
rho                  0.096881   Durbin-Watson        1.688182
```

```
Test for differing group intercepts -
  Null hypothesis: The groups have a common intercept
  Test statistic: F(11, 138) = 2.89064
  with p-value = P(F(11, 138) > 2.89064) = 0.00188114

? panel growth 0 interest money bankcred pcrddba inslife

Model 5: Fixed-effects, using 150 observations
Included 12 cross-sectional units
Time-series length: minimum 3, maximum 16
Dependent variable: growth

             coefficient   std. error   t-ratio   p-value
  -----------------------------------------------------
  const       3.82363      1.69930       2.250    0.0261  **
  interest   -0.0439500    0.0147414    -2.981    0.0034  ***
  money       0.0149529    0.0406540     0.3678   0.7136
  bankcred   -0.0907878    0.0298017    -3.046    0.0028  ***
  pcrddba     0.0442586    0.0132242     3.347    0.0011  ***
  inslife     0.715112     1.27641       0.5603   0.5762

Mean dependent var   3.390003   S.D. dependent var   3.694156
Sum squared resid    1341.437   S.E. of regression   3.175845
R-squared            0.340289   Adjusted R-squared   0.260926
F(16, 133)           4.287719   P-value(F)           1.09e-06
Log-likelihood      -377.1554   Akaike criterion     788.3108
Schwarz criterion    839.4916   Hannan-Quinn         809.1039
rho                  0.108875   Durbin-Watson        1.661489

Test for differing group intercepts -
  Null hypothesis: The groups have a common intercept
  Test statistic: F(11, 133) = 2.42469
  with p-value = P(F(11, 133) > 2.42469) = 0.00877894

? panel growth 0 interest money bankcred pcrddba insnonlife privcred

Model 6: Fixed-effects, using 155 observations
Included 12 cross-sectional units
Time-series length: minimum 3, maximum 16
Dependent variable: growth

               coefficient   std. error   t-ratio   p-value
  -----------------------------------------------------
  const         3.43626      1.94181       1.770    0.0790  *
  interest     -0.0740995    0.0269990    -2.745    0.0069  ***
  money         0.0469203    0.0436385     1.075    0.2842
  bankcred     -0.0912200    0.0536339    -1.701    0.0913  *
  pcrddba       0.0367415    0.0132510     2.773    0.0063  ***
  insnonlife    0.756657     0.648814      1.166    0.2456
  privcred     -0.0307603    0.0483319    -0.6364   0.5256

Mean dependent var   3.381660   S.D. dependent var   3.703408
Sum squared resid    1386.413   S.E. of regression   3.181163
R-squared            0.343600   Adjusted R-squared   0.262149
F(17, 137)           4.218481   P-value(F)           8.09e-07
Log-likelihood      -389.7418   Akaike criterion     815.4837
Schwarz criterion    870.2653   Hannan-Quinn         837.7347
rho                  0.099888   Durbin-Watson        1.681472
```

```
Test for differing group intercepts -
  Null hypothesis: The groups have a common intercept
  Test statistic: F(11, 137) = 1.69985
  with p-value = P(F(11, 137) > 1.69985) = 0.0794509

? panel growth 0 interest money bankcred pcrddba insnonlife open1

Model 7: Fixed-effects, using 155 observations
Included 12 cross-sectional units
Time-series length: minimum 3, maximum 16
Dependent variable: growth

               coefficient   std. error   t-ratio   p-value
  -------------------------------------------------------
  const        −1.18379      2.11242      −0.5604   0.5761
  interest     −0.0514413    0.0252358    −2.038    0.0434  **
  money        −0.0499045    0.0458058    −1.089    0.2779
  bankcred     −0.0776170    0.0340008    −2.283    0.0240  **
  pcrddba       0.0352933    0.0121721     2.900    0.0044  ***
  insnonlife    0.364044     0.623160      0.5842   0.5601
  open1         0.0823674    0.0208455     3.951    0.0001  ***

Mean dependent var   3.381660   S.D. dependent var   3.703408
Sum squared resid    1248.256   S.E. of regression   3.018502
R-squared            0.409011   Adjusted R-squared   0.335676
F(17, 137)           5.577333   P-value(F)           2.13e-09
Log-likelihood      −381.6065   Akaike criterion     799.2129
Schwarz criterion    853.9946   Hannan-Quinn         821.4640
rho                  0.117564   Durbin-Watson        1.619763

Test for differing group intercepts -
  Null hypothesis: The groups have a common intercept
  Test statistic: F(11, 137) = 4.49198
  with p-value = P(F(11, 137) > 4.49198) = 8.77076e-006

? panel growth 0 interest money bankcred pcrddba insnonlife open1 risk1

Model 8: Fixed-effects, using 97 observations
Included 8 cross-sectional units
Time-series length: minimum 3, maximum 16
Dependent variable: growth

               coefficient   std. error   t-ratio   p-value
  -------------------------------------------------------
  const         7.34206      2.68757       2.732    0.0077  ***
  interest     −0.197226     0.0657949    −2.998    0.0036  ***
  money        −0.0864753    0.0800007    −1.081    0.2829
  bankcred     −0.100435     0.0495130    −2.028    0.0458  **
  pcrddba       0.0218272    0.0128774     1.695    0.0939  *
  insnonlife    0.404077     1.26651       0.3190   0.7505
  open1         0.0427598    0.0269681     1.586    0.1167
  risk1         0.205908     0.0876128     2.350    0.0212  **

Mean dependent var   3.403177   S.D. dependent var   3.702472
Sum squared resid    648.5774   S.E. of regression   2.812380
R-squared            0.507159   Adjusted R-squared   0.423015
F(14, 82)            6.027296   P-value(F)           5.32e-08
Log-likelihood      −229.7905   Akaike criterion     489.5809
Schwarz criterion    528.2016   Hannan-Quinn         505.1972
```

```
rho                  0.160332   Durbin-Watson        1.473659

Test for differing group intercepts -
  Null hypothesis: The groups have a common intercept
  Test statistic: F(7, 82) = 2.58125
  with p-value = P(F(7, 82) > 2.58125) = 0.0186324

? panel growth 0 interest money bankcred pcrddba insnonlife open1 risk1 savings

Model 9: Fixed-effects, using 97 observations
Included 8 cross-sectional units
Time-series length: minimum 3, maximum 16
Dependent variable: growth

               coefficient   std. error   t-ratio   p-value
  -------------------------------------------------------
  const        −0.941018     3.93276      −0.2393   0.8115
  interest     −0.140099     0.0664524    −2.108    0.0381  **
  money        −0.0851342    0.0768783    −1.107    0.2714
  bankcred     −0.102764     0.0475869    −2.159    0.0338  **
  pcrddba       0.0300058    0.0127164     2.360    0.0207  **
  insnonlife    0.499922     1.21754       0.4106   0.6824
  open1         0.0683113    0.0274827     2.486    0.0150  **
  risk1         0.139827     0.0874534     1.599    0.1137
  savings       0.272069     0.0974193     2.793    0.0065  ***

Mean dependent var   3.403177   S.D. dependent var   3.702472
Sum squared resid    591.6110   S.E. of regression   2.702562
R-squared            0.550446   Adjusted R-squared   0.467196
F(15, 81)            6.611914   P-value(F)           5.42e-09
Log-likelihood      −225.3317   Akaike criterion     482.6635
Schwarz criterion    523.8589   Hannan-Quinn         499.3209
rho                  0.103260   Durbin-Watson        1.569183

Test for differing group intercepts -
  Null hypothesis: The groups have a common intercept
  Test statistic: F(7, 81) = 3.50054
  with p-value = P(F(7, 81) > 3.50054) = 0.00249209

? panel growth 0 interest money bankcred pcrddba insnonlife open1 risk1 savings --
rendom-effects
Invalid option '--rendom-effects'
? panel growth 0 interest money bankcred pcrddba insnonlife open1 risk1 savings --
random-effects
Insufficient degrees of freedom for regression
? panel growth 0 interest bankcred pcrddba open1 risk1 savings --rendom-effects
Invalid option '--rendom-effects'
? panel growth 0 interest bankcred pcrddba open1 risk1 savings --random-effects

Model 10: Random-effects (GLS), using 134 observations
Included 12 cross-sectional units
Time-series length: minimum 5, maximum 16
Dependent variable: growth

             coefficient   std. error   t-ratio   p-value
  -------------------------------------------------------
  const       6.42926      1.67590       3.836    0.0002   ***
  interest   −0.250596     0.0516240    −4.854    3.48e-06 ***
  bankcred   −0.0576653    0.00998058   −5.778    5.52e-08 ***
```

```
  pcrddba     0.0150915    0.0104320     1.447    0.1505
  open1      -0.0124523    0.00836588   -1.488    0.1391
  risk1       0.263042     0.0630336     4.173    5.53e-05 ***
  savings     0.0490529    0.0557611     0.8797   0.3807

Mean dependent var   3.158307   S.D. dependent var   3.616992
Sum squared resid    1224.655   S.E. of regression   3.093157
Log-likelihood      -338.3803   Akaike criterion     690.7606
Schwarz criterion    711.0454   Hannan-Quinn         699.0037

'Within' variance = 7.4542
'Between' variance = 0.640371

Breusch-Pagan test -
  Null hypothesis: Variance of the unit-specific error = 0
  Asymptotic test statistic: Chi-square(1) = 0.17106
  with p-value = 0.679171

Hausman test -
  Null hypothesis: GLS estimates are consistent
  Asymptotic test statistic: Chi-square(6) = 49.6669
  with p-value = 5.48222e-009

? smpl kriza=0 --restrict
Full data set: 272 observations
Current sample: 1:01 - 17:12 (n = 204)

? panel growth 0 interest bankcred pcrddba open1 risk1 savings --random-effects

Model 11: Random-effects (GLS), using 105 observations
Included 12 cross-sectional units
Time-series length: minimum 2, maximum 12
Dependent variable: growth

             coefficient   std. error   t-ratio   p-value
  -----------------------------------------------------
  const       5.81489      1.98986       2.922    0.0043   ***
  interest   -0.279762     0.0437663    -6.392    5.56e-09 ***
  bankcred   -0.0406012    0.0109929    -3.693    0.0004   ***
  pcrddba    -0.00898660   0.0158882    -0.5656   0.5729
  open1       0.0119982    0.0119172     1.007    0.3165
  risk1       0.282330     0.0539599     5.232    9.52e-07 ***
  savings     0.0586847    0.0612727     0.9578   0.3405

Mean dependent var   3.837413   S.D. dependent var   3.020474
Sum squared resid    498.9344   S.E. of regression   2.244937
Log-likelihood      -230.8105   Akaike criterion     475.6211
Schwarz criterion    494.1988   Hannan-Quinn         483.1492

'Within' variance = 3.30536
'Between' variance = 1.77677

Breusch-Pagan test -
  Null hypothesis: Variance of the unit-specific error = 0
  Asymptotic test statistic: Chi-square(1) = 0.184604
  with p-value = 0.667446

Hausman test -
  Null hypothesis: GLS estimates are consistent
```

```
  Asymptotic test statistic: Chi-square(6) = 24.9871
  with p-value = 0.000343339

? panel growth 0 interest bankcred pcrddba open1 risk1 savings

Model 12: Fixed-effects, using 105 observations
Included 12 cross-sectional units
Time-series length: minimum 2, maximum 12
Dependent variable: growth

             coefficient   std. error   t-ratio   p-value
  -------------------------------------------------------
  const      −1.66509      2.66537      −0.6247   0.5338
  interest   −0.268409     0.0486903    −5.513    3.56e-07 ***
  bankcred   −0.00600485   0.0189684    −0.3166   0.7523
  pcrddba    −0.0252562    0.0191138    −1.321    0.1898
  open1       0.0325374    0.0179564     1.812    0.0734   *
  risk1       0.253203     0.0587246     4.312    4.26e-05 ***
  savings     0.300005     0.0774467     3.874    0.0002   ***

Mean dependent var   3.837413   S.D. dependent var   3.020474
Sum squared resid    287.5667   S.E. of regression   1.818066
R-squared            0.696922   Adjusted R-squared   0.637699
F(17, 87)            11.76791   P-value(F)           5.57e-16
Log-likelihood      −201.8820   Akaike criterion     439.7640
Schwarz criterion    487.5353   Hannan-Quinn         459.1219
rho                  0.285706   Durbin-Watson        1.203678

Test for differing group intercepts -
  Null hypothesis: The groups have a common intercept
  Test statistic: F(11, 87) = 4.43536
  with p-value = P(F(11, 87) > 4.43536) = 2.78204e-005

? smpl full
Full data range: 1:01 - 17:16 (n = 272)

? panel growth 0 interest bankcred pcrddba open1 risk1 savings --between

Model 13: Between-groups, using 12 observations
Dependent variable: growth

             coefficient   std. error   t-ratio   p-value
  -------------------------------------------------------
  const       9.69252      1.99112       4.868    0.0046  ***
  interest   −0.269128     0.0881467    −3.053    0.0283  **
  bankcred   −0.0361397    0.0113271    −3.191    0.0243  **
  pcrddba    −0.0247813    0.0179212    −1.383    0.2253
  open1      −0.0121584    0.00943045   −1.289    0.2537
  risk1       0.292336     0.101743      2.873    0.0349  **
  savings    −0.0541917    0.0610290    −0.8880   0.4152

Mean dependent var   3.086833   S.D. dependent var   1.262416
Sum squared resid    3.201853   S.E. of regression   0.800232
R-squared            0.817357   Adjusted R-squared   0.598185
F(6, 5)              3.729292   P-value(F)           0.085057
Log-likelihood      −9.100200   Akaike criterion     32.20040
Schwarz criterion    35.59475   Hannan-Quinn         30.94369

? smpl kriza=0 --restrict
```

```
Full data set: 272 observations
Current sample: 1:01 - 17:12 (n = 204)

? panel growth 0 interest bankcred pcrddba open1 risk1 savings --between

Model 14: Between-groups, using 12 observations
Dependent variable: growth

             coefficient   std. error   t-ratio   p-value
  -----------------------------------------------------
  const      12.8278       2.95266       4.344    0.0074  ***
  interest   -0.314094     0.103440     -3.036    0.0289  **
  bankcred   -0.0437154    0.0185845    -2.352    0.0654  *
  pcrddba    -0.0164079    0.0279770    -0.5865   0.5830
  open1       0.00841790   0.0189327     0.4446   0.6752
  risk1       0.289315     0.120486      2.401    0.0615  *
  savings    -0.243384     0.0976720    -2.492    0.0550  *

Mean dependent var   4.168020   S.D. dependent var   2.258961
Sum squared resid    8.883840   S.E. of regression   1.332955
R-squared            0.841733   Adjusted R-squared   0.651813
F(6, 5)              4.432029   P-value(F)           0.061824
Log-likelihood      -15.22323   Akaike criterion     44.44645
Schwarz criterion    47.84080   Hannan-Quinn         43.18974

? smpl full
Full data range: 1:01 - 17:16 (n = 272)

? dpanel growth 0 interest bankcred pcrddba open1 risk1 savings --twoo-step
Invalid option '--twoo-step'
? dpanel 1 ; growth 0 interest bankcred pcrddba open1 risk1 savings --two-step

Model 15: 2-step dynamic panel, using 113 observations
Included 12 cross-sectional units
Time-series length: minimum 4, maximum 14
Dependent variable: growth

               coefficient   std. error      z      p-value
  -------------------------------------------------------
  growth(-1)   -0.437881     0.262764     -1.666    0.0956   *
  interest     -0.342820     0.719912     -0.4762   0.6339
  bankcred     -0.0652827    0.0568794    -1.148    0.2511
  pcrddba       0.0809082    0.0265253     3.050    0.0023   ***
  open1         0.134761     0.0332756     4.050    5.13e-05 ***
  risk1         0.328581     0.886531      0.3706   0.7109
  savings       0.582214     0.125587      4.636    3.55e-06 ***

Sum squared resid    1125.511   S.E. of regression   3.258532

Number of instruments = 84
Test for AR(1) errors: z = -0.583746 [0.5594]
Test for AR(2) errors: z = -1.32735 [0.1844]
Sargan over-identification test: Chi-square(77) = 3.14588 [1.0000]
Wald (joint) test: Chi-square(0) = NA

? smpl kriza=0 --restrict
Full data set: 272 observations
Current sample: 1:01 - 17:12 (n = 204)
```

```
? dpanel 1 ; growth 0 interest bankcred pcrddba open1 risk1 savings --two-step

Model 16: 2-step dynamic panel, using 84 observations
Included 12 cross-sectional units
Time-series length: minimum 1, maximum 10
Dependent variable: growth

               coefficient   std. error      z      p-value
  -------------------------------------------------------
  growth(-1)    0.0706958    0.339896      0.2080   0.8352
  interest     −0.0941664    0.172690     −0.5453   0.5856
  bankcred      0.0564698    0.0761145     0.7419   0.4581
  pcrddba       0.0128984    0.0754152     0.1710   0.8642
  open1         0.0193963    0.0209285     0.9268   0.3540
  risk1         0.0379596    0.219261      0.1731   0.8626
  savings       0.576931     0.184141      3.133    0.0017  ***

Sum squared resid    249.9533   S.E. of regression   1.801707

Number of instruments = 55
Test for AR(1) errors: z = -0.424076 [0.6715]
Test for AR(2) errors: z = 0.124764 [0.9007]
Sargan over-identification test: Chi-square(48) = 6.40735 [1.0000]
Wald (joint) test: Chi-square(0) = NA

? smpl full
Full data range: 1:01 - 17:16 (n = 272)

? dpanel 1 ; growth 0 interest bankcred pcrddba open1 risk1 savings --two-step
sy
? dpanel 1 ; growth 0 interest bankcred pcrddba open1 risk1 savings --system

Model 17: 1-step dynamic panel, using 125 observations
Included 12 cross-sectional units
Time-series length: minimum 4, maximum 14
Including equations in levels
Dependent variable: growth

               coefficient   std. error     z      p-value
  -------------------------------------------------------
  growth(-1)    0.236330     0.0882816     2.677   0.0074   ***
  const         3.97091      1.24282       3.195   0.0014   ***
  interest     −0.173942     0.0488633    −3.560   0.0004   ***
  bankcred     −0.0432491    0.0108153    −3.999   6.36e-05 ***
  pcrddba       0.0166000    0.0131302     1.264   0.2061
  open1        −0.00662578   0.00593440   −1.117   0.2642
  risk1         0.196803     0.0561184     3.507   0.0005   ***
  savings       0.0424811    0.0362656     1.171   0.2414

Sum squared resid    1113.416   S.E. of regression   4.377314

Number of instruments = 99
Test for AR(1) errors: z = -2.30245 [0.0213]
Test for AR(2) errors: z = 1.01418 [0.3105]
Sargan over-identification test: Chi-square(91) = 108.598 [0.1007]
Wald (joint) test: Chi-square(7) = 127.28 [0.0000]

? smpl kriza=0 --restrict
Full data set: 272 observations
```

```
Current sample: 1:01 - 17:12 (n = 204)

? dpanel 1 ; growth 0 interest bankcred pcrddba open1 risk1 savings --system

Model 18: 1-step dynamic panel, using 96 observations
Included 12 cross-sectional units
Time-series length: minimum 1, maximum 10
Including equations in levels
Dependent variable: growth

               coefficient   std. error      z       p-value
  -----------------------------------------------------------
  growth(-1)    0.496554     0.0806620     6.156    7.46e-010 ***
  const         3.71644      1.34793       2.757    0.0058    ***
  interest     −0.127962     0.0585036    −2.187    0.0287    **
  bankcred     −0.0236928    0.00756993   −3.130    0.0017    ***
  pcrddba       0.00313888   0.00912454    0.3440   0.7308
  open1         0.00201539   0.00708782    0.2843   0.7761
  risk1         0.157873     0.0674214     2.342    0.0192    **
  savings      −0.0226372    0.0498147    −0.4544   0.6495

Sum squared resid    323.6475   S.E. of regression   2.525213

Number of instruments = 66
Test for AR(1) errors: z = -1.74619 [0.0808]
Test for AR(2) errors: z = 0.395738 [0.6923]
Sargan over-identification test: Chi-square(58) = 70.9269 [0.1186]
Wald (joint) test: Chi-square(7) = 369.082 [0.0000]

? dpanel 1 ; growth 0 interest bankcred pcrddba open1 risk1 savings cbagdp --
system

Model 19: 1-step dynamic panel, using 95 observations
Included 12 cross-sectional units
Time-series length: minimum 1, maximum 10
Including equations in levels
Dependent variable: growth

               coefficient   std. error      z       p-value
  -----------------------------------------------------------
  growth(-1)    0.539448     0.0385298    14.00     1.54e-044 ***
  const         3.29767      1.30342       2.530    0.0114    **
  interest     −0.0410798    0.0394081    −1.042    0.2972
  bankcred     −0.0187352    0.00590384   −3.173    0.0015    ***
  pcrddba      −0.00295152   0.00889569   −0.3318   0.7400
  open1         0.00615638   0.00806319    0.7635   0.4452
  risk1         0.0561808    0.0459322     1.223    0.2213
  savings      −0.0296374    0.0542596    −0.5462   0.5849
  cbagdp        0.0132550    0.0153723     0.8623   0.3885

Sum squared resid    262.7021   S.E. of regression   2.477610

Number of instruments = 67
Test for AR(1) errors: z = -2.10356 [0.0354]
Test for AR(2) errors: z = 0.437601 [0.6617]
Sargan over-identification test: Chi-square(58) = 67.4744 [0.1849]
Wald (joint) test: Chi-square(8) = 1865.53 [0.0000]

? dpanel 1 ; growth 0 interest bankcred pcrddba open1 risk1 savings money --system
```

```
Model 20: 1-step dynamic panel, using 69 observations
Included 9 cross-sectional units
Time-series length: minimum 1, maximum 10
Including equations in levels
Dependent variable: growth

               coefficient   std. error      z       p-value
  ---------------------------------------------------------
  growth(-1)    0.415038     0.0906071     4.581     4.64e-06 ***
  const         5.27562      1.78776       2.951     0.0032   ***
  interest     −0.167427     0.0619007    −2.705     0.0068   ***
  bankcred     −0.0396488    0.0143597    −2.761     0.0058   ***
  pcrddba       0.00111134   0.0133040     0.08353   0.9334
  open1         0.00194788   0.00759910    0.2563    0.7977
  risk1         0.199056     0.0701929     2.836     0.0046   ***
  savings      −0.0259170    0.0721496    −0.3592    0.7194
  money        −0.00417293   0.0180152    −0.2316    0.8168

Sum squared resid    271.0874   S.E. of regression   2.805029

Number of instruments = 63
Test for AR(1) errors: z = -1.61864 [0.1055]
Test for AR(2) errors: z = 0.298523 [0.7653]
Sargan over-identification test: Chi-square(54) = 60.3036 [0.2585]
Wald (joint) test: Chi-square(8) = 311875 [0.0000]

? dpanel 1 ; growth 0 interest bankcred pcrddba open1 risk1 --system

Model 21: 1-step dynamic panel, using 96 observations
Included 12 cross-sectional units
Time-series length: minimum 1, maximum 10
Including equations in levels
Dependent variable: growth

               coefficient   std. error      z      p-value
  ---------------------------------------------------------
  growth(-1)    0.500689     0.0836533     5.985    2.16e-09 ***
  const         3.23452      1.11685       2.896    0.0038   ***
  interest     −0.124605     0.0570733    −2.183    0.0290   **
  bankcred     −0.0243963    0.00734751   −3.320    0.0009   ***
  pcrddba       0.00510391   0.00882328    0.5785   0.5630
  open1         0.00113783   0.00640536    0.1776   0.8590
  risk1         0.154473     0.0655319     2.357    0.0184   **

Sum squared resid    326.0632   S.E. of regression   2.498907

Number of instruments = 65
Test for AR(1) errors: z = -1.77141 [0.0765]
Test for AR(2) errors: z = 0.41486 [0.6782]
Sargan over-identification test: Chi-square(58) = 72.167 [0.0999]
Wald (joint) test: Chi-square(6) = 285.677 [0.0000]

? dpanel 1 ; growth 0 interest bankcred pcrddba open1 risk1 infl --system

Model 22: 1-step dynamic panel, using 96 observations
Included 12 cross-sectional units
Time-series length: minimum 1, maximum 10
Including equations in levels
```

```
Dependent variable: growth

               coefficient   std. error      z       p-value
  ---------------------------------------------------------
  growth(-1)    0.418135     0.0582207     7.182    6.88e-013 ***
  const         0.869213     1.08011       0.8047   0.4210
  interest      0.104371     0.0659841     1.582    0.1137
  bankcred     -0.0192244    0.00376010   -5.113    3.18e-07  ***
  pcrddba       0.00489060   0.00538474    0.9082   0.3638
  open1         0.0135607    0.00547157    2.478    0.0132    **
  risk1         0.176603     0.0421644     4.188    2.81e-05  ***
  infl         -0.0385590    0.0115932    -3.326    0.0009    ***

Sum squared resid    272.0921   S.E. of regression   2.421378

Number of instruments = 66
Test for AR(1) errors: z = -2.00196 [0.0453]
Test for AR(2) errors: z = -0.0455406 [0.9637]
Sargan over-identification test: Chi-square(58) = 71.1348 [0.1153]
Wald (joint) test: Chi-square(7) = 1329.41 [0.0000]

? dpanel 1 ; growth 0 interest bankcred pcrddba open1 risk1 inslife --system

Model 23: 1-step dynamic panel, using 90 observations
Included 11 cross-sectional units
Time-series length: minimum 4, maximum 10
Including equations in levels
Dependent variable: growth

               coefficient   std. error      z      p-value
  ---------------------------------------------------------
  growth(-1)    0.362711     0.111902      3.241    0.0012   ***
  const         2.33457      0.838419      2.784    0.0054   ***
  interest     -0.0940998    0.0232844    -4.041    5.32e-05 ***
  bankcred     -0.0115652    0.00624098   -1.853    0.0639   *
  pcrddba       0.0168287    0.00866959    1.941    0.0522   *
  open1         0.00334834   0.00397961    0.8414   0.4001
  risk1         0.209983     0.130786      1.606    0.1084
  inslife      -0.656597     0.202581     -3.241    0.0012   ***

Sum squared resid    250.9233   S.E. of regression   2.377196

Number of instruments = 65
Test for AR(1) errors: z = -1.8734 [0.0610]
Test for AR(2) errors: z = -0.0708284 [0.9435]
Sargan over-identification test: Chi-square(57) = 73.0182 [0.0749]
Wald (joint) test: Chi-square(7) = 11942.4 [0.0000]

? dpanel 1 ; growth 0 interest bankcred pcrddba open1 risk1 insnonlife --system

Model 24: 1-step dynamic panel, using 93 observations
Included 11 cross-sectional units
Time-series length: minimum 4, maximum 10
Including equations in levels
Dependent variable: growth

               coefficient   std. error      z      p-value
  ---------------------------------------------------------
  growth(-1)    0.434593     0.0998772     4.351    1.35e-05 ***
```

```
  const         2.59242      0.816349      3.176    0.0015   ***
  interest     -0.0707410    0.0178073    -3.973    7.11e-05 ***
  bankcred     -0.0217293    0.00551432   -3.941    8.13e-05 ***
  pcrddba       0.00875730   0.0119376     0.7336   0.4632
  open1         0.00492936   0.00505381    0.9754   0.3294
  risk1         0.191000     0.125496      1.522    0.1280
  insnonlife   -0.275100     0.331048     -0.8310   0.4060

Sum squared resid    292.1623   S.E. of regression   2.442851

Number of instruments = 65
Test for AR(1) errors: z = -1.76614 [0.0774]
Test for AR(2) errors: z = -0.0657663 [0.9476]
Sargan over-identification test: Chi-square(57) = 68.8247 [0.1356]
Wald (joint) test: Chi-square(7) = 1120.3 [0.0000]

? dpanel 1 ; growth 0 interest bankcred pcrddba open1 risk1 bankref --system

Model 25: 1-step dynamic panel, using 96 observations
Included 12 cross-sectional units
Time-series length: minimum 1, maximum 10
Including equations in levels
Dependent variable: growth

              coefficient   std. error      z      p-value
  -----------------------------------------------------------
  growth(-1)    0.460472     0.0782636     5.884    4.01e-09 ***
  const         4.53108      1.12595       4.024    5.72e-05 ***
  interest     -0.138982     0.0552986    -2.513    0.0120   **
  bankcred     -0.0150002    0.00870764   -1.723    0.0850   *
  pcrddba       0.00943913   0.0109116     0.8651   0.3870
  open1         0.00199345   0.00592598    0.3364   0.7366
  risk1         0.167152     0.0635045     2.632    0.0085   ***
  bankref      -0.542009     0.388871     -1.394    0.1634

Sum squared resid    315.2957   S.E. of regression   2.451477

Number of instruments = 66
Test for AR(1) errors: z = -1.76189 [0.0781]
Test for AR(2) errors: z = 0.422374 [0.6728]
Sargan over-identification test: Chi-square(58) = 72.5278 [0.0949]
Wald (joint) test: Chi-square(7) = 407.042 [0.0000]

? dpanel 1 ; growth 0 interest bankcred pcrddba open1 risk1 savings bankref
privcred --system

Model 26: 1-step dynamic panel, using 96 observations
Included 12 cross-sectional units
Time-series length: minimum 1, maximum 10
Including equations in levels
Dependent variable: growth

              coefficient   std. error      z       p-value
  ------------------------------------------------------------
  growth(-1)    0.455182     0.0778696     5.845     5.05e-09 ***
  const         3.62290      1.83805       1.971     0.0487   **
  interest     -0.140715     0.0546181    -2.576     0.0100   ***
  bankcred      0.00473881   0.0237678     0.1994    0.8420
  pcrddba       0.0231887    0.0231176     1.003     0.3158
```

```
  open1         0.00319498   0.00724836    0.4408    0.6594
  risk1         0.165963     0.0625648     2.653     0.0080   ***
  savings      -0.00141206   0.0512497    -0.02755   0.9780
  bankref      -0.578334     0.430701     -1.343     0.1793
  privcred     -0.0263032    0.0249194    -1.056     0.2912

Sum squared resid    311.0918   S.E. of regression   2.474049

Number of instruments = 68
Test for AR(1) errors: z = -1.73861 [0.0821]
Test for AR(2) errors: z = 0.380047 [0.7039]
Sargan over-identification test: Chi-square(58) = 74.3201 [0.0731]
Wald (joint) test: Chi-square(9) = 1018.56 [0.0000]

? dpanel 1 ; growth 0 interest bankcred pcrddba open1 risk1 savings privcred --
system

Model 27: 1-step dynamic panel, using 96 observations
Included 12 cross-sectional units
Time-series length: minimum 1, maximum 10
Including equations in levels
Dependent variable: growth

               coefficient   std. error      z      p-value
  -----------------------------------------------------------
  growth(-1)    0.493264     0.0831879     5.930    3.04e-09 ***
  const         3.15722      2.00720       1.573    0.1157
  interest     -0.130067     0.0602038    -2.160    0.0307   **
  bankcred     -0.0135773    0.0183281    -0.7408   0.4588
  pcrddba       0.0106881    0.0193029     0.5537   0.5798
  open1         0.00237415   0.00728268    0.3260   0.7444
  risk1         0.158038     0.0688288     2.296    0.0217   **
  savings      -0.0206804    0.0522171    -0.3960   0.6921
  privcred     -0.0142236    0.0252908    -0.5624   0.5738

Sum squared resid    322.6091   S.E. of regression   2.532986

Number of instruments = 67
Test for AR(1) errors: z = -1.72461 [0.0846]
Test for AR(2) errors: z = 0.36753 [0.7132]
Sargan over-identification test: Chi-square(58) = 71.4274 [0.1108]
Wald (joint) test: Chi-square(8) = 937.17 [0.0000]

? dpanel 1 ; growth 0 interest bankcred pcrddba open1 risk1 privcred --system

Model 28: 1-step dynamic panel, using 96 observations
Included 12 cross-sectional units
Time-series length: minimum 1, maximum 10
Including equations in levels
Dependent variable: growth

               coefficient   std. error      z      p-value
  -----------------------------------------------------------
  growth(-1)    0.496931     0.0870258     5.710    1.13e-08 ***
  const         2.65089      1.46139       1.814    0.0697   *
  interest     -0.127086     0.0586530    -2.167    0.0303   **
  bankcred     -0.0129804    0.0190727    -0.6806   0.4961
  pcrddba       0.0133500    0.0169939     0.7856   0.4321
  open1         0.00164462   0.00662185    0.2484   0.8039
```

```
  risk1         0.154815     0.0665417     2.327    0.0200   **
  privcred     -0.0159196    0.0247705    -0.6427   0.5204

Sum squared resid    324.6604   S.E. of regression   2.506661

Number of instruments = 66
Test for AR(1) errors: z = -1.74505 [0.0810]
Test for AR(2) errors: z = 0.384107 [0.7009]
Sargan over-identification test: Chi-square(58) = 72.8417 [0.0908]
Wald (joint) test: Chi-square(7) = 908.308 [0.0000]

? dpanel 1 ; growth 0 interest bankcred privcred open1 risk1 savings --system

Model 29: 1-step dynamic panel, using 96 observations
Included 12 cross-sectional units
Time-series length: minimum 1, maximum 10
Including equations in levels
Dependent variable: growth

               coefficient   std. error      z       p-value
  -----------------------------------------------------------
  growth(-1)    0.494371     0.0763503     6.475    9.48e-011 ***
  const         3.88751      1.30629       2.976    0.0029    ***
  interest     -0.127216     0.0582120    -2.185    0.0289    **
  bankcred     -0.0217289    0.0111675    -1.946    0.0517    *
  privcred     -0.00172482   0.0105844    -0.1630   0.8706
  open1         0.00326305   0.00612450    0.5328   0.5942
  risk1         0.156110     0.0679786     2.296    0.0216    **
  savings      -0.0273583    0.0459149    -0.5958   0.5513

Sum squared resid    323.4032   S.E. of regression   2.522029

Number of instruments = 66
Test for AR(1) errors: z = -1.7591 [0.0786]
Test for AR(2) errors: z = 0.389203 [0.6971]
Sargan over-identification test: Chi-square(58) = 71.2879 [0.1129]
Wald (joint) test: Chi-square(7) = 386.589 [0.0000]

? smpl full
Full data range: 1:01 - 17:16 (n = 272)

? dpanel 1 ; growth 0 interest bankcred privcred open1 risk1 savings --system

Model 30: 1-step dynamic panel, using 125 observations
Included 12 cross-sectional units
Time-series length: minimum 4, maximum 14
Including equations in levels
Dependent variable: growth

               coefficient    std. error      z       p-value
  ------------------------------------------------------------
  growth(-1)    0.243172      0.0608635     3.995     6.46e-05 ***
  const         4.78440       1.07898       4.434     9.24e-06 ***
  interest     -0.170448      0.0630221    -2.705     0.0068   ***
  bankcred      0.00173993    0.0108894     0.1598    0.8731
  privcred     -0.0530585     0.0119564    -4.438     9.09e-06 ***
  open1         0.00262875    0.00709543    0.3705    0.7110
  risk1         0.185718      0.0734359     2.529     0.0114   **
  savings      -0.000800204   0.0362954    -0.02205   0.9824
```

```
Sum squared resid    1089.862   S.E. of regression   4.437780

Number of instruments = 99
Test for AR(1) errors: z = -2.3875 [0.0170]
Test for AR(2) errors: z = 1.21835 [0.2231]
Sargan over-identification test: Chi-square(91) = 103.629 [0.1723]
Wald (joint) test: Chi-square(7) = 216.458 [0.0000]

? dpanel 1 ; growth 0 interest bankcred privcred open1 risk1 bankref --system

Model 31: 1-step dynamic panel, using 125 observations
Included 12 cross-sectional units
Time-series length: minimum 4, maximum 14
Including equations in levels
Dependent variable: growth

               coefficient   std. error      z       p-value
  -----------------------------------------------------------
  growth(-1)    0.243764     0.0610921     3.990     6.60e-05 ***
  const         4.75724      0.945319      5.032     4.84e-07 ***
  interest     -0.166168     0.0630734    -2.635     0.0084   ***
  bankcred      0.00132866   0.0122940     0.1081    0.9139
  privcred     -0.0521631    0.0114508    -4.555     5.23e-06 ***
  open1         0.00284710   0.00641636    0.4437    0.6572
  risk1         0.182865     0.0732661     2.496     0.0126   **
  bankref      -0.0122277    0.202569     -0.06036   0.9519

Sum squared resid    1090.047   S.E. of regression   4.439329

Number of instruments = 99
Test for AR(1) errors: z = -2.38378 [0.0171]
Test for AR(2) errors: z = 1.21164 [0.2257]
Sargan over-identification test: Chi-square(91) = 104.402 [0.1593]
Wald (joint) test: Chi-square(7) = 237.048 [0.0000]

? dpanel 1 ; growth 0 interest bankcred privcred open1 risk1 inslife --system

Model 32: 1-step dynamic panel, using 116 observations
Included 11 cross-sectional units
Time-series length: minimum 5, maximum 14
Including equations in levels
Dependent variable: growth

               coefficient   std. error      z      p-value
  ---------------------------------------------------------
  growth(-1)    0.251440     0.0706355     3.560    0.0004  ***
  const         3.41039      1.38128       2.469    0.0135  **
  interest     -0.0730701    0.0627992    -1.164    0.2446
  bankcred      0.00245415   0.00988681    0.2482   0.8040
  privcred     -0.0537597    0.0138794    -3.873    0.0001  ***
  open1         0.00545681   0.00761600    0.7165   0.4737
  risk1         0.226083     0.128217      1.763    0.0779  *
  inslife       0.264885     0.355223      0.7457   0.4559

Sum squared resid    935.6529   S.E. of regression   4.218129

Number of instruments = 95
Test for AR(1) errors: z = -2.11234 [0.0347]
```

```
Test for AR(2) errors: z = 1.20514 [0.2281]
Sargan over-identification test: Chi-square(87) = 100.822 [0.1476]
Wald (joint) test: Chi-square(7) = 704.47 [0.0000]

? dpanel 1 ; growth 0 interest bankcred privcred open1 risk1 insnonlife --system

Model 33: 1-step dynamic panel, using 119 observations
Included 11 cross-sectional units
Time-series length: minimum 5, maximum 14
Including equations in levels
Dependent variable: growth

               coefficient   std. error      z      p-value
  -------------------------------------------------------
  growth(-1)    0.241350     0.0720742     3.349    0.0008   ***
  const         2.30532      1.71841       1.342    0.1797
  interest     -0.0543869    0.0710876    -0.7651   0.4442
  bankcred      0.0243443    0.0127089     1.916    0.0554   *
  privcred     -0.0801027    0.0169700    -4.720    2.36e-06 ***
  open1         0.00481079   0.00643474    0.7476   0.4547
  risk1         0.208981     0.108747      1.922    0.0546   *
  insnonlife    0.847052     0.547015      1.549    0.1215

Sum squared resid    936.0518   S.E. of regression   4.183643

Number of instruments = 94
Test for AR(1) errors: z = -2.14427 [0.0320]
Test for AR(2) errors: z = 1.04951 [0.2939]
Sargan over-identification test: Chi-square(86) = 99.6106 [0.1497]
Wald (joint) test: Chi-square(7) = 967.749 [0.0000]

? smpl full
Full data range: 1:01 - 17:16 (n = 272)

? panel growth 0 concetration fba_tba fbno_tbno soebankshare
'concetration' is not the name of a variable
? panel growth 0 concentration fba_tba fbno_tbno soebankshare

Model 34: Fixed-effects, using 243 observations
Included 17 cross-sectional units
Time-series length: minimum 9, maximum 15
Dependent variable: growth

                  coefficient   std. error   t-ratio   p-value
  ---------------------------------------------------------
  const            6.22247      4.53749       1.371    0.1717
  concentration    0.00384596   0.0267296     0.1439   0.8857
  fba_tba         -0.0407095    0.0625381    -0.6510   0.5157
  fbno_tbno       -0.0155902    0.0582622    -0.2676   0.7893
  soebankshare    -0.0327562    0.0552696    -0.5927   0.5540

Mean dependent var   3.045297   S.D. dependent var   4.016413
Sum squared resid    3332.619   S.E. of regression   3.874506
R-squared            0.146323   Adjusted R-squared   0.069415
F(20, 222)           1.902572   P-value(F)           0.013372
Log-likelihood      -662.9440   Akaike criterion     1367.888
Schwarz criterion    1441.242   Hannan-Quinn         1397.434
rho                  0.268566   Durbin-Watson        1.185824
```

```
Test for differing group intercepts -
  Null hypothesis: The groups have a common intercept
  Test statistic: F(16, 222) = 1.62455
  with p-value = P(F(16, 222) > 1.62455) = 0.0639999

? panel growth 0 concentration fba_tba fbno_tbno soebankshare risk1 open1 savings

Model 35: Fixed-effects, using 129 observations
Included 12 cross-sectional units
Time-series length: minimum 3, maximum 15
Dependent variable: growth

                  coefficient   std. error   t-ratio   p-value
  ---------------------------------------------------------
  const           20.7953       27.9115       0.7450   0.4578
  concentration   -0.0204994     0.0332775   -0.6160   0.5392
  fba_tba         -0.413198      0.336123    -1.229    0.2216
  fbno_tbno        0.0340065     0.0660355    0.5150   0.6076
  soebankshare    -0.308357      0.332828    -0.9265   0.3562
  risk1           -0.0499184     0.0272584   -1.831    0.0698  *
  open1            0.0831400     0.0301569    2.757    0.0068  ***
  savings          0.320679      0.110850     2.893    0.0046  ***

Mean dependent var   2.969218   S.D. dependent var   3.595371
Sum squared resid    1198.918   S.E. of regression   3.301401
R-squared            0.275411   Adjusted R-squared   0.156842
F(18, 110)           2.322785   P-value(F)           0.003983
Log-likelihood      -326.8369   Akaike criterion     691.6738
Schwarz criterion    746.0103   Hannan-Quinn         713.7518
rho                  0.434304   Durbin-Watson        0.894938

Test for differing group intercepts -
  Null hypothesis: The groups have a common intercept
  Test statistic: F(11, 110) = 2.71832
  with p-value = P(F(11, 110) > 2.71832) = 0.00385861

? panel growth 0 concentration fba_tba soebankshare risk1 open1 savings

Model 36: Fixed-effects, using 129 observations
Included 12 cross-sectional units
Time-series length: minimum 3, maximum 15
Dependent variable: growth

                  coefficient   std. error   t-ratio   p-value
  ---------------------------------------------------------
  const           20.3435       27.8053       0.7316   0.4659
  concentration   -0.0183012     0.0328931   -0.5564   0.5791
  fba_tba         -0.388400      0.331553    -1.171    0.2439
  soebankshare    -0.309303      0.331720    -0.9324   0.3531
  risk1           -0.0496457     0.0271629   -1.828    0.0703  *
  open1            0.0847775     0.0298894    2.836    0.0054  ***
  savings          0.307162      0.107341     2.862    0.0050  ***

Mean dependent var   2.969218   S.D. dependent var   3.595371
Sum squared resid    1201.808   S.E. of regression   3.290456
R-squared            0.273664   Adjusted R-squared   0.162423
F(17, 111)           2.460105   P-value(F)           0.002623
Log-likelihood      -326.9922   Akaike criterion     689.9845
Schwarz criterion    741.4611   Hannan-Quinn         710.9005
```

```
rho                   0.446260   Durbin-Watson        0.880834

Test for differing group intercepts -
  Null hypothesis: The groups have a common intercept
  Test statistic: F(11, 111) = 2.7131
  with p-value = P(F(11, 111) > 2.7131) = 0.00389741

? panel growth 0 concentration fba_tba fbno_tbno soebankshare risk1 open1 savings
--random-effects

Model 37: Random-effects (GLS), using 129 observations
Included 12 cross-sectional units
Time-series length: minimum 3, maximum 15
Dependent variable: growth

                  coefficient   std. error   t-ratio    p-value
  ---------------------------------------------------------------
  const           -1.03746      2.21785      -0.4678    0.6408
  concentration   -0.00434917   0.0246406    -0.1765    0.8602
  fba_tba          0.0493275    0.0291992     1.689     0.0937  *
  fbno_tbno       -0.00564278   0.0598296    -0.09431   0.9250
  soebankshare     0.0462679    0.0235175     1.967     0.0514  *
  risk1           -0.00538882   0.0266440    -0.2023    0.8401
  open1           -0.00465570   0.0117525    -0.3961    0.6927
  savings          0.0494574    0.0681299     0.7259    0.4693

Mean dependent var   2.969218   S.D. dependent var   3.595371
Sum squared resid    1524.821   S.E. of regression   3.535327
Log-likelihood      -342.3465   Akaike criterion     700.6929
Schwarz criterion    723.5714   Hannan-Quinn         709.9889

'Within' variance = 10.8993
'Between' variance = 1.10086

Breusch-Pagan test -
  Null hypothesis: Variance of the unit-specific error = 0
  Asymptotic test statistic: Chi-square(1) = 0.422688
  with p-value = 0.515599

Hausman test -
  Null hypothesis: GLS estimates are consistent
  Asymptotic test statistic: Chi-square(7) = 28.2883
  with p-value = 0.000194948

? smpl kriza=0 --restrict
Full data set: 272 observations
Current sample: 1:01 - 17:12 (n = 204)

? panel growth 0 concentration fba_tba fbno_tbno soebankshare risk1 open1 savings

Model 38: Fixed-effects, using 96 observations
Included 12 cross-sectional units
Time-series length: minimum 2, maximum 11
Dependent variable: growth

                  coefficient   std. error   t-ratio   p-value
  ----------------------------------------------------------------
  const           11.9113       24.3267       0.4896   0.6258
  concentration   -0.0282985     0.0228875   -1.236    0.2201
```

```
  fba_tba         −0.201225      0.298214    −0.6748   0.5018
  fbno_tbno        0.0632401     0.0382908    1.652    0.1027
  soebankshare    −0.243821      0.293904    −0.8296   0.4093
  risk1           −0.0536042     0.0163279   −3.283    0.0015   ***
  open1            0.0123467     0.0236438    0.5222   0.6030
  savings          0.492088      0.0921142    5.342    9.04e-07 ***

Mean dependent var   3.848368   S.D. dependent var   2.803087
Sum squared resid    255.2597   S.E. of regression   1.820731
R-squared            0.658032   Adjusted R-squared   0.578091
F(18, 77)            8.231513   P-value(F)           1.29e-11
Log-likelihood      −183.1589   Akaike criterion     404.3178
Schwarz criterion    453.0404   Hannan-Quinn         424.0123
rho                  0.291003   Durbin-Watson        1.018596

Test for differing group intercepts -
  Null hypothesis: The groups have a common intercept
  Test statistic: F(11, 77) = 8.05645
  with p-value = P(F(11, 77) > 8.05645) = 3.67752e-009

? panel growth 0 concentration fba_tba fbno_tbno soebankshare risk1 open1 savings
--random-effects

Model 39: Random-effects (GLS), using 96 observations
Included 12 cross-sectional units
Time-series length: minimum 2, maximum 11
Dependent variable: growth

                  coefficient   std. error   t-ratio   p-value
  ---------------------------------------------------------------
  const           −1.76425      3.23803      −0.5449   0.5872
  concentration   −0.0471304    0.0220830    −2.134    0.0356  **
  fba_tba          0.0556790    0.0321484     1.732    0.0868  *
  fbno_tbno        0.0487627    0.0392751     1.242    0.2177
  soebankshare     0.0258348    0.0322992     0.7999   0.4259
  risk1           −0.0310068    0.0170517    −1.818    0.0724  *
  open1            0.00305301   0.0169094     0.1806   0.8571
  savings          0.239098     0.0779567     3.067    0.0029  ***

Mean dependent var   3.848368   S.D. dependent var   2.803087
Sum squared resid    683.9549   S.E. of regression   2.772163
Log-likelihood      −230.4682   Akaike criterion     476.9364
Schwarz criterion    497.4512   Hannan-Quinn         485.2288

'Within' variance = 3.31506
'Between' variance = 3.22179

Breusch-Pagan test -
  Null hypothesis: Variance of the unit-specific error = 0
  Asymptotic test statistic: Chi-square(1) = 11.0738
  with p-value = 0.000875575

Hausman test -
  Null hypothesis: GLS estimates are consistent
  Asymptotic test statistic: Chi-square(7) = 32.0529
  with p-value = 3.97088e-005

? smpl full
Full data range: 1:01 - 17:16 (n = 272)
```

```
? dpanel 1 ; growth 0 concentration fba_tba fbno_tbno soebankshare risk1 open1
savings

Model 40: 1-step dynamic panel, using 117 observations
Included 12 cross-sectional units
Time-series length: minimum 2, maximum 14
Dependent variable: growth

                  coefficient   std. error      z      p-value
  -----------------------------------------------------------
  growth(-1)       0.197403     0.0640853     3.080    0.0021  ***
  concentration   -0.00300000   0.0196434    -0.1527   0.8786
  fba_tba         -0.280731     0.166671     -1.684    0.0921  *
  fbno_tbno       -0.0143579    0.0430668    -0.3334   0.7388
  soebankshare    -0.153117     0.172096     -0.8897   0.3736
  risk1           -0.0158420    0.0400651    -0.3954   0.6925
  open1            0.0906648    0.0384968     2.355    0.0185  **
  savings          0.173279     0.124590      1.391    0.1643

Sum squared resid    1830.389   S.E. of regression   4.097872

Number of instruments = 92
Test for AR(1) errors: z = -2.11509 [0.0344]
Test for AR(2) errors: z = 1.21793 [0.2233]
Sargan over-identification test: Chi-square(84) = 115.674 [0.0125]
Wald (joint) test: Chi-square(8) = 698.973 [0.0000]

? dpanel 1 ; growth 0 concentration fba_tba fbno_tbno soebankshare risk1 open1
savings --two-step

Model 41: 2-step dynamic panel, using 117 observations
Included 12 cross-sectional units
Time-series length: minimum 2, maximum 14
Dependent variable: growth

                  coefficient   std. error      z      p-value
  -----------------------------------------------------------
  growth(-1)      -0.132882     0.304623     -0.4362   0.6627
  concentration    0.0362776    0.0556090     0.6524   0.5142
  fba_tba         -5.12679      6.28250      -0.8160   0.4145
  fbno_tbno        0.138396     0.282931      0.4892   0.6247
  soebankshare    -4.93960      6.28850      -0.7855   0.4322
  risk1           -0.0581900    0.0678791    -0.8573   0.3913
  open1            0.168625     0.0461984     3.650    0.0003  ***
  savings          0.389786     0.499396      0.7805   0.4351

Sum squared resid    1760.256   S.E. of regression   4.018599

Number of instruments = 92
Test for AR(1) errors: z = -0.295584 [0.7675]
Test for AR(2) errors: z = -0.602081 [0.5471]
Sargan over-identification test: Chi-square(84) = 5.13032 [1.0000]
Wald (joint) test: Chi-square(0) = NA

? dpanel 1 ; growth 0 concentration fba_tba fbno_tbno soebankshare risk1 open1
savings --system

Model 42: 1-step dynamic panel, using 129 observations
```

```
Included 12 cross-sectional units
Time-series length: minimum 2, maximum 14
Including equations in levels
Dependent variable: growth

                  coefficient    std. error      z        p-value
  ---------------------------------------------------------------
  growth(-1)       0.386715      0.0398755     9.698     3.07e-022 ***
  const           -0.342756      0.954154     -0.3592    0.7194
  concentration   -0.000671804   0.0185121    -0.03629   0.9711
  fba_tba          0.0380761     0.0151527     2.513     0.0120    **
  fbno_tbno       -0.0358056     0.0325079    -1.101     0.2707
  soebankshare     0.0231473     0.0116202     1.992     0.0464    **
  risk1            0.0127873     0.0180339     0.7091    0.4783
  open1            0.00191132    0.00962547    0.1986    0.8426
  savings          0.00650060    0.0535826     0.1213    0.9034

Sum squared resid    1317.184   S.E. of regression   4.832881

Number of instruments = 107
Test for AR(1) errors: z = -2.29818 [0.0216]
Test for AR(2) errors: z = 1.50073 [0.1334]
Sargan over-identification test: Chi-square(98) = 105.957 [0.2739]
Wald (joint) test: Chi-square(8) = 3650.57 [0.0000]

? smpl kriza=0 --restrict
Full data set: 272 observations
Current sample: 1:01 - 17:12 (n = 204)

? dpanel 1 ; growth 0 concentration fba_tba fbno_tbno soebankshare risk1 open1
savings --system

Model 43: 1-step dynamic panel, using 96 observations
Included 12 cross-sectional units
Time-series length: minimum 1, maximum 10
Including equations in levels
Dependent variable: growth

                  coefficient   std. error      z       p-value
  ------------------------------------------------------------
  growth(-1)       0.598616     0.0696313     8.597    8.19e-018 ***
  const            1.39445      1.01343       1.376    0.1688
  concentration   -0.0334568    0.0218371    -1.532    0.1255
  fba_tba          0.0183965    0.00883145    2.083    0.0372    **
  fbno_tbno        0.0171961    0.0213871     0.8040   0.4214
  soebankshare     0.0219265    0.0104623     2.096    0.0361    **
  risk1            0.0297913    0.0173254     1.720    0.0855    *
  open1            0.00204452   0.00906902    0.2254   0.8216
  savings          0.0111960    0.0640663     0.1748   0.8613

Sum squared resid    348.1297   S.E. of regression   2.688939

Number of instruments = 70
Test for AR(1) errors: z = -1.95611 [0.0505]
Test for AR(2) errors: z = 0.791278 [0.4288]
Sargan over-identification test: Chi-square(61) = 67.8108 [0.2563]
Wald (joint) test: Chi-square(8) = 2971.25 [0.0000]

? dpanel 1 ; growth 0 concentration fba_tba fbno_tbno soebankshare risk1 --system
```

```
Model 44: 1-step dynamic panel, using 96 observations
Included 12 cross-sectional units
Time-series length: minimum 1, maximum 10
Including equations in levels
Dependent variable: growth

                  coefficient   std. error      z       p-value
  -----------------------------------------------------------
  growth(-1)       0.593461     0.0641785     9.247    2.31e-020 ***
  const            1.78422      1.16029       1.538    0.1241
  concentration   −0.0345609    0.0184318    −1.875    0.0608    *
  fba_tba          0.0204564    0.00614111    3.331    0.0009    ***
  fbno_tbno        0.0160100    0.0190871     0.8388   0.4016
  soebankshare     0.0227602    0.00920669    2.472    0.0134    **
  risk1            0.0309440    0.0181982     1.700    0.0891    *

Sum squared resid    348.0496   S.E. of regression   2.659158

Number of instruments = 68
Test for AR(1) errors: z = -1.95958 [0.0500]
Test for AR(2) errors: z = 0.81297 [0.4162]
Sargan over-identification test: Chi-square(61) = 69.0718 [0.2234]
Wald (joint) test: Chi-square(6) = 800.616 [0.0000]

? dpanel 1 ; growth 0 concentration fba_tba soebankshare risk1 --system

Model 45: 1-step dynamic panel, using 96 observations
Included 12 cross-sectional units
Time-series length: minimum 1, maximum 10
Including equations in levels
Dependent variable: growth

                  coefficient   std. error     z       p-value
  ----------------------------------------------------------
  growth(-1)       0.595895     0.0615297     9.685   3.50e-022 ***
  const            1.93509      1.26919       1.525   0.1273
  concentration   −0.0351595    0.0190695    −1.844   0.0652    *
  fba_tba          0.0268225    0.00673780    3.981   6.87e-05  ***
  soebankshare     0.0207586    0.00890586    2.331   0.0198    **
  risk1            0.0311763    0.0186909     1.668   0.0953    *

Sum squared resid    348.7791   S.E. of regression   2.642483

Number of instruments = 67
Test for AR(1) errors: z = -1.96812 [0.0491]
Test for AR(2) errors: z = 0.838972 [0.4015]
Sargan over-identification test: Chi-square(61) = 70.005 [0.2010]
Wald (joint) test: Chi-square(5) = 682.108 [0.0000]

? dpanel 1 ; growth 0 concentration fba_tba soebankshare risk1 open1 --system

Model 46: 1-step dynamic panel, using 96 observations
Included 12 cross-sectional units
Time-series length: minimum 1, maximum 10
Including equations in levels
Dependent variable: growth

                  coefficient   std. error      z       p-value
```

```
  ------------------------------------------------------------
  growth(-1)       0.602559     0.0603198     9.989    1.70e-023 ***
  const            1.69874      1.33314       1.274    0.2026
  concentration   −0.0328520    0.0190432    −1.725    0.0845    *
  fba_tba          0.0241501    0.00636694    3.793    0.0001    ***
  soebankshare     0.0191319    0.00937387    2.041    0.0413    **
  risk1            0.0300158    0.0183543     1.635    0.1020
  open1            0.00269540   0.00707444    0.3810   0.7032

Sum squared resid    348.8703   S.E. of regression   2.662159

Number of instruments = 68
Test for AR(1) errors: z = -1.97795 [0.0479]
Test for AR(2) errors: z = 0.83413 [0.4042]
Sargan over-identification test: Chi-square(61) = 69.3169 [0.2174]
Wald (joint) test: Chi-square(6) = 1617.88 [0.0000]

? smpl full
Full data range: 1:01 - 17:16 (n = 272)

? dpanel 1 ; growth 0 overhead netmargin marketcap marktturn risk1 open1 savings -
-system
'marketcap' is not the name of a variable
? dpanel 1 ; growth 0 overhead netmargin markcap marktturn risk1 open1 savings --
system

Model 47: 1-step dynamic panel, using 110 observations
Included 11 cross-sectional units
Time-series length: minimum 3, maximum 13
Including equations in levels
Dependent variable: growth

               coefficient    std. error      z      p-value
  ---------------------------------------------------------
  growth(-1)    0.287328      0.0532983     5.391    7.01e-08 ***
  const        −4.50243       2.80849      −1.603    0.1089
  overhead      0.169426      0.129618      1.307    0.1912
  netmargin     0.348156      0.164221      2.120    0.0340   **
  markcap       0.0182089     0.0111876     1.628    0.1036
  marktturn     0.000815764   0.00807336    0.1010   0.9195
  risk1         0.181242      0.136315      1.330    0.1837
  open1         0.0148676     0.00960092    1.549    0.1215
  savings       0.0907235     0.0724878     1.252    0.2107

Sum squared resid    1112.619   S.E. of regression   4.860642

Number of instruments = 99
Test for AR(1) errors: z = -2.29456 [0.0218]
Test for AR(2) errors: z = 1.26751 [0.2050]
Sargan over-identification test: Chi-square(90) = 93.5354 [0.3784]
Wald (joint) test: Chi-square(8) = 1174.38 [0.0000]

? dpanel 1 ; growth 0 overhead netmargin markcap marktturn risk1 --system

Model 48: 1-step dynamic panel, using 110 observations
Included 11 cross-sectional units
Time-series length: minimum 3, maximum 13
Including equations in levels
Dependent variable: growth
```

```
               coefficient   std. error      z        p-value
  ---------------------------------------------------------
  growth(-1)    0.321986     0.0402718     7.995     1.29e-015 ***
  const         0.0780849    0.994181      0.07854   0.9374
  overhead      0.0835428    0.115043      0.7262    0.4677
  netmargin     0.224626     0.150645      1.491     0.1359
  markcap       0.00747834   0.0100302     0.7456    0.4559
  marktturn    -0.00313261   0.00512961   -0.6107    0.5414
  risk1         0.132886     0.131700      1.009     0.3130

Sum squared resid    1153.426   S.E. of regression   4.958557

Number of instruments = 97
Test for AR(1) errors: z = -2.30473 [0.0212]
Test for AR(2) errors: z = 1.22053 [0.2223]
Sargan over-identification test: Chi-square(90) = 93.1002 [0.3905]
Wald (joint) test: Chi-square(6) = 826.3 [0.0000]

? smpl kriza=0 --restrict
Full data set: 272 observations
Current sample: 1:01 - 17:12 (n = 204)

? dpanel 1 ; growth 0 overhead netmargin markcap marktturn risk1 --system

Model 49: 1-step dynamic panel, using 81 observations
Included 11 cross-sectional units
Time-series length: minimum 1, maximum 9
Including equations in levels
Dependent variable: growth

               coefficient   std. error      z       p-value
  ---------------------------------------------------------
  growth(-1)    0.514729     0.0621199     8.286    1.17e-016 ***
  const         1.15045      0.980388      1.173    0.2406
  overhead      0.110177     0.101652      1.084    0.2784
  netmargin     0.108583     0.177987      0.6101   0.5418
  markcap       0.0212782    0.00976783    2.178    0.0294    **
  marktturn    -0.0170446    0.00527528   -3.231    0.0012    ***
  risk1         0.0798494    0.0753153     1.060    0.2891

Sum squared resid    196.5508   S.E. of regression   2.325001

Number of instruments = 64
Test for AR(1) errors: z = -2.28464 [0.0223]
Test for AR(2) errors: z = -0.372179 [0.7098]
Sargan over-identification test: Chi-square(57) = 66.6352 [0.1794]
Wald (joint) test: Chi-square(6) = 654 [0.0000]

? dpanel 1 ; growth 0 overhead netmargin markcap marktturn risk1 open1 savings --
system

Model 50: 1-step dynamic panel, using 81 observations
Included 11 cross-sectional units
Time-series length: minimum 1, maximum 9
Including equations in levels
Dependent variable: growth

               coefficient   std. error      z       p-value
```

```
  ----------------------------------------------------------
  growth(-1)     0.447691     0.0657787     6.806     1.00e-011 ***
  const         -1.67222      1.36228      -1.228     0.2196
  overhead       0.201212     0.0958901     2.098     0.0359    **
  netmargin      0.131569     0.179269      0.7339    0.4630
  markcap        0.0252023    0.00808565    3.117     0.0018    ***
  marktturn     -0.0148521    0.00646017   -2.299     0.0215    **
  risk1          0.123597     0.0820281     1.507     0.1319
  open1          0.0149056    0.00710440    2.098     0.0359    **
  savings        0.0425548    0.0407213     1.045     0.2960

Sum squared resid    176.8036   S.E. of regression   2.200089

Number of instruments = 66
Test for AR(1) errors: z = -2.29624 [0.0217]
Test for AR(2) errors: z = -0.568822 [0.5695]
Sargan over-identification test: Chi-square(57) = 68.5283 [0.1410]
Wald (joint) test: Chi-square(8) = 635.198 [0.0000]
```

Rezultati za drugu pomoćnu hipotezu:

fba_tba	fbno_tbno	soebankshare	overhead	
1,0000	0,9261	-0,6359	0,0789	fba_tba
	1,0000	-0,7080	0,0080	fbno_tbno
		1,0000	0,2736	soebankshare
			1,0000	overhead

netmargin	markcap	tradstock	
0,2939	-0,1201	-0,4001	fba_tba
0,1899	-0,0426	-0,3042	fbno_tbno
0,1317	-0,0881	-0,0290	soebankshare
0,6629	-0,2010	-0,3309	overhead
1,0000	-0,3145	-0,4596	netmargin
	1,0000	0,6119	markcap
		1,0000	tradstock

Rezultati su:

```
Model 1: 1-step dynamic panel, using 168 observations
Included 15 cross-sectional units
Time-series length: minimum 6, maximum 11
Including equations in levels
Dependent variable: growth

                 coefficient    std. error       z      p-value
  ---------------------------------------------------------------
  growth(-1)      0,225509      0,0651546      3,461    0,0005   ***
  const          -2,04073       1,13562       -1,797    0,0723   *
  concentration   0,0276596     0,0143650      1,925    0,0542   *
  soebankshare   -0,00284848    0,0176515     -0,1614   0,8718
  netmargin       0,895649      0,207088       4,325    1,53e-05 ***
  marktturn       0,00197853    0,000858346    2,305    0,0212   **
  tradstock       0,0121197     0,00941679     1,287    0,1981
  nplintotal     -0,129759      0,0623818     -2,080    0,0375   **
  listed         -0,000461149   0,000244292   -1,888    0,0591   *

Sum squared resid    1696,766   S.E. of regression   4,602696
```

```
Number of instruments = 119
Test for AR(1) errors: z = -3,11953 [0,0018]
Test for AR(2) errors: z = 0,0760382 [0,9394]
Sargan over-identification test: Chi-square(110) = 139,937 [0,0285]
Wald (joint) test: Chi-square(8) = 391,585 [0,0000]


Model 2: 1-step dynamic panel, using 168 observations
Included 15 cross-sectional units
Time-series length: minimum 6, maximum 11
Including equations in levels
Dependent variable: growth

                  coefficient    std. error       z      p-value
  ---------------------------------------------------------------
  growth(-1)       0,289755      0,0777244      3,728    0,0002  ***
  const           -1,07374       1,07446       -0,9993   0,3176
  concentration    0,0404175     0,0138825      2,911    0,0036  ***
  soebankshare    -0,00366564    0,0158705     -0,2310   0,8173
  overhead         0,398618      0,167665       2,377    0,0174  **
  marktturn        0,00221092    0,000867787    2,548    0,0108  **
  tradstock       -0,0111109     0,00741033    -1,499    0,1338
  nplintotal      -0,124700      0,0641941     -1,943    0,0521  *
  listed           0,000117823   0,000138395    0,8514   0,3946

Sum squared resid    1753,013   S.E. of regression   4,756378

Number of instruments = 119
Test for AR(1) errors: z = -3,1084 [0,0019]
Test for AR(2) errors: z = 0,145669 [0,8842]
Sargan over-identification test: Chi-square(110) = 135,767 [0,0483]
Wald (joint) test: Chi-square(8) = 278,632 [0,0000]

Model 3: 1-step dynamic panel, using 168 observations
Included 15 cross-sectional units
Time-series length: minimum 6, maximum 11
Including equations in levels
Dependent variable: growth

                  coefficient    std. error       z      p-value
  ----------------------------------------------------------------
  growth(-1)       0,220283      0,0661110      3,332    0,0009   ***
  const           -2,51195       1,10688       -2,269    0,0232   **
  concentration    0,0263539     0,0128579      2,050    0,0404   **
  fba_tba          0,00994774    0,0122092      0,8148   0,4152
  netmargin        0,849569      0,203314       4,179    2,93e-05 ***
  marktturn        0,00209078    0,000891900    2,344    0,0191   **
  tradstock        0,0175764     0,0118200      1,487    0,1370
  nplintotal      -0,125209      0,0631435     -1,983    0,0474   **
  listed          -0,000423327   0,000236499   -1,790    0,0735   *

Sum squared resid    1692,710   S.E. of regression   4,580463

Number of instruments = 119
Test for AR(1) errors: z = -3,07624 [0,0021]
Test for AR(2) errors: z = 0,149357 [0,8813]
Sargan over-identification test: Chi-square(110) = 141,061 [0,0245]
Wald (joint) test: Chi-square(8) = 152,465 [0,0000]

Model 4: 1-step dynamic panel, using 168 observations
Included 15 cross-sectional units
Time-series length: minimum 6, maximum 11
Including equations in levels
Dependent variable: growth

                  coefficient    std. error       z      p-value
  ----------------------------------------------------------------
```

```
  growth(-1)       0,224824      0,0659323      3,410    0,0006   ***
  const           -2,31901       1,16068       -1,998    0,0457   **
  concentration    0,0274864     0,0138247      1,988    0,0468   **
  fbno_tbno        0,00711388    0,0234494      0,3034   0,7616
  netmargin        0,887319      0,194299       4,567    4,95e-06 ***
  marktturn        0,00198117    0,000929813    2,131    0,0331   **
  tradstock        0,0138520     0,0113475      1,221    0,2222
  nplintotal      -0,127590      0,0623378     -2,047    0,0407   **
  listed          -0,000453998   0,000222444   -2,041    0,0413   **

Sum squared resid    1697,211   S.E. of regression   4,602172

Number of instruments = 119
Test for AR(1) errors: z = -3,10585 [0,0019]
Test for AR(2) errors: z = 0,102347 [0,9185]
Sargan over-identification test: Chi-square(110) = 140,38 [0,0269]
Wald (joint) test: Chi-square(8) = 164,631 [0,0000]

Model 5: 1-step dynamic panel, using 168 observations
Included 15 cross-sectional units
Time-series length: minimum 6, maximum 11
Including equations in levels
Dependent variable: growth

                 coefficient    std. error      z      p-value
  ---------------------------------------------------------------
  growth(-1)       0,230372      0,0635155      3,627   0,0003  ***
  const           -2,05255       1,15820       -1,772   0,0764  *
  concentration    0,0287429     0,0134411      2,138   0,0325  **
  fba_tba          0,0697468     0,0265886      2,623   0,0087  ***
  fbno_tbno       -0,125517      0,0483569     -2,596   0,0094  ***
  netmargin        0,751973      0,210542       3,572   0,0004  ***
  marktturn        0,00162137    0,000882770    1,837   0,0663  *
  tradstock        0,0195826     0,0126437      1,549   0,1214
  nplintotal      -0,125843      0,0585163     -2,151   0,0315  **
  listed          -0,000335047   0,000236738   -1,415   0,1570

Sum squared resid    1657,048   S.E. of regression   4,590036

Number of instruments = 120
Test for AR(1) errors: z = -3,0319 [0,0024]
Test for AR(2) errors: z = 0,159287 [0,8734]
Sargan over-identification test: Chi-square(110) = 137,586 [0,0385]
Wald (joint) test: Chi-square(9) = 143,183 [0,0000]

Model 6: 1-step dynamic panel, using 168 observations
Included 15 cross-sectional units
Time-series length: minimum 6, maximum 11
Including equations in levels
Dependent variable: growth

                 coefficient    std. error       z      p-value
  ----------------------------------------------------------------
  growth(-1)       0,280655      0,0798975      3,513    0,0004  ***
  const           -1,61648       1,34238       -1,204    0,2285
  concentration    0,0387901     0,0127681      3,038    0,0024  ***
  fbno_tbno        0,0176588     0,0228346      0,7733   0,4393
  overhead         0,397037      0,163650       2,426    0,0153  **
  marktturn        0,00240304    0,000931721    2,579    0,0099  ***
  tradstock       -0,00591945    0,0108341     -0,5464   0,5848
  nplintotal      -0,124269      0,0660392     -1,882    0,0599  *
  listed           0,000114815   0,000134305    0,8549   0,3926

Sum squared resid    1750,419   S.E. of regression   4,732814

Number of instruments = 119
Test for AR(1) errors: z = -3,0649 [0,0022]
Test for AR(2) errors: z = 0,172055 [0,8634]
```

```
Sargan over-identification test: Chi-square(110) = 136,616 [0,0435]
Wald (joint) test: Chi-square(8) = 448,026 [0,0000]

Model 7: 1-step dynamic panel, using 168 observations
Included 15 cross-sectional units
Time-series length: minimum 6, maximum 11
Including equations in levels
Dependent variable: growth

                 coefficient    std. error       z       p-value
  ---------------------------------------------------------------
  growth(-1)       0,268717      0,0804913      3,338     0,0008  ***
  const           -2,04538       1,23483       -1,656     0,0976  *
  concentration    0,0381525     0,0122264      3,121     0,0018  ***
  fba_tba          0,0173575     0,0118959      1,459     0,1445
  overhead         0,391351      0,162425       2,409     0,0160  **
  marktturn        0,00252977    0,000917013    2,759     0,0058  ***
  tradstock        0,00116806    0,0116890      0,09993   0,9204
  nplintotal      -0,125627      0,0680006     -1,847     0,0647  *
  listed           0,000110155   0,000149330    0,7377    0,4607

Sum squared resid    1734,046   S.E. of regression   4,683939

Number of instruments = 119
Test for AR(1) errors: z = -3,01265 [0,0026]
Test for AR(2) errors: z = 0,213763 [0,8307]
Sargan over-identification test: Chi-square(110) = 137,702 [0,0380]
Wald (joint) test: Chi-square(8) = 437,633 [0,0000]

Model 8: 1-step dynamic panel, using 168 observations
Included 15 cross-sectional units
Time-series length: minimum 6, maximum 11
Including equations in levels
Dependent variable: growth

                 coefficient    std. error       z      p-value
  --------------------------------------------------------------
  growth(-1)       0,213740      0,0666099      3,209    0,0013   ***
  const           -2,53274       1,17157       -2,162    0,0306   **
  concentration    0,0296421     0,0145125      2,043    0,0411   **
  fbno_tbno        0,00439162    0,0210164      0,2090   0,8345
  netmargin        0,847396      0,182440       4,645    3,40e-06 ***
  marktturn        0,00255214    0,000986750    2,586    0,0097   ***
  markcap          0,0172166     0,00958099     1,797    0,0723   *
  nplintotal      -0,131116      0,0630441     -2,080    0,0375   **
  listed          -0,000367142   0,000201212   -1,825    0,0681   *

Sum squared resid    1686,843   S.E. of regression   4,573329

Number of instruments = 119
Test for AR(1) errors: z = -3,11106 [0,0019]
Test for AR(2) errors: z = 0,518386 [0,6042]
Sargan over-identification test: Chi-square(110) = 140,883 [0,0251]
Wald (joint) test: Chi-square(8) = 188,906 [0,0000]

Model 9: 1-step dynamic panel, using 168 observations
Included 15 cross-sectional units
Time-series length: minimum 6, maximum 11
Including equations in levels
Dependent variable: growth

                 coefficient    std. error       z       p-value
  ---------------------------------------------------------------
  growth(-1)       0,212608      0,0673716      3,156     0,0016   ***
  const           -2,36365       1,34412       -1,759     0,0787   *
  concentration    0,0296493     0,0152349      1,946     0,0516   *
  soebankshare    -0,00110604    0,0189132     -0,05848   0,9534
  netmargin        0,854717      0,182146       4,692     2,70e-06 ***
```

```
  marktturn        0,00253320    0,000914575    2,770     0,0056   ***
  markcap          0,0165918     0,00965499     1,718     0,0857   *
  nplintotal      -0,133731      0,0628968     -2,126     0,0335   **
  listed          -0,000372135   0,000216243   -1,721     0,0853   *

Sum squared resid    1687,101   S.E. of regression   4,569727

Number of instruments = 119
Test for AR(1) errors: z = -3,11494 [0,0018]
Test for AR(2) errors: z = 0,487357 [0,6260]
Sargan over-identification test: Chi-square(110) = 140,508 [0,0264]
Wald (joint) test: Chi-square(8) = 558,763 [0,0000]


Model 10: 1-step dynamic panel, using 91 observations
Included 10 cross-sectional units
Time-series length: minimum 2, maximum 11
Including equations in levels
Dependent variable: growth

                 coefficient    std. error       z      p-value
  ---------------------------------------------------------------
  growth(-1)       0,127176      0,0701790      1,812    0,0700   *
  const           -6,13428       1,59694       -3,841    0,0001   ***
  concentration    0,0479563     0,00866089     5,537    3,08e-08 ***
  soebankshare     0,0518913     0,0286521      1,811    0,0701   *
  netmargin        1,01851       0,258398       3,942    8,09e-05 ***
  marktturn        0,00452376    0,00686385     0,6591   0,5098
  markcap          0,0222294     0,0108164      2,055    0,0399   **
  nplintotal      -0,0992765     0,0552919     -1,795    0,0726   *
  listed          -0,000542678   0,000314937   -1,723    0,0849   *
  risk1            0,0447557     0,150300       0,2978   0,7659

Sum squared resid    977,7843   S.E. of regression   5,141406

Number of instruments = 91
Test for AR(1) errors: z = -2,36924 [0,0178]
Test for AR(2) errors: z = 0,307461 [0,7585]
Sargan over-identification test: Chi-square(81) = 73,9791 [0,6969]
Wald (joint) test: Chi-square(9) = 1238,52 [0,0000]

Model 11: 1-step dynamic panel, using 91 observations
Included 10 cross-sectional units
Time-series length: minimum 2, maximum 11
Including equations in levels
Dependent variable: growth

                 coefficient    std. error       z       p-value
  ----------------------------------------------------------------
  growth(-1)       0,134365      0,0695675      1,931    0,0534    *
  const           -7,35298       2,62238       -2,804    0,0050    ***
  concentration    0,0430691     0,00634182     6,791    1,11e-011 ***
  soebankshare     0,0550412     0,0298136      1,846    0,0649    *
  netmargin        0,938368      0,261664       3,586    0,0003    ***
  marktturn        0,00697520    0,00984882     0,7082   0,4788
  markcap          0,0240200     0,0110812      2,168    0,0302    **
  nplintotal      -0,0687750     0,0720453     -0,9546   0,3398
  listed          -0,000301237   0,000404499   -0,7447   0,4564
  risk1            0,0525512     0,152034       0,3457   0,7296
  open1            0,0115065     0,0142091      0,8098   0,4181

Sum squared resid    970,2094   S.E. of regression   5,142152

Number of instruments = 91
Test for AR(1) errors: z = -2,37256 [0,0177]
Test for AR(2) errors: z = 0,485925 [0,6270]
Sargan over-identification test: Chi-square(80) = 73,3847 [0,6862]
Wald (joint) test: Chi-square(0) = NA
```

```
Model 12: 1-step dynamic panel, using 91 observations
Included 10 cross-sectional units
Time-series length: minimum 2, maximum 11
Including equations in levels
Dependent variable: growth

                 coefficient    std. error       z       p-value
  ---------------------------------------------------------------
  growth(-1)       0,126182      0,0767662      1,644    0,1002
  const           -5,83297       3,56622       -1,636    0,1019
  concentration    0,0482513     0,00762449     6,328    2,48e-010 ***
  soebankshare     0,0529270     0,0329396      1,607    0,1081
  netmargin        1,00066       0,260616       3,840    0,0001    ***
  marktturn        0,00441483    0,00694052     0,6361   0,5247
  markcap          0,0213681     0,0164871      1,296    0,1950
  nplintotal      -0,102036      0,0782940     -1,303    0,1925
  listed          -0,000531973   0,000280724   -1,895    0,0581    *
  risk1            0,0419200     0,137349       0,3052   0,7602
  savings         -0,0116683     0,115623      -0,1009   0,9196

Sum squared resid    977,6187   S.E. of regression   5,174617

Number of instruments = 91
Test for AR(1) errors: z = -2,4232 [0,0154]
Test for AR(2) errors: z = 0,28825 [0,7732]
Sargan over-identification test: Chi-square(80) = 73,0202 [0,6969]
Wald (joint) test: Chi-square(10) = 8,70445e+009 [0,0000]

Model 13: 1-step dynamic panel, using 91 observations
Included 10 cross-sectional units
Time-series length: minimum 2, maximum 11
Including equations in levels
Dependent variable: growth

                 coefficient    std. error       z      p-value
  ---------------------------------------------------------------
  growth(-1)       0,127176      0,0701790      1,812    0,0700   *
  const           -6,13428       1,59694       -3,841    0,0001   ***
  concentration    0,0479563     0,00866089     5,537    3,08e-08 ***
  soebankshare     0,0518913     0,0286521      1,811    0,0701   *
  netmargin        1,01851       0,258398       3,942    8,09e-05 ***
  marktturn        0,00452376    0,00686385     0,6591   0,5098
  markcap          0,0222294     0,0108164      2,055    0,0399   **
  nplintotal      -0,0992765     0,0552919     -1,795    0,0726   *
  listed          -0,000542678   0,000314937   -1,723    0,0849   *
  risk1            0,0447557     0,150300       0,2978   0,7659

Sum squared resid    977,7843   S.E. of regression   5,141406

Number of instruments = 91
Test for AR(1) errors: z = -2,36924 [0,0178]
Test for AR(2) errors: z = 0,307461 [0,7585]
Sargan over-identification test: Chi-square(81) = 73,9791 [0,6969]
Wald (joint) test: Chi-square(9) = 1238,52 [0,0000]

Model 14: 1-step dynamic panel, using 168 observations
Included 15 cross-sectional units
Time-series length: minimum 6, maximum 11
Including equations in levels
Dependent variable: growth

                 coefficient    std. error       z       p-value
  ---------------------------------------------------------------
  growth(-1)       0,215435      0,0581591      3,704     0,0002   ***
  const           -5,03780       2,20578       -2,284     0,0224   **
  concentration    0,0284214     0,0149911      1,896     0,0580   *
  soebankshare    -0,000737480   0,0160930     -0,04583   0,9634
```

```
  netmargin        0,934916      0,173313       5,394     6,88e-08 ***
  marktturn        0,00188053    0,000967223    1,944     0,0519   *
  markcap          0,0225033     0,0102916      2,187     0,0288   **
  nplintotal      -0,103403      0,0732076     -1,412     0,1578
  listed          -0,000359522   0,000218015   -1,649     0,0991   *
  savings          0,109468      0,0769366      1,423     0,1548

Sum squared resid    1643,792   S.E. of regression   4,581359

Number of instruments = 120
Test for AR(1) errors: z = -3,11622 [0,0018]
Test for AR(2) errors: z = 0,859031 [0,3903]
Sargan over-identification test: Chi-square(110) = 137,801 [0,0375]
Wald (joint) test: Chi-square(9) = 361,929 [0,0000]
```

PRIJE KRIZE

```
Model 1: 1-step dynamic panel, using 108 observations
Included 15 cross-sectional units
Time-series length: minimum 2, maximum 7
Including equations in levels
Dependent variable: growth

                 coefficient    std. error       z      p-value
  ---------------------------------------------------------------
  growth(-1)       0,412408      0,155102       2,659    0,0078  ***
  const            3,24360       1,89144        1,715    0,0864  *
  concentration   -0,0162113     0,0206501     -0,7850   0,4324
  soebankshare    -0,00883109    0,0110598     -0,7985   0,4246
  netmargin        0,390960      0,207862       1,881    0,0600  *
  marktturn        0,00158102    0,000676043    2,339    0,0194  **
  tradstock       -0,0182311     0,00934457    -1,951    0,0511  *
  nplintotal      -0,0782041     0,0560761     -1,395    0,1631
  listed          -0,000159215   0,000215854   -0,7376   0,4608

Sum squared resid    380,1659   S.E. of regression   2,702897

Number of instruments = 65
Test for AR(1) errors: z = -2,90702 [0,0036]
Test for AR(2) errors: z = 0,782165 [0,4341]
Sargan over-identification test: Chi-square(56) = 56,4047 [0,4597]
Wald (joint) test: Chi-square(8) = 364,574 [0,0000]

Model 2: 1-step dynamic panel, using 108 observations
Included 15 cross-sectional units
Time-series length: minimum 2, maximum 7
Including equations in levels
Dependent variable: growth

                 coefficient    std. error       z      p-value
  ---------------------------------------------------------------
  growth(-1)       0,445500      0,152867       2,914    0,0036  ***
  const            3,50745       1,67250        2,097    0,0360  **
  concentration   -0,0147067     0,0180263     -0,8158   0,4146
  soebankshare    -0,00702642    0,0104309     -0,6736   0,5006
  overhead         0,284524      0,143924       1,977    0,0481  **
  marktturn        0,00185196    0,000688821    2,689    0,0072  ***
  tradstock       -0,0243684     0,00856322    -2,846    0,0044  ***
  nplintotal      -0,0915004     0,0639177     -1,432    0,1523
  listed           5,77753e-05   0,000131354    0,4398   0,6600

Sum squared resid    384,2489   S.E. of regression   2,701072

Number of instruments = 65
Test for AR(1) errors: z = -2,7002 [0,0069]
```

```
Test for AR(2) errors: z = 0,654544 [0,5128]
Sargan over-identification test: Chi-square(56) = 56,776 [0,4459]
Wald (joint) test: Chi-square(8) = 493,148 [0,0000]

Model 3: 1-step dynamic panel, using 108 observations
Included 15 cross-sectional units
Time-series length: minimum 2, maximum 7
Including equations in levels
Dependent variable: growth

                  coefficient    std. error       z      p-value
  ---------------------------------------------------------------
  growth(-1)       0,335201      0,145085       2,310    0,0209  **
  const            2,76122       1,76461        1,565    0,1176
  concentration   -0,0211685     0,0203477     -1,040    0,2982
  fba_tba          0,0206392     0,0108092      1,909    0,0562  *
  netmargin        0,289847      0,195060       1,486    0,1373
  marktturn        0,00181954    0,000633513    2,872    0,0041  ***
  tradstock       -0,0109054     0,0100173     -1,089    0,2763
  nplintotal      -0,0745768     0,0561607     -1,328    0,1842
  listed          -7,39692e-05   0,000219127   -0,3376   0,7357

Sum squared resid    360,7121   S.E. of regression   2,583790

Number of instruments = 65
Test for AR(1) errors: z = -2,84516 [0,0044]
Test for AR(2) errors: z = 0,727939 [0,4667]
Sargan over-identification test: Chi-square(56) = 55,0937 [0,5092]
Wald (joint) test: Chi-square(8) = 796,144 [0,0000]

Model 4: 1-step dynamic panel, using 108 observations
Included 15 cross-sectional units
Time-series length: minimum 2, maximum 7
Including equations in levels
Dependent variable: growth

                  coefficient    std. error       z      p-value
  ---------------------------------------------------------------
  growth(-1)       0,357575      0,151980       2,353    0,0186  **
  const            2,92481       1,81750        1,609    0,1076
  concentration   -0,0219859     0,0206215     -1,066    0,2863
  fbno_tbno        0,0299857     0,0217925      1,376    0,1688
  netmargin        0,327600      0,199773       1,640    0,1010
  marktturn        0,00187547    0,000688201    2,725    0,0064  ***
  tradstock       -0,0143622     0,00978893    -1,467    0,1423
  nplintotal      -0,0770811     0,0573400     -1,344    0,1789
  listed          -0,000103229   0,000213659   -0,4831   0,6290

Sum squared resid    371,3878   S.E. of regression   2,629794

Number of instruments = 65
Test for AR(1) errors: z = -2,93398 [0,0033]
Test for AR(2) errors: z = 0,710535 [0,4774]
Sargan over-identification test: Chi-square(56) = 55,9304 [0,4775]
Wald (joint) test: Chi-square(8) = 675,91 [0,0000]
Model 5: 1-step dynamic panel, using 108 observations
Included 15 cross-sectional units
Time-series length: minimum 2, maximum 7
Including equations in levels
Dependent variable: growth

                  coefficient    std. error       z      p-value
  ---------------------------------------------------------------
  growth(-1)       0,340481      0,144760       2,352    0,0187  **
  const            2,78683       1,79662        1,551    0,1209
  concentration   -0,0183680     0,0209434     -0,8770   0,3805
  fba_tba          0,0497150     0,0218233      2,278    0,0227  **
  fbno_tbno       -0,0612974     0,0386931     -1,584    0,1131
```

```
  netmargin        0,257000      0,186162       1,381    0,1674
  marktturn        0,00154549    0,000702780    2,199    0,0279  **
  tradstock       -0,00923820    0,0105676     -0,8742   0,3820
  nplintotal      -0,0742833     0,0525971     -1,412    0,1579
  listed          -4,33964e-05   0,000213328   -0,2034   0,8388

Sum squared resid    352,5388   S.E. of regression   2,605871

Number of instruments = 66
Test for AR(1) errors: z = -2,91315 [0,0036]
Test for AR(2) errors: z = 0,772901 [0,4396]
Sargan over-identification test: Chi-square(56) = 52,3902 [0,6123]
Wald (joint) test: Chi-square(9) = 998,013 [0,0000]

Model 6: 1-step dynamic panel, using 108 observations
Included 15 cross-sectional units
Time-series length: minimum 2, maximum 7
Including equations in levels
Dependent variable: growth

                 coefficient    std. error       z      p-value
  ---------------------------------------------------------------
  growth(-1)       0,378289      0,148129       2,554    0,0107  **
  const            3,07458       1,63661        1,879    0,0603  *
  concentration   -0,0195327     0,0176512     -1,107    0,2685
  fbno_tbno        0,0301118     0,0221688      1,358    0,1744
  overhead         0,260090      0,148584       1,750    0,0800  *
  marktturn        0,00211325    0,000743766    2,841    0,0045  ***
  tradstock       -0,0190682     0,00925699    -2,060    0,0394  **
  nplintotal      -0,0911382     0,0660615     -1,380    0,1677
  listed           6,54007e-05   0,000138963    0,4706   0,6379

Sum squared resid    373,2232   S.E. of regression   2,612376

Number of instruments = 65
Test for AR(1) errors: z = -2,69358 [0,0071]
Test for AR(2) errors: z = 0,559601 [0,5758]
Sargan over-identification test: Chi-square(56) = 56,3824 [0,4605]
Wald (joint) test: Chi-square(8) = 965,28 [0,0000]

Model 7: 1-step dynamic panel, using 108 observations
Included 15 cross-sectional units
Time-series length: minimum 2, maximum 7
Including equations in levels
Dependent variable: growth

                 coefficient    std. error       z      p-value
  ---------------------------------------------------------------
  growth(-1)       0,348066      0,142164       2,448    0,0144  **
  const            2,75018       1,54592        1,779    0,0752  *
  concentration   -0,0178529     0,0170481     -1,047    0,2950
  fba_tba          0,0212994     0,0113778      1,872    0,0612  *
  overhead         0,249776      0,155443       1,607    0,1081
  marktturn        0,00204583    0,000693616    2,950    0,0032  ***
  tradstock       -0,0142583     0,00977248    -1,459    0,1446
  nplintotal      -0,0903740     0,0650870     -1,389    0,1650
  listed           6,43038e-05   0,000152441    0,4218   0,6732

Sum squared resid    360,5946   S.E. of regression   2,552026

Number of instruments = 65
Test for AR(1) errors: z = -2,6063 [0,0092]
Test for AR(2) errors: z = 0,566051 [0,5714]
Sargan over-identification test: Chi-square(56) = 55,6157 [0,4894]
Wald (joint) test: Chi-square(8) = 1195,21 [0,0000]

Model 8: 1-step dynamic panel, using 108 observations
Included 15 cross-sectional units
```

```
Time-series length: minimum 2, maximum 7
Including equations in levels
Dependent variable: growth

                 coefficient    std. error       z      p-value
  ---------------------------------------------------------------
  growth(-1)       0,338606      0,156748       2,160    0,0308  **
  const            0,573091      2,20366        0,2601   0,7948
  concentration   -0,00726993    0,0226757     -0,3206   0,7485
  fbno_tbno        0,0405381     0,0211351      1,918    0,0551  *
  netmargin        0,473355      0,202800       2,334    0,0196  **
  marktturn        0,00161746    0,000992449    1,630    0,1032
  markcap          0,0119857     0,0126990      0,9438   0,3453
  nplintotal      -0,0689295     0,0588414     -1,171    0,2414
  listed          -0,000189060   0,000209775   -0,9012   0,3675

Sum squared resid    376,7233   S.E. of regression   2,573824

Number of instruments = 65
Test for AR(1) errors: z = -2,90144 [0,0037]
Test for AR(2) errors: z = 0,594141 [0,5524]
Sargan over-identification test: Chi-square(56) = 57,2662 [0,4279]
Wald (joint) test: Chi-square(8) = 289,121 [0,0000]


Model 9: 1-step dynamic panel, using 108 observations
Included 15 cross-sectional units
Time-series length: minimum 2, maximum 7
Including equations in levels
Dependent variable: growth

                 coefficient    std. error       z       p-value
  ---------------------------------------------------------------
  growth(-1)       0,424137      0,160935       2,635     0,0084  ***
  const            0,834571      2,29048        0,3644    0,7156
  concentration    0,00137982    0,0225633      0,06115   0,9512
  soebankshare    -0,0122636     0,0135893     -0,9024    0,3668
  netmargin        0,584687      0,222516       2,628     0,0086  ***
  marktturn        0,00107423    0,00104732     1,026     0,3050
  markcap          0,00906339    0,0123322      0,7349    0,4624
  nplintotal      -0,0699119     0,0579736     -1,206     0,2278
  listed          -0,000293337   0,000223542   -1,312     0,1894

Sum squared resid    391,4414   S.E. of regression   2,698997

Number of instruments = 65
Test for AR(1) errors: z = -2,89578 [0,0038]
Test for AR(2) errors: z = 0,702955 [0,4821]
Sargan over-identification test: Chi-square(56) = 57,3413 [0,4252]
Wald (joint) test: Chi-square(8) = 231,541 [0,0000]

Model 10: 1-step dynamic panel, using 62 observations
Included 10 cross-sectional units
Time-series length: minimum 1, maximum 7
Including equations in levels
Dependent variable: growth

                 coefficient    std. error       z      p-value
  ---------------------------------------------------------------
  growth(-1)       0,363626      0,116368       3,125    0,0018  ***
  const            1,51649       3,21258        0,4720   0,6369
  concentration    0,00434325    0,0157107      0,2765   0,7822
  soebankshare     0,00206858    0,0200873      0,1030   0,9180
  netmargin        0,406787      0,220894       1,842    0,0655  *
  marktturn       -0,0220225     0,0100549     -2,190    0,0285  **
  markcap          0,0336366     0,0163567      2,056    0,0397  **
  nplintotal      -0,0425777     0,0413648     -1,029    0,3033
  listed          -0,000206966   0,000253707   -0,8158   0,4146
```

```
  risk1           -0,0371291     0,152127      -0,2441   0,8072

Sum squared resid    136,3055   S.E. of regression   2,150513

Number of instruments = 60
Test for AR(1) errors: z = -1,85212 [0,0640]
Test for AR(2) errors: z = -1,32561 [0,1850]
Sargan over-identification test: Chi-square(50) = 57,7305 [0,2112]
Wald (joint) test: Chi-square(9) = 72767,8 [0,0000]

Model 11: 1-step dynamic panel, using 62 observations
Included 10 cross-sectional units
Time-series length: minimum 1, maximum 7
Including equations in levels
Dependent variable: growth

                 coefficient    std. error        z       p-value
  ---------------------------------------------------------------
  growth(-1)       0,345733      0,0859595      4,022      5,77e-05 ***
  const            0,349094      3,81375        0,09154    0,9271
  concentration    2,39969e-05   0,0136735      0,001755   0,9986
  soebankshare     0,00320073    0,0207728      0,1541     0,8775
  netmargin        0,362082      0,211243       1,714      0,0865   *
  marktturn       -0,0192841     0,0115115     -1,675      0,0939   *
  markcap          0,0338217     0,0170442      1,984      0,0472   **
  nplintotal      -0,0148627     0,0490946     -0,3027     0,7621
  listed          -4,69937e-05   0,000297463   -0,1580     0,8745
  risk1           -0,0196188     0,160299      -0,1224     0,9026
  open1            0,0116986     0,0116029      1,008      0,3133

Sum squared resid    132,1565   S.E. of regression   2,146298

Number of instruments = 61
Test for AR(1) errors: z = -1,83884 [0,0659]
Test for AR(2) errors: z = -1,3216 [0,1863]
Sargan over-identification test: Chi-square(50) = 57,3428 [0,2215]
Wald (joint) test: Chi-square(0) = NA

Model 12: 1-step dynamic panel, using 62 observations
Included 10 cross-sectional units
Time-series length: minimum 1, maximum 7
Including equations in levels
Dependent variable: growth

                 coefficient    std. error        z       p-value
  ---------------------------------------------------------------
  growth(-1)       0,360117      0,108274       3,326      0,0009  ***
  const            1,16198       4,71237        0,2466     0,8052
  concentration    0,00413711    0,0167497      0,2470     0,8049
  soebankshare    -0,000176080   0,0179616     -0,009803   0,9922
  netmargin        0,433067      0,269451       1,607      0,1080
  marktturn       -0,0223827     0,00919295    -2,435      0,0149  **
  markcap          0,0344376     0,0176692      1,949      0,0513  *
  nplintotal      -0,0398044     0,0527411     -0,7547     0,4504
  listed          -0,000231473   0,000260888   -0,8873     0,3749
  risk1           -0,0303672     0,165502      -0,1835     0,8544
  savings          0,0163422     0,0832840      0,1962     0,8444

Sum squared resid    136,1457   S.E. of regression   2,159602

Number of instruments = 61
Test for AR(1) errors: z = -1,85818 [0,0631]
Test for AR(2) errors: z = -1,29493 [0,1953]
Sargan over-identification test: Chi-square(50) = 57,2582 [0,2238]
Wald (joint) test: Chi-square(0) = NA

Model 13: 1-step dynamic panel, using 62 observations
Included 10 cross-sectional units
```

```
Time-series length: minimum 1, maximum 7
Including equations in levels
Dependent variable: growth

                 coefficient    std. error       z      p-value
  ---------------------------------------------------------------
  growth(-1)       0,363626      0,116368       3,125    0,0018  ***
  const            1,51649       3,21258        0,4720   0,6369
  concentration    0,00434325    0,0157107      0,2765   0,7822
  soebankshare     0,00206858    0,0200873      0,1030   0,9180
  netmargin        0,406787      0,220894       1,842    0,0655  *
  marktturn       -0,0220225     0,0100549     -2,190    0,0285  **
  markcap          0,0336366     0,0163567      2,056    0,0397  **
  nplintotal      -0,0425777     0,0413648     -1,029    0,3033
  listed          -0,000206966   0,000253707   -0,8158   0,4146
  risk1           -0,0371291     0,152127      -0,2441   0,8072

Sum squared resid    136,3055   S.E. of regression   2,150513

Number of instruments = 60
Test for AR(1) errors: z = -1,85212 [0,0640]
Test for AR(2) errors: z = -1,32561 [0,1850]
Sargan over-identification test: Chi-square(50) = 57,7305 [0,2112]
Wald (joint) test: Chi-square(9) = 72767,8 [0,0000]

Model 14: 1-step dynamic panel, using 108 observations
Included 15 cross-sectional units
Time-series length: minimum 2, maximum 7
Including equations in levels
Dependent variable: growth

                 coefficient    std. error       z      p-value
  ---------------------------------------------------------------
  growth(-1)       0,424581      0,160546       2,645    0,0082  ***
  const           -0,797388      2,91361       -0,2737   0,7843
  concentration    0,00391767    0,0211485      0,1852   0,8530
  soebankshare    -0,0146058     0,0121004     -1,207    0,2274
  netmargin        0,646129      0,216051       2,991    0,0028  ***
  marktturn        0,000632398   0,00111586     0,5667   0,5709
  markcap          0,0118376     0,0124679      0,9494   0,3424
  nplintotal      -0,0575573     0,0573811     -1,003    0,3158
  listed          -0,000305806   0,000205393   -1,489    0,1365
  savings          0,0593018     0,0719056      0,8247   0,4095

Sum squared resid    384,3933   S.E. of regression   2,696239

Number of instruments = 66
Test for AR(1) errors: z = -2,80362 [0,0051]
Test for AR(2) errors: z = 0,795098 [0,4266]
Sargan over-identification test: Chi-square(56) = 59,3533 [0,3544]
Wald (joint) test: Chi-square(9) = 192,802 [0,0000]
```