

UNIVERZA V LJUBLJANI
EKONOMSKA FAKULTETA

MAGISTRSKO DELO

**NAPOVEDOVANJE PLAČILNE NEDISCIPLINE SLOVENSКИH
PODJETIJ S POMOČJO VEČNIVOJSKEGA MODELIRANJA**

Ljubljana, september 2018

ŠPELA SLAK KOZELJ

IZJAVA O AVTORSTVU

Podpisana Špela Slak Kozelj, študentka Ekonomske fakultete Univerze v Ljubljani, avtorica predloženega dela z naslovom Napovedovanje plačilne nediscipline slovenskih podjetij s pomočjo večnivojskega modeliranja, pripravljenega v sodelovanju s svetovalko izr. prof. dr. Sergejo Slapničar

IZJAVLJAM,

1. da sem predloženo delo pripravila samostojno;
2. da je tiskana oblika predloženega dela istovetna njegovi elektronski obliki;
3. da je besedilo predloženega dela jezikovno korektno in tehnično pripravljeno v skladu z Navodili za izdelavo zaključnih nalog Ekonomske fakultete Univerze v Ljubljani, kar pomeni, da sem poskrbela, da so dela in mnenja drugih avtorjev oziroma avtoric, ki jih uporabljam oziroma navajam v besedilu, citirana oziroma povzeta v skladu z Navodili za izdelavo zaključnih nalog Ekonomske fakultete Univerze v Ljubljani;
4. da se zavedam, da je plagiatorstvo – predstavljanje tujih del (v pisni ali grafični obliki) kot mojih lastnih – kaznivo po Kazenskem zakoniku Republike Slovenije;
5. da se zavedam posledic, ki bi jih na osnovi predloženega dela dokazano plagiatorstvo lahko predstavljalo za moj status na Ekonomski fakulteti Univerze v Ljubljani v skladu z relevantnim pravilnikom;
6. da sem pridobila vsa potrebna dovoljenja za uporabo podatkov in avtorskih del v predloženem delu in jih v njem jasno označila;
7. da sem pri pripravi predloženega dela ravnala v skladu z etičnimi načeli in, kjer je to potrebno, za raziskavo pridobila soglasje etične komisije;
8. da soglašam, da se elektronska oblika predloženega dela uporabi za preverjanje podobnosti vsebine z drugimi deli s programsko opremo za preverjanje podobnosti vsebine, ki je povezana s študijskim informacijskim sistemom članice;
9. da na Univerzo v Ljubljani neodplačno, neizključno, prostorsko in časovno neomejeno prenašam pravico shranitve predloženega dela v elektronski obliki, pravico reproduciranja ter pravico dajanja predloženega dela na voljo javnosti na svetovnem spletu preko Repozitorija Univerze v Ljubljani;
10. da hkrati z objavo predloženega dela dovoljujem objavo svojih osebnih podatkov, ki so navedeni v njem in v tej izjavi.

V Ljubljani, dne _____

Podpis študentke: _____

KAZALO

UVOD	1
1 PLAČILNA NEDISCIPLINA	3
1.1 Opredelitev plačilne discipline in plačilne sposobnosti	3
1.2 Vzroki za nastanek plačilne nediscipline.....	4
1.3 Posledice zamujanja s plačili za dolžnika in upnika.....	5
1.3.1 Blokade transakcijskih računov.....	7
1.3.2 Postopki zaradi insolventnosti.....	8
1.3.2.1 Prisilna poravnava.....	8
1.3.2.2 Poenostavljena prisilna poravnava.....	8
1.3.2.3 Stečaj.....	8
1.4 Zavarovanje pred tveganjem neplačila.....	9
1.5 Pretekle raziskave s področja kreditnega tveganja in plačilne discipline.....	10
2 PLAČILNA DISCIPLINA V SVETU IN SLOVENIJI	14
2.1 Plačilna disciplina v tujini	14
2.2 Plačilna disciplina v Sloveniji	18
2.2.1 Dospеле neporavnane obveznosti po letih.....	18
2.2.2 Dospеле neporavnane obveznosti po področjih dejavnosti	20
2.3 Ukrepi za izboljšanje plačilne nediscipline	21
3 NAPOVEDOVANJE NEPLAČILA Z VEČNIVOJSKIM LINEARNIM MODELIRANJEM	23
3.1 Predstavitev modela.....	24
3.1.1 Variiranje regresijske konstante in regresijskih koeficientov	25
3.2 Cilj raziskave in opredelitev hipotez	26
3.2.1 Pričakovane omejitve pri raziskavi	26
3.3 Predstavitev vzorca.....	27
3.4 Opis spremenljivk.....	29
3.4.1 Predstavitev odvisne spremenljivke	30
3.4.2 Predstavitev neodvisnih spremenljivk.....	33
3.4.2.1 Prvi nivo – Podjetje: letna opazovanja.....	33
3.4.2.1.1 Velikost.....	33
3.4.2.1.2 Plačilni rok do dobaviteljev	34
3.4.2.1.3 Delež kapitala v financiranju.....	34
3.4.2.1.4 Delež dolga in delež finančnega dolga v financiranju.....	35
3.4.2.1.5 Pospešeni koeficient	35
3.4.2.1.6 Dobičkonosnost kapitala (ROE).....	35
3.4.2.1.7 Dobičkonosnost sredstev (ROA).....	36
3.4.2.1.8 Delež kratkoročnih sredstev	36
3.4.2.1.9 Koeficient obračanja celotnih sredstev.....	36
3.4.2.1.10 Čista dobičkonosnost prihodkov	37

3.4.2.1.11	Blokada transakcijskega računa.....	37
3.4.2.1.12	Število odprtih bančnih računov (pozicija na finančnem trgu)	37
3.4.2.1.13	Rast podjetja (prodaje).....	37
3.4.2.1.14	Prihodki na zaposlenega	38
3.4.2.2	Drugi nivo – Podjetje	38
3.4.2.2.1	Pravnoorganizacijska oblika podjetja.....	38
3.4.2.3	Tretji nivo – Spremenljivke na ravni panoge.....	38
3.4.2.3.1	Število blokiranih podjetij v panogi	38
3.4.2.3.2	Prihodki panoge.....	39
3.4.3	Opisna statistika spremenljivk	39
3.5	Statistična obdelava in zmanjševanje števila spremenljivk.....	40
3.5.1	Preverjanje ekstremnih vrednosti	40
3.5.2	Preverjanje neodvisnosti opazovanj	41
3.5.3	Preverjanje multikolinearnosti	42
3.5.4	Metoda glavnih komponent.....	43
3.5.5	Preverjanje heteroskedastičnosti	46
3.6	Oblikovanje modela večnivojske linearne regresije za napovedovanje plačilne nediscipline slovenskih podjetij	47
3.6.1	Rezultati	60

SKLEP.....	61
-------------------	-----------

LITERATURA IN VIRI.....	65
--------------------------------	-----------

PRILOGE

KAZALO TABEL

Tabela 1: Porazdelitev podjetij po panogah.....	28
Tabela 2: Korelacijski koeficienti med spremenljivko velikost in odvisno spremenljivko.....	34
Tabela 3: Opisna statistika spremenljivk	39
Tabela 4: Ocene kovariančnih parametrov	41
Tabela 5: Statistika kolinearnosti.....	43
Tabela 6: KMO statistika in Barlettov test.....	44
Tabela 7: Kaiserjevo pravilo.....	45
Tabela 8: Komponentna matrika.....	46
Tabela 9: Multipla linearna regresija, ki ne upošteva časovne odvisnosti med opazovanji	50
Tabela 10: Multipla linearna regresija, ki upošteva časovno odvisnost med opazovanji.....	50
Tabela 11: Parametri – Model 0a.....	50
Tabela 12: Ocena kovariančnih parametrov in kriteriji primerljivosti – Model 0a	51
Tabela 13: Parametri – Model 0b.....	52
Tabela 14: Ocena kovariančnih parametrov in kriteriji primerljivosti – Model 0b	52
Tabela 15: Število parametrov oziroma stopinj prostosti po modelih	53
Tabela 16: Parametri – Model 1.....	54

Tabela 17: Ocena kovariančnih parametrov in kriteriji primerljivosti – Model 1	54
Tabela 18: Parametri – Model 2	55
Tabela 19: Ocena kovariančnih parametrov in kriteriji primerljivosti – Model 2	56
Tabela 20: Parametri – Model 3	57
Tabela 21: Ocena kovariančnih parametrov in kriteriji primerljivosti – Model 3	57
Tabela 22: Parametri – Model 4	59
Tabela 23: Ocena kovariančnih parametrov in kriteriji primerljivosti – Model 4	59
Tabela 24: Povzetek rezultatov večnivojskega modela.....	61

KAZALO SLIK

Slika 1: Vzroki zamud pri plačilih v letu 2016 po regijah (v %)	4
Slika 2: Posledice zamud pri plačilih v letu 2016 po regijah (v %)	6
Slika 3: Število poslovnih subjektov z začetimi postopki zaradi insolventnosti v obdobju 2008– 2017.....	9
Slika 4: Letne spremembe insolventnosti po regijah v obdobju 2016–2018	15
Slika 5: Delež podjetij po državah in plačilnih razredih v letu 2016	17
Slika 6: Delež podjetij v Evropi po dejavnostih in plačilnih razredih v letu 2016	18
Slika 7: Število pravnih oseb z dospelimi neporavnanimi obveznostmi in povprečni dnevni znesek dospelih neporavnanih obveznosti v mesecu januarju v letih 2007–2018.....	19
Slika 8: Število pravnih oseb z dospelimi neporavnanimi obveznostmi nad 5 dni neprekinjeno po področjih dejavnosti v mesecu januarju v letih 2012–2018.....	20
Slika 9: Povprečni dnevni znesek dospelih neporavnanih obveznosti po področjih dejavnosti v mesecu januarju v letih 2012–2018 (v 000 EUR).....	21
Slika 10: Variiranje regresijske konstante, fiksni regresijski koeficienti.....	25
Slika 11: Fiksna regresijska konstanta, variiranje regresijskih koeficientov	25
Slika 12: Variiranje regresijske konstante in regresijskih koeficientov	26
Slika 13: Shematski prikaz modela	30
Slika 14: Normalnost porazdelitve odvisne spremenljivke zamuda – kvantilni verjetostni grafikon	31
Slika 15: Normalnost porazdelitve odvisne spremenljivke zamuda - histogram.....	31
Slika 16: Normalnost porazdelitve odvisne spremenljivke logaritem zamuda – kvantilni verjetostni grafikon	32
Slika 17: Normalnost porazdelitve odvisne spremenljivke logaritem zamuda - histogram.....	32
Slika 18: Diagram lastnih vrednosti	45
Slika 19: Heteroskedastičnost odvisne spremenljivke	47
Slika 20: Koraki razvoja večnivojskega linearnega modela	49

UVOD

Plačilna nedisciplina, ki jo povezujemo z neporavnanimi ali nepravočasno poravnanimi obveznostmi, je v slovenskem poslovnem okolju velik problem. Zaviralno deluje na razvoj podjetij, pri čemer so likvidnostnim težavam najbolj izpostavljena mikro, mala in srednje velika podjetja (STA, 2009). V Sloveniji se plačilna disciplina zadnja leta izboljšuje, vendar so zaradi nestabilnosti podjetij opazna močna nihanja. Delež podjetij, ki zamujajo s plačilom svojih obveznosti, je še vedno večji od polovice (CRIBIS D&B, 2017, str. 110–111). Evropska komisija (2012) ugotavlja, da gre v Evropi zaradi plačilnih zamud vsako leto v stečaj na tisoče malih in srednje velikih podjetij, kar vodi v izgubo številnih delovnih mest.

Pomen upravljanja s tveganjem neplačila je v svetu postal izjemno pomemben ob pojavu finančne in gospodarske krize, ki se je začela s kreditnim krčem leta 2006. Ta je pokazal, da slabe odločitve in podcenjevanje vpliva kreditnega tveganja tako v podjetjih kot v finančnih institucijah vodijo do znatnih izgub. Zmožnost upravljanja s kreditnim tveganjem je večkrat dobro razumljena v teoriji, ampak ne vedno v praksi (Brown & Moles, 2014, str. ix). Zaznavanje in upravljanje tveganja neplačila je tako v svetu kot v Sloveniji ključnega pomena za uspeh podjetja. Obvladovanje kreditnega tveganja v zadnjih petdesetih letih doživlja izjemen razvoj, k čemur so prispevali naslednji dejavniki: porast števila stečajev na svetovni ravni, trend disintermediacije med najbolj kakovostnimi in največjimi izposojevalci, bolj konkurenčne posojilne marže, zmanjševanje tržne vrednosti realnih sredstev in posledično njihovih zavarovanj, povečanje zunajbilančnih postavk in s tem povečana izpostavljenost tveganju neplačila (Altman & Saunders, 1998, str. 1722). Berg (2005, str. 1) kot gonilo razvoja tovrstnih študij izpostavlja stalni razvoj novih izvedenih finančnih inštrumentov, katerih cene so odvisne od ocene tveganja neizpolnitve obveznosti nasprotne stranke. Mramor et al. (1998, str. 1) omenjajo še zaostritev konkurence med finančnimi institucijami in med podjetji, ki deležnikom na trgu onemogoča izbiro samo najkakovostnejših dolžnikov.

Magistrsko delo obravnava tematiko plačilne sposobnosti podjetij za potrebe finančnega odločanja z vidika upnikov oziroma problematiko zamud pri plačilu obveznosti do dobaviteljev. Raziskava je izvedena s pomočjo dokaj nepoznane statistične metode večnivojskega linearnega modeliranja.

Namen magistrske naloge je raziskati in poglobiti znanje predhodnih raziskav s področja plačilne nediscipline, in sicer z vpeljavo tehnike večnivojskega linearnega modeliranja, ki se je v več pogledih izkazala za bolj primerno metodo od pogosteje uporabljenih regresijskih metod, saj odpravlja njihove številne pomanjkljivosti.

Končni model bi koristil zunanjim uporabnikom, ki bi z njegovo uporabo lahko preverili plačilno sposobnost podjetij, s katerimi že sodelujejo oziroma s katerimi želijo sodelovati, oziroma ocenili njihove potencialne zamude pri plačevanju obveznosti. Model, ki bi uspešno napovedoval zamude pri plačilu obveznosti do dobaviteljev, bi znanstveno prispeval k že obstoječim empiričnim ugotovitvam. Za namen zaščite zunanjih uporabnikov se v praksi pojavlja veliko inštrumentov zavarovanja pred plačilno nesposobnostjo kupcev podjetja, vendar pa je učinkovit model napovedovanja zamud s plačili v kombinaciji z nadaljnjimi kvalitativnimi metodami najboljša

rešitev pri prepoznavanju plačilno nesposobnih potencialnih partnerjev. Služi kot odlično sredstvo pri selekcioniranju podjetij oziroma ločevanju dobrih podjetij od slabih.

Glavni cilj magistrske naloge je razviti večnivojski linearni model za ocenjevanje plačilne discipline podjetij ter tako prispevati k empiričnim ugotovitvam s tega področja. Z vključitvijo velikega vzorca podatkov slovenskih podjetij med letoma 2011 in 2015 želim razviti model, ki bi uspešno napovedoval zamudo pri plačilu obveznosti do dobaviteljev in bi ga lahko z vzorca posplošili na populacijo ter bi bil tako uporaben tudi v praksi.

V prvem delu magistrske naloge je uporabljena deskriptivna metoda raziskovanja. Prikazan je pregled tuje in domače strokovne literature, povezane s plačilno nedisciplino. Sledi pregled trenutnega stanja plačilne discipline v Sloveniji in tujini ter pregled že obstoječih modelov za napovedovanje plačilne sposobnosti z uporabo zgodovinske metode raziskovanja.

V praktičnem delu je uporabljen analitični pristop raziskovanja, saj skušam na podlagi danih podatkov dokazati povezavo med odvisno spremenljivko in postopnim uvajanjem neodvisnih spremenljivk na različnih ravneh. V empirični analizi najprej opišem vzorec, predstavim odvisno in neodvisne spremenljivke ter izvedem statistično obdelavo podatkov. Nato z metodo večnivojskega linearnega modeliranja razvijem model za ugotavljanje plačilne sposobnosti podjetij. Model je sestavljen iz pojasnjevalnih spremenljivk na treh nivojih. Na prvem nivoju so predstavljene značilnosti podjetij, ki variirajo v času (po letih), na drugem spremenljivke na ravni podjetja, ki ne variirajo v času, na tretjem pa spremenljivke na nivoju panoge. Raziskava je izvedena s pomočjo statističnega programa SPSS (procedura Linear mixed models).

Magistrsko delo je vsebinsko razdeljeno na dva dela. V prvem delu je opredeljen širši in ožji kontekst plačilne discipline, sledi predstavitev vzrokov, posledic in možnosti zavarovanja pred plačilno nedisciplino. V nadaljevanju so predstavljene ugotovitve preteklih raziskav s področja kreditnega tveganja in plačilne discipline. Prvi del zaključim s predstavitvijo trenutnega stanja plačilne discipline v svetu in Sloveniji ter s predlogi za njeno izboljšanje.

V drugem delu magistrske naloge je najprej predstavljena statistična metoda, na kateri temelji moja raziskava, to je večnivojsko linearno modeliranje. Opisane so prednosti in slabosti izbranega modela v primerjavi z ostalimi regresijskimi tehnikami, ki so pogosto uporabljene v finančnih študijah. Sledi predstavitev odvisne in neodvisnih spremenljivk na več nivojih, predstavitev vzorca. Nato preverim nekatere predpostavke modela in vključenih podatkov, kot so na primer preverba multikolinearnosti, homoskedastičnosti, prisotnosti osamelcev itd. Po potrebi slednje pomanjkljivosti minimiziram s pomočjo ustreznih statističnih metod. Sledi postopni razvoj modela za napovedovanje plačilne nediscipline, predstavitev rezultatov ter možnih omejitev. Magistrsko delo zaključim s sklepom, kjer povzamem glavne ugotovitve raziskave.

1 PLAČILNA NEDISCIPLINA

1.1 Opredelitev plačilne discipline in plačilne sposobnosti

Plačilna nedisciplina je zavlačevanje poravnavanja obveznosti s strani podjetij, ki so sicer sposobna njihovega odplačevanja, vendar jih zaradi različnih razlogov ne poravnajo v roku. Plačilna nesposobnost pa je nezmožnost poravnavanja obveznosti ob njihovi dospelosti zaradi nezadostnega obsega likvidnih sredstev podjetja (Berk, 2004a, str. 80). Podjetje je plačilno sposobno, ko je v vsakem trenutku sposobno pravočasno poravnati svoje dospele obveznosti in je trajno sposobno poravnati vse svoje obveznosti (Jurčič, 2006, str. 135). Delitev plačilne sposobnosti je lahko opredeljena z različnih vidikov, vendar pa se v literaturi največkrat pojavlja časovni kriterij, po katerem plačilno sposobnost razdelimo na kratkoročno in dolgoročno.

Kratkoročna plačilna sposobnost ali likvidnost podjetja je sposobnost podjetja, da v kratkem roku (do enega leta) razpolaga z ustreznimi likvidnimi sredstvi za pravočasno izvedbo dospelih obveznosti, kar podjetje dosega z usklajevanjem denarnih tokov in obvladovanjem z njimi povezanih tveganj (Bergant, 2002, str. 137). Po Kodeksu poslovnofinančnih načel (v nadaljevanju KPFN) (Slovenski inštitut za revizijo, 1996, str. 34) kratkoročno plačilno sposobnost opredelimo kot stanje, ko so prejemki, z vključenim začetnim stanjem denarnih sredstev, v določenem trenutku na kratek rok večji ali vsaj enaki izdatkom, ki zapadejo v plačilo. Podjetje mora biti torej sposobno, da v kratkem roku zagotovi potrebna likvidna sredstva za pravočasno poplačilo obveznosti.

Dolgoročna plačilna sposobnost ali solventnost podjetja je sposobnost podjetja, da kot delujoče podjetje z dolgoročnega vidika obvladuje tveganje pri zagotavljanju kratkoročne plačilne sposobnosti v prihodnosti, kar dosega s povečevanjem finančne moči ter z vzpostavljanjem in vzdrževanjem kapitalske ustreznosti podjetja (Bergant, 2002, str. 137). Pri dolgoročni plačilni sposobnosti torej ocenjujemo, kakšno je tveganje pri zagotavljanju kratkoročne plačilne sposobnosti v prihodnosti (Bergant, 2012, str. 20). Po KPFN (Slovenski inštitut za revizijo, 1996, str. 39) se z dolgoročno plačilno nesposobnostjo srečamo, ko so sredstva podjetja manjša od njegovih dolgov. Podjetje je lahko kratkoročno plačilno sposobno, vendar obstaja tveganje dolgoročne plačilne nesposobnosti. To se zgodi, ko podjetje posluje z izgubo ali ko dolgoročna sredstva financira s kratkoročnimi obveznostmi. Podjetje mora biti z ustrezno poslovno politiko sposobno zagotavljati plačilno sposobnost na dolgi rok.


Kratkoročna in dolgoročna plačilna sposobnost sta povezani oziroma sovplivata druga na drugo. Kratkoročna plačilna sposobnost namreč omogoča poslovanje z dobičkom in ohranjanje kapitalske ustreznosti, kar vpliva na plačilno sposobnost v prihodnosti. Podjetje, ki je dolgoročno plačilno sposobno, bo lažje zagotavljalo tekočo plačilno sposobnost (Bergant, 2012, str. 20–21). Po drugi strani je podjetje v določenem trenutku lahko kratkoročno plačilno sposobno, ampak posluje z izgubo ali dolgoročna sredstva financira s kratkoročnimi obveznostmi. S tem ogroža dolgoročno plačilno sposobnost oziroma povečuje tveganje prezadolženosti, ki nastopi, ko je premoženje podjetja manjše od njegovih obveznosti. Možno je tudi, da ima podjetje ustrezno strukturo financiranja in posluje z dobičkom, vendar pa kljub temu ni kratkoročno plačilno sposobno (Jurčič, 2006, str. 136).

1.2 Vzroki za nastanek plačilne nediscipline

Plačilna nedisciplina je posledica številnih, med seboj prepletenih vzrokov. Med najpomembnejšimi je problem strukture trga, kjer peščica najmočnejših igralcev, povezanih z državo kot največjim investitorjem, obvladuje trg, kopica manjših igralcev pa je prisiljena sprejeti neugodne plačilne pogoje, da sploh dobijo posel (Možina, 2011, str. 9). Poleg tega upniki velikokrat niso nagnjeni k izvrševanju sankcij za plačilne zamude, saj bi v nasprotnem primeru ogrozili dobre poslovne odnose s svojimi strankami. Plačilno nedisciplino povzročata tudi otežen dostop do financ in kreditov ter posledično likvidnostne težave podjetij (Komisija Evropskih skupnosti, 2009, str. 2–3). Poleg tega, da je v Sloveniji močno prisotno nespoštovanje pogodbenih obveznosti, k povečanju plačilne nediscipline pripomorejo tudi počasni sodni postopki, ki kot taki ne delujejo kot spodbuda k hitremu poravnavanju obveznosti (Možina, 2011, str. 9). Berk (2004b, str. 79) opozarja tudi na to, da se v praksi ne uveljavlja odškodninska odgovornost uprav družb, saj je članom uprave zelo težko dokazati kršenje zakonodaje in neizvajanje primernih ukrepov ob pojavu finančnih težav. Pri analiziranju vzrokov plačilne nediscipline se pojavi tudi vprašanje etičnih vrednot podjetij. Podjetje deluje etično, ko ne gleda le na lastno dobičkonosnost, ampak obenem upošteva družbene posledice svojih dejanj. Pri tem mora težiti k maksimiranju pozitivnega in zmanjševanju negativnega vpliva na okolico (Ferrell & Hirt, 2003, str. 32). Podjetja, ki se obnašajo neetično, so plačilno sposobna, vendar namenoma zamujajo s plačili ter tako zmanjšujejo potrebo po novih virih financiranja (Berk, 2005).

Slika 1 prikazuje izsledke raziskave vzrokov zamud pri plačilih v Evropi, izvedene s strani podjetja Intrum Justitia (2016, str. 12). Prikazani so vzroki plačilne nediscipline po regijah. Finančne težave dolžnikov so najbolj problematične v državah južne Evrope, kjer beležijo tudi največ namernega zamujanja s plačili, ki je sicer drugi najpogostejši razlog plačilnih zamud v celotni Evropi. Administrativna neučinkovitost kupcev je prisotna predvsem v državah severne Evrope, nespornosti glede dobave dobrin pa prednjačijo v vzhodni Evropi (Intrum Justitia, 2016, str. 12).

Slika 1: Vzroki zamud pri plačilih v letu 2016 po regijah (v %)



Vir: Intrum Justitia, *European Payment Report 2016*, 2016, str. 12.

Vključena slovenska podjetja kot glavni razlog plačilne nediscipline navajajo finančne težave dolžnikov (75 % podjetij), sledi namerno zamujanje s plačili (69 % podjetij), administrativna neučinkovitost (35 % podjetij) in nesporazumi glede dobavljenega blaga oziroma storitev (14 % podjetij) (Intrum Justitia, 2016, str. 42).

1.3 Posledice zamujanja s plačili za dolžnika in upnika

Kot ugotavlja Evropski ekonomsko-socialni odbor (Ur.l. EU, C255, str. 43–44), zamude pri plačilih:

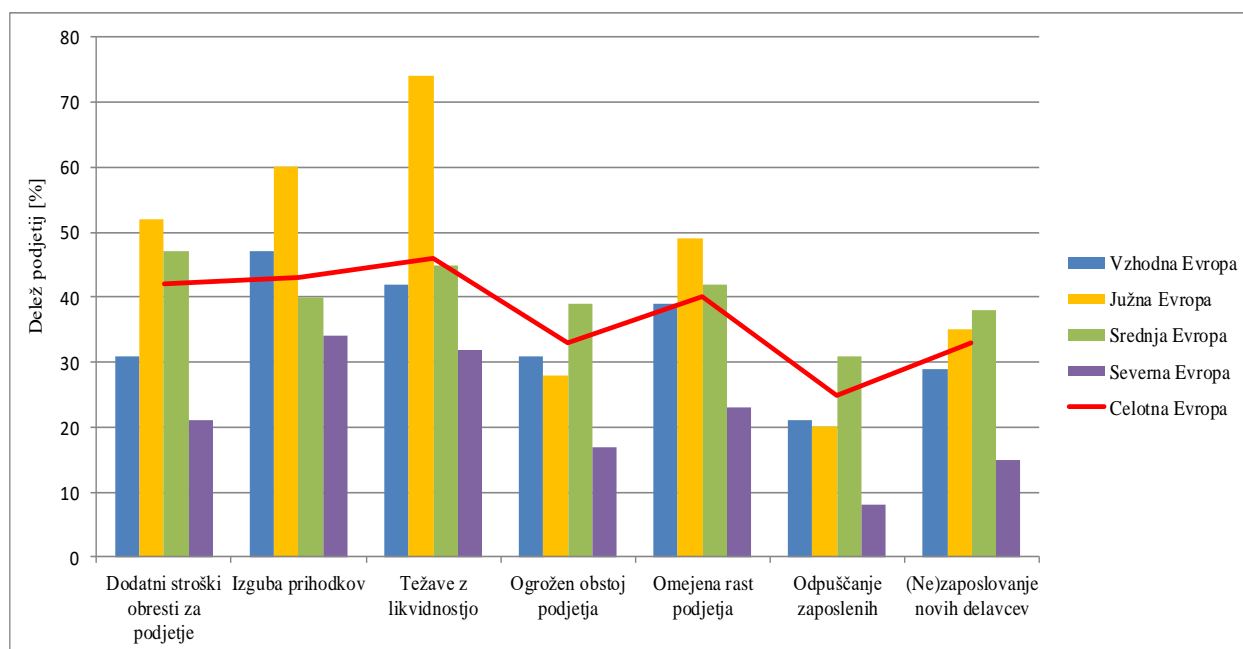
- povečujejo negotovost poslovanja in otežujejo finančno upravljanje upniškim podjetjem, zlasti malim in srednje velikim podjetjem, ter jim povzročajo dodatne neposredne stroške ter oportunitetne stroške izgubljenih naložb;
- vodijo v nadaljnje zamude pri plačilih in stečaje posameznih – sicer preživetja sposobnih – podjetij ali v verižne stečaje v celotni dobavni verigi, ki imajo občutne negativne posledice na celotno gospodarstvo;
- neugodno vplivajo na trgovino znotraj Evropske skupnosti, saj vplivajo na percepcijo podjetij, da poslovanje s podjetji iz drugih držav članic pomeni večje tveganje zamud pri plačilih, kar povečuje stroške in nezaupanje do trgovinskih poslov;
- v primeru plačilnih zamud javnih organov lahko prispevajo h korupciji, in sicer v smislu pospešitve plačevanja obveznosti, vezanih na javna naročila;
- v primeru plačilnih zamud in dolgih plačilnih rokov javnih organov odvrčajo gospodarske subjekte od prijave na javne razpise. To povzroča izkrivljanje konkurence ter manj učinkovito porabo javnih sredstev.

Negative posledice pa ne doletijo le dolžniške družbe, ampak tudi njene družbenike. Če ti ne delujejo v skladu z Zakonom o finančnem poslovanju, postopkih zaradi insolventnosti in prisilnem prenehanju (Ur.l. RS, št. 13/2014-UPB8, 10/2015-popr., 27/2016, 31/2016-odl. US, 38/2016-odl. US, 63/2016-ZD-C, v nadaljevanju ZFPPIPP), so namreč lahko osebno odškodninsko odgovorni. Če družba po ZFPPIPP postane plačilno nesposobna, je razen nujnih stroškov za redno poslovanje prepovedano prevzemanje kakršnihkoli novih obveznosti. Prepovedano je tudi vsakršno odplačevanje dolgov, saj bi to pomenilo neenakovreden položaj upnikov. Če lastniki podjetja niso pripravljeni vložiti novega kapitala, mora vodstvo podjetja v točno določenem roku sestaviti poročilo o finančnem prestrukturiranju s potrebnimi ukrepi za morebitno prisilno poravnavo oziroma razglasiti stečaj podjetja. Če družbenik ne upošteva zakonsko predpisanih postopkov, je odgovoren za škodo, ki bi jo v stečajnem postopku utrpeli upniki. To pomeni, da mora odškodninsko odgovarjati za terjatve svojih upnikov, zaradi česar mu lahko grozi tudi osebni stečaj (Raktelj, 2011).

Podjetje Intrum Justitia (2016) v svoji raziskavi, izvedeni med evropskimi podjetji, ugotavlja, da posledice plačilne nediscipline najbolj občutijo v južni Evropi, najmanj pa v severni Evropi. Likvidnostne težave podjetij so najpogostejša posledica plačilne nediscipline, in sicer se s tem problemom v Evropi srečuje 46 % anketiranih podjetij, v južni Evropi celo 74 % podjetij. Problematična je tudi izguba dohodkov kot posledica plačilnih zamud oziroma neplačil, ki jo občuti 43 % evropskih podjetij. Ogroženost obstoja podjetij kot posledica plačilne nediscipline je

s 39 % pritrdilnih odgovorov najbolj prisotna v državah srednje Evrope. Med posledicami plačilnih zamud, ki med evropskimi državami prav tako variirajo, je tudi odpuščanje zaposlenih ter omejeno zaposlovanje novih kadrov. Četrtnina vseh vprašanih podjetij meni, da ima plačilna nedisciplina občuten vpliv na odpuščanje zaposlenih, tretjina pa vidi njen negativen vpliv na zaposlovanje novih delavcev. Rezultati zaznavanja posledic plačilne nediscipline po evropskih regijah so razvidni s Slike 2.

Slika 2: Posledice zamud pri plačilih v letu 2016 po regijah (v %)



Vir: Intrum Justitia, European Payment Report 2016, 2016, str. 7, 13.

Po podatkih podjetja Intrum Justitia slovenska podjetja med posledicami plačilne nediscipline najbolj pestijo izguba prihodkov, likvidnostne težave in omejena rast podjetij, najmanj pa odpuščanje zaposlenih (Intrum Justitia, 2016, str. 42).

Plačilna nedisciplina je za dolžnika posebej problematična, če je posledica plačilne nesposobnosti, saj se vse bolj stopnjuje in povzroča verižno kopičenje dolgov in terjatev. Za plačilno nesposobna podjetja zamujanje s plačili namreč postaja vse pomembnejši zunanji vir financiranja (Berk, 2004a, str. 80). Ta problematika je bila v Sloveniji prisotna v času finančne in gospodarske krize, saj so bila slovenska podjetja takrat zelo zadolžena. V obdobju rasti in povečanega povpraševanja po letu 2002 so namreč veliko investirala in se zato pospešeno zadolževala. Leta 2008 je finančni vzvod dosegel 165 %. Tako so podjetja zaradi povečanih stroškov zadolževanja postala občutljivejša na nihanje denarnega toka. To je postalo posebej problematično ob zaostritvi razmer, ko je povpraševanje po proizvodih in storitvah upadlo, pridobivanje novih virov financiranja pa postalo oteženo (Vlada Republike Slovenije, 2011, str. 2). Zadolženost slovenskih podjetij se je sicer v zadnjih letih močno znižala. Banka Slovenije (Banka Slovenije, 2015, str. 15) ugotavlja, da je razmerje med dolžniškim in lastniškim financiranjem 120-odstotno, vendar je zadolženost podjetij še vedno nad evropskim povprečjem. Plačilna nesposobnost podjetij privede do blokad računov ter v skrajnem primeru do zaprtja podjetja zaradi insolventnosti.

1.3.1 Blokade transakcijskih računov

Blokada transakcijskega računa podjetja vpliva na njegovo boniteto, dobro ime in povzroča slabše plačilne pogoje, otežen dostop do virov financiranja ter izgubo poslovnih partnerjev. Dolgotrajna blokada lahko vodi do zaprtja podjetja zaradi insolventnosti (NLB d.d., 2014).

Blokada računa nastane, ker podjetje ne poravnava obveznosti do davčnega organa oziroma upravičencev, zastopanih s strani davčne uprave, ali ker podjetje ne opravlja plačil poslovnim upnikom. Neporavnane obveznosti do davčne uprave z davčno izvršbo ureja Zakon o davčnem postopku (Ur.l. RS, št. 13/2011-UPB4, 32/2012, 94/2012, 101/2013-ZDavNepr, 111/2013, 25/2014-ZFU, 40/2014-ZIN-B, 90/2014, 91/2015, 63/2016, 69/2017, v nadaljevanju ZDavP-2), neporavnane obveznosti do poslovnih upnikov pa Zakon o izvršbi in zavarovanju (Ur.l. RS, št. 3/2007-UPB4, 93/2007, 37/2008-ZST-1, 45/2008-ZArbit, 28/2009, 51/2010, 26/2011, 17/2013 Odl. US, 45/2014 Odl. US, 53/2014, 54/2014 Odl. US, 54/2015, 76/2015 Odl. US, v nadaljevanju ZIZ). V obeh primerih se postopek izterjave začne z izdajo sklepa o izvršbi. Sklep o izvršbi izdada davčna in carinska uprava oziroma sodišče, in sicer na predlog poslovnega upnika. Poslovni upnik lahko izvršbo doseže z zahtevo na spletnem portalu e-sodstvo ali preko sodnega postopka, ki pa je dražji in dolgotrajnejši (NLB d.d., 2014). Ponudnik plačilnih storitev, pri katerem ima dolžnik odprt račun, s prejemom sklepa o izvršbi zarubi dolžnikova denarna sredstva v višini, ki je določena v izvršbi. Če sredstva na računu primarne banke ne zadoščajo za poplačilo dolga in z izvršbo povezanih stroškov, primarna banka o izvršbi obvesti druge banke, pri katerih ima dolžnik odprte transakcijske račune. Ostale banke nato izvedejo prenos sredstev na primarno banko. Primarna banka izvrši prenos sredstev na davčni organ oziroma račun poslovnega upnika. Če primarna banka tudi s pomočjo ostalih bank dolžnika ne zbere dovolj sredstev za poplačilo upnikov, te poplača delno, dolžniku pa blokira račun (Moti, 2013).

V primeru blokade so do poplačila vseh dolgov predmet izvršbe vsi denarni prejemi dolžnika, razen prejemkov, ki so v 159. in 160. členu ZDavP-2 oziroma v 101. do 103. členu ZIZ izvzeti iz davčne izvršbe. Te omejitve veljajo le za izplačila upnikom, ne pa tudi za stroške izvršbe, ki jih dolžniku zaračuna banka. Ker so stroški obdelave postopka izvršbe in nakazil zelo visoki, predvsem v primeru poslovnih upnikov pa je tudi sam postopek dolgotrajen, se za upnika in dolžnika bolj splača, da skleneta medsebojni dogovor pred začetkom izvršbe ali dogovor o deblokadi računa pred polnim poplačilom upnika. Takšen dogovor je v odnosu dolžnika do davčne uprave težko dosežen. Rešitev plačilnih težav med upnikom in dolžnikom je tudi vključitev v večstranski pobot (NLB d.d., 2014).

Agencija Republike Slovenije za javnopravne evidence in storitve (v nadaljevanju Ajpes) vodi register transakcijskih računov, kjer v skladu s 144. členom Zakona o plačilnih storitvah in sistemih (Ur.l. RS, št. 58/2009, 34/2010, 9/2011, 32/2012, 81/2015, v nadaljevanju ZPlaSS) za vse gospodarske subjekte zagotavlja informacijo o tem, ali sredstva na posameznem transakcijskem računu imetnikov zadoščajo za izvršitev sklepa o izvršbi. Če ta pogoj ni izpolnjen, to pomeni blokado računa. Poleg tega Ajpes vodi mesečno evidenco dospelih neporavnanih obveznosti nad 5 dni neprekinjeno za pravne osebe ter podjetnike, kar kaže na gospodarske subjekte, ki so imeli v določenem mesecu blokiran enega ali več transakcijskih računov. 144. člen ZPlaSS bo 30. junija 2018 sicer nadomeščen z novim Zakonom o plačilnih storitvah, storitvah izdajanja elektronskega

denarja in plačilnih sistemih (Ur.l. RS, št. 7/2018, 9/2018-popr., v nadaljevanju ZPlaSSIED), kot določa 335. člen ZPlaSSIED. Tovrstna statistika je podrobneje predstavljena v Poglavju 2.2, informacija o blokadah transakcijskega računa podjetij pa je kot spremenljivka vključena tudi v model, ki je predstavljen v praktičnem delu magistrskega dela.

1.3.2 Postopki zaradi insolventnosti

Po 5. členu ZFPPIPP med postopke zaradi insolventnosti pravnih oseb uvrščamo postopka prisilne poravnave ter poenostavljene prisilne poravnave in stečajni postopek nad pravno osebo. Vsi insolvenčni postopki se začnejo, če dolžnik po 14. členu ZFPPIPP postane insolventen in so namenjeni ureditvi razmerij med insolventnim dolžnikom in njegovimi upniki, pri čemer dolžnik nima zadostnih sredstev za poplačilo vseh dolgov.

1.3.2.1 Prisilna poravnava

Prisilna poravnava se izvede z namenom finančnega prestrukturiranja insolvenčnega dolžnika. Cilj je doseči uspešno nadaljevanje poslovanja, torej kratkoročno in dolgoročno plačilno sposobnost dolžnika. Za začetek postopka se odloči dolžnik sam, vendar mora pri tem pridobiti soglasje upnikov. Upniki se za prisilno poravnavo odločijo, če dosežejo ugodnejše poplačilo terjatev kot v primeru stečaja nad dolžnikom. Če prisilna poravnava ni potrjena, se po ZFPPIPP začne stečajni postopek nad dolžnikom (Finančna uprava Republike Slovenije – v nadaljevanju FURS, 2015).

1.3.2.2 Poenostavljena prisilna poravnava

Postopek poenostavljene prisilne poravnave je podoben navadni prisilni poravnavi, le da je zasnovan preprosteje in bolj učinkovito. Namenjen je mikro in malim podjetjem ter samostojnim podjetnikom, ki ustrezajo tem merilom. V nasprotju s prisilno poravnavo se pri poenostavljeni prisilni poravnavi ne oblikuje upniški odbor, prav tako se ne imenuje upravitelja. Terjatev ne prijavijo upniki, pač pa posodobljeni seznam terjatev predloži dolžnik. Če postopek ni potrjen, se nad dolžnikom ne začne stečajni postopek. Poenostavljena prisilna poravnava je v primerjavi s prisilno poravnavo za dolžnika ugodnejša, hkrati pa prinaša omejen nadzor nad njegovimi dejanji (FURS, 2015).

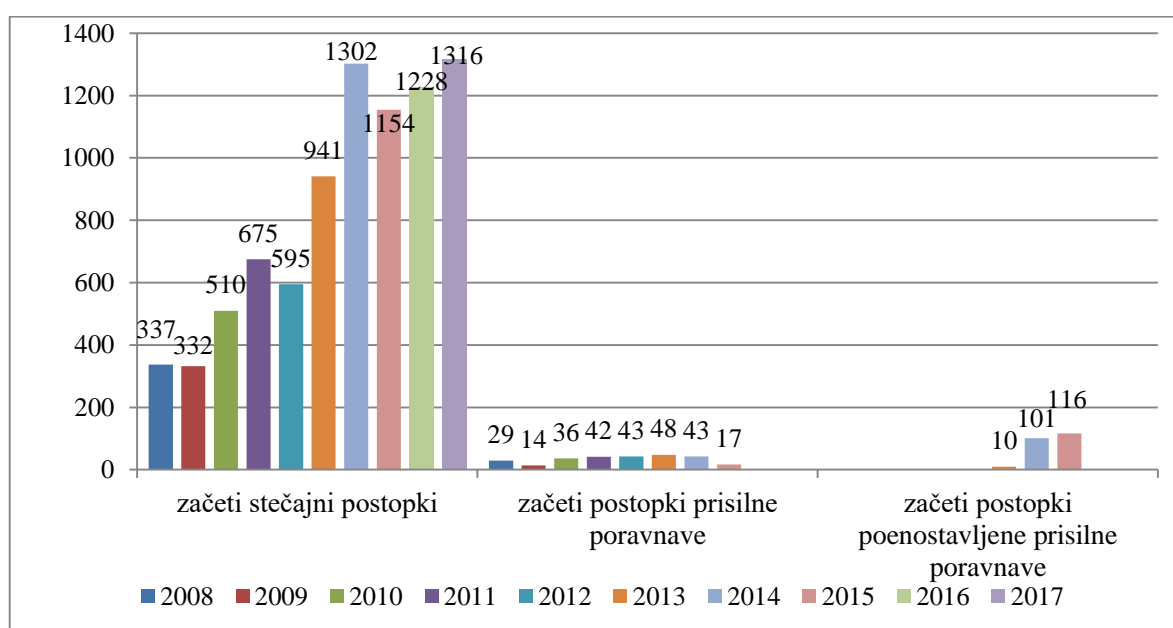
1.3.2.3 Stečaj

Stečaj nad pravno osebo se izvede z namenom pravične razdelitve premoženja upnikom iz stečajne mase dolžnika, po končanem postopku pa dolžnik preneha s poslovanjem. Postopek lahko predlaga dolžnik ali upniki, pri čemer imajo slednji tri mesece časa, da prijavijo svoje terjatve. Določi se tudi stečajnega upravitelja, naloga katerega je unovčenje stečajne mase, kar pomeni izterjavo terjatev dolžnika, prodajo njegovega premoženja itd. Po začetku stečajnega postopka dolžnik s poslovanjem nadaljuje le izjemoma, in sicer če pridobi dovoljenje sodišča (FURS, 2015).

Slika 3 prikazuje število pravnih oseb z začetimi postopki zaradi insolventnosti po letih, in sicer od leta 2008 do leta 2017. Razviden je hiter porast stečajev, predvsem po letu 2012, ko se je število začetih stečajnih postopkov v dveh letih povečalo za skoraj 120 % in svoj vrhunec doseglo leta 2017.

Razlog za rast števila začetih stečajnih postopkov je – poleg propadlih poslov – sprememba zakonodaje leta 2013, ki določa, da je podjetje, ki samo sproži stečaj, oproščeno plačila predujma (Šimac, 2015). ZFPPIPP poleg tega od leta 2013 v 14. členu določa novo merilo insolventnosti po kriteriju blokade računov, ki upnikom omogoča lažje dokazovanje plačilne nesposobnosti dolžnikov. Število prisilnih poravnav je začelo upadati že leta 2014, vendar predvsem na račun uvedbe postopka poenostavljene prisilne poravnave v letu 2013, ki je zamenjal navadno prisilno poravnavo med mikro in malimi podjetji. Skupno število začetkov poenostavljene in navadne prisilne poravnave je začelo upadati šele leta 2015, medtem ko se število stečajev v zadnjih treh letih ponovno povečuje. Po podatkih Ajpesa je bilo v letu 2017 nad gospodarskimi subjekti začetih 1366 insolvenčnih postopkov, kar je 2 % več kot v letu 2016.

Slika 3: Število poslovnih subjektov z začetimi postopki zaradi insolventnosti v obdobju 2008–2017



Vir: Ajpes, Poslovni subjekti z začetimi postopki zaradi insolventnosti v letih 2008 do 2017, 2017.

1.4 Zavarovanje pred tveganjem neplačila

Da se izognemo neplačilu in njegovim posledicam oziroma te omilimo, se je za takšne primere vedno priporočljivo zavarovati. Tveganju neplačila se povsem izognemo s prodajo s predplačilom, ki pa je v Sloveniji zelo redka. Tako obliko plačila si lahko zagotovijo samo podjetja, ki imajo zaradi ponudbe nižnih proizvodov ali storitev na trgu monopolni ali oligopolni položaj in podjetja s proizvodi, katerih stroški logistike so relativno visoki glede na njihovo vrednost (Krašovec, 2008). Na trgu so se oblikovali različni načini zavarovanj pred tveganjem neplačila, pri čemer so eni bolj, drugi manj stroškovno učinkoviti. Poznamo prodajo terjatev (cesijo), zavarovanje terjatev in oblikovanje rezervacij za primer neplačila (Krašovec, 2008).

Z namenom dodatne zaščite upnika je bil z nastopom Zakona o preprečevanju zamud pri plačilih (Ur.l. RS, št. 18/2011, 57/2012, v nadaljevanju ZPreZP-1) v šestem poglavju uveden instrument izvršnica. Gre za listino, s katero se dolžnik zaveže izplačati znesek, ki je določen v izvršnici.

Listino lahko izda gospodarski subjekt ali javni organ. Upnik lahko ob zapadlosti obveznosti zahteva plačilo z izvršnico določenega zneska, in sicer v breme denarnih sredstev, vodenih na kateremkoli dolžnikovem transakcijskem računu pri bankah (ZPreZP-1). Za razliko od menice je banka primorana izplačati sredstva z naslova izvršnice, ko ta prispejo na dolžnikov račun (Nov instrument zoper plačilno nedisciplino, 2012).

Svoje potencialne poslovne partnerje je priporočljivo preveriti že pred sklenitvijo posla, in sicer s preverbo podjetju specifičnih dejavnikov, kot so zadolženost, dobičkonosnost in kapitalska moč, prav tako je priporočljivo preveriti tveganost panoge, v kateri posamezni morebitni partner deluje. Na podlagi teh informacij se podjetje odloči, ali bo s potencialnim poslovnim partnerjem sklenilo posel, prav tako je tudi v bodoče treba nenehno spremljati morebitne spremembe kakovosti poslovnih partnerjev. Pomembno je, da delež nezavarovanih terjatev ne ogroža poslovanja in finančne stabilnosti podjetja ter da ima podjetje vzpostavljen dober sistem opozarjanja, opominjanja in izterjave (Bertoncelj, 2015).

1.5 Pretekle raziskave s področja kreditnega tveganja in plačilne discipline

V preteklosti se je kot pomoč zunanjim uporabnikom pri napovedovanju plačilne nediscipline in njenih posledic zvrstilo veliko raziskav. Pod pojmom zunanji uporabniki so mišljeni deležniki kot so: finančne institucije, poslovni partnerji, investitorji, bonitetne hiše in finančni analitiki. V primerjavi s poslovodstvom proučevanega podjetja zunanji uporabniki niso v privilegiranem položaju, saj razpolagajo z manjšim številom informacij o podjetju, ki niso vedno verodostojne. Običajno so jim namreč na razpolago le računovodski izkazi in poslovna poročila, če so podjetja zavezana za njihovo javno objavo, poleg tega je vprašljiva verodostojnost računovodskih izkazov podjetij, ki niso zavezanci za revizijo. Zunanji deležniki se običajno ukvarjajo s preučevanjem več podjetij hkrati, zato je potreben hiter vpogled v njihovo trenutno finančno stanje ter predvideno stanje v prihodnosti (Bergant, 2012, str. 253–254). Za ta namen so se in se še razvijajo številni modeli, tako v Sloveniji kot na mednarodni ravni.

Altman (1968) je s svojo Z-score diskriminantno analizo pionir na področju modeliranja kreditnega tveganja, v literaturi pa je nasploh mogoče najti velik nabor študij različnih avtorjev. Te se večinoma usmerjajo v preučevanje stečajev (Altman, 1968; Ohlson, 1980; Aziz & Dar, 2004; Berg, 2005; idr.), kapitalske ustreznosti (Bergant, 2012) in blokad transakcijskega računa (Mramor et al., 1998; Mramor & Valentinčič, 2003). Najti je mogoče tudi študije, osredotočene na zamude pri plačilu obveznosti do dobaviteljev (Carling, Jacobson, Lindé, & Roszbach, 2007; Javoršek, 2007; Šalamon & Meško, 2015).

V osnovi ločimo dve vrsti modelov za ocenjevanje kreditnega tveganja: računovodske in tržne modele. Računovodski modeli temeljijo na podatkih, zbranih iz finančnih izkazov podjetij, tržni modeli pa na tržni vrednosti podjetij, pridobljeni na finančnih trgih (Agarwal & Taffler, 2008).

Apergis, Sorros, Artikis in Zizis (2011, str. 689) ugotavljajo, da je za napovedovanje stečajev podjetja v praksi najpogosteje uporabljena metodologija, ki izhaja iz prvega računovodskega modela, tj. Altmanovega z-score modela iz leta 1968. Gre za linearni model, ki temelji na petih kazalnikih, ki so s pomočjo diskriminantne analize ponderirani tako, da maksimirajo

napovedovalno moč modela. Po Altmanu med bolj znanimi raziskavami, ki temeljijo na računovodskih izkazih, sledijo Ohlson (1980), Bernhardsen (2001), Carling et al. (2007), idr. Tovrstni modeli so deležni nekaterih kritik, kar je tudi prispevalo k razvoju modelov, ki temeljijo na tržni vrednosti podjetij.

Agarwal in Taffler (2008) med kritikami navajata dejstvo, da rezultati računovodskih modelov temeljijo na vzorcu enot ter je zato njihova posplošitev na populacijo velikokrat vprašljiva. Poleg tega ne vključujejo realne tržne rasti ter nimajo zadostnega teoretičnega ozadja. Dejstva, ki pod vprašanje postavljajo njihovo verodostojnost, so povezana z naravo računovodskih izkazov. Ti namreč predstavljajo preteklo poslovanje podjetja in zato niso nujno dobri v napovedovanju prihodnosti. Poleg tega se zaradi njihovega zgodovinskega pristopa resnična tržna vrednost lahko močno razlikuje od računovodske vrednosti, računovodske informacije pa so lahko manipulirane s strani managementa podjetja.

Kljub nekaterim kritikam avtorja Agarwal in Taffler (2008) navajata tudi številne argumente v prid računovodskim izkazom:

- Stečaji podjetij običajno niso nenadni dogodki, pač pa so odraz slabega poslovanja več zaporednih let, kar se odraža v računovodskih izkazih podjetij. Zelo redko se zgodi, da podjetje z dobrimi finančnimi izkazi propade zaradi nenadne spremembe v poslovnem okolju.
- Dvostavni sistem v računovodstvu zagotavlja, da prilagoditve izkazov in spremembe računovodskih usmeritev ne vplivajo bistveno na končne informacije.
- Posojilne pogodbe so načeloma vezane na računovodske postavke, kar se bolje odraža v modelih, ki temeljijo na računovodskih kazalcih.

Med prve avtorje modelov, ki temeljijo na tržnih informacijah, se uvrščajo Black in Scholes (1973) ter Merton (1974). Black in Scholes (1973) sta razvila tržni model za vrednotenje evropskih opcij, Merton (1974) pa je slednjega razširil na vrednotenje dolga oziroma kreditnega tveganja. Osnovna ideja modela je, da do neplačila (in stečaja) podjetja pride, če je ob zapadlosti dolga (brezkuponskih obveznic) tržna vrednost sredstev podjetja nižja od nominalne vrednosti njegovih obveznosti. Pri tem je lastniški kapital obravnavan kot nakupna (angl. *Call*) opcija na sredstva podjetja z izvršilno ceno, enako nominalni vrednosti dolga (Agarwal & Taffler, 2008). Mertonov model je služil kot osnova številnim tržnim modelom napovedovanja stečajev podjetij, ki so sledili: Hillegeist, Keating, Cram in Lundstedt (2004), Reisz in Perlich (2007), Vassalou in Xing (2004), Campbell, Hilscher in Szilagyi (2008), idr.

Modeli, ki temeljijo na tržnih informacijah, verjetnost stečaja povezujejo s sistematičnim tveganjem podjetja, ki je vključeno v njegovo tržno kapitalizacijo. Po tej logiki naj bi podjetja, ki imajo veliko verjetnost stečaja, v zameno za veliko tveganost delničarjem prinašala večje donose (Apergis et al., 2011, str. 689).

Prednosti v prid modelom, ki temeljijo na tržni vrednosti podjetij, so naslednji (Agarwal & Taffler, 2008):

- Na učinkovitih trgih kapitala borzna cena dobro odraža vse informacije, zajete v računovodskih izkazih, poleg tega pa tudi informacije, ki jih v računovodskih izkazih ne najdemo.
- Teoretično ozadje je močnejše.
- V nasprotju z računovodskim pristopom tržne informacije niso pod vplivom računovodskih usmeritev.
- Ker tržne informacije odražajo pričakovane denarne tokove, bi morale biti primernejše za napovedovanje prihodnosti.
- Rezultat raziskav, temelječih na tržnih informacijah, ni časovno ali vzorčno omejen.

V literaturi je mogoče najti tako raziskave, ki preferirajo tržne modele (Kealhofer, 2003; Oderda, Dacorogna, & Jung, 2003; Hillegeist et al., 2004), kot tudi tiste, ki dokazujejo večjo uspešnost računovodskih modelov (Campbell et al., 2008). Reisz in Perlich (2007) ugotavljata, da so računovodski modeli uspešnejši pri napovedovanju stečajev na kratek rok (do enega leta), tržni modeli pa na dolgi rok (za obdobje od treh do desetih let). Agarwal in Taffler (2008) ugotavljata, da kljub majhni razliki v napovedovalni moči modelov lahko nastajajo velike razlike v ekonomskem učinku uporabnika modela. Čeprav se napovedovalna moč med tržnimi in računovodskimi modeli ne razlikuje bistveno, pa tržni modeli prinašajo veliko višje stroške, povezane z napačnimi klasifikacijami (napaka tipa I in II), ter zato manjšo profitabilnost uporabnikov tovrstnih modelov. Niti tržni niti računovodski model ni zadostno statistično orodje za napovedovanje stečajev podjetij, vendar oba nosita edinstvene informacije, ki so uporabni pokazatelji potencialnih težav podjetja. Sama uporabim model, ki temelji na računovodskih izkazih podjetij. Neodvisne spremenljivke so za odvisno spremenljivko zamaknjene za eno leto, za kar so po Reisz in Perlich (2007) bolj primerni računovodski modeli. Ti so pri napovedovanju na krajši rok, do enega leta, uspešnejši od tržnih. Poleg tega moja raziskava vključuje tudi podjetja, ki ne kotirajo na finančnih trgih ter zato nimajo dostopnih tržnih informacij.

Na tematiko plačilne nediscipline je bilo v preteklosti narejenih veliko raziskav, vendar predvsem povezanih s proučevanjem stečajev podjetij, v slovenskem prostoru pa se je velik poudarek namenilo tudi blokadam transakcijskega računa. Med študijami, ki se osredotočajo na zamude pri plačilu, najdemo nekaj domačih in tujih raziskav, kot na primer Prašnikar, Pahor in Cirman (2004), Bonfim (2006), Carling et al. (2007), Javoršek (2007), Brezigar-Masten, Masten in Volk (2015), Šalamon in Meško (2015), idr. Med njimi se nekatere osredotočajo na zamujene obveznosti do bank, druge pa na zamude do dobaviteljev. Slednje so tudi predmet raziskovalnega dela moje magistrske naloge.

Prašnikar et al. (2004, str. 52) so v raziskavi, ki temelji na vzorcu 191 slovenskih podjetij, ugotovili, da so plačilne zamude v Sloveniji vezane predvsem na tveganja, ki nastanejo pri poslovanju s podjetji v finančni stiski, pri čemer so izpostavili poslovanje z majhnimi podjetji. Bolj kot so podjetja zadolžena, daljše plačilne zamude imajo. Pri daljših plačilnih rokih so zamude pri plačilih krajše, vendar pa si jih večinoma lahko izpogajajo le večja podjetja, ki imajo večjo pogajalsko moč. Večja podjetja si tako lahko izpogajajo tudi večje popuste za takojšnja plačila ter

so posledično bolj motivirana za pravočasno poravnavanje obveznosti. Dlje kot s plačili zamujajo kupci podjetja, večja je verjetnost, da bo tudi podjetje svoje obveznosti plačevalo z zamudo.

Šalamon in Meško (2015, str. 42), ki sta proučevali zamude slovenskih podjetij s pomočjo dejavnikov na ravni podjetja in dejavnosti, ugotavljata, da na povprečni čas zamude plačila vplivajo zadolženost, dobičkonosnost in blokade TRR podjetja ter delež podjetij z blokiranimi računi v panogi.

Carling et al. (2007) so se usmerili v proučevanje vpliva podjetjem specifičnih in makroekonomskih dejavnikov na njihovo plačilno nedisciplino pri odplačevanju kreditov. Raziskavo so izvedli na vzorcu 54.603 švedskih podjetij z uporabo četrletnih podatkov v obdobju 6 let, vključili so primerjavo med različnimi panogami. Uporabili so t.i. model trajanja, ki meri čas do pojava neplačila pri odplačevanju kredita. Pri tem so kot kriterij neplačila postavili mejo 60 dni zamude s plačili, ki jih banka po vsej verjetnosti nikoli ne bo izterjala. Ugotavljajo, da vključitev makroekonomskih dejavnikov, ki so razlika med ocenjenim in dejanskim bruto domačim proizvodom (v nadaljevanju BDP), krivulja donosnosti in pričakovanja kupcev glede prihodnjega stanja gospodarstva pomembno izboljšajo pojasnjevalno moč modela. Model, ki vključuje samo dejavnike na ravni podjetja, sicer dovolj natančno rangira podjetja v določene razrede tveganosti, z vključitvijo makroekonomskih dejavnikov pa je možno določiti absolutno raven kreditnega tveganja oziroma tveganja neplačila. Tveganje neplačila je sicer občutno večje za kratkoročna posojila v primerjavi z dolgoročnimi, kar je v skladu s splošnim mnenjem, da imajo varnejša podjetja lažji dostop do dolgoročnih posojil.

Bonfim (2006) je izvedel raziskavo na vzorcu 30.000 portugalskih podjetij, pri čemer je proučeval zamude pri odplačevanju kreditov, danih s strani portugalskih bank. Ugotavlja, da je tveganje neplačila v veliki meri pogojeno s tveganjem na ravni podjetja, vendar pa vključitev časovnega dejavnika in sistematičnega tveganja, ki hkrati vpliva na vsa podjetja, izboljša napovedno moč modelov. Sistematično tveganje je izraženo z makroekonomskimi spremenljivkami, med katerimi so najpomembnejše rast BDP, rast izdanih posojil, obrestna mera na posojila in sprememba borznih cen. Uporabljeni probit modeli so prav tako kot pri Carling et al. (2007) modeli trajanja. Pojasnjujejo, zakaj podjetja zamujajo z odplačevanjem kredita in kdaj je največja verjetnost, da se bo to zgodilo. Avtor ugotavlja, da verjetnost neplačila narašča prva 4 leta od ustanovitve podjetja, nato pa se ta verjetnost zmanjšuje, pri čemer se nabor pojasnjevalnih spremenljivk pri start-up podjetjih nekoliko razlikuje od tistih pri zrelih podjetjih. Podjetja, ki so s plačili zamujala v preteklosti, imajo večjo verjetnost plačilne nediscipline v prihodnosti, kot podjetja, kjer zamuda še ni bila zabeležena. Nedavno poslovanje podjetja ima na sedanjo plačilno disciplino večji vpliv kot njegovo zgodovinsko ozadje. Uporabljene neodvisne spremenljivke, z izjemo stopnje investiranja, namreč najboljše pojasnjujejo odvisno spremenljivko, če so za njo zamaknjene za od 1 do 2 leti, z večjim zamikom pa začne pojasnjevalna moč modela upadati. Primerjava po panogah je pokazala, da so zamude z odplačevanjem kreditov najbolj problematične v rudarstvu in ribištvu.

Brezigar-Masten et al. (2015) so preverjali, kako uspešni so bili v času gospodarske krize modeli za napovedovanje kreditnega tveganja slovenskega bančnega sistema. Banke so bile v času finančne krize nagnjene k podcenjevanju kreditnega tveganja, kar se odraža v precenjenih bonitetnih ocenah. Kljub poslabšanju kakovosti komitentov, kar se kaže v povečanem deležu

slabih posojil, ki imajo več kot 90 dni plačilne zamude, so bili ti s strani bank razvrščeni v relativno visoke bonitetne razrede. Slabše bonitetne ocene namreč vodijo v višje potrebne rezervacije za pokrivanje izgub slabih posojil, s tem pa dodaten pritisk na kapital bank. Zato so se mnoge banke z napihovanjem lastnih bilanc začasno izognile povišanju rezervacij za slaba posojila. Pri tem so bile največ kritik deležne manjše banke v slovenski lasti. Tovrstne banke imajo zaradi svoje majhnosti večje omejitve pri pridobivanju dodatnega kapitala, poleg tega so imele večjo izpostavljenost do slabih posojil. Obratno so se banke s tujimi lastniki v času finančne krize manj izpostavljale tveganim posojilom, ki so postala slaba. Zaradi večje dostopnosti sredstev znotraj bančne skupine, ki ji pripadajo, so imele tudi manj težav z ohranjanjem kapitalske ustreznosti in financiranjem. Velike domače banke so bile privilegirane s strani države, saj so »prevelike, da bi propadle«. Zaradi precenjenosti bonitetnih ocen bank se je zmanjšala njihova pojasnjevalna moč. V času finančne krize so modeli, temelječi le na računovodskih postavkah, pri prepoznavanju slabih posojil dajali občutno boljše rezultate, čeprav bančni modeli zajemajo več informacij kot le grobe računovodske postavke, kot na primer strokovno znanje in medletne informacije.

Spremenljivke, ki so bile v omenjenih študijah največkrat uporabljene ter katerih vpliv na plačilno disciplino je statistično dokazan, bodo služile kot prvotni izbor spremenljivk, vključenih v mojo raziskavo, kar je podrobneje opisano v Poglavju 3.4.2.


2 PLAČILNA DISCIPLINA V SVETU IN SLOVENIJI

2.1 Plačilna disciplina v tujini

Problem plačilne nediscipline in posledična insolventnost podjetij sta s pojavom finančno gospodarske krize postala svetoven problem. Stanje se na svetovni ravni počasi izboljšuje, a je v marsikateri državi še vedno pod predkrizno ravni. Krepitev svetovnega gospodarstva je vidna predvsem na račun povečanja investicij, proizvodnje in trgovine – ob hkratnih ugodnih pogojih financiranja, prilagodljivih politikah, povečanju zaupanja ter krepitvi cen surovin. Konstanten trend svetovne gospodarske rasti se pričakuje tudi v naslednjih letih, v državah v razvoju pa celo povečanje rasti. Po 2,4-% rasti v letu 2016 je svetovna rast BDP v letu 2017 ocenjena na 3 %, takšna je tudi napovedana povprečna letna rast do leta 2020. Za Evroobmočje je značilna počasnejša rast BDP, in sicer je v letu 2016 znašala 1,8 %, za leto 2017 je ocenjena na 2,4 %, napoved za leto 2018 znaša 2,1 %, za 2019 pa 1,7 % (World Bank Group, 2018, str. 3–4).

V raziskavi svetovne insolventnosti oddelka za ekonomske raziskave podjetja Euler Hermes (2018) ugotavljajo, da se je v letu 2017 insolventnost, merjena s številom stečajev, po sedmih letih upadanja na svetovni ravni prvič povečala, in sicer za 1 % glede na predhodno leto. Za leto 2018 se napoveduje 1-% upad števila stečajev, kar pomeni 4,5 % pod predkrizno ravni (Euler Hermes 2018, str. 2-4). Povprečno trajanje plačila (angl. *Days Sales Outstanding – DSO*) se od leta 2010 na svetovni ravni giblje okrog 64 dni, kakršna je tudi ocena za leto 2017. V letu 2016 je četrtnina podjetij na svetovni ravni na plačilo v povprečju čakala 88 in več dni, četrtnina pa je plačilo prejela v roku enega meseca od prodaje (Euler Hermes, 2017, str. 5).

Slika 4: Letne spremembe insolventnosti po regijah v obdobju 2016–2018



Vir: Euler Hermes, *Insolvencies. February 2018. Economic Research, 2018, str. 2.*

Slika 4 prikazuje letne spremembe insolventnosti po regijah v obdobju 2016–2018. Podjetje Euler Hermes (2018) v letu 2017 na svetovni ravni ugotavlja povečanje števila stečajev večjih podjetij s prihodki nad 50 milijonov evrov (v nadaljevanju EUR), predvsem v sektorjih storitvenih dejavnosti, prodaje na drobno in kmetijstva. Glede geografske lege je porast svetovne insolventnosti za 1 % v letu 2017 mogoče predpisati predvsem povečanju števila stečajev v Aziji, Rusiji in Braziliji. Azijsko-pacifiška regija se kljub gospodarski rasti sooča s turbulencami v nekaterih sektorjih, ki so predvsem posledica gospodarskih in monetarnih ukrepov na Kitajskem. Regija v letu 2017 beleži 14-% porast stečajev glede na predhodno leto (35-% povečanje na Kitajskem), za 2018 pa se predvideva njihovo 6-% povečanje (10-% povečanje na Kitajskem). Latinska Amerika v letu 2017 beleži 17-% porast insolventnosti, v letu 2018 se po 6 letih rasti števila stečajev pričakuje njihova stabilizacija (0-% sprememba), in sicer predvsem zaradi pospešenega gospodarskega okrevanja in sprostitev finančnih pogojev v Braziliji. Centralno-vzhodna Evropa v letu 2017 beleži 4-% letni porast stečajev. Ta je posledica težav ruskih, poljskih in turških podjetij, davčnih sprememb v Romuniji in sprememb insolventne zakonodaje na Slovaškem. Regiji se v letu 2018 napoveduje upad števila stečajev, in sicer za 4 %. Zahodna Evropa zadnjih 5 let beleži upad insolventnosti, 6 % v letu 2017, v 2018 pa se predvideva 3-% upad. Kljub temu vsaka druga država ostaja nad predkriznim nivojem, pri čemer v negativnem smislu izstopa Velika Britanija, ki naj bi po napovedih v letu 2018 beležila 8-% porast števila stečajev, predvsem zaradi negotovosti, povezanih z izstopom iz Evropske unije. Severni Ameriki, ki upad insolventnosti beleži že 8 let zapored, se v letu 2018 z 2-% upadom števila stečajev napoveduje doseganje predkrizne ravni, k čemur bo pripomoglo sproščanje fiskalne politike (Euler Hermes, 2018).


Podjetje Euler Hermes (2017) ugotavlja, da je povprečno trajanje plačila močno odvisno od dejavnosti, v kateri deluje posamezno podjetje. V negativnem smislu v letu 2016 izstopajo

elektronika, strojna industrija, gradbeništvo in farmacija, katerih trajanje plačila je 80 dni ali več. Prve tri zato, ker se nahajajo na koncu oskrbovalne verige in tako akumulirajo vse plačilne zamude znotraj verige, farmacevtska industrija pa na račun sistemov javnega zdravstvenega zavarovanja, ki jim primanjkuje denarja. Kljub temu imajo večja farmacevtska podjetja zadostne rezerve, da premostijo visoke plačilne zamude. Problematičen je tudi sektor letalstva, katerega povprečno trajanje plačila v zadnjih letih hitro narašča, v letu 2016 z 8-dnevnim povečanjem glede na leto 2012 trajanje plačila v povprečju dosega 68 dni. Problematična je predvsem slaba organizacija v dobavni verigi, saj dobava izdelkov težko sledi hitro naraščajočemu povpraševanju po letalskem prometu. Sektorji, za katere je značilna trgovina na drobno, kot so prehranska, transportna industrija in ponudniki gospodinjskega blaga, so v povprečju plačani hitreje od svetovnega povprečja (Euler Hermes, 2017, str. 4–9).

Povprečno trajanje plačila je najbolj kritično na Kitajskem, saj je v letu 2016 z 89 dnevi doseglo najvišjo vrednost v zadnjih 9 letih. Povprečno trajanje plačil se je glede na predhodno leto povišalo tudi v Rusiji in na Bližnjem Vzhodu. Počasno podaljševanje trajanja plačil v zadnjih letih beleži tudi zahodna Evropa, ki je v letu 2016 s povečanjem za 1 dan glede na predhodno leto v povprečju dosegla 61 dni. Kljub temu je v zadnjem letu opazno močno krajšanje trajanja plačil v sredozemskih državah, s čimer se razlike med državami znotraj regije zmanjšujejo. Združene države Amerike (v nadaljevanju ZDA) zadnja 3 leta beležijo stabilno trajanje plačil, in sicer v povprečju okrog 50 dni. Najkrajše trajanje plačila je v letu 2016 zabeležila Nova Zelandija, in sicer 42 dni, pod svetovnim povprečjem pa se nahaja tudi Avstralija (Euler Hermes, 2017, str. 4–9).

Bonitetna hiša CRIBIS D&B (2017) je v svoji letni študiji plačil ugotovila, da težnja pravočasnega plačevanja dobaviteljem med evropskimi družbami v letu 2016 ostaja na približno enaki ravni kot v letu 2015, vendar pa trend močno niha med državami. Kot je razvidno s Slike 5, v Evropi v povprečju slabih 40 % družb spoštuje plačilne roke in ne zamuja s plačili. Med podjetji, ki zamujajo s plačevanjem, največji delež družb najdemo v razredu z zamudami pri plačilih do 30 dni, saj se tukaj nahaja 51 % vseh evropskih družb, slabih 4 % evropskih družb pa s plačili zamuja več kot 90 dni, 2,2 % celo več kot 120 dni. Med evropskimi državami največ podjetij pravočasno plačuje račune na Danskem, in sicer kar 86,5 %, sledi ji Nemčija. Največ težav s pravočasnim plačevanjem imajo podjetja na Portugalskem, saj svoje obveznosti pravočasno poravnava le 19,5 % podjetij. Slovenija se z 43,7 % nahaja nad evropskim povprečjem. Največji delež slovenskih podjetij se z 48,9 % nahaja v razredu zamud do 30 dni, v katerem najvišjo vrednost v letu 2016 dosega Portugalska (61,4 %). Med evropskimi državami z največjimi zamudami je na prvem mestu Poljska, kjer 15 % podjetij svoje obveznosti poravnava z zamudo nad 90 dni, 12 % celo nad 120 dni. Na Sliki 5 je poleg evropskih držav prikazana tudi praksa plačevanja v nekaterih drugih svetovnih velesilah. Kot je razvidno, se po deležu podjetij s pravočasno poravnanimi računi nad evropsko povprečje uvrščajo ZDA, Mehika in Rusija. Slednja se z 71,2 % uvršča celo takoj za Dansko in Nemčijo. Med neevropskimi državami največji delež podjetij z zamudami nad 90 dni v letu 2016 beleži Kitajska (CRIBIS D&B, 2017).

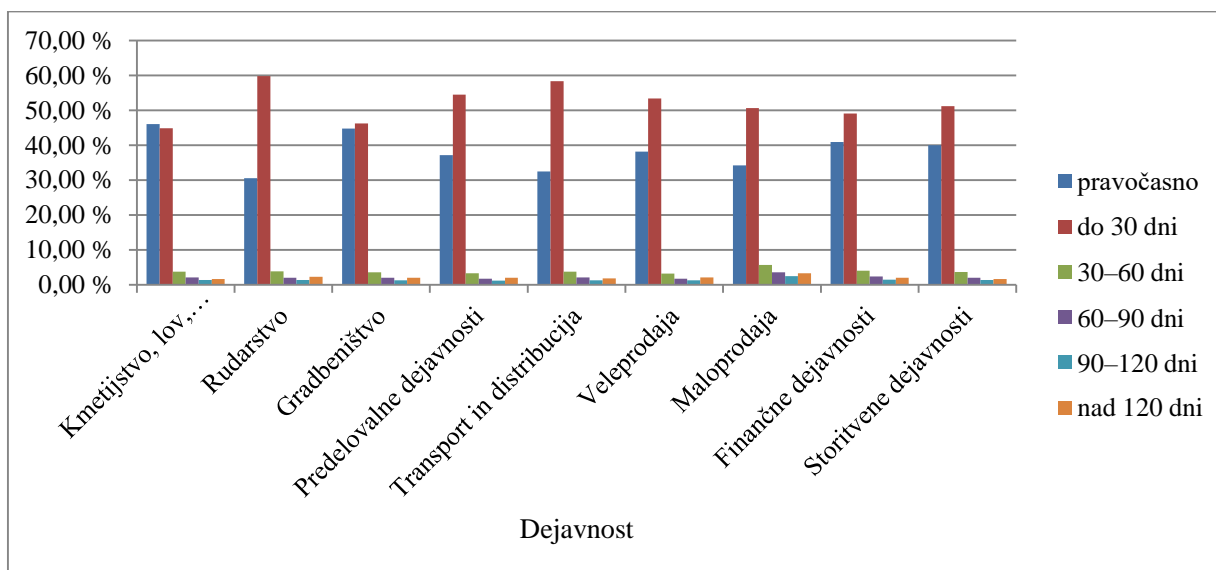
Slika 5: Delež podjetij po državah in plačilnih razredih v letu 2016



Vir: Cribis D&B, Payment Study 2017, 2017.

Kot je razvidno s Slike 6, je v Evropi v letu 2016 največ podjetij, ki plačujejo pravočasno, in sicer je 46,1% zabeleženih v panogi kmetijstva, lova, gozdarstva in ribištva, sledi jim gradbeništvo s 44,8 % pravočasnih plačnikov. Najbolj problematična je situacija v rudarstvu, kjer le 30,6 % podjetij svoje obveznosti poravnava v roku. Maloprodaja beleži največji delež najslabših plačnikov z zamudami nad 90 dni, in sicer 5,8 %, od tega 3,3 % podjetij v tem sektorju s plačili zamuja več kot 120 dni. Najnižji procent podjetij, ki s plačili zamujajo več kot 90 dni, je v panogi kmetijstva, lova, gozdarstva in ribištva ter storitvenih dejavnostih, in sicer 3,1 %. Razen v panogi kmetijstva, lova, gozdarstva in ribištva je v vseh drugih panogah najpogostejša praksa plačevanja računov z zamudo do 30 dni. V tem plačilnem razredu je z 59,8 % največji delež podjetij v panogi rudarstva. V plačilnem razredu z zamudami od 30 do 60 dni in od 60 do 90 dni pa prednjači maloprodaja s 5,7-% in 3,6-% deležem podjetij. Na Kitajskem podjetja v vseh panogah večinoma plačujejo z do 30-dnevno zamudo. Najuspešnejša panoga glede pravočasnega poravnavanja obveznosti je s 36,3 % pravočasnih plačnikov transport in distribucija, ki prav tako beleži najmanj plačnikov, ki zamujajo več kot 90 dni. V ZDA največ pravočasnih plačnikov s 63,5 % najdemo v finančnih dejavnostih, kjer je prav tako najmanj zamudnikov z več kot 90-dnevno zamudo, in sicer 2,5 %. V Mehiki največ – 73,5 % – podjetij pravočasno plačuje račune v panogi gradbeništva, panoga rudarstva pa ne beleži zamud nad 90 dni (CRIBIS D&B, 2017).

Slika 6: Delež podjetij v Evropi po dejavnostih in plačilnih razredih v letu 2016



Vir: Cribis D&B, Payment Study 2017, 2017, str. 65.

2.2 Plačilna disciplina v Sloveniji

Slovenija od 2014 beleži rast BDP, ta je za leto 2017 ocenjena na 4,4 %. Gospodarsko okrevanje se bo nadaljevalo tudi v letih 2018 in 2019, in sicer se bo rast BDP gibala med 3–4 %. Ključna dejavnika gospodarskega okrevanja v letu 2017 sta bila povečanje državnih investicij in izvoza. Slednji bo na rast BDP pomembno vplival tudi v prihodnjih letih, prav tako bo pomembna rast domače potrošnje. Ta se bo sicer postopoma upočasnila, predvsem zaradi pričakovane nižje rasti zaposlenosti, ki je posledica demografskih dejavnikov. Pričakuje se tudi nadaljevanje rasti investicij (Urad RS za makroekonomske analize in razvoj, 2017, str. 3). Vzporedno z gospodarskim okrevanjem se od leta 2013 naprej postopno izboljšuje tudi plačilna disciplina. Podjetja so pri poslovanju s svojimi kupci zaradi preteklih slabih izkušenj previdnejša, bolje se zavarujejo in pogosteje zahtevajo predplačila. Zaradi nekaj uspešnih privatizacij je na trgu več denarja, k izboljšanju plačilne discipline pa je pripomoglo tudi zaprtje nekaterih velikih slabih podjetij, predvsem gradbenih, od katerih je bilo odvisno veliko podizvajalcev (Smrekar, 2015).


2.2.1 Dospеле nepravne obveznosti po letih

Ajpes od 1. 1. 2003 vodi mesečno statistiko poslovnih subjektov z dospelimi nepravnanimi obveznostmi nad 5 dni neprekinjeno. Podatki so vezani zgolj na obveznosti iz naslova sodnih sklepov o izvršbi, davčnega dolga, stroškov davčne izvršbe in od 29. 12. 2012 na obveznosti z naslova izvršnice (do uvedbe insolvenčnih postopkov), ne pa na ostale dospеле nepravne obveznosti, vezane na poslovanje med upniki in dolžniki. Do leta 2003 je tovrstno statistiko vodila Agencija Republike Slovenije za plačilni promet.

V celotni zgodovini Republike Slovenije je njena plačilna disciplina vrh dosegla v letu 2003, ko je bilo v januarju število pravnih oseb z nedospelimi obveznostmi nad 5 dni le 1.352, povprečni dnevni znesek teh obveznosti pa je znašal dobrih 7,826 milijarde tolarjev oziroma 32.657.319

EUR. Tako število pravnih oseb kot tudi skupni znesek dospelih neporavnanih obveznosti sta začela v času gospodarske in finančne krize po letu 2008 hitro rasti, po letu 2013 oziroma 2014 pa upadati, kot je razvidno s Slike 7. Število pravnih oseb z dospelimi neporavnanimi obveznostmi nad 5 dni neprekinjeno je bilo najvišje v letu 2013, in sicer s 6875 blokiranimi osebami, povprečni dnevni znesek neporavnanih obveznosti pa je svoj višek dosegel leta 2014, znašal je 735.840.000 EUR. S Slike 7 je razvidno tudi, da poseben problem predstavljajo subjekti, katerih transakcijski računi so blokirani že daljše obdobje, tj. nad 90 dni neprekinjeno. Njihov delež glede na celotno število blokiranih pravnih oseb od leta 2012 upada, vendar se v januarju 2018 še vedno giblje nad 50 % vseh dospelih neporavnanih obveznosti, natančneje ta delež znaša 57,39 %. Januarja 2018 je bilo 4.032 pravnih oseb, ki so imele račune blokirane več kot 5 dni, povprečni dnevni znesek neporavnanih obveznosti pa je znašal 294.821.000 EUR. Pravnih oseb, ki dospelih obveznosti niso imele poravnanih že več kot eno leto, je bilo januarja 2018 1217 oziroma 30,2 % vseh pravnih oseb z dospelimi neporavnanimi obveznostmi. V tem obdobju je bilo pravnih oseb z dospelimi neporavnanimi obveznostmi do 30 dni 27,8 % (Ajpes, 2018a).

Slika 7: Število pravnih oseb z dospelimi neporavnanimi obveznostmi in povprečni dnevni znesek dospelih neporavnanih obveznosti v mesecu januarju v letih 2007–2018



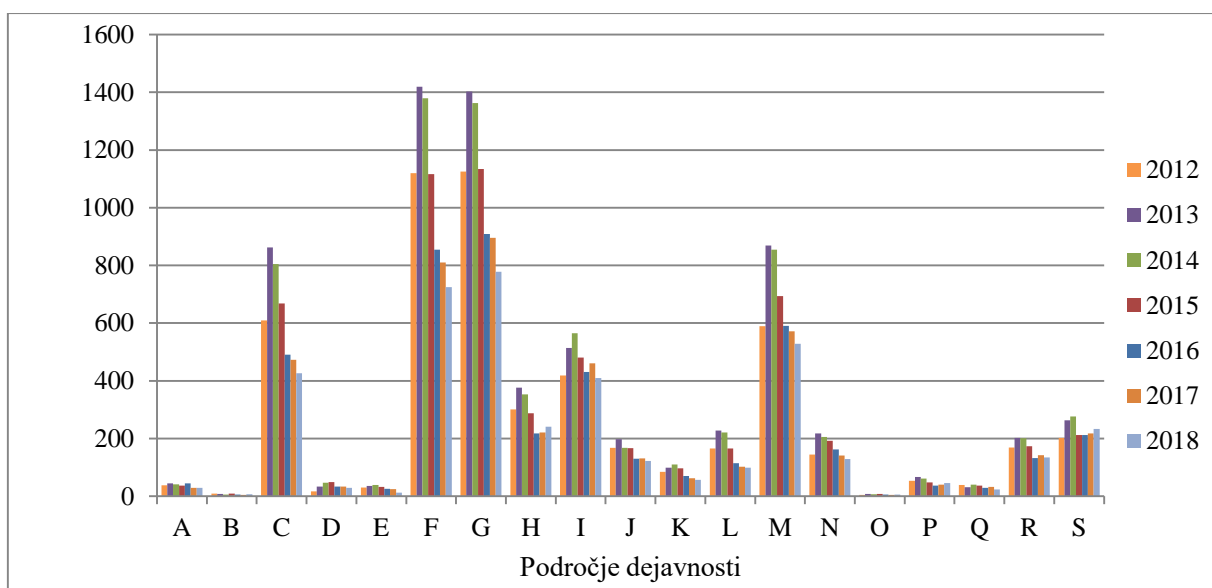
Legenda: *Podatki ne vključujejo samostojnih podjetnikov, vsi podatki se nanašajo na mesec januar posameznega leta.

Vir: Ajpes, Poslovni subjekti z dospelimi neporavnanimi obveznostmi po dnevih v letih 2007 do 2018, 2018a.

2.2.2 Dospеле neporavnane obveznosti po področjih dejavnosti

Po podatkih Ajpesa (2018b) največ blokiranih pravnih oseb prihaja iz dejavnosti trgovine, vzdrževanja in popravil motornih vozil (dejavnost G) ter gradbeništva (dejavnost F), sledita pa jima panogi strokovnih, znanstvenih in tehničnih dejavnosti (dejavnost M) ter predelovalnih dejavnosti (dejavnost C). Kot je razvidno s Slike 8, je bilo v večini dejavnosti najbolj kritično leto 2013, ko so bile v dejavnosti trgovine, vzdrževanja in popravil motornih vozil 1403 pravne osebe z dospelimi neporavnanimi obveznostmi nad 5 dni, v panogi gradbeništva pa je bilo 1419 takšnih pravnih oseb. Delež blokiranih pravnih oseb v dejavnosti trgovine, vzdrževanja in popravil motornih vozil med vsemi blokiranimi pravnimi osebami v tej dejavnosti je v januarju 2018 s 778 pravnimi osebami znašal 19,3 %, v dejavnosti gradbeništva pa s 725 pravnimi osebami 18 %. Najmanj težav s plačilno nedisciplino je v vseh prikazanih letih opaziti v dejavnosti javne uprave in obrambe, dejavnosti obvezne socialne varnosti (dejavnost O) in dejavnosti rudarstva (dejavnost B).

Slika 8: Število pravnih oseb z dospelimi neporavnanimi obveznostmi nad 5 dni neprekinjeno po področjih dejavnosti v mesecu januarju v letih 2012–2018



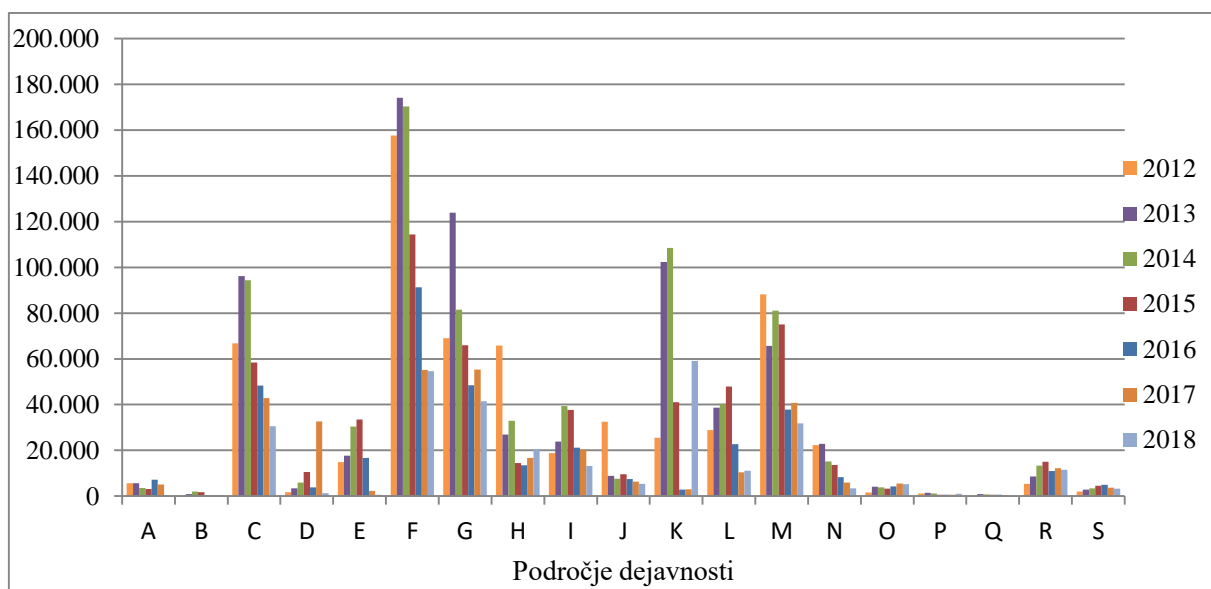
Legenda: *A – Kmetijstvo in lov, gozdarstvo, ribištvo; B – Rudarstvo; C – predelovalne dejavnosti; D – Oskrba z električno energijo, plinom in paro; E – Oskrba z vodo, ravnanje z odplakami in odpadki, saniranje okolja; F – Gradbeništvo; G – Trgovina, vzdrževanje in popravila motornih vozil; H – Promet in skladiščenje; I – Gostinstvo; J – Informacijske in komunikacijske dejavnosti; K – Finančne in zavarovalniške dejavnosti; L – Poslovanje z nepremičninami; M – Strokovne, znanstvene in tehnične dejavnosti; N – Druge raznovrstne poslovne dejavnosti; O – Dejavnost javne uprave in obrambe, dejavnost obvezne socialne varnosti; P – Izobraževanje; Q – Zdravstvo in socialno varstvo; R – Kulturne, razvedrilne in rekreacijske dejavnosti; S – Druge dejavnosti

Vir: Ajpes, Poslovni subjekti z dospelimi neporavnanimi obveznostmi po področjih dejavnosti v letih 2012 do 2018, 2018b.

Čeprav sta dejavnost trgovine, vzdrževanja in popravila motornih vozil in dejavnost gradbeništva po številu blokiranih pravnih oseb z vidika plačilne nedisciplin približno enako kritični, pri povprečnem dnevnom znesku dospelih neporavnanih obveznosti nastajajo velike razlike. V

januarju 2018 je v dejavnosti gradbeništva znesek 54.635.000 EUR povprečnih dnevni dospelih neporavnanih obveznosti predstavljal 18,5 % vseh dospelih neporavnanih obveznosti pravnih oseb, znesek 41.419.000 EUR v dejavnosti trgovine, vzdrževanja in popravila motornih vozil pa 14 %. Sicer je bilo za obe dejavnosti najbolj kritično leto 2013, ko je dejavnost gradbeništva beležila 174.134.000 EUR povprečnih dnevni dospelih neporavnanih obveznosti, dejavnost trgovine, vzdrževanja in popravila motornih vozil pa 123.959.000 EUR takih obveznosti. Največjo volatilitnost povprečnega dnevnega zneska dospelih neporavnanih obveznosti opazimo pri dejavnosti finančnih in zavarovalniških dejavnosti (dejavnost K). Delež obveznosti v tej dejavnosti glede na vse dospele neporavnane obveznosti pravnih oseb se je v obdobju od 2012 do 2018 gibal med 108.493.000 EUR in 2.841.000 EUR. Dejavnosti z najnižjimi povprečnimi dnevnimi zneski dospelih neporavnanih obveznosti v prikazanih letih so dejavnost zdravstva in socialnega varstva (dejavnost Q), dejavnost izobraževanja (dejavnost P) in dejavnost rudarstva (dejavnost B), v letu 2018 pa tudi dejavnost oskrbe z vodo, ravnanja z odpadki in odpadki, saniranje okolja (dejavnost E). Prikaz povprečnih dnevni zneskov dospelih neporavnanih obveznosti je prikazan na Sliki 9.

Slika 9: Povprečni dnevni znesek dospelih neporavnanih obveznosti po področjih dejavnosti v mesecu januarju v letih 2012–2018 (v 000 EUR)



Vir: Ajpes, Poslovni subjekti z dospelimi neporavnanimi obveznostmi po področjih dejavnosti v letih 2012 do 2018, 2018b.

2.3 Ukrepi za izboljšanje plačilne nediscipline

Kljub vidnemu izboljšanju plačilne nediscipline v večini svetovnih držav je praksa neplačanih računov še vedno precej pogosta. Z namenom izboljšanja plačilne nediscipline je bilo sprejetih že veliko ukrepov – tako na mednarodni ravni kot v slovenski zakonodaji –, vendar pa je na tem področju še vedno veliko manevrskega prostora za izboljšave.

Ukrep za izboljšanje plačilne discipline bi bila javna objava zamud pri plačilih, z zbiranjem informacij o dogovorjenih plačilnih rokih in dejanskih izplačilih. S tem bi podjetja lahko prepoznala potencialne slabe poslovne partnerje ter se tako izognila poslovanju z njimi. Po drugi

strani bi ukrep vplival tudi na podjetja, ki so nagnjena k plačilni nedisciplini, saj bi z javno objavo večjega števila zamujenih računov izgubili potencialne poslovne partnerje. Na podoben način bi na Ajpesu večjo dostopnost podatkov o neplačnikih omogočili z javno objavo vseh dolžnikov, vključenih v obvezni večstranski pobot. Trenutno je v skladu z 29. členom ZPreZP-1 upnikom sicer omogočeno le preverjanje prijavljenih obveznosti svojih dolžnikov, kar pomeni vpogled v že nastale terjatve, ki že vplivajo na likvidnost upnikov. Objava vseh udeležencev pobota bi podjetjem dala informacijo o neplačnikih, ki se jim lahko izognejo vnaprej, s tem da z njimi ne poslujejo. Poleg tega bi javna objava udeležencev pobota od prijave v večstranski pobot odvrnila podjetja, ki so sposobna odplačati dolg, vendar čakajo na morebitno pobotanje preko obveznega večstranskega pobota ter tako izkoristijo možnost nedenarnega plačila.

Evropska komisija (Evropska komisija, 2015, str. 11) svetuje zaostritev v Direktivi oziroma v ZPreZP-1 določenih kazni za neplačnike. Potrebna bi bila vpeljava avtomatskih zamudnih obrestih namesto pravice do uveljavitve zamudnih obresti. Upniki se v velikem številu ne poslužujejo zamudnih obresti, da ne bi ogrozili dobrih poslovnih odnosov, z obveznimi obrestmi jim ne bi bilo treba prevzeti pobude za uveljavljanje pravic. Nadomestilo stroškov izterjave, določenih z Direktivo in z ZPreZP-1 v slovenski zakonodaji, ki znaša 40 EUR, je prenizko. Dolžnikom namreč ne predstavlja občutnega finančnega bremena, upnikom pa velikokrat ne pokrije stroškov zaradi plačilne zamude, poleg tega nadomestilo velikokrat ni sorazmerno z dolgovanim zneskom. Potrebni bi bilo tudi nekaj sprememb glede obveznega večstranskega pobota. V pobot trenutno ni mogoče prijaviti obveznosti iz naslova davkov in prispevkov, kar bi bilo treba spremeniti, saj obveznosti do davčnega organa močno bremenijo marsikatero podjetje (Štrancar, 2011). Morali bi uvesti večji nadzor nad dolžniki pri prijavi njihovih obveznosti v pobot. Podjetij, ki svojih dolgov ne prijavijo v pobot, je namreč vse več, vendar za to velikokrat niso kaznovana (Weiss, 2013).

Problem slovenskega sodstva so dolgotrajni in posledično dragi sodni postopki, zato bi bila njihova pospešitev nujna. Kakor svetuje Evropska komisija (Evropska komisija, 2015, str. 11), bi bila smiselna tudi vpeljava alternativnega reševanja sporov. Zmanjšati bi bilo treba tudi število podjetij, ki imajo račun blokiran vsaj 60 dni neprekinjeno ali s prekinitvami več kot 60 dni v obdobju zadnjih 90 dni, kar po 14. členu ZFPPIPP predstavlja mejo insolventnosti in s tem izpolnjen pogoj za začetek stečajnega postopka. V tem primeru upniki lahko vložijo predlog za začetek insolventnega postopka nad dolžnikom, vendar se – glede na statistiko v Sloveniji – to v velikih primerih ne zgodi. Po podatkih Ajpesa je imelo februarja 2016 420 slovenskih podjetij račune blokirane celo več kot 1095 dni (Ajpes, 2018a). Zanimivo bi bilo izvesti raziskavo o tem, kolikšen je odstotek podjetij z blokadami nad 60 dni, katerih računi so bili odblokirani. Takšne raziskave nisem zasledila. Weiss, Grapulin in Šimac (2014) navajajo, da so podjetja z blokadami nad enim letom nedelujoča podjetja, nad katerimi bi bilo treba sprožiti stečajni postopek. Vodilni v podjetju morajo v določenem roku sami sprožiti začetek insolventnega postopka, sicer so odškodninsko odgovorni. Tega velikokrat ne storijo, saj raje zavlačujejo s stečajem podjetja in v tem času iz podjetja izžamejo čim več premoženja, hkrati pa v tem času določena dejanja lahko zastarajo. Pri tem so najbolj oškodovani upniki. Upniki namreč lahko uveljavljajo samo dejanja, ki so se zgodila v obdobju enega leta pred stečajem. Če so uprave neodgovorne, bi se morali odzvati upniki. Banke in Družba za upravljanje terjatev bank (v nadaljevanju DUTB) tega velikokrat ne počnejo, ker menijo, da s stečajem ne bi prišli do boljšega poplačila kot sicer. Prav tako velikokrat ne ukrepa Davčna uprava Republike Slovenije (v nadaljevanju DURS), čeprav je večino neplačnikov tudi

davčnih dolžnikov. V primeru državnih bank kot upnikov so oškodovani tudi davkoplačevalci, zato bi morali spodbuditi upnike k hitrejšemu ukrepanju, predvsem banke, DUTB in DURS, in zahtevati razlage, zakaj ne sprožijo stečajev posameznih dolžnikov. Banke s stečaji dostikrat odlašajo, da ne bi prišlo do razkritja neupravičeno odobrenih posojil.

Država svoje obveznosti plačuje z veliko zamudo ter tako ne vpliva na dvig zavesti pravočasnega plačevanja. Država bi morala svoje obveznosti poravnati v 30 dneh, kakor določa zakon, in biti zgled pravočasnega plačevanja. Država bi k izboljšanju plačilne discipline pripomogla tudi tako, da bi pri javnih naročilih izločila ponudnike, ki svojih obveznosti ne poravnajo v roku. Pozitiven vpliv na plačilno disciplino bi imelo bolj intenzivno ozaveščanje podjetij o negativnih posledicah plačilne nediscipline, o koristnosti predhodnega preverjanja potencialnih poslovnih partnerjev preko bonitetnih ocen bonitetnih agencij ter redno spremljanje poslovanja že obstoječih poslovnih partnerjev. Spodbujati je treba tudi vzpostavitev učinkovitega sistema upravljanja s krediti in z njimi povezanimi tveganji v podjetjih.

Poleg kaznovanja slabih plačnikov bi bilo z uvedbo politik pravočasnega plačevanja dobro uvesti tudi sistem nagrajevanja za podjetja, ki svoje račune poravnajo pravočasno. Na ravni države bi lahko uvedli sistem za prijavo pravočasno poravnanih obveznosti, katerih podjetja bi bila deležna posebnih ugodnosti. Poleg tega lahko podjetja tudi sama spodbudijo svoje kupce k plačevanju v dogovorjenih rokih, s tem da jim ponudijo popust na pravočasna plačila.

3 NAPOVEDOVANJE NEPLAČILA Z VEČNIVOJSKIM LINEARNIM MODELIRANJEM

Glavni cilj magistrske naloge je pojasniti vpliv različnih dejavnikov na plačilno disciplino podjetij. Raziskavo sem izvedla s pomočjo manj poznane statistične metode večnivojskega linearnega modeliranja, ki se v tujih študijah uporablja pogosteje, v Sloveniji pa je njena uporaba zelo redka. V nadaljevanju prikažem model, ki kljub nekaterim kritikam temelji na računovodskih podatkih podjetij. Časovni razmik med pojasnjevalnimi dejavniki in odvisnim dejavnikom dnevi zamud pri plačilih je eno leto, zato je po mnenju Reisz in Perlich (2007) bolj smiselna uporaba računovodskega modela. Avtorja namreč ugotavljata, da so računovodski modeli pri napovedovanju na krajši rok, in sicer do enega leta, uspešnejši od tržnih.

V nadaljevanju najprej predstavim izbrano metodo večnivojskega linearnega modeliranja, sledijo predstavitev ciljev raziskave in raziskovalnih hipotez ter pričakovanih omejitev pri raziskavi. Nato so predstavljeni vzorec ter spremenljivke, vključene v raziskavo. Sledi statistična obdelava podatkov, znotraj katere je z namenom zmanjšanja dimenzije podatkov izvedena metoda glavnih komponent. Nato postopoma po korakih razvijem večnivojski linearni model za napovedovanje plačilne discipline slovenskih podjetij. Praktični del zaključim s povzetkom glavnih ugotovitev raziskovalnega dela.

3.1 Predstavitev modela

Regresijski modeli, ki so običajno uporabljeni v finančnih študijah (npr. multipla regresija) in s katerimi se napoveduje plačilno nesposobnost podjetij, temeljijo na predpostavki neodvisnosti opazovanj, ki pa je v realnosti velikokrat kršena, predvsem ko imamo opravka s pojasnjevalnimi spremenljivkami na več nivojih (npr. relacija država–panoga–podjetje). Obstaja namreč velika verjetnost, da med enotami (npr. podjetja), razvrščenimi v isto skupino (npr. panoga), obstaja večja podobnost kot med enotami iz drugih skupin. Zato z regresijskimi modeli, ki ne upoštevajo te podobnosti, sicer lahko pravilno ocenimo povezave med spremenljivkami oziroma regresijske koeficiente, vendar naletimo na pristranskost ocen njihovih standardnih napak, kar vodi v napačne zaključke glede statistične značilnosti opazovanj (O'Dwyer & Parker, 2014, str. I). To slabost uspešno odpravimo s tehniko večnivojskega linearnega modeliranja.

Večnivojsko linearno modeliranje, v nadaljevanju MLM (angl. *Multilevel linear modeling/hierarchical linear models/linear mixed models*) je nadgradnja multiple linearne regresije (OLS regresije). Uporablja se za analizo odvisne spremenljivke in z njo povezane variance, ko so neodvisne spremenljivke prisotne na več nivojih (t.i. gnezdeni podatki) ali ko neki pojav opazujemo v času (Woltman, Feldstain, MacKay, & Rocchi, 2012, str. 52). V raziskavi so vključena slovenska podjetja, ki poslujejo v različnih panogah, karakteristike podjetij so opazovane skozi obdobje štirih let. Glavna prednost MLM v primerjavi z regresijskimi tehnikami (kot na primer multipla linearna regresija) je, da uspešno upošteva dve vrsti odvisnosti, ki sta najbolj pogosti v finančnih študijah. Hkrati namreč razreši problem presečne odvisnosti (angl. *Cross-sectional dependency*) in longitudinalne (časovne) odvisnosti (angl. *Time-series dependency*) (Petersen, 2005, str. 436). Presečna odvisnost se pojavi kot posledica medsebojne odvisnosti med podjetji, ki poslujejo v isti panogi oziroma državi. Podjetja, ki poslujejo v isti panogi, so si med seboj bolj podobna – v primerjavi s podjetji iz drugih panog, saj na njih vplivajo karakteristike posamezne panoge. Longitudinalna odvisnost oziroma odvisnost med opazovanji se pojavi, ko podjetje opazujemo skozi daljše časovno obdobje. V tem primeru so večkratna opazovanja vgnazdana znotraj podjetij. Omenjeni odvisnosti uspešno modeliramo s hierarhično strukturo podatkov, ki omogoča analizo variance v odvisnih spremenljivkah na več ravneh (Woltman et al., 2012, str. 53). Prednost MLM je tudi ta, da manjkajoče vrednosti opazovanj ne vplivajo na njegovo zanesljivost (Woltman et al., 2012, str. 56).

Slabost MLM je, da je za dobre rezultate potreben velik vzorec, predvsem za enote na prvem nivoju. Kljub temu pa nam večje število enot na višjih nivojih prinese večje učinke modela. Čeprav MLM brez zmanjšanja zanesljivosti dopušča manjkajoče vrednosti, je to možno le za enote na najnižjem nivoju. Zaradi obeh razlogov je priporočljivo večje število enot na najvišjem nivoju (Woltman et al., 2012, str. 56). O'Dwyer in Parker (2014, str. 7) svetujeta, da naj bo število enot na najvišjem nivoju vsaj 20–25 za točnost ocen varianc, regresijskih koeficientov in njihovih standardnih napak; oziroma vsaj 50 enot za nepristranske ocene standardnih napak na najvišjem nivoju.


Pred razvojem MLM so raziskave, vključujoče hierarhične podatke, običajno temeljile na tehnikah linearne regresije z uporabo fiksnega parametra, ki pa so zaradi neupoštevanja skupne variance znotraj skupin dajale pristranske rezultate (Woltman et al., 2012, str. 52). Začetki MLM segajo v

sedemdeseta leta prejšnjega stoletja (Lindley & Smith, 1972). V začetku osemdesetih let je bil razvit prvi algoritem MLM (Dempster, Rubin, & Tsutakawa, 1981), ki je omogočal poenostavljen izračun kovariance kljub manjkajočim vrednostim oziroma neuravnoteženim podatkom. Ta napredek v statistični teoriji je bistveno vplival na razcvet MLM, sledile so študije z različnih področij: Aitkin in Longford, 1986; Kreft, 1996; Raudenbush in Bryk, 2002; Gelman in Hill, 2007; Tabachnick in Fidell, 2012; Field, 2009; Newman, Newman in Salzman, 2010; Garson, 2013; Marinšek, 2015a; idr.

3.1.1 Variiranje regresijske konstante in regresijskih koeficientov


Presečno odvisnost upoštevamo tako, da omogočimo prosto variiranje regresijske konstante in/ali regresijskih koeficientov v skupinah na višjih nivojih. To pomeni, da vrednosti parametrov niso fiksne, ampak variirajo (Field, 2009, str. 821). Prosto variiranje regresijske konstante (b_0) pomeni, da ta prosto variira med različnimi skupinami. S tem predpostavimo, da so povezave med posameznimi pojasnjevalnimi spremenljivkami in odvisno spremenljivko v različnih skupinah enake, vendar je model (oziroma regresijska premica) za vsako panogo lociran na drugi geometrijski lokaciji (Field, 2009, str. 821). Model s prosto variirajočo regresijsko konstanto in fiksnimi regresijskimi koeficienti je prikazan na Sliki 10.

Slika 10: Variiranje regresijske konstante, fiksni regresijski koeficienti



Vir: A. Field, *Discovering Statistics Using SPSS*, 2009, str. 822.

Slika 11: Fiksna regresijska konstanta, variiranje regresijskih koeficientov




Vir: A. Field, *Discovering Statistics Using SPSS*, 2009, str. 822.

Prosto variiranje regresijskih koeficientov (b_i) pomeni, da koeficienti prosto variirajo med različnimi skupinami. S tem predpostavimo, da se povezave med posameznimi pojasnjevalnimi spremenljivkami in odvisno spremenljivko med panogami razlikujejo, sam model (oziroma

regresijska premica) pa je fiksiran na enaki geometrijski lokaciji, kar je prikazano na Sliki 11. Poznamo tudi kombinacijo obojega, variiranje regresijske konstante in koeficientov, kar prikazuje Slika 12 (Field, 2009, str. 822–823).

Slika 12: Variiranje regresijske konstante in regresijskih koeficientov



Vir: A. Field, *Discovering Statistics Using SPSS*, 2009, str. 822.

Sama bom v nadaljevanju predstavila samo prosto variiranje regresijske konstante, kot je prikazano na Sliki 10. Variiranje posameznega regresijskega koeficienta namreč uporabimo, ko pričakujemo, da se povezave med odvisno in neodvisnimi spremenljivkami med skupinami razlikujejo (Tabachnick & Fidell, 2012). Ker nisem našla nobenega teoretičnega ozadja, ki bi kazal na različen vpliv neodvisnih spremenljivk na plačilno disciplino v različnih panogah, bom uporabila fiksne regresijske koeficiente.

3.2 Cilj raziskave in opredelitev hipotez

Glavni cilj magistrske naloge je z uporabo večnivojskega linearnega modela dokazati statistično povezavo med plačilno nedisciplino in dejavniki, ki vplivajo nanjo. Z raziskavo želim potrditi osrednjo hipotezo:

H1: Napovedovalna moč modela za napovedovanje plačilne discipline slovenskih podjetij se bistveno izboljša z uporabo tehnike MLM.

Poleg osrednje hipoteze H1 bodo v Poglavju 3.6 predstavljene tudi bolj specifične hipoteze, vezane na različno stopnjo vključenosti podatkov.

3.2.1 Pričakovane omejitve pri raziskavi

Model napovedovanja plačilne nediscipline temelji na računovodskih podatkih, ki prinašajo nekatere pomanjkljivosti. Glavna omejitev raziskave je vprašljiva kakovost oziroma verodostojnost danih statističnih podatkov, saj ti niso revidirani. Agarwal in Taffler (2008) opozarjata, da izkazi predstavljajo preteklo poslovanje podjetja in zato niso nujno dobri v napovedovanju prihodnosti, poleg tega pa se zaradi njihovega zgodovinskega pristopa resnična tržna vrednost lahko močno razlikuje od računovodske vrednosti. Naslednja slabost je, da so računovodske informacije lahko manipulirane s strani managementa podjetja, na kar opozarja tudi Bergant (2012, str. 226–227). Avtor opozarja, da pri omejitvi na računovodske postavke

zanemarjamo zunajbilančni položaj podjetij. Prav tako računovodski izkazi ne zajemajo vseh dejavnikov, ki vplivajo na uspešnost podjetja oziroma njegovo poslovanje (npr. motiviranost zaposlenih, vplivi okolja, lansiranje novega proizvoda konkurenta itd.). Šalamon in Meško (2015, str. 41) opozarjata na namerno zamujanje s plačili, ki bi lahko vplivalo na rezultate magistrskega dela, v smislu nepravilnih oziroma neobstoječih povezav med odvisno in neodvisnimi spremenljivkami. Podjetja, ki sicer nimajo finančnih težav, zamujanje plačilnih rokov izkoristijo kot brezplačno financiranje, saj zamudnih obresti običajno ni. Problematična je tudi izbira kazalcev oziroma njihovo število. Preveliko število kazalcev lahko vodi do multikolinearnosti, ki jo sicer preverim in minimiziram, pri premajhnem številu kazalcev pa lahko izpustimo pomembne informacije, ki vplivajo na odvisno spremenljivko (Pahor, 1999, str. 358).

3.3 Predstavitev vzorca

Za namene raziskave sta uporabljena dva različna vira podatkov. Študija temelji na letnih podatkih iz baze Ajpes in baze plačil slovenskih podjetij Bonitetne hiše i, d.o.o. Začetni vzorec zajema podatke vseh gospodarskih družb v Republiki Sloveniji, za katere je Ajpes dostavil statistične računovodske izkaze v letih od 2011¹ do 2014 in so bili v letu 2015 še vedno aktivni ter za katere so v bazi Bonitetne hiše i, d.o.o., dostopni podatki o zamudah pri plačilih za obdobje 2012–2015. Podjetij, ki zadoščajo začetnim kriterijem, je 13.314. Uporabljeni finančni kazalci so izračunani na podlagi statističnih podatkov iz bilance stanja in izkaza poslovnega izida v letih od 2011² do 2014, in sicer z zamikom enega leta za odvisno spremenljivko, ki je merjena v letih od 2012 do 2015. Ta tehnika je pogosto uporabljena pri analizi časovnih vrst (Mramor et al., 1998; Feinstein & Thomas, 2002; Bonfim, 2006; Frank & Goyal, 2009; Marinšek, 2015a), saj podjetja potrebujejo nekaj časa, da se prilagodijo trenutnim razmeram. Bonfim (2006) ugotavlja, da večino neodvisnih spremenljivk, uporabljenih v njegovi raziskavi, najbolje pojasnjuje odvisno spremenljivko, če so za njo zamaknjene za od 1 do 2 leti, z večjim zamikom pa začne njihova pojasnjevalna moč upadati. Poleg tega so za napovedovanje trenutne plačilne sposobnosti na voljo samo podatki prejšnjega leta, saj so ti javno objavljeni z zamikom.

Pri izbiri podjetij, vključenih v raziskavo, so izključene vse finančne družbe (družbe, ki po standardni klasifikaciji dejavnosti SKD opravljajo finančne oziroma zavarovalniške dejavnosti), kot so pred tem storili že številni avtorji (Volk, 2014; Marinšek, 2015a; idr.) Izločim tudi novoustanovljena podjetja, katerih poslovanje običajno še ni stabilizirano. To so družbe, mlajše od dveh let od prve meritve neodvisnih spremenljivk iz računovodskih izkazov 2011, torej bodo izključene družbe ustanovljene leta 2010 in mlajše. Tako se izognem podjetjem, katerih statistični podatki so pomanjkljivi ali neobstoječi. S tem namenom so izločena tudi preostala podjetja, ki imajo v proučevanem obdobju manjkajoče računovodske vrednosti in zato ne omogočajo izračuna nekaterih kazalcev. Izključena so podjetja, katerih število zaposlenih je 0. Končno število podjetij je 8.866.

Vzorec na najvišjem nivoju, ki predstavlja panoge, je sestavljen iz 77 panog. Pri tem termin »panoga« uporabim za nivo oddelka po SKD 2008, ki je ponazorjen z dvomestno številčno oznako. Število oddelkov v SKD 2008 je sicer 88, pri čemer so iz vzorca izključeni 3 oddelki, uvrščeni pod

¹ Za izračun nekaterih kazalnikov za leto 2011, ki temeljijo na primerjavi s predhodnim letom, so uporabljeni podatki iz računovodskih izkazov za leto 2010.

Finančne in zavarovalniške dejavnosti (področje K), 8 oddelkov pa nima pripadajočih podjetij. Definicija panoge z uporabo višje hierarhične kategorije po SKD 2008, to je področja (enomenstna črkovna oznaka), je rizična s statističnega vidika uporabe MLM. MLM namreč predpostavlja minimalno velikost vzorca, da dosežemo optimalne rezultate. Velikost vzorca se nanaša na najvišji nivo (panoga), pri čemer je za točnost ocen regresijskih koeficientov, varianc in njihovih standardnih napak potrebnih vsaj 20–25 enot oziroma vsaj 50 enot za nepristranske ocene standardnih napak na najvišjem nivoju (O'Dwyer & Parker, 2014, str. 7). Kategorija področje po SKD zajema le 21 postavk, zato sem se za kriterij panoge odločila izbrati nivo oddelka. Porazdelitev podjetij po panogah je prikazana v Tabeli 1.

Tabela 1: Porazdelitev podjetij po panogah

Področje	Oddelok	Število	Delež v %
A	01	45	0,51
	02	26	0,29
	03	3	0,03
Vsota A		74	0,83
B	05	1	0,01
	08	20	0,23
	09	1	0,01
Vsota B		22	0,25
C	10	156	1,76
	11	15	0,17
	13	32	0,36
	14	23	0,26
	15	10	0,11
	16	109	1,23
	17	32	0,36
	18	84	0,95
	20	55	0,62
	21	6	0,07
	22	183	2,06
	23	63	0,71
	24	34	0,38
	25	565	6,37
	26	54	0,61
27	80	0,90	
28	186	2,10	
29	42	0,47	
30	6	0,07	
31	76	0,86	
32	38	0,43	
33	105	1,18	
Vsota C		1.954	22,04
D	35	26	0,29
Vsota D		26	0,29

Področje	Oddelok	Število	Delež v %
H	49	699	7,88
	50	3	0,03
	51	8	0,09
	52	71	0,80
	53	16	0,18
Vsota H		797	8,99
I	55	107	1,21
	56	631	7,12
Vsota I		738	8,32
J	58	44	0,50
	59	27	0,30
	60	27	0,30
	61	35	0,39
	62	200	2,26
	63	18	0,20
Vsota J		351	3,96
L	68	111	1,25
Vsota L		111	1,25
M	69	165	1,86
	70	130	1,47
	71	353	3,98
	72	41	0,46
	73	79	0,89
	74	36	0,41
	75	21	0,24
	Vsota M		825
N	77	27	0,30
	78	12	0,14
	79	35	0,39
	80	29	0,33
	81	75	0,85
	82	34	0,38
Vsota N		212	2,39

se nadaljuje

Tabela 1: Porazdelitev podjetij po panogah (nad.)

Področje	Oddelek	Število	Delež v %	Področje	Oddelek	Število	Delež v %	
E	36	26	0,29	O	84	2	0,02	
	37	6	0,07		Vsota O	2	0,02	
	38	48	0,54		P	85	76	0,86
	39	3	0,03			Vsota P	76	0,86
Vsota E	83	0,94	Q	86	58	0,65		
F	41	224		2,53	87	7	0,08	
	42	91		1,03	88	2	0,02	
	43	832	9,38	Vsota Q	67	0,76		
Vsota F	1.147	12,94	R	90	9	0,10		
G	45	295		3,33	92	16	0,18	
	46	1.328		14,98	93	25	0,28	
	47	624	7,04	Vsota R	50	0,56		
Vsota G	2.247	25,34	S	94	3	0,03		
Vsota E	36	26		0,29	95	29	0,33	
	37	6		0,07	96	52	0,59	
	38	48	0,54	Vsota S	84	0,95		
39	3	0,03	Skupaj	8.866	100,00			
Vsota E	83	0,94						
Vsota F	41	224	2,53					
	42	91	1,03					
	43	832	9,38					
Vsota F	1.147	12,94						
Vsota G	45	295	3,33					
	46	1.328	14,98					
	47	624	7,04					
Vsota G	2.247	25,34						

Legenda: * A - Kmetijstvo in lov, gozdarstvo, ribištvo; B – Rudarstvo; C – predelovalne dejavnosti; D – Oskrba z električno energijo, plinom in paro; E – Oskrba z vodo, ravnanje z odplakami in odpadki, saniranje okolja; F – Gradbeništvo; G – Trgovina, vzdrževanje in popravila motornih vozil; H – Promet in skladiščenje; I – Gostinstvo; J – Informacijske in komunikacijske dejavnosti; K – Finančne in zavarovalniške dejavnosti; L – Poslovanje z nepremičninami; M – Strokovne, znanstvene in tehnične dejavnosti; N – Druge raznovrstne poslovne dejavnosti; O – Dejavnost javne uprave in obrambe, dejavnost obvezne socialne varnosti; P – Izobraževanje; Q – Zdravstvo in socialno varstvo; R – Kulturne, razvedrilne in rekreacijske dejavnosti; S – Druge dejavnosti

Vir: Ajpes, Baza podatkov letnih poročil gospodarskih družb v Sloveniji 2011–2014, 2014.


Kot je razvidno iz Tabele 1, največ obravnavanih podjetij prihaja iz panoge trgovine, vzdrževanja in popravil motornih vozil ter predelovalnih dejavnosti. Najmanj podjetij prihaja iz dejavnosti javne uprave in obrambe.

3.4 Opis spremenljivk

Z modelom napovedovanja plačilne discipline želim ugotoviti, kako neodvisne spremenljivke na treh nivojih vplivajo na odvisno spremenljivko – število dni zamude pri plačilu obveznosti do dobaviteljev – na prvem nivoju. V model so vključene spremenljivke na ravni podjetja in panoge. Prvi nivo predstavljajo spremenljivke, katerih vrednosti se v času spreminjajo: velikost podjetja, plačilni rok do dobaviteljev, delež kapitala v financiranju, delež dolga v financiranju, delež finančnega dolga v financiranju, pospešeni koeficient, dobičkonosnost kapitala, dobičkonosnost sredstev, delež kratkoročnih sredstev, koeficient obračanja celotnih sredstev, čista dobičkonosnost prihodkov, blokada transakcijskega računa, število odprtih bančnih računov, rast podjetja, prihodki na zaposlenega. Gre za opazovanja po letih, in sicer v obdobju 4 let, od leta 2011 do leta 2014. Opazovanja so vgnedena znotraj podjetij. Spremenljivka pravnoorganizacijska oblika podjetja je spremenljivka na ravni podjetja, ki se ne spreminja v času in predstavlja drugi nivo

modela. Podjetja so nato glede na naravo njihovega poslovanja vgnezdena v panoge. Spremenljivki na ravni panoge – število blokiranih podjetij v panogi in prihodki panoge – predstavljata tretji nivo modela. Odvisna spremenljivka povprečno število dni zamude pri plačilu obveznosti do dobaviteljev je merjena na prvem nivoju, saj se njene vrednosti letno spreminjajo. Shematski prikaz hierarhije modela je predstavljen na Sliki 13.

Slika 13: Shematski prikaz modela




3.4.1 Predstavitev odvisne spremenljivke

Odvisna spremenljivka je definirana kot povprečno število dni zamude pri plačilu obveznosti do dobaviteljev. Izračunana je na podlagi podatkov iz baze Bonitetne hiše i, d.o.o., ki že vrsto let zbira podatke o plačilih za vsa slovenska podjetja. Zamuda pri plačilu je izračunana kot razlika med datumom plačila in datumom zapadlosti posamezne fakture, povprečno število dni zamude pa kot povprečje vseh zamujenih plačil dobaviteljem posameznega podjetja v posameznem letu. V vzorec so vključena samo podjetja, za katera so dostopna plačila za vsa obravnavana leta ter pri katerih je za posamezno leto dostopnih vsaj pet plačil.


Ena od predpostavk regresijske analize je normalna porazdelitev odvisne spremenljivke, ki se porazdeljuje s pričakovano vrednostjo $E(y_i)$ in konstantno varianco σ^2 (Marinšek, 2015b, str. 18). V teoriji obstaja več številskih in grafičnih testov normalnosti, pri čemer sem se osredotočila na grafične teste. Številski testi pri večjih vzorcih, kot je moj, zaradi velike občutljivosti niso priporočljivi. Že majhna, nepomembna odstopanja od normalnosti močno vplivajo na omenjene teste ter s tem kažejo na nenormalno porazdelitev (Field, 2009, str. 184–188).

Kot grafično merilo normalnosti odvisne spremenljivke se uporabljajo normalni verjetnostni grafikon (angl. *P-P plot*), kvantilni verjetnostni grafikon (angl. *Q-Q plot*) ter histogram. Verjetnostna grafikona prikazujeta primerjavo kumulativne verjetnosti opazovane spremenljivke s kumulativno pričakovano verjetnostjo normalne porazdelitve (Field, 2009, str. 179), pri čemer kvantilni verjetnostni grafikon prikazuje kvantile, normalni verjetnostni grafikon pa posamezne vrednosti spremenljivke. Kakršnakoli odstopanja točk od diagonalne črte kažejo na nenormalno porazdelitev. Ker moj vzorec zajema veliko število podatkov, sem kot merilo normalnosti izbrala kvantilni verjetnostni grafikon, saj prikazuje manj vrednosti in je zato lažje razumljiv (Field, 2009, str. 185). Kot je razvidno iz grafikona na Sliki 14, odvisna spremenljivka y ni porazdeljena normalno. Enako je razvidno tudi iz histograma na Sliki 15, kjer je razvidno, da je spremenljivka asimetrična v desno.

Slika 14: Normalnost porazdelitve odvisne spremenljivke zamuda – kvantilni verjetostni grafikon



Slika 15: Normalnost porazdelitve odvisne spremenljivke zamuda - histogram




Field (2009, str. 172) navaja, da za optimalno oceno parametrov modela normalnost porazdelitve vzorca ni pomembna, za točnost ocen intervalov zaupanja in statistične značilnosti modelov pa je normalnost porazdelitve vzorca pomembna samo pri majhnih vzorcih (običajno manjših od 30 enot). Centralni limitni teorem (angl. *Central limit theorem*) namreč predpostavlja, da z velikimi vzorci dosežemo točnost ocen ne glede na obliko porazdelitve vzorca. Pri velikih vzorcih večjo težavo kot normalnost porazdelitve predstavljajo osamelci, ki pa sem jih že predhodno odpravila (Field, 2009, str. 172). Postopek odprave osamelcev je opisan v Poglavlju 3.5.1.

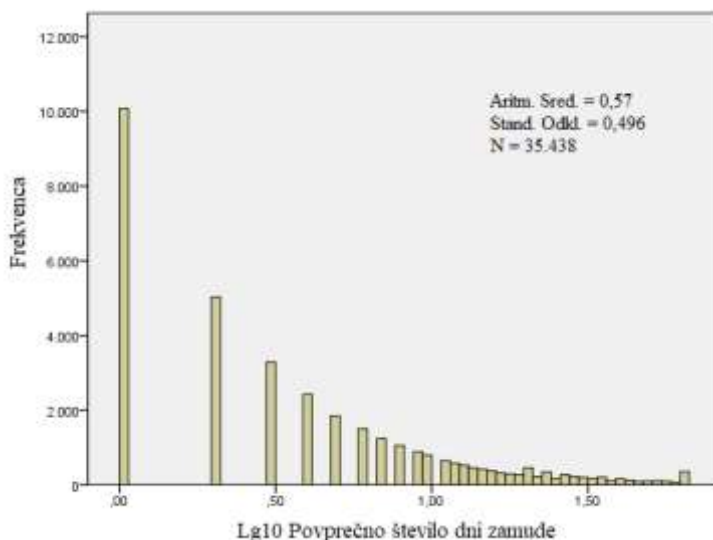
Ker moj vzorec zajema veliko število enot, lahko kljub nenormalni porazdelitvi odvisne spremenljivke in njene slučajne napake pričakujem optimalne rezultate regresijskega modela, vendar sem z namenom izboljšanja rezultatov kljub temu odločila razviti model s transformirano

odvisno spremenljivko. Ker je odvisna spremenljivka močno asimetrična v desno, sem z namenom izboljšanja normalnosti njene porazdelitve in linearnosti posameznih bivariatnih povezav izvedla različne transformacije odvisne spremenljivke: logaritmiranje odvisne spremenljivke z naravnim in desetiškim logaritmom ter korenjenje. Največjo normalnost in linearnost sem dosegla z uporabo desetiškega logaritma odvisne spremenljivke (Field, 2009, str. 203–208). Ker večina podjetij, vključenih v vzorec, v povprečju ne zamuja s plačili, odvisna spremenljivka vključuje veliko ničnih vrednosti. Ker logaritem števila 0 ne obstaja, sem odvisno spremenljivko logaritmirala tako, da sem vsem vrednostim prištela vrednost 1 ($\log(Y_i + 1)$) ter se tako znebila ničnih vrednosti. Normalnost porazdelitve odvisne spremenljivke, ki je razvidna iz kvantilnega verjetnostnega grafikona na Sliki 16 in histograma na Sliki 17, se je z njeno transformacijo izboljšala. V regresijski analizi je zato kot odvisna spremenljivka uporabljen logaritem povprečnega števila dni zamude pri plačilu obveznosti do dobaviteljev.

Slika 16: Normalnost porazdelitve odvisne spremenljivke logaritem zamuda – kvantilni verjetnostni grafikon



Slika 17: Normalnost porazdelitve odvisne spremenljivke logaritem zamuda - histogram



3.4.2 Predstavitev neodvisnih spremenljivk

Prvotni izbor neodvisnih spremenljivk temelji na obstoječi literaturi s področja plačilne discipline. Izbrane so različne postavke in finančni kazalniki, ki so bili v preteklih študijah največkrat uporabljeni in statistično vplivajo na zamudo pri plačilih oziroma imajo v literaturi močno teoretično povezavo s plačilno nedisciplino. Prašnikar et al. (2004) ugotavljajo, da so zamude pri plačilih značilne predvsem za majhna podjetja v finančni stiski, pri čemer zadolženost pozitivno vpliva na zamude. Prav tako krajši plačilni roki vplivajo na večje zamude. Enak vpliv zadolženosti ugotavljata tudi Šalamon in Meško (2015), ki ugotavljata tudi vpliv dobičkonosnosti, blokad transakcijskih računov podjetja ter deleža podjetij z blokiranimi računi v panogi. V nadaljevanju sledi predstavitev posameznih neodvisnih spremenljivk, ki sem jih uporabila pri analizi.

3.4.2.1 Prvi nivo – Podjetje: letna opazovanja

Za spremenljivke prvega nivoja je značilno, da so merjene na ravni podjetja in se v času spreminjajo. To pomeni, da se vrednosti spremenljivk posameznega podjetja med leti razlikujejo. Večino obravnavanih spremenljivk je merjenih na prvem nivoju, njihov podrobnejši opis je prikazan spodaj. Spremenljivke prvega nivoja imajo v računalniškem izpisu oznako L1.

3.4.2.1.1 Velikost

Večja podjetja lažje dostopajo do finančnih sredstev pri bankah in zato v primerjavi z manjšimi podjetji lažje zagotovijo denarna sredstva za pravočasno poplačilo svojih obveznosti (Šalamon & Meško, 2015, str. 36). Velikost podjetja praviloma določa njegovo pogajalsko moč. Podjetja z večjo pogajalsko močjo lažje dosežejo daljše plačilne roke ter večji popust za pravočasno poravnavanje obveznosti. Pogajalska moč majhnih podjetij je nizka, posledično so njihovi plačilni roki kratki, poleg tega niso deležni popustov. Glede na to bi morala biti večja podjetja bolj dovzetna za pravočasno plačevanje (Prašnikar et al., 2004, str. 57). Po drugi strani pa si večja podjetja ravno zaradi večje pogajalske moči lažje privoščijo, da dogovorjenih plačilnih rokov ne spoštujejo, saj lažje dosežejo odpis zamudnih obresti. V veliko primerih je takšno financiranje s strani dobaviteljev za podjetja celo cenejše kot popust za pravočasna plačila. Prav tako je v Sloveniji uporaba popustov za pravočasna plačila manj pogosta kot v ostalih evropskih državah (Prašnikar et al., 2004, str. 60). Glede na to predvidevam, da velikost podjetja negativno vpliva na njegovo plačilno disciplino, dopuščam pa tudi možnost pozitivnega vpliva.

Spremenljivka velikost je bila v preteklih raziskavah plačilne discipline velikokrat uporabljena (Šalamon & Meško, 2015; Volk, 2014; Carling et al., 2007; Bonfim, 2006; Brezigar-Masten et al., 2015; idr.), pri čemer Volk (2014), Carling et al. (2007) in Brezigar-Masten et al. (2015) ugotavljajo njen statistično značilen vpliv na zamude pri plačilih. Kot kriterij velikosti se v literaturi največkrat uporabljajo postavke povprečno število zaposlenih, čisti prihodki od prodaje in celotna sredstva.

V začetni izbor pojasnjevalnih spremenljivk so prvotno vključene tri spremenljivke, ki ponazarjajo velikost (povprečno število zaposlenih, čisti prihodki od prodaje in celotna sredstva). Vse tri spremenljivke so močno asimetrične v desno, saj prevladujejo manjša podjetja. Z namenom

doseganja večje normalnosti porazdelitve spremenljivk ter večje linearne povezanosti z odvisno spremenljivko so v izbor vključeni tudi desetiški logaritmi navedenih spremenljivk. V analizo je izmed naštetih verzij spremenljivk (povprečno število zaposlenih, čisti prihodki od prodaje, celotna sredstva in njihovi desetiški logaritmi) vključena tista, ki najbolj korelira z odvisno spremenljivko. V Tabeli 2 so prikazani korelacijski koeficienti med odvisno spremenljivko in šestimi verzijami spremenljivke velikost ter verjetnost njihove napake. Na podlagi največje korelacije z odvisno spremenljivko je v nadaljnjo analizo kot pokazatelj velikosti podjetja izbrana spremenljivka logaritem čistih prihodkov od prodaje. Poleg tega spremenljivka logaritem prihodkov od prodaje, kot predvideno, kaže na negativno korelacijo z odvisno spremenljivko. Podatki so pridobljeni iz letnih izkazov.

Tabela 2: Korelacijski koeficienti med spremenljivko velikost in odvisno spremenljivko

		Zaposleni	Prihodki	Sredstva	Log_zaposleni	Log_prihodki	Log_sredstva
Log_zamuda	Pearsonov korelacijski koeficient	0,023**	-0,012*	0,006	0,031**	-0,036**	-0,005
	Statistična značilnost	0,000	0,021	0,255	0,000	0,000	0,342

Legenda: ** korelacija je značilna pri $p < 0,01$; * korelacija je značilna pri $p < 0,05$

3.4.2.1.2 Plačilni rok do dobaviteljev

Prašnikar et al. (2004, str. 52) ugotavlja statistično značilen negativen vpliv plačilnega roka do dobaviteljev na plačilne zamude. Pričakujem, da podjetja z daljšimi plačilnimi roki zamujajo manj, saj imajo več časa za poravnavo svojih obveznosti. Po drugi strani se za dolge plačilne roke do dobaviteljev lahko dogovorijo podjetja z visoko pogajalsko močjo, ki dogovorjenih rokov velikokrat ne spoštujejo, kot je opisano predhodno. Spremenljivka plačilni rok do dobaviteljev je merjena v dnevih, in sicer kot povprečje vseh plačilnih rokov, ki jih ima posamezno podjetje do svojih dobaviteljev.

3.4.2.1.3 Delež kapitala v financiranju

Kazalnik delež kapitala v financiranju nam pove, kolikšen delež sredstev je financiran s kapitalom oziroma notranjimi viri. Čim višja je vrednost kazalnika, tem manj je podjetje zadolženo, s čimer pa se zmanjša tudi tveganje neplačila (Zaman Groff, Hočevan, & Igličar, 2007, str. 285–286). Glede na to pričakujem negativno korelacijo med deležem kapitala v financiranju in dnevi zamud pri plačilu. Negativen vpliv na plačilno disciplino sta dokazala Bonfim (2006) in Javoršek (2007). Kazalnik je izračunan po naslednji enačbi (1):

$$\text{Delež kapitala v financiranju} = \text{kapital} / \text{obveznosti do virov sredstev} \quad (1)$$

3.4.2.1.4 Delež dolga in delež finančnega dolga v financiranju

Kazalnik delež dolgov v financiranju nam pokaže, kakšen delež sredstev je financiran z dolgom oziroma z zunanjimi viri. Velikost kazalnika kaže na odvisnost podjetja od zunanjih virov financiranja (Zaman Groff et al., 2007, str. 286). Bolj kot je podjetje zadolženo, večje je tveganje neplačila, zato je pričakovana pozitivna korelacija z odvisno spremenljivko. To so v svojih raziskavah dokazali tudi Šalomon in Meško (2015), Volk (2014), Carling et al. (2007) ter delno Brezigar-Masten et al. (2015) (statistično značilen vpliv kazalnika na zamude pri plačilih je dokazan v treh proučevanih letih). Kazalnik je izračunan po naslednji enačbi (2):

$$\text{Delež dolga v financiranju} = (\text{dolgoročne obveznosti} + \text{kratkoročne obveznosti}) / \text{obveznosti do virov sredstev} \quad (2)$$

Prašnikar et al. (2004) je v kazalnik financiranja namesto celotnih obveznosti vključil samo finančne obveznosti ter dokazal statistično značilen vpliv na plačilno disciplino. Finančne obveznosti so obveznosti z naslova dobljenih posojil in izdanih vrednostnih papirjev (Zaman Groff et al., 2007, str. 79). Zaradi dokazanega vpliva na plačilno disciplino je poleg osnovnega kazalnika delež dolga v financiranju vključen tudi kazalnik delež finančnega dolga, ki je izračunan po naslednji enačbi (3):

$$\text{Delež finančnega dolga v financiranju} = (\text{dolgoročne finančne obveznosti} + \text{kratkoročne finančne obveznosti}) / \text{obveznosti do virov sredstev} \quad (3)$$

Iz istih razlogov kot pri kazalniku delež dolga v financiranju tudi pri kazalniku delež finančnega dolga v financiranju pričakujem pozitivno korelacijo z odvisno spremenljivko.

3.4.2.1.5 Pospešeni koeficient

Pospešeni koeficient kaže na likvidnost podjetja oziroma na njegovo kratkoročno sposobnost odplačila dolgov (Weygandt, Kimmel, & Kieso, 2011, str. 668). Prikazuje razmerje med kratkoročnimi sredstvi in kratkoročnimi dolgovi, pri čemer so iz kratkoročnih sredstev izvzete zaloge, ki predstavljajo manj likviden del kratkoročnih sredstev (Zaman Groff et al., 2007, str. 295). Vpliv pospešenega koeficienta na plačilno disciplino je bil večkrat testiran, med drugim so ga v svoje raziskave vključili Prašnikar et al. (2004), Brezigar-Masten et al. (2015) in Volk (2014). Pri tem sta zadnja dva dokazala statistično značilen negativen vpliv na zamude pri plačilih. Ker višje vrednosti kazalca pomenijo lažje odplačevanje obveznosti, tudi sama predvidevam negativen vpliv na odvisno spremenljivko. Kazalec je izračunan po naslednji enačbi (4):

$$\text{Pospešeni koeficient} = (\text{kratkoročna sredstva} - \text{zaloge}) / \text{kratkoročne obveznosti} \quad (4)$$

3.4.2.1.6 Dobičkonosnost kapitala (ROE)

Dobičkonosnost kapitala meri dobičkonosnost z vidika lastnikov podjetja oziroma delničarjev. Pove nam, koliko denarnih enot čistega poslovnega izida je podjetje generiralo na vsako denarno enoto, investirano s strani lastnikov (Weygandt et al., 2011, str. 673). Kazalnik je izračunan po spodnji enačbi (5):

$$ROE = \text{čisti poslovni izid}_t / ((\text{kapital}_t + \text{kapital}_{t-1})/2) \quad (5)$$

pri čemer kapital_t predstavlja kapital tekočega leta, kapital_{t-1} pa kapital preteklega leta.

Čim večja je vrednost ROE, tem uspešnejše je poslovanje podjetja, zato predvidevam negativen vpliv kazalnika na zamude pri plačilih. Problematične so nerealne pozitivne vrednosti kazalnika, ki nastanejo zaradi kombinacije čiste poslovne izgube in negativnega kapitala. Takšne vrednosti, ki jih je 961, so zaokrožene na vrednost 1. centila, izračunanega na podlagi ostalih vrednosti kazalnika. Šalamon (2014) v svoji raziskavi ni ugotovila statistično značilne povezave med dobičkonosnostjo kapitala in zamudami pri plačilih.

3.4.2.1.7 Dobičkonosnost sredstev (ROA)

Kazalnik dobičkonosnosti sredstev kaže, kako uspešno je podjetje pri uporabi lastnih sredstev (Zaman Groff et al., 2007, str. 300). Kazalnik je izračunan po naslednji enačbi (6):

$$ROA = \text{čisti dobiček (oz. izguba)}_t / ((\text{sredstva}_t + \text{sredstva}_{t-1}) / 2) \quad (6)$$

Čim večja je vrednost ROA, tem uspešnejše je poslovanje podjetja, zato predvidevam negativen vpliv kazalnika na zamude pri plačilih. Negativen vpliv dobičkonosnosti sredstev na plačilno disciplino so dokazali Psillaki, Tsolas in Margaritis (2010), Bonfim (2006) in Carling et al. (2007).

3.4.2.1.8 Delež kratkoročnih sredstev

Kazalnik delež kratkoročnih sredstev prikazuje delež kratkoročnih sredstev v vseh sredstvih. Njegova visoka vrednost pomeni izboljšanje poslovanja, ko so se kratkoročna sredstva povečala na račun povečane poslovne dejavnosti. Če se delež kratkoročnih sredstev, predvsem zalog in kratkoročnih poslovnih terjatev, poveča, ne da bi se povečal obseg poslovanja, pa to lahko predstavlja nevarnost za podjetje (Zaman Groff et al., 2007, str. 290). Večji delež kratkoročnih sredstev v celotnih sredstvih kaže na večjo likvidnost sredstev za poravnavo obveznosti, zato predvidevam negativen vpliv na zamude pri plačilih, kar je v svoji raziskavi potrdil tudi Javoršek (2007). Kazalnik se izračuna po naslednji enačbi (7):

$$\text{Delež kratkoročnih sredstev} = \text{kratkoročna sredstva} / \text{celotna sredstva} \quad (7)$$

3.4.2.1.9 Koeficient obračanja celotnih sredstev

Koeficient obračanja celotnih sredstev nam pove, kako učinkovito podjetje uporablja lastna sredstva za ustvarjanje prodaje. Pove nam, koliko denarnih enot prodaje podjetje ustvari z vsako denarno enoto, investirano v sredstva (Weygandt et al., 2011, str. 672). Kazalnik je izračunan po spodnji enačbi (8):

$$\text{Koeficient obračanja celotnih sredstev} = \text{Prihodki od prodaje}_t / ((\text{sredstva}_t + \text{sredstva}_{t-1}) / 2) \quad (8)$$

Višji kot je kazalnik, bolj uspešno je podjetje, kar bi se moralo odražati v manjših plačilnih zamudah. Zato predvidevam negativen vpliv na odvisno spremenljivko. Statistično značilen negativen vpliv so dokazali Brezigar-Masten et al. (2015), Volk (2014) in Bonfim (2006).

3.4.2.1.10 Čista dobičkonosnost prihodkov

Čista dobičkonosnost prihodkov pokaže, koliko denarnih enot dobička podjetje ustvari na vsako denarno enoto sredstev (Weygandt et al., 2011, str. 672). Izračuna se po naslednji enačbi (9):

$$\text{Čista dobičkonosnost prihodkov} = \text{čisti dobiček} / \text{prihodki} \quad (9)$$

Nizka vrednost kazalnika oziroma zmanjšanje njegove vrednosti kaže na to, da mora poslovodstvo podjetja skrbneje spremljati stroške podjetja (Zaman Groff et al., 2007, str. 301). Predvidevam negativno povezavo med kazalnikom in odvisno spremenljivko, ki jo je v svoji raziskavi dokazal tudi Javoršek (2007).

3.4.2.1.11 Blokada transakcijskega računa

Blokada enega ali več transakcijskih računov podjetja pomeni neporavnane obveznosti do državnih organov ali poslovnih upnikov. Spremenljivka blokada je neprava spremenljivka (angl. *Dummy*), ki lahko zavzame dve možni vrednosti, to sta 0 in 1. Podjetje ima vrednost spremenljivke 1, če je imelo v posameznem letu blokiran vsaj 1 račun (vsaj 1 dan); in vrednost 0, če blokade ni bilo. Sklepam, da so podjetja z blokadami slabši plačniki in zato beležijo večje zamude pri plačilih. Statistično pozitiven vpliv blokade so v svojih raziskavah dokazali tudi Šalamon (2014), Brezigar-Masten et al. (2015) in Volk (2014).

3.4.2.1.12 Število odprtih bančnih računov (pozicija na finančnem trgu)

Brezigar-Masten et al. (2015) in Volk (2014) ugotavljata močno pozitivno povezavo med številom odprtih bančnih računov in plačilno disciplino. Podjetja z več odprtimi transakcijskimi računi so bolj nagnjena k zamujanju s plačili. Manj kredibilna podjetja namreč zaprosajo za kredite v več različnih bankah, ker jim prvotni kreditodajalci ne odobrijo dodatnih kreditov ali ker so zaradi tveganja sami raje izpostavljeni manjšim kreditom (Volk, 2014, str. 15).

3.4.2.1.13 Rast podjetja (prodaje)

Pričakuje se, da podjetja z večjo rastjo (prodaje) beležijo manjše zamude pri plačilih, zato predvidevam negativno povezavo med rastjo podjetja in zamudami pri plačilih. Bonfim (2006) je v svoji raziskavi dokazal statistično značilen negativen vpliv rasti prodaje na plačilno disciplino, in sicer v primeru napovedovanja plačilne discipline za največ dve leti vnaprej. Kot pokazatelj rasti podjetja je vključena spremenljivka rast prihodkov, ki prikazuje procentualno rast prihodkov tekočega leta glede na preteklo leto. Kazalec je izračunan po spodnji enačbi (10):

$$\text{Rast podjetja} = ((\text{prihodki}_t - \text{prihodki}_{t-1}) / \text{prihodki}_{t-1}) * 100 \quad (10)$$

3.4.2.1.14 Prihodki na zaposlenega

Kazalec prihodki na zaposlenega je kazalec produktivnosti, ki kaže na stroškovno učinkovitost podjetja. Pokaže nam, koliko prihodkov podjetja je bilo ustvarjenih na vsakega zaposlenega. Kazalec je izračunan po naslednji enačbi (11):

$$\text{Prihodki na zaposlenega} = \text{prihodki} / \text{povpr. št. zaposlenih} \quad (11)$$

Ker višja vrednost kazalca kaže na večjo produktivnost podjetja, pričakujem negativen vpliv na plačilno disciplino, kar je v svojem delu dokazal tudi Javoršek (2007).

3.4.2.2 Drugi nivo – Podjetje

Za spremenljivke drugega nivoja je značilno, da so merjene na ravni podjetja in se v času ne spreminjajo. To pomeni, da je vrednost spremenljivke za posamezno podjetje enaka skozi vsa opazovana leta. Na drugem nivoju je v model vključena spremenljivka pravnoorganizacijska oblika podjetja. Spremenljivka drugega nivoja ima v računalniškem izpisu oznako L2.

3.4.2.2.1 Pravnoorganizacijska oblika podjetja

Kot je opisano predhodno, je pričakovana negativna povezava med spremenljivko delež kapitala v financiranju in zamudami pri plačilih. Kot ugotavljajo Frank in Goyal (2008) ter Marinšek (2015a) so javna podjetja v povprečju manj zadolžena ter bolj nagnjena k financiranju s kapitalom. Zato pričakujem, da javna podjetja beležijo manjše zamude. Spremenljivka pravnoorganizacijska oblika podjetja je nepravna spremenljivka, pri čemer ima podjetje vrednost spremenljivke 1, če je delniška (javna) družba; in vrednost 0, če ima katerikoli drugo pravnoorganizacijsko obliko.

3.4.2.3 Tretji nivo – Spremenljivke na ravni panoge

Kot je opisano v Poglavlju 2, je iz različnih statistik razvidno, da se plačilna disciplina med panogami razlikuje. Pomemben vpliv dejavnikov na ravni panoge na plačilno disciplino ugotavljata tudi Šalamon in Meško (2015). Na nivoju panoge bosta v model vključeni dve spremenljivki, opisani v nadaljevanju. Spremenljivki tretjega nivoja imata v računalniškem izpisu oznako L3.

3.4.2.3.1 Število blokiranih podjetij v panogi

Spremenljivka število blokiranih podjetij v panogi vključuje seštevek blokad vseh podjetij v posamezni panogi, za katera je imela Bonitetna hiša i, d.o.o., v posameznem letu podatke o odprtih transakcijskih računih v Sloveniji (to je približno 210.000 podjetij). Pri tem se podjetje šteje kot blokirano, če je imelo v določenem letu blokirani katerikoli račun najmanj 1 dan. Ker so podjetja z blokadami slabši plačniki, predvidevam pozitivno korelacijo s plačilno disciplino, kot ugotavljata tudi Šalamon in Meško (2015).

3.4.2.3.2 Prihodki panoge

Spremenljivka prihodki panoge vključuje seštevek prihodkov vseh podjetij, za katera je imela Bonitetna hiša i, d.o.o., v posameznem letu dostopne statistične računovodske izkaze (to je približno 110.000 podjetij).

3.4.3 Opisna statistika spremenljivk

V Tabeli 3 je prikazana opisna statistika za vsako od predhodno opisanih spremenljivk, in sicer so prikazani aritmetična sredina, mediana in standardni odklon. Vrednosti se nanašajo na vzorec 8.866 podjetij, vendar nekatera podjetja ne vključujejo opazovanj za vsa obravnavana leta. Do tega pride zaradi predhodne statistične obdelave podatkov, kot je opisano v Poglavju 3.5.1. Pri tem so vrednosti spremenljivk z namenom odprave ekstremnih vrednosti zaokrožene na 1. in 99. centil, nekatera opazovanja so odstranjena iz nadaljnje analize. Kot že omenjam, manjkajoče vrednosti opazovanj ne vplivajo na zanesljivost večnivojske linearne regresije. Zaradi lažje predstaviteljivosti je poleg logaritmov zamude pri plačilih in prihodkov od prodaje dodana tudi opisna statistika njenih nelogaritmiranih vrednosti. Nenavadno je aritmetična sredina kazalnika ROE nižja od aritmetične sredine kazalnika ROA. Do tega pride zaradi popravka nerealnih pozitivnih vrednosti kazalnika ROE, kot opisano v Poglavju 3.4.2.1.6.

Tabela 3: Opisna statistika spremenljivk

Spremenljivka	Aritmetična sredina	Standardni odklon	Mediana
Odvisna spremenljivka			
Log_zamuda	0,57	0,50	0,48
Zamuda (št. dni)	6,52	10,87	2,00
Nivo 1			
Log_prihodki	2,88	0,66	2,80
Prihodki (000 EUR)	3.514,31	11.641,85	633,00
Plačilni rok (št. dni)	21,48	11,79	17,00
Kapital v financiranju (%)	0,43	0,33	0,44
Dolg (%)	0,57	0,36	0,54
Finančni dolg (%)	0,23	0,24	0,16
Pospešeni koeficient (%)	1,70	2,10	1,06
ROE (%)	0,03	0,61	0,06
ROA (%)	0,05	0,13	0,03
Kratkoročna sredstva (%)	0,56	0,27	0,56
Obračanje sredstev (%)	1,83	1,69	1,38
Dobičkonosnost prihodkov (%)	0,02	0,08	0,02
Blokada TRR	0,13	/	0,00
Bančni računi (št. računov)	1,74	1,08	1,00
Rast prihodkov (%)	4,00	26,52	0,73
Prihodki na zaposlenega (000 EUR)	158,15	181,21	102,66

se nadaljuje

Tabela 3: Opisna statistika spremenljivk (nad.)

Spremenljivka	Aritmetična sredina	Standardni odklon	Mediana
	Nivo 2		
Pravnoorganizacijska oblika	0,03	/	0,00
	Nivo 3		
Blokada panoga (št. podjetij)	1.076,71	935,35	854,00
Prihodki panoge (000 EUR)	3.859.975,70	4.410.625,68	2.005.640,00

Vir: Ajpes, Baza podatkov letnih poročil gospodarskih družb v Sloveniji 2011–2014, 2014; Bonitetna hiša i, d.o.o., Ljubljana, Povprečno število dni zamude za slovenska podjetja med leti 2012–2015, 2015.

3.5 Statistična obdelava in zmanjševanje števila spremenljivk

Za vzpostavitev dobrega statističnega modela je ključna izbira spremenljivk, vključenih v model. Veliko število neodvisnih spremenljivk lahko pripelje do nepreglednosti in nerazumljivosti modela, zato je smiselno čim bolj omejiti število kazalcev ter hkrati ohraniti čim večji del informacije prvotnih spremenljivk. Ker moj prvoten izbor zajema 18 neodvisnih spremenljivk, je njihovo število smiselno zmanjšati. Za zmanjšanje dimenzije podatkov je uporabljena metoda glavnih komponent, ki je predstavljena v nadaljevanju.

Pred zmanjševanjem števila neodvisnih spremenljivk je treba dane podatke statistično obdelati. S statistično obdelavo podatkov poskrbimo tudi, da so izpolnjene temeljne predpostavke analize podatkov z uporabo regresije. Kršitev teh lahko privede do pristranskosti modela. Če predpostavke niso izpolnjene, dobimo napačne vrednosti testnih statistik in p-vrednosti, kar lahko vodi do napačnih sklepov pri interpretaciji rezultatov modela (Field, 2009, str. 165).

3.5.1 Preverjanje ekstremnih vrednosti

Osamelci (angl. *Outliers*) so vrednosti spremenljivke, ki se zelo razlikujejo od ostalih vrednosti spremenljivke. Te ekstremne vrednosti je treba ustrezno modelirati, v nasprotnem primeru lahko močno vplivajo na ocenjeno regresijsko funkcijo ter na oceno parametrov, kot tudi na napako modela in s tem intervale zaupanja (Field, 2009, str. 165–167). Osamelce sem pri vseh številskih spremenljivkah odpravila s pomočjo t.i. metode winsorizacije. Za vse številске spremenljivke, ki so vključene v model, sem izračunala 1. in 99. centil. Nizke ekstremne vrednosti sem nato zaokrožila na 1. centil, visoke ekstremne vrednosti pa na 99. centil. Nato sem preverila, če ima katera od enot še vedno visok ostanek (e_i), ki nam pove, koliko se dejanska vrednost odvisne spremenljivke razlikuje od vrednosti, ocenjene z regresijo. Izmed različnih opcij, ki jih ponuja SPSS, sem izbrala t.i. studentizirane ostanke, ki omogočajo najbolj natančen izračun ostankov (Field, 2009, str. 306). Ker so ti ostanki standardizirani, lahko pri izločanju ekstremnih ostankov upoštevam značilnosti normalne porazdelitve. Normalna porazdelitev predpostavlja, da se 99,9 % enot nahaja znotraj intervala $\pm 3,29$ standardnega odklona, vrednosti, ki padejo izven tega intervala, pa so ekstremi (Field, 2009, str. 306). Kritično mejo sem zaokrožila na vrednost ± 3 standardnega odklona ter iz nadaljnje analize izključila vse ostanke, ki presegajo to vrednost.

3.5.2 Preverjanje neodvisnosti opazovanj

Regresijska analiza predpostavlja neodvisnost opazovanj, kar pomeni, da je kovarianca med dvema naključno izbranim opazovanjema enaka 0 oziroma da napake modela niso povezane. To lahko zapišemo s spodnjo enačbo (12) (Marinšek, 2015b, str. 20):

$$\text{Cov}(\varepsilon_i, \varepsilon_j) = 0 \quad \text{Cov}(y_i, y_j) = 0 \quad \text{za vsak } i \neq j \quad (12)$$

Predpostavka o odvisnosti opazovanj je pogosto kršena, saj so opazovanja med seboj velikokrat odvisna. To se dogaja predvsem, ko iste enote opazujemo v času – longitudinalna odvisnost (angl. *Time-series dependency*), ko so opazovane enote razvrščene v iste skupine – presečna odvisnost (angl. *Cross-sectional dependency*) ali pri kombinaciji presečne in longitudinalne odvisnosti – panelni podatki (Marinšek, 2015b, str. 21). Če je pri multipli regresiji predpostavka o neodvisnosti opazovanj kršena, so intervali zaupanja in testi značilnosti neveljavni. Ocene parametrov so sicer veljavne, vendar ne optimalne (Field, 2009, str. 176). Presečno in longitudinalno odvisnost uspešno upoštevamo z uporabo MLM.

Prisotnost presečne odvisnosti se preveri s t.i. korelacijo znotraj skupine (angl. *Interclass correlation; ICC*). Ker menim, da panoga, v kateri posluje podjetje, vpliva na njegovo plačilno disciplino, pričakujem, da se bodo vrednosti posameznih spremenljivk bolj razlikovale med panogami, znotraj panog pa si bodo podjetja bolj podobna. Presečno odvisnost je treba modelirati, če je ICC kazalnik večji od 0,1. S tem upoštevamo hierarhičnost podatkov ter pri testiranju parcialnih regresijskih koeficientov zmanjšamo verjetnost napake prve vrste (tj. α) (Marinšek, 2015b, str. 30–31).

V Tabeli 4 je varianca merjena na dveh nivojih:

- Varianca slučajne napake (v nadaljevanju $\text{Var}_{\text{slučajna napaka}}$), ki meri varianco prvega nivoja (nivo, na katerem se vrednosti spremenljivk na ravni podjetja letno spreminjajo); in drugega nivoja (nivo, na katerem se vrednosti spremenljivk na ravni podjetja v času ne spreminjajo): 0,239 (močno statistično značilna od nič).
- Varianca na nivoju panoge, ki meri tretji nivo (v nadaljevanju $\text{Var}_{\text{panoga}}$): 0,005 (statistično značilno različna od nič pri $p = 0,021$).

Tabela 4: Ocene kovariančnih parametrov

Parameter		Ocena	Standardna napaka	Sig.
Ponavljajoče meritve	AR1 diagonalno	0,239241	0,002842	0,000
	AR1 ρ	0,819431	0,002458	0,000
Regresijska konstanta (predmet = Panoga)	Varianca	0,004644	0,002012	0,021

ICC je izračunan po naslednji enačbi (13) (Marinšek, 2015b, str. 34):

$$ICC_{panoga} = \frac{Var_{panoga}}{Var_{panoga} + Var_{stučajna\ napaka}} = \frac{0,004644}{0,004644 + 0,239241} = 0,01904 \quad (13)$$

ICC panoge predstavlja delež celotne variabilnosti odvisne spremenljivke, ki jo je mogoče predpisati panogi. Izračunan nizek ICC panoge pomeni, da panoga nima močnega vpliva na podjetja. Podjetja znotraj iste panoge se bodo obnašala različno, zato razlike med panogami ne bodo velike (Field, 2009, str. 817). Glede na to, da je izračunana ICC panoge manjša od 0,1, presečna odvisnost ni tako visoka, da bi bila predpostavka o neodvisnosti opazovanj kršena. Presečne odvisnosti zato ni nujno treba modelirati.

Longitudinalna odvisnost je pri opazovanju enot skozi čas vedno prisotna, zato jo je treba vedno upoštevati (Marinšek, 2015b, str. 30). Kako močna je longitudinalna odvisnost, pa nam pove koeficient avtokorelacije (AR1 ρ) (Tabela 4). Koeficient lahko zavzame vrednosti med -1 in 1 , bolj kot se približa skrajnima vrednostma, močnejša je longitudinalna odvisnost med zaporednimi opazovanji. V mojem primeru koeficient avtokorelacije znaša $0,819$, kar kaže na močno avtokorelacijo.

Glede na dobljene rezultate presečna odvisnost ni tako visoka, da bi predstavljala problem, v nasprotnem primeru pa je treba nujno upoštevati longitudinalno odvisnost, saj je predpostavka od neodvisnosti opazovanj kršena. Kot že predhodno omenjam, MLM – v nasprotju z multiplo linearno regresijo – uspešno upošteva neodvisnost opazovanj oziroma njihovih napak, zato je njena uporaba smiselna. Poleg longitudinalne odvisnosti je v regresiji upoštevana tudi presečna odvisnost, saj je ta kljub nizkim vrednostim prisotna. S tem preizkusim, če se z upoštevanjem presečne odvisnosti izboljša pojasnjevalna moč modela.

3.5.3 Preverjanje multikolinearnosti

Multikolinearnost se pojavi, če obstaja močna korelacija med dvema (ali več) spremenljivkama, kar vodi do nestabilnosti regresijskega modela. Visoka multikolinearnost povzroča visoke standardne napake regresijskih koeficientov, ki so zato nezanesljivi. Vrednosti regresijskih koeficientov namreč močno nihajo med različnimi vzorci in jih zato težko posplošimo na populacijo (Field, 2009, str. 325).

Multikolinearnost sem preverila s pomočjo korelacijske tabele in s pomočjo VIF statistike (oziroma tolerance). VIF statistika in toleranca nam povesta, če je posamezna pojasnjevalna spremenljivka močno linearno povezana z ostalimi spremenljivkami. Toleranca je definirana kot variabilnost izbrane neodvisne spremenljivke, ki ni pojasnjena z ostalimi neodvisnimi spremenljivkami, VIF statistika pa je njena obratna vrednost (Hair, Black, Babin, & Anderson, 2010, str. 200–201). Izračunamo jo s pomočjo spodnje enačbe (14):

$$VIF = \frac{1}{toleranca} = \frac{1}{1 - R_{i^2}} \quad (14)$$

Pri tem R_{i^2} predstavlja koeficient determinacije.

Povezava med spremenljivkami v korelacijski tabeli ne sme biti višja od $|0,9|$, absolutna vrednost VIF kazalca pa ne sme biti višja od 10 (oziroma tolerance ne nižja od 0,1), sicer imamo težave z multikolinearnostjo (Hair et al., 2010, str. 204). Korelacijska tabela je prikazana v Prilogi 1. Kot lahko razberemo, nobena povezanost med spremenljivkama ne presega vrednosti 0,9. Najvišja je povezanost med ROA in dobičkonosnostjo prihodkov, in sicer znaša 0,705.

V Tabeli 5 so prikazane vrednosti VIF statistike in tolerance. Pri vseh neodvisnih spremenljivkah je VIF statistika manjša od 10 oziroma so vse vrednosti tolerance višje od 0,1. VIF statistika je najvišja pri spremenljivki Dolg, in sicer znaša 3,742.

Tabela 5: Statistika kolinearnosti

Parameter	VIF	Toleranca
Log_prihodki	1,949	0,513
Plačilni rok	1,127	0,887
Kapital v financiranju	2,011	0,497
Dolg	3,742	0,267
Finančni dolg	2,195	0,456
Pospešeni koeficient	1,566	0,639
ROE	1,684	0,594
ROA	2,811	0,356
Kratkoročna sredstva	1,509	0,663
Obračanje sredstev	1,929	0,518
Dobičkonosnost prihodkov	2,365	0,423
Blokada TRR	1,095	0,914
Bančni računi	1,459	0,686
Rast prihodkov	1,110	0,901
Prihodki na zaposlenega	1,421	0,704
Pravnoorganizacijska oblika	1,154	0,866
Blokada panoga	1,264	0,791
Prihodki panoge	1,367	0,731

Kot lahko razberemo, multikolinearnost v mojem modelu ne predstavlja problema. Hair et al. (2010, str. 200) sicer opozarja, da je meja $|0,9|$ v večini primerov zanesljiva, a je multikolinearnost lahko prisotna tudi pri manjših vrednostih korelacijskih koeficientov, saj nastane zaradi združenih efektov dveh ali več neodvisnih spremenljivk. Morebitna multikolinearnost je odpravljena z metodo glavnih komponent.

3.5.4 Metoda glavnih komponent

Metoda glavnih komponent (angl. *Principal Component Analysis*) je ena najstarejših in najpogosteje uporabljenih metod v multivariatni analizi, njeni začetki segajo že v leto 1901. Cilj metode glavnih komponent je zmanjšanje dimenzije podatkov, pri čemer tvorimo komponente, ki so kombinacija prvotnih spremenljivk. Z novonastalimi komponentami želimo ohraniti čim večji

del informacije oziroma variabilnosti začetnih spremenljivk, pri tem prva komponenta zajema največji del variabilnosti prvotnih spremenljivk, delež zajete informacije pa se s številom komponent zmanjšuje. Za uspešno izvedbo metode, ki jo merimo z deležem izgubljene informacije, je potrebna dovolj visoka korelacija med spremenljivkami (Jolliffe, 2002). Metodo glavnih komponent želim izvesti predvsem zaradi zmanjšanja dimenzije podatkov kljub nizki prisotnosti multikolinearnosti. Prvotni izbor namreč vključuje 18 pojasnjevalnih spremenljivk, z zmanjšanjem števila teh lahko dosežem večjo razumljivost in preglednost modela, pri čemer je treba ohraniti zadosten del prvotne informacije. Smiselnost uporabe metode glavnih komponent preverim v nadaljevanju.

Večnivojski linearni model je priporočljivo graditi po korakih, in sicer tako da v model postopoma po nivojih vključujemo pojasnjevalne spremenljivke (Marinšek, 2015b, str. 34). Ker moj prvoten izbor pojasnjevalnih spremenljivk zajema 15 spremenljivk na prvem nivoju, 1 spremenljivko na drugem nivoju in 2 spremenljivki na tretjem nivoju, se mi zdi smiselna uporaba metode glavnih komponent samo za prvi nivo. Število spremenljivk na drugem in tretjem nivoju je optimalno, z metodo glavnih komponent pa zaradi načina vključevanja v večnivojski model ne želim združevati spremenljivk z različnih nivojev. V izvedbo metode glavnih komponent je vključenih 14 številskih pojasnjevalnih spremenljivk prvega nivoja. Spremenljivka prvega nivoja blokada podjetja ni številska spremenljivka, zato je v metodi glavnih komponent ne morem upoštevati in bo v nadaljnjo analizo vključena po izbiri glavnih komponent. Prav tako so v nadaljnjo analizo vključene spremenljivke drugega in tretjega nivoja: pravnoorganizacijska oblika podjetja, število blokiranih podjetij v panogi in prihodki panoge.

Korelacija med posameznimi pari neodvisnih spremenljivk prvega nivoja je prikazana v korelacijski tabeli v Prilogi 2, pri čemer je priporočljiva korelacija vsaj v višini $\rho = |0,4|$. Od 91 povezav med spremenljivkami je 10 takšnih, ki presegajo vrednost $|0,4|$. Zaradi povprečno nizke korelacije med spremenljivkami se lahko zgodi, da metoda glavnih komponent zaradi izgube prevelikega dela informacije ni učinkovita. Korelacijo med spremenljivkami in s tem smiselnost uporabe metode glavnih komponent sem preverila tudi s pomočjo KMO statistike in Barlettovega poizkusa, ki sta prikazana v Tabeli 6. Vrednost KMO statistike mora biti vsaj 0,4, zaželen pa je vrednost nad 0,6. V konkretnem primeru znaša 0,635 in je zato sprejemljiva. Bartlettov preizkus preizkuša domnevo, da je korelacijska matrika enaka enotski matriki, ki predpostavlja, da med spremenljivkami ni statistično pomembne povezanosti (Marinšek, 2015b). V konkretnem primeru lahko domnevo zavrnem ter sprejemam sklep, da je med pari spremenljivk vsaj nekaj statistično značilnih korelacij. Kljub nizkim posameznim koeficientom korelacije KMO statistika in Bartlettov preizkus kažeta na to, da lahko uspešno zmanjšam dimenzijo podatkov, zato metodo glavnih komponent izvedem.

Tabela 6: KMO statistika in Barlettov test


KMO statistika		0,635
Barlettov test	Približek Chi-kvadrata	157276
	df	91
	Sig.	0,000

Pri izbiri števila glavnih komponent je upoštevano Kaiserjevo pravilo in diagram lastnih vrednosti, kar prikazujeta Tabela 7 in Slika 18.

Tabela 7: Kaiserjevo pravilo

Komponenta	Lastna vrednost	Odstotek pojasnjene variance	Kumulativa (%)
1	3,072	21,940	21,940
2	2,044	14,602	36,542
3	1,900	13,575	50,117
4	1,462	10,441	60,558
5	0,969	6,921	67,479
6	0,893	6,377	73,857
7	0,754	5,385	79,242
8	0,694	4,959	84,200
9	0,614	4,389	88,589
10	0,461	3,295	91,884
11	0,382	2,727	94,611
12	0,360	2,574	97,185
13	0,219	1,563	98,749
14	0,175	1,251	100,000

Slika 18: Diagram lastnih vrednosti



Glede na Kaiserjevo pravilo obdržim toliko glavnih komponent, kolikor jih ima lastno vrednost, višjo od vrednosti 1. Pri tem so podatki standardizirani (varianca spremenljivk je normirana na

vrednost 1), zato vsaka spremenljivka prispeva enak delež informacije (Marinšek, 2015b, str. 49). Kot je prikazano v Tabeli 7, so izmed začetnih 14 spremenljivk podatki skrčeni na 4 glavne komponente, ki ohranijo 60,56 % variabilnosti prvotnih spremenljivk, pri čemer vsaka od komponent dodatno zajame vsaj 10 % celotne informacije prvotnih podatkov. V praksi sicer velja, da je na komponente priporočljivo prenesti vsaj 80 % začetne informacije, vendar je to odvisno tudi od podatkov (Marinšek, 2015b, str. 49). Diagram lastnih vrednosti, prikazan na Sliki 18, potrди, da je smiselna uporaba 4 glavnih komponent.

V Tabeli 8 so prikazane korelacije med posameznimi spremenljivkami in komponentami, pri čemer so za vsako komponento poudarjene spremenljivke, ki jo najbolj opredeljujejo. Za lažjo interpretacijo in razumljivost glavnih komponent sem jih glede na uteži spremenljivk na posameznih komponentah poimenovala sledeče:

- Glavna komponenta 1: Struktura financiranja
- Glavna komponenta 2: Dobičkonosnost
- Glavna komponenta 3: Pozicija na trgu
- Glavna komponenta 4: Struktura sredstev

Tabela 8: Komponentna matrika

Kazalnik	Komponenta			
	1. Struktura financiranja	2. Dobičkonosnost	3. Pozicija na trgu	4. Struktura sredstev
Log_prihodki	0,033	0,237	0,828	0,184
Plačilni rok	-0,004	0,024	0,456	0,090
Kapital v financiranju	0,691	-0,453	0,029	0,062
Dolg	-0,782	0,446	-0,188	0,010
Finančni dolg	-0,679	0,111	0,138	-0,412
Pospešeni koeficient	0,575	-0,318	-0,062	0,265
ROE	0,620	0,285	0,127	-0,349
ROA	0,557	0,617	-0,168	-0,298
Kratkoročna sredstva	0,204	0,291	-0,194	0,711
Obračanje sredstev	-0,062	0,637	-0,401	0,335
Dobičkonosnost prihodkov	0,640	0,426	0,017	-0,386
Bančni računi	-0,119	0,065	0,730	-0,033
Rast prihodkov	0,140	0,459	0,057	-0,059
Prihodki na zaposlenega	0,084	0,371	0,410	0,440

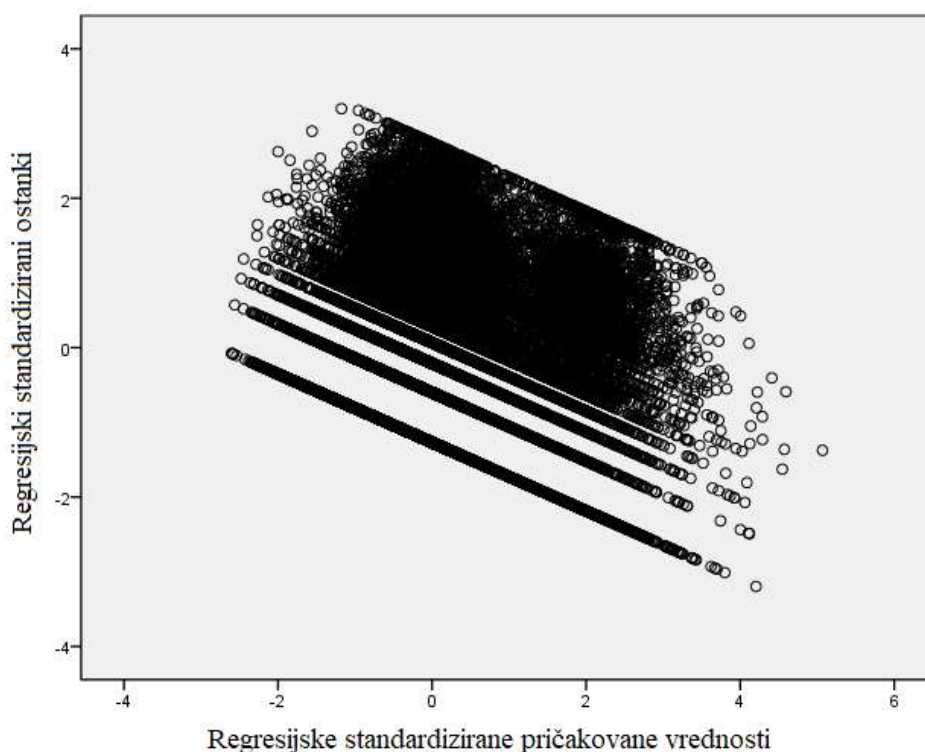
3.5.5 Preverjanje heteroskedastičnosti

Po končani metodi glavnih komponent je treba preveriti, če je v modelu prisotna heteroskedastičnost. Heteroskedastičnost se pojavi, kadar se varianca napak razlikuje pri različnih vrednostih odvisne spremenljivke. V nasprotju si prizadevamo za to, da je v modelu prisotna

homoskedastičnost, ki pomeni konstantno varianco napak odvisne spremenljivke (Osbourne & Waters, 2002, str. 4). Prisotnost heteroskedastičnosti sem preverila s pomočjo grafa, ki prikazuje razmerje med standardiziranimi ostanki (ZResid) in standardiziranimi pričakovanimi vrednostmi (ZPred). Heteroskedastičnost je prisotna, če je razpršenost ostankov različna pri različnih pričakovanih vrednostih.

Na Sliki 19 je prikazan graf ZResid-ZPred, iz katerega je razvidno, da je razpršenost ostankov konstantna, točke so slučajno razporejene, torej heteroskedastičnost ni problematična. Negativen vzorec lahko pripišemo winsorizaciji podatkov.

Slika 19: Heteroskedastičnost odvisne spremenljivke



3.6 Oblikovanje modela večnivojske linearne regresije za napovedovanje plačilne nedisciplin slovenskih podjetij

V sledečem poglavju prikažem razvoj večnivojskega linearne modela za napovedovanje plačilne discipline. Kot je prikazano v Poglavju 3.5.2, je uporaba tovrstne tehnike upravičena, saj je pri danih podatkih prisotna longitudinalna odvisnost, delno pa tudi presečna odvisnost. Pri razvoju večnivojskega linearne modela je tega priporočljivo graditi postopoma, od najbolj enostavnega do bolj zapletenih različic modela (Field, 2009, str. 820).

Z namenom lažje razumljivosti in primerljivosti z večnivojsko linearno regresijo je najprej izvedena bolj poznana tehnika multiple linearne regresije. Kot že omenjeno, je večnivojska linearna regresija nadgradnja multiple linearne regresije, saj za razliko od slednje uspešno upošteva longitudinalno in presečno odvisnost med opazovanji. Multipla linearna regresija se običajno ocenjuje po metodi najmanjših kvadratov oziroma po OLS metodi (angl. *Ordinary Least*

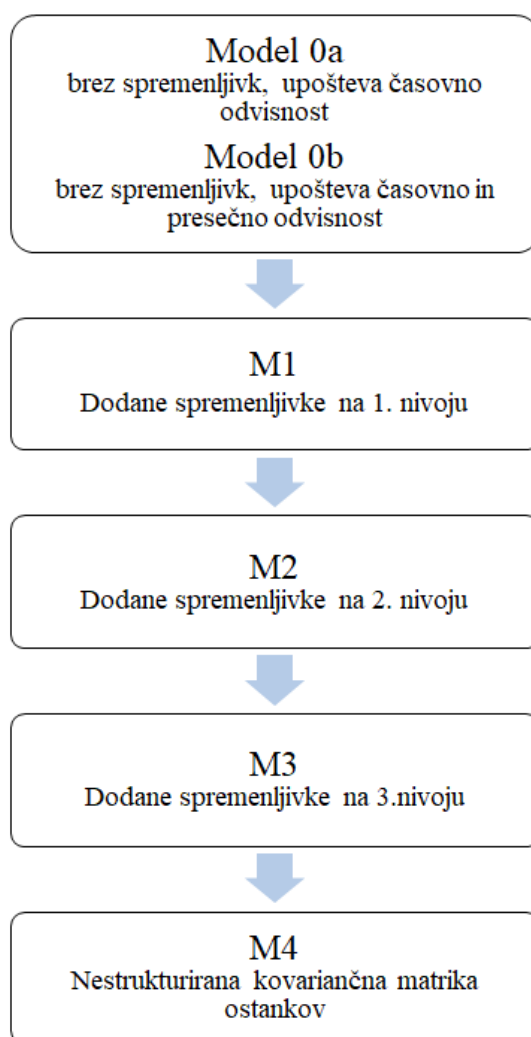
Squares), medtem ko se za večnivojsko linearno regresijo uporablja metoda največjega verjetja (angl. *Maximum Likelihood Method*). Pri metodi najmanjših kvadratov ocena statističnih parametrov temelji na minimizaciji vsote kvadratov napak, pri metodi največjega verjetja pa so parametri izbrani na način, da se najbolj prilagajajo podatkom, zajetim v izbranem vzorcu.

Pri metodi največjega verjetja regresijske koeficiente ocenjujemo s pomočjo Maximum Likelihooda (ML) ali s pomočjo Restricted Maximum Likelihooda (REML). ML je bolj primerna izbira za oceno fiksnih parametrov, medtem ko REML omogoča bolj natančne ocene slučajnih vplivov. Izbira med ML in REML metodo sicer običajno ne prinese bistvene razlike ocen parametrov (Field, 2009, str. 835). Sama v modelih, kjer se postopno vključujejo fiksni vplivi na različnih nivojih, uporabim metodo ML, v ostalih modelih, kjer so pomembnejši slučajni vplivi, pa metodo REML.

Regresijske modele, ocenjene po metodi največjega verjetja, primerjamo s pomočjo -2 Log-Likelihood statistike (-2 ML LL oziroma -2 REML LL), ki je porazdeljena v χ^2 porazdelitvi. Nižja kot je -2 LL statistika, boljši je model. Pri tem je treba upoštevati tudi število parametrov oziroma stopinj prostosti, vključenih v model, in χ^2 porazdelitve, kar je podrobneje predstavljeno v nadaljevanju. Če preprostejši model ni podmnožica kompleksnejšega modela, se za primerjavo med večnivojskimi modeli alternativno uporablja AIC statistika, ki je prilagojena različica -2 LL statistike. AIC statistika prav tako pokaže, kako dobro se regresijski model prilagaja podatkom, popravljena je za kompleksnost modela, saj upošteva število ocenjenih parametrov. Njena nižja vrednost pomeni boljše prilaganje. -2LL in AIC statistika sta uporabni za primerjavo različnih modelov, saj njuna vrednost omogoča primerjavo nepojasnjene informacije, ki ni zajeta z modelom, vendar pa njuna vrednost ni interpretabilna (Marinšek, 2015b, str. 32; Field, 2009, str. 763, 826). Ker med seboj primerjam modele, ki so podmnožice kompleksnejših modelov (t.i. vgnezdene modeli), je za primerjavo med modeli uporabljena -2 Log-Likelihood statistika, kot alternativa je v končnem povzetku rezultatov modelov (Tabela 24) prikazana tudi AIC statistika. Z namenom primerljivosti modelov so vsi modeli ocenjeni po metodi največjega verjetja. V programu SPSS je za izgradnjo večnivojske linearne regresije uporabljena procedura Mixed models (Linear).

Na Sliki 20 je grafični prikaz razvoja večnivojskega linearnega modela, ki je zgrajen v petih korakih. Prvi model (M0) prikazuje model brez pojasnjevalnih spremenljivk, in sicer v dveh različicah: model M0a upošteva samo časovno odvisnost, model M0b pa časovno in presečno odvisnost. Nato skozi modele M1-M3 sledi sprotno dodajanje pojasnjevalnih spremenljivk od prvega do tretjega nivoja. V modelu M4 je uporabljena nestrukturirana kovariančna matrika ostankov namesto AR(1) matrike, ki je uporabljena v predhodnih modelih.

Slika 20: Koraki razvoja večnivojskega linearnega modela



V Tabeli 9 je povzetek modela multiple linearne regresije, v katero je vključenih vseh 8 pojasnjevalnih spremenljivk (uporabljena je Enter metoda vključevanja neodvisnih spremenljivk). Koeficient multiple determinacije znaša 0,174, kar pomeni, da je 17,4 % variabilnosti odvisne spremenljivke logaritma zamud pri plačilih pojasnjenih z variiranjem pojasnjevalnih spremenljivk vključenih v analizo. AIC statistika, ki je pomembna za primerjavo z nadaljnjimi modeli, znaša 44.211. Multipla regresija ni zanesljiva, saj ne upošteva niti presečne niti longitudinalne odvisnosti ter zato v nadaljevanju ne bo obravnavana/pojasnjena. Izvedena je samo z namenom primerjave z večnivojsko linearno regresijo, da dokažem, da s slednjo pri analizi panelnih podatkov lahko dosežemo večjo napovedovalno moč modela. Ker želim pokazati pomembnost upoštevanja časovne komponente, sem izvedla tudi multiplo linearno regresijo, ki upošteva longitudinalno odvisnost. Napovedovalna moč modela, ki je prikazan v Tabeli 10, se z vključitvijo časovne komponente močno izboljša. Kot že omenjeno, lahko kot merilo izboljšave uporabim kazalnik AIC. Slednji se z upoštevanjem longitudinalne odvisnosti močno zmanjša, in sicer iz predhodne vrednosti 44.211 na vrednost 19.678. Oba modela multiple linearne regresije sta v namene primerjave z večnivojskimi modeli predstavljena v Tabeli 24, kjer so predstavljeni tudi povzetki večnivojskih linearnih modelov, predstavljenih v nadaljevanju.

Tabela 9: Multipla linearna regresija, ki ne upošteva časovne odvisnosti med opazovanji

R	R ²	Prilagojen R ²	Std. napaka	-2 Log Likelihood	AIC
0,417	0,174	0,173	0,45072	44208,527	44210,527

Tabela 10: Multipla linearna regresija, ki upošteva časovno odvisnost med opazovanji

-2 Log Likelihood	19673,653
Akaike informacijski kriterij (AIC)	19677,653

V nadaljevanju predstavljam postopen razvoj večnivojskega modela za napovedovanje plačilne discipline. Struktura modela je zasnovana na že vzpostavljeni tehniki (Marinšek, 2015a). Osrednja hipoteza H1 predpostavlja, da se napovedovalna moč modela za napovedovanje plačilne discipline slovenskih podjetij bistveno izboljša z uporabo tehnike MLM. Hipoteza H1 bo sprejeta ali zavrnjena po končanem razvoju modela za napovedovanje plačilne discipline. Poleg osrednje hipoteze H1 so v nadaljevanju pri vsakem modelu predstavljene tudi bolj specifične hipoteze H₂–H₆.

Model 0

Model 0 je osnovni model brez pojasnjevalnih spremenljivk, vključena je samo regresijska konstanta. Spodaj sta predstavljeni dve različici modela, in sicer Model 0a upošteva samo longitudinalno odvisnost med opazovanji, Model 0b pa longitudinalno in presečno odvisnost.

Kot lahko vidimo v Poglavju 3.5.2, koeficient avtokorelacije kaže na močno longitudinalno odvisnost med opazovanimi enotami, zato je modeliranje slednje nujno potrebno. Model 0a brez pojasnjevalnih spremenljivk, ki upošteva longitudinalno odvisnost, je prikazan z enačbo (15). Uporabljena je REML metoda.

$$\begin{aligned} \text{Log_zamuda}_{ij} &= \beta_0 + \varepsilon_{ij} \\ \varepsilon_{ij} &\sim N(0, \sigma^2) \end{aligned} \quad (15)$$

Pri tem Log_zamuda_{ij} predstavlja vrednost odvisne spremenljivke v času t, za podjetje i, ki posluje v panogi j. β_0 je fiksna regresijska konstanta, ε_{ij} pa slučajna napaka. Predpostavlja se normalna porazdelitev slučajne napake ε_{ij} , σ^2 predstavlja varianco slučajne napake. Prikaz parametrov modela je predstavljen v Tabeli 11, ocena kovariančnih parametrov in kriteriji primerljivosti pa v Tabeli 12. Kriteriji primerljivosti so uporabljeni pri primerjavi z ostalimi modeli. Model je na podlagi Tabele 11 in Tabele 12 prikazan v enačbi (16).

$$\begin{aligned} \text{Log_zamuda}_{ij} &= 0,560 \\ \varepsilon_{ij} &\sim N(0, 0,243) \end{aligned} \quad (16)$$

Tabela 11: Parametri – Model 0a

Parameter	Ocena	Std. napaka	t	Sig.
Konstanta	0,559649	0,004603	121,574	0,000

Tabela 12: Ocena kovariančnih parametrov in kriteriji primerljivosti – Model 0a

Parameter	Ocena	Std. napaka	Wald Z	Sig.
Ponavljajoče meritve Var slučajna napaka	0,242883	0,002892	83,995	0,000
-2 Log Likelihood	20493,009			
Akaike informacijski kriterij (AIC)	20497,009			

Za ocenjevanje modela je izbrana AR(1) (angl. *First-order autoregressive structure*) kovariančna matrika ostankov, ki predpostavlja, da so opazovanja, ki so bližje v času, med seboj bolj odvisna. V primeru panelnih podatkov, ki vključujejo letna opazovanja, je AR(1) najbolj primerna oblika kovariančne matrike ostankov (Marinšek, 2015b, str. 31).

Model 0b ne vključuje pojasnjevalnih spremenljivk in upošteva časovno in presečno odvisnost. Čeprav glede na predhodno izračunan ICC kazalnik, presečna odvisnost v danih podatkih ni problematična v takšni meri, da bi jo bilo treba obvezno modelirati, je ta kljub temu delno prisotna. Iz tega razloga sem se odločila, da jo kljub temu poizkusim odpraviti ter tako morebiti izboljšati rezultate predhodnega modela. Model 0a predpostavlja, da je regresijska konstanta fiksna. Predpostavlja, da lahko za napovedovanje plačilne discipline v vseh panogah uporabimo enake vrednosti regresijske konstante, torej da med skupinami ni razlik. Presečna odvisnost je v modelu 0b upoštevana tako, da je omogočeno prosto variiranje regresijske konstante v skupinah na višjih nivojih, tj. panogah. Regresijska konstanta se tako med panogami razlikuje, kar je grafično prikazano na Sliki 10. To storimo tako, da namesto fiksnih vplivov (angl. *Fixed effects*) uporabimo t.i. slučajne vplive (angl. *Random effects*). Uporabljena je AR(1) kovariančna matrika ostankov. Model 0b je prikazan v enačbi (17).

$$\begin{aligned} \text{Log_zamuda}_{tij} &= \beta_0 + u_{0j} + \varepsilon_{tij} \\ u_{0j} &\sim N(0, \sigma_{pan}^2) \quad \varepsilon_{tij} \sim N(0, \sigma^2) \end{aligned} \quad (17)$$

Pri tem Log_zamuda_{tij} predstavlja vrednost odvisne spremenljivke v času t , za podjetje i , ki posluje v panogi j . β_0 je fiksna regresijska konstanta, u_{0j} slučajen vpliv, povezan s konstanto na nivoju panoge, ε_{tij} pa slučajna napaka. Predpostavlja se normalna porazdelitev slučajnega vpliva u_{0j} in slučajne napake ε_{tij} . σ_{pan}^2 predstavlja varianco slučajnega vpliva konstante na nivoju panoge, σ^2 pa varianco slučajne napake. Prikaz parametrov modela je predstavljen v Tabeli 13, ocena kovariančnih parametrov in kriteriji primerljivosti pa v Tabeli 14. Model je na podlagi Tabele 13 in Tabele 14 prikazan v enačbi (18):

$$\begin{aligned} \text{Log_zamuda}_{tij} &= 0,539 \\ u_{0j} &\sim N(0, 0,005) \quad \varepsilon_{tij} \sim N(0, 0,239) \end{aligned} \quad (18)$$

Tabela 13: Parametri – Model 0b

Parameter	Ocena	Std. napaka	t	Sig.
Konstanta	0,539013	0,019052	28,291	0,000

Tabela 14: Ocena kovariančnih parametrov in kriteriji primerljivosti – Model 0b

Parameter	Ocena	Std. napaka	Wald Z	Sig.
Ponavljajoče meritve Var slučajna napaka	0,239241	0,002842	84,189	0,000
Konstanta (nivo = Panoga) Var panoga	0,004644	0,002012	3,874	0,021
-2 Log Likelihood	20348,586			
Akaike informacijski kriterij (AIC)	20354,586			

Testiranje hipoteze

$$H_0: \sigma_{pan}^2 = 0 \quad H_2: \sigma_{pan}^2 > 0$$

Testiranje učinkovitosti upoštevanja presečne odvisnosti oziroma slučajnega vpliva, povezanega s konstanto na nivoju panoge u_{0j} , je izvedeno posredno preko testiranja njegove variance σ_{pan}^2 . Kot omenjeno, je za primerjavo prileganja večnivojskih modelov uporabljena -2 Log-Likelihood statistika (v nadaljevanju -2LL). To storimo tako, da od -2LL novega modela odštejemo -2LL starega modela, kot je prikazano v nadaljevanju. Pri tem je treba upoštevati spremembo števila stopinj prostosti, kot je prikazano spodaj (Field, 2009, str. 826). Število stopinj prostosti vseh modelov, vključenih v analizo, je prikazano v Tabeli 15.

-2 REML log-likelihood vgnezenega modela (M0a): 20.493,0

-2 REML log-likelihood referenčnega modela (M0b): 20.348,6

$$\chi_{sprememba}^2 = \Delta -2 REML LL = (-2LL_{stara}) - (-2LL_{nova}) = (-2LL_{M0a}) - (-2LL_{M0b}) = 20.493,0 - 20.348,6 = 144,4$$

Sprememba stopinj prostosti :

$$df_{sprememba} = k_{nova} - k_{stara} = k_{M0b} - k_{M0a} = 4 - 3 = 1,$$

kjer k predstavlja število parametrov v posameznem modelu.

Kritična vrednost χ^2 statistike z 1 stopinjo prostosti je 3,84 ($p < 0,05$) in 6,63 ($p < 0,01$) (Košmelj & Rován, 2006, str. 67). Ker $\chi_{sprememba}^2$ znaša 144,4, je razlika močno statistično značilna pri $p = 0,01$. Lahko zaključim, da je varianca konstante na nivoju panoge σ_{pan}^2 pozitivna ter sprejemem hipotezo H_2 . Konstanta na nivoju panoge značilno variira med različnimi panogami. Slučajen vpliv je zato uporabljen tudi v nadaljnjih modelih. Model 0b je primernejši od Modela 0a.

Tabela 15: Število parametrov oziroma stopinj prostosti po modelih

Model		M0a		M0b		M1		M2		M3		M4	
		N	df	N	df	N	df	N	df	N	df	N	df
Fiksni efekti	Konstanta	1	1	1	1	1	1	1	1	1	1	1	1
	Struktura financiranja_L1					1	1	1	1	1	1	1	1
	Dobičkonosnost_L1					1	1	1	1	1	1	1	1
	Pozicija na trgu_L1					1	1	1	1	1	1	1	1
	Struktura sredstev_L1					1	1	1	1	1	1	1	1
	Blokada_L1					1	1	1	1	1	1	1	1
	DD_L2							1	1				
	Blokada_panoga_L3									1	1	1	1
	Prihodki_panoga_L3									1	1	1	1
Slučajni vplivi	Konstanta (panoga)			1	1	1	1	1	1	1	1	1	1
Ponavljajoči vplivi	Leto (panoga * ID podjetja)	4	2*	4	2*	4	2*	4	2*	4	2*	4	10**
Skupno		5	3	6	4	11	9	12	10	13	11	13	19

Legenda: * N – število nivojev, df – število parametrov/stopinj prostosti; * AR(1) kovariančna struktura, ** Nestrukturirana kovariančna struktura

Model 1

V Modelu 1, ki je nadgradnja Modela 0b, so dodane neodvisne spremenljivke na prvem nivoju oziroma spremenljivke na ravni podjetja, katerih vrednosti se spreminjajo v času. Regresijski koeficienti so fiksni, uporabljena je AR(1) kovariančna matrika ostankov. Model 1 opisuje enačba (19). Uporabljena je ML metoda.

$$\begin{aligned} \text{Log_zamuda}_{ij} = & \beta_0 + \beta_1 \cdot \text{Struktura financiranja}_{(t-1)ij} + \beta_2 \cdot \text{Dobičkonosnost}_{(t-1)ij} + \beta_3 \cdot \text{Pozicija na trgu}_{(t-1)ij} + \beta_4 \cdot \text{Struktura sredstev}_{(t-1)ij} + \beta_5 \cdot \text{Blokada}_{(t-1)ij} + u_{0j} + \varepsilon_{ij} \quad (19) \\ & u_{0j} \sim N(0, \sigma_{pan}^2) \quad \varepsilon_{ij} \sim N(0, \sigma^2) \end{aligned}$$

Pri tem Log_zamuda_{ij} predstavlja vrednost odvisne spremenljivke v času t , za podjetje i , ki posluje v panogi j . β_0 je fiksna regresijska konstanta, β_1 do β_5 so fiksni regresijski koeficienti/vplivi, povezani s pojasnjevalnimi spremenljivkami na prvem nivoju. u_{0j} je slučajen vpliv, povezan s konstanto na nivoju panoge, ε_{ij} pa slučajna napaka. Predpostavlja se normalna porazdelitev slučajnega vpliva u_{0j} in slučajne napake ε_{ij} . σ_{pan}^2 predstavlja varianco slučajnega vpliva konstante na nivoju panoge, σ^2 pa varianco slučajne napake. Prikaz parametrov modela je predstavljen v Tabeli 16, ocena kovariančnih parametrov in kriteriji primerljivosti pa v Tabeli 17. Model je na podlagi Tabele 16 in Tabele 17 prikazan v enačbi (20).

$$\begin{aligned} \text{Log_zamuda}_{ij} = & 0,530 - 0,076 \cdot \text{Struktura financiranja}_{(t-1)ij} + 0,009 \cdot \text{Dobičkonosnost}_{(t-1)ij} + 0,029 \cdot \text{Pozicija na trgu}_{(t-1)ij} - 0,037 \cdot \text{Struktura sredstev}_{(t-1)ij} + 0,051 \cdot \text{Blokada}_{(t-1)ij} \quad (20) \\ & u_{0j} \sim N(0, 0,003) \quad \varepsilon_{ij} \sim N(0, 0,216) \end{aligned}$$

Tabela 16: Parametri – Model 1

Parameter	Ocena	Std. napaka	t	Sig.
Konstanta	0,530030	0,016369	32,379	0,000
Struktura financiranja_L1	-0,076192	0,002798	-27,230	0,000
Dobičkonosnost_L1	0,009478	0,002433	3,895	0,000
Pozicija na trgu_L1	0,029177	0,003835	7,609	0,000
Struktura sredstev_L1	-0,036937	0,002991	-12,352	0,000
Blokada_L1	0,051045	0,005310	9,613	0,000

Tabela 17: Ocena kovariančnih parametrov in kriteriji primerljivosti – Model 1

Parameter	Ocena	Std. napaka	Wald Z	Sig.
Ponavljajoče meritve Var slučajna napaka	0,215836	0,002565	84,161	0,000
Konstanta (nivo = Panoga) Var panoga	0,003273	0,001490	2,196	0,028
-2 Log Likelihood	19448,888			
Akaike informacijski kriterij (AIC)	19466,888			

Testiranje hipotez

$H_0: \beta_1 = \beta_2 = \beta_3 = \beta_4 = \beta_5 = 0$ $H_3: \text{Vsaj en } \beta_j \text{ ni enak } 0.$

Kot je razvidno iz Tabele 16, imajo vse pojasnjevalne spremenljivke prvega nivoja statistično značilen vpliv na plačilno disciplino. To je razvidno iz t-testov, ki kažejo na statistično značilnost spremenljivk pri $p = 0,000$. Prav tako s pomočjo -2LL statistike preverim ustreznost celotnega kompleksnejšega Modela 1 v primerjavi z vgnezenim Modelom 0b.

-2 ML log-likelihood M0b: 20.348,6

-2 ML log-likelihood M1: 19.448,9

$$\chi^2_{\text{sprememba}} = \Delta -2 \text{ ML LL} = (-2LL_{M0b}) - (-2LL_{M1}) = 20.348,6 - 19.448,9 = 899,7$$

Sprememba stopinj prostosti :

$$df_{\text{sprememba}} = k_{M1} - k_{M0b} = 9 - 4 = 5,$$

kjer k predstavlja število parametrov v posameznem modelu.

Kritična vrednost χ^2 statistike s 5 stopinjami prostosti je 11,07 ($p < 0,05$) in 15,09 ($p < 0,01$) (Košmelj & Rován, 2006, str. 67). Vidimo lahko, da je razlika močno statistično značilna pri $p = 0,01$. Sprejemem hipotezo H_3 , saj vsaj en β_j ni enak 0. Model 1 je primernejši od Modela 0b, saj se z vključitvijo pojasnjevalnih spremenljivk na prvem nivoju pojasnjevalna moč modela poveča.

Model 2

V Modelu 2, ki je nadgradnja Modela 1, je dodana spremenljivka drugega nivoja, tj. pravnoorganizacijska oblika podjetja (DD). To je spremenljivka na ravni podjetja, katere vrednost se v času ne spreminja. Regresijski koeficienti so fiksni, uporabljena je AR(1) kovariančna matrika ostankov. Model 2 je prikazan z enačbo (21). Uporabljena je ML metoda.

$$\begin{aligned} \text{Log_zamuda}_{ij} = & \beta_0 + \beta_1 \cdot \text{Struktura financiranja}_{(t-1)ij} + \beta_2 \cdot \text{Dobičkonosnost}_{(t-1)ij} \\ & + \beta_3 \cdot \text{Pozicija na trgu}_{(t-1)ij} + \beta_4 \cdot \text{Struktura sredstev}_{(t-1)ij} + \beta_5 \cdot \text{Blokada}_{(t-1)ij} \\ & + \beta_6 \cdot \text{DD}_{ij} + u_{0j} + \varepsilon_{ij} \end{aligned} \quad (21)$$

$$u_{0j} \sim N(0, \sigma_{pan}^2) \quad \varepsilon_{ij} \sim N(0, \sigma^2)$$

Pri tem Log_zamuda_{ij} predstavlja vrednost odvisne spremenljivke v času t , za podjetje i , ki posluje v panogi j . β_0 je fiksna regresijska konstanta, β_1 – β_6 so fiksni regresijski koeficienti/vplivi, povezani s pojasnjevalnimi spremenljivkami na prvem in drugem nivoju. u_{0j} je slučajen vpliv, povezan s konstanto na nivoju panoge, ε_{ij} pa slučajna napaka. Predpostavlja se normalna porazdelitev slučajnega vpliva u_{0j} in slučajne napake ε_{ij} . σ_{pan}^2 predstavlja varianco slučajnega vpliva konstante na nivoju panoge, σ^2 pa varianco slučajne napake. Prikaz parametrov modela je predstavljen v Tabeli 18, ocena kovariančnih parametrov in kriteriji primerljivosti pa v Tabeli 19. Model je na podlagi Tabele 18 in Tabele 19 prikazan v enačbi (22).

$$\begin{aligned} \text{Log_zamuda}_{ij} = & 0,531 - 0,076 \cdot \text{Struktura financiranja}_{(t-1)ij} + 0,009 \\ & \text{Dobičkonosnost}_{(t-1)ij} + 0,030 \cdot \text{Pozicija na trgu}_{(t-1)ij} - 0,037 \cdot \text{Struktura sredstev}_{(t-1)ij} \\ & + 0,051 \cdot \text{Blokada}_{(t-1)ij} - 0,020 \cdot \text{DD}_{ij} \end{aligned} \quad (22)$$

$$u_{0j} \sim N(0, 0,003) \quad \varepsilon_{ij} \sim N(0, 0,216)$$

Tabela 18: Parametri – Model 2

Parameter	Ocena	Std. napaka	t	Sig.
Konstanta	0,530791	0,016414	32,338	0,000
Struktura financiranja_L1	-0,076212	0,002798	-27,237	0,000
Dobičkonosnost_L1	0,009439	0,002434	3,878	0,000
Pozicija na trgu_L1	0,029907	0,003974	7,526	0,000
Struktura sredstev_L1	-0,036929	0,002990	-12,349	0,000
Blokada_L1	0,051088	0,005310	9,621	0,000
DD_L2	-0,019606	0,028006	-0,700	0,484

Tabela 19: Ocena kovariančnih parametrov in kriteriji primerljivosti – Model 2

Parameter		Ocena	Std. napaka	Wald Z	Sig.
Ponavljajoče meritve	Var slučajna napaka	0,215819	0,002564	84,159	0,000
Konstanta (nivo = Panoga)	Var panoga	0,003277	0,001493	2,194	0,028
-2 Log Likelihood		19448,398			
Akaike informacijski kriterij (AIC)		19468,398			

Testiranje hipotez

$$H_0: \beta_6 = 0 \quad H_4: \beta_6 \neq 0$$

S pomočjo -2LL statistike sem preverila ustreznost Modela 2 v primerjavi z vgnezenim Modelom 1.

-2 ML log-likelihood M1: 19.448,9

-2 ML log-likelihood M2: 19.448,4

$$\chi^2_{sprememba} = \Delta -2 ML LL = (-2LL_{M1}) - (-2LL_{M2}) = 19.448,9 - 19.448,4 = 0,5$$

Sprememba stopinj prostosti:

$$df_{sprememba} = k_{M2} - k_{M1} = 10 - 9 = 1,$$

kjer k predstavlja število parametrov v posameznem modelu.

Kritična vrednost χ^2 statistike z 1 stopinjo prostosti je 3,84 ($p < 0,05$) in 6,63 ($p < 0,01$) (Košmelj & Rovan, 2006, str. 67). Ker χ^2 statistika v mojem primeru znaša 0,5, razlika ni statistično značilna. Zavrnem hipotezo H_4 . Prav tako edina spremenljivka drugega nivoja (DD) nima statistično značilnega vpliva na plačilno disciplino, kar je razvidno iz t-testa v Tabeli 18. Model 2 ni primernejši od Modela 1. Z danimi podatki nisem uspela dokazati, da spremenljivka drugega nivoja statistično vpliva na plačilno disciplino. Drugi nivo je zato izključen iz nadaljnje analize.

Model 3

V Modelu 3, ki je nadgradnja Modela 1, sta dodani spremenljivki tretjega nivoja – blokada panoge in prihodki panoge. To sta spremenljivki na ravni panoge. Regresijski koeficienti so fiksni, uporabljena je AR(1) kovariančna matrika ostankov. Model 3 je prikazan z enačbo (23). Uporabljena je ML metoda.

$$\begin{aligned} \text{Log_zamuda}_{ij} = & \beta_0 + \beta_1 \cdot \text{Struktura financiranja}_{(t-1)ij} + \beta_2 \cdot \text{Dobičkonosnost}_{(t-1)ij} \quad (23) \\ & + \beta_3 \cdot \text{Pozicija na trgu}_{(t-1)ij} + \beta_4 \cdot \text{Struktura sredstev}_{(t-1)ij} + \beta_5 \cdot \text{Blokada}_{(t-1)ij} \\ & + \beta_6 \cdot \text{Blokada panoge}_{(t-1)ij} + \beta_7 \cdot \text{Prihodki panoge}_{(t-1)ij} + u_{0j} + \varepsilon_{ij} \\ & u_{0j} \sim N(0, \sigma_{pan}^2) \quad \varepsilon_{ij} \sim N(0, \sigma^2) \end{aligned}$$

Pri tem Log_zamuda_{ij} predstavlja vrednost odvisne spremenljivke v času t , za podjetje i , ki posluje v panogi j . β_0 je fiksna regresijska konstanta, β_1 do β_7 so fiksni regresijski koeficienti/vplivi, povezani s pojasnjevalnimi spremenljivkami na prvem in tretjem nivoju. u_{0j} je slučajen vpliv, povezan s konstanto na nivoju panoge, ε_{ij} pa slučajna napaka. Predpostavlja se normalna porazdelitev slučajnega vpliva u_{0j} in slučajne napake ε_{ij} . σ_{pan}^2 predstavlja varianco slučajnega vpliva konstante na nivoju panoge, σ^2 pa varianco slučajne napake. Prikaz parametrov modela je predstavljen v Tabeli 20, ocena kovariančnih parametrov in kriteriji primerljivosti pa v Tabeli 21. Model je na podlagi Tabele 20 in Tabele 21 prikazan v enačbi (24).

$$\begin{aligned} \text{Log_zamuda}_{ij} = & 0,509 - 0,075 \cdot \text{Struktura financiranja}_{(t-1)ij} + 0,009 \quad (24) \\ & \text{Dobičkonosnost}_{(t-1)ij} + 0,029 \cdot \text{Pozicija na trgu}_{(t-1)ij} - 0,037 \cdot \text{Struktura sredstev}_{(t-1)ij} \\ & + 0,052 \cdot \text{Blokada}_{(t-1)ij} - 3,19 E^{-5} \cdot \text{Blokada panoge}_{(t-1)ij} \\ & + 0,000 \cdot \text{Prihodki panoge}_{(t-1)ij} \\ & u_{0j} \sim N(0, 0,008) \quad \varepsilon_{ij} \sim N(0, 0,216) \end{aligned}$$

Tabela 20: Parametri – Model 3

Parameter	Ocena	Std. napaka	t	Sig.
Konstanta	0,508606	0,024553	20,715	0,000
Struktura financiranja_L1	-0,074980	0,002799	-26,786	0,000
Dobičkonosnost_L1	0,008692	0,002433	3,573	0,000
Pozicija na trgu_L1	0,029242	0,003848	7,599	0,000
Struktura sredstev_L1	-0,037036	0,002991	-12,381	0,000
Blokada_L1	0,051741	0,005306	9,751	0,000
Blokada_panoga_L3	-3,19E-05	4,96E-06	-6,431	0,000
Prihodki_panoga_L3	2,00E-08	2,47E-09	8,099	0,000

Tabela 21: Ocena kovariančnih parametrov in kriteriji primerljivosti – Model 3

Parameter	Ocena	Std. napaka	Wald Z	Sig.
Ponavljajoče meritve Var slučajna napaka	0,215555	0,002566	84,011	0,000
Konstanta (nivo = Panoga) Var panoga	0,008347	0,003501	2,384	0,017
-2 Log Likelihood	19366,167			
Akaike informacijski kriterij (AIC)	19388,167			

Testiranje hipotez

$H_0: \beta_6 = \beta_7 = 0$ $H_5: Vsaj en \beta_j$ tretjega nivoja ni enak 0.

S pomočjo -2LL statistike sem preverila ustreznost Modela 3 v primerjavi z vgnezdenim Modelom 1.

-2 ML log-likelihood M1: 19.448,9

-2 ML log-likelihood M3: 19.366,2

$$\chi^2_{sprememba} = \Delta -2 ML LL = (-2LL_{M1}) - (-2LL_{M3}) = 19.366,2 - 19.448,9 = 82,7$$

Sprememba stopinj prostosti:

$$df_{sprememba} = k_{M3} - k_{M1} = 11 - 9 = 2,$$

kjer k predstavlja število parametrov v posameznem modelu.

Kritična vrednost χ^2 statistike z 2 stopinjama prostosti je 5,99 ($p < 0,05$) in 9,21 ($p < 0,01$) (Košmelj & Rovan, 2006, str. 67). Razlika je močno statistično značilna pri $p = 0,01$, zato sprejemem hipotezo H_5 . Glede na t-statistiko imajo vse pojasnjevalne spremenljivke statistično značilen vpliv na plačilno disciplino. Čeprav sta regresijska koeficienta spremenljivk tretjega nivoja β_6 in β_7 zelo nizka, spremenljivki obdržim, saj se pojasnjevalna moč modela z vključitvijo spremenljivk tretjega nivoja poveča. Kompleksnejši Model 3 je primernejši od vgnezdenega Modela 1.

Model 4

Model 4 je po strukturi enak Modelu 3, od njega se razlikuje v tem, da je namesto AR(1) uporabljena nestrukturirana (angl. *Unstructured*) kovariančna matrika ostankov. Za nestrukturirano matriko ostankov je značilno, da kovariance ne sledijo sistematičnemu vzorcu, ampak so popolnoma nepredvidljive ter heterogene (Field, 2009, str. 827). Zaradi spremenjene strukture matrike ostankov so parametri ocenjeni na drugačen način kot v predhodnih modelih, zato pričakujem spremembo njihovih vrednosti (Field, 2009, str. 826). Model 4 je prikazan z enačbo (25). Uporabljena je REML metoda.

$$\begin{aligned} \text{Log_zamuda}_{ij} = & \beta_0 + \beta_1 \cdot \text{Struktura financiranja}_{(t-1)ij} + \beta_2 \cdot \text{Dobičkonosnost}_{(t-1)ij} & (25) \\ & + \beta_3 \cdot \text{Pozicija na trgu}_{(t-1)ij} + \beta_4 \cdot \text{Struktura sredstev}_{(t-1)ij} + \beta_5 \cdot \text{Blokada}_{(t-1)ij} \\ & + \beta_6 \cdot \text{Blokada panoge}_{(t-1)j} + \beta_7 \cdot \text{Prihodki panoge}_{(t-1)j} + u_{0j} + \varepsilon_{ij} \\ & u_{0j} \sim N(0, \sigma_{pan}^2) \quad \varepsilon_{ij} \sim N(0, \sigma^2) \end{aligned}$$

Pri tem Log_zamuda_{ij} predstavlja vrednost odvisne spremenljivke v času t, za podjetje i, ki posluje v panogi j. β_0 je fiksna regresijska konstanta, β_1 do β_7 so fiksni regresijski koeficienti/vplivi, povezani s pojasnjevalnimi spremenljivkami na prvem in tretjem nivoju. u_{0j} je slučajen vpliv, povezan s konstanto na nivoju panoge, ε_{ij} pa slučajna napaka. Predpostavlja se normalna

porazdelitev slučajnega vpliva u_{0j} in slučajne napake ε_{tij} . σ_{pan}^2 predstavlja varianco slučajnega vpliva konstante na nivoju panoge, σ^2 pa varianco slučajne napake. Prikaz parametrov modela je predstavljen v Tabeli 22, ocena kovariančnih parametrov in kriteriji primerljivosti pa v Tabeli 23. Model je na podlagi Tabele 22 in Tabele 23 prikazan v enačbi (26).

$$\begin{aligned} \text{Log_zamuda}_{tij} = & 0,504 - 0,074 \cdot \text{Struktura financiranja}_{(t-1)ij} + 0,007 \cdot \\ & \text{Dobičkonosnost}_{(t-1)ij} + 0,031 \cdot \text{Pozicija na trgu}_{(t-1)ij} - 0,035 \cdot \text{Struktura sredstev}_{(t-1)ij} \\ & + 0,051 \cdot \text{Blokada}_{(t-1)ij} - 3,87 E^{-5} \cdot \text{Blokada panoge}_{(t-1)j} \\ & + 0,000 \cdot \text{Prihodki panoge}_{(t-1)j} \\ u_{0j} \sim & N(0, 0,009) \quad \varepsilon_{tij} \sim N(0, \sigma^2) \end{aligned} \quad (26)$$

Tabela 22: Parametri – Model 4

Parameter	Ocena	Std. napaka	t	Sig.
Konstanta	0,503892	0,025898	19,457	0,000
Struktura financiranja_L1	-0,074369	0,002796	-26,601	0,000
Dobičkonosnost_L1	0,006757	0,002443	2,766	0,006
Pozicija na trgu_L1	0,031045	0,003861	8,041	0,000
Struktura sredstev_L1	-0,034705	0,002996	-11,585	0,000
Blokada_L1	0,051467	0,005375	9,576	0,000
Blokada_panoga_L3	-3,87E-05	4,44E-06	-8,729	0,000
Prihodki_panoga_L3	2,11E-08	2,49E-09	8,493	0,000

Tabela 23: Ocena kovariančnih parametrov in kriteriji primerljivosti – Model 4

Parameter	Ocena	Std. napaka	Wald Z	Sig.	
Ponavljajoče meritve	Var (1)	0,226704	0,003494	64,886	0,000
	Cov (2, 1)	0,184077	0,003218	57,207	0,000
	Var (2)	0,229026	0,003529	64,889	0,000
	Cov (3, 1)	0,160470	0,003024	53,059	0,000
	Cov (3, 2)	0,181714	0,003175	57,236	0,000
	Var (3)	0,218346	0,003377	64,656	0,000
	Cov (4, 1)	0,130933	0,002725	48,051	0,000
	Cov (4, 2)	0,147845	0,002835	52,158	0,000
	Cov (4, 3)	0,163377	0,002892	56,489	0,000
	Var (4)	0,199257	0,003055	65,232	0,000
Konstanta (nivo = Panoga)	Var panoga	0,009410	0,004004	2,350	0,019
-2 Log Likelihood		18847,582			
Akaike informacijski kriterij (AIC)		18869,582			

Testiranje hipotez

Testirati želim, ali se napovedovalna moč modela z izbiro nestrukturirane kovariančne matrike ostankov namesto predhodno uporabljene AR(1) matrike izboljša.

H₆: Napovedovalna moč modela se izboljša z uporabo nestrukturirane kovariančne matrike ostankov namesto AR(1) matrike ostankov.

Vsi Wald z-testi so statistično značilni pri $p = 0,05$, kar je razvidno iz Tabele 23. Ustreznost Modela 4 v primerjavi z vgnezenim Modelom 3 preverim tudi s pomočjo -2LL statistike.

-2 REML log-likelihood M3: 19.366,2

-2 REML log-likelihood M4: 18.847,6

$$\chi^2_{sprememba} = \Delta -2 REML LL = (-2LL_{M3}) - (-2LL_{M4}) = 19.366,2 - 18.847,6 = 518,6$$

Sprememba stopinj prostosti:

$$df_{sprememba} = k_{M4} - k_{M3} = 19 - 11 = 8,$$

kjer k predstavlja število parametrov v posameznem modelu.

Kritična vrednost χ^2 statistike z 8 stopinjami prostosti je 15,51 ($p < 0,05$) in 20,09 ($p < 0,01$) (Košmelj & Rován, 2006, str. 67). Razlika je močno statistično značilna pri $p = 0,01$. Glede na t-statistiko imajo vse pojasnjevalne spremenljivke statistično značilen vpliv na plačilno disciplino. Z izborom nestrukturirane matrike ostankov namesto AR(1) matrike ostankov dobim boljši rezultat, zato je Model 4 primernejši od Modela 3. Sprejemem hipotezo H₆.

3.6.1 Rezultati

V Tabeli 24 so prikazani rezultati večnivojskega linearnega modela. V namene primerjave sta prikazana dva modela multiple linearne regresije, pri čemer drugi upošteva časovno odvisnost, prvi pa ne. Nato je prikazanih šest modelov večnivojske linearne regresije. Vsi, razen modela M2, se izkažejo za močno statistično značilne. Vključitev spremenljivke drugega nivoja pravnoorganizacijska oblika podjetja ne pripomore k izboljšanju napovedovalne moči modela M1 in zato ni vključena v nadaljnjo analizo. V Tabeli 24 so za vse modele prikazani rezultati -2 log-likelihood in AIC statistike, ki se uporabljata za primerjavo med modeli. Kot je razvidno iz primerjave AIC statistike modelov multiple linearne regresije, se napovedovalna moč modela bistveno izboljša že z vpeljavo upoštevanja časovne odvisnosti med opazovanji, saj AIC statistika prvega modela, ki ne upošteva časovne odvisnosti, znaša 44.211, drugega modela, ki upošteva časovno odvisnost, pa občutno manj, in sicer 19.678. Z vpeljavo MLM in upoštevanja presečne odvisnosti se pojasnjevalna moč modela še dodatno izboljša. Najboljše rezultate dosežemo z zadnjim modelom M4, kjer je upoštevana nestrukturirana kovariančna matrika ostankov. AIC statistika slednjega modela znaša 18.870 in je občutno nižja od prvotnega modela multiple linearne regresije, ki se običajno uporablja pri tovrstnih študijah. Z uporabo MLM mi je uspelo dokazati

statistično povezavo med plačilno disciplino podjetij in dejavniki, ki vplivajo nanjo ter potrditi osrednjo hipotezo, da se z uporabo te tehnike napovedovalna moč modela izboljša.

Tabela 24: Povzetek rezultatov večnivojskega modela

		Multipla regresija		Večnivojska regresija					
			AR(1)	M0a AR(1)	M0b AR(1)	M1 AR(1)	M2 AR(1)	M3 AR(1)	M4 UNR
Matrika ostankov									
Spremenljivka									
Časovna odvisnost		NE	DA	DA	DA	DA	DA	DA	DA
Presečna odvisnost		NE	NE	NE	DA	DA	DA	DA	DA
Nivo 1	KONSTANTA (β_0)	,517	,557	,560	,539	,530	,531	,509	,504
	STRUKTURA								
	FINANCIRANJA (β_1)	-,121	-,078			-,076	-,076	-,075	-,074
	P (2-tailed)	,000	,000			,000	,000	,000	,000
	DOBIČKONOSNOST (β_2)	,013	,010			,009	,009	,009	,007
	P (2-tailed)	,000	,000			,000	,000	,000	,006
	POZICIJA NA TRGU (β_3)	,036	,025			,029	,030	,029	,031
	P (2-tailed)	,000	,000			,000	,000	,000	,000
	STRUKTURA SREDSTEV (β_4)	-,044	-,040			-,037	-,037	-,037	-,035
	P (2-tailed)	,000	,000			,000	,000	,000	,000
	BLOKADA (β_5)	,378	,052			,051	,051	,052	,052
	P (2-tailed)	,000	,000			,000	,000	,000	,000
	Nivo 2	DD (β_6)	-,047	-,014				-,020	
P (2-tailed)	,003	,613					,484		
Nivo 3	BLOKADA PANOGE (β_7)	,000	,000					,000	,000
	P (2-tailed)	,000	,708					,000	,000
	PRIHODKI PANOGE (β_8)	,000	,000					,000	,000
P (2-tailed)	,000	,923					,000	,000	
-2 log-likelihood		44.209	19.674	20.493	20.349	19.449	19.448	19.366	18.848
χ^2		/	/	/	144	900	1	83	519
P		/	/	/	,000	,000	/	,000	,000
AIC		44.211	19.678	20.497	20.355	19.467	19.468	19.388	18.870

SKLEP

Velik delež plačil v poslih med gospodarskimi subjekti oziroma med gospodarskimi subjekti in javnimi organi se opravi z zamudo, kasneje kot je dogovorjeno s pogodbo oziroma določeno v splošnih trgovinskih pogojih. Takšne zamude vplivajo na likvidnostne težave podjetij ter izgubo prihodkov, hkrati pa podjetjem onemogočajo investicije v razvoj ter zaposlovanje novega kadra. S tem tako ni ogrožena le sposobnost preživetja podjetij, pač pa je ovirana tudi njihova konkurenčnost. Tveganje zaradi takšnih negativnih vplivov se močno poveča v obdobjih gospodarskega upada, ko je dostop do financiranja težji.

Stanje se na svetovni ravni izboljšuje, a je v marsikateri državi še vedno pod predkrizno ravniyo, pojavljajo se velike razlike v insolventnosti in plačilni disciplini glede na dejavnost in makroekonomski položaj države, v kateri deluje posamezno podjetje. Z največjimi problemi se sooča azijska regija, predvsem Kitajska, najboljša plačilna disciplina pa je prisotna v Avstraliji, Novi Zelandiji ter ZDA. V evropski regiji z najboljšo plačilno disciplino izstopa zahodna Evropa,

predvsem Nemčija, najslabše pa kaže državam južne Evrope. Slovenija se nahaja nekoliko nad evropskim povprečjem.

Kljub vidnemu izboljšanju plačilne nediscipline v večini svetovnih držav je ta še vedno problematična. V izogib tveganju zamud pri plačilu oziroma neplačilu se podjetja poslužujejo različnih oblik zavarovanja, kot so na primer cesija, zavarovanje terjatev z različnimi finančnimi instrumenti, oblikovanja rezervacij za primer neplačila itd. Velik poudarek dajejo tudi raziskavam za področju napovedovanja plačilne discipline, ki podjetjem omogočajo prepoznati potencialne neplačnike, še preden začnejo z njimi poslovati. V preteklosti je bilo izvedenih veliko raziskav na področju kreditnega tveganja in plačilne discipline, ki se osredotočajo predvsem na proučevanje stečajev podjetij ter blokad transakcijskega računa. Problem raziskav, ki proučujejo pojav v obdobju več let ter katerih opazovane enote so razvrščene v različne kontekstualne skupine, je, da so izvedene z uporabo regresijskih metod, ki ne upoštevajo časovne in presečne odvisnosti. Ta problem lahko rešimo z uporabo tehnike MLM, ki sem ga predstavila v moji raziskavi.

Želela sem pokazati, da je z uporabo MLM mogoče dokazati statistično povezavo med plačilno nedisciplino in dejavniki, ki vplivajo nanjo, oziroma da se napovedovalna moč modela izboljša, če upoštevamo časovno in presečno odvisnost med opazovanji. Raziskavo sem izvedla na vzorcu 8.866 podjetij, ki delujejo v 77 različnih panogah. Opazovala sem vpliv kazalnikov, izračunanih na podlagi letnih računovodskih izkazov v obdobju 2011–2014, na zamude pri plačilih obveznosti do dobaviteljev v obdobju 2012–2015.

Ker je bila odvisna spremenljivka močno asimetrična v desno, sem z namenom izboljšanja normalnosti njene porazdelitve in linearnosti posameznih bivariatnih povezav izvedla njeno transformacijo ter tako dobila desetiški logaritem zamud pri plačilih obveznosti do dobaviteljev. Na podlagi dosedanjih raziskav, ki se osredotočajo na vpliv dejavnikov na zamude pri plačilih, sem naredila prvoten izbor 18 neodvisnih spremenljivk. Z namenom izpolnitve temeljnih predpostavk regresijske analize sem izvedla statistično obdelavo podatkov, kar vključuje odpravo ekstremnih vrednosti številskih spremenljivk s pomočjo postopka winsorizacije, poleg tega sem ugotovila, da multikolinearnost in heteroskedastičnost podatkov ne predstavljata večjega problema. Preverila sem predpostavko neodvisnosti opazovanj oziroma prisotnost presečne in časovne (longitudinalne) odvisnosti. Ugotovila sem, da presečna odvisnost podatkov ni problematična, nujno pa je treba upoštevati časovno odvisnost med opazovanji. S tem sem upravičila uporabo MLM. Z namenom zmanjšanja dimenzije podatkov sem izvedla metodo glavnih komponent ter tako dobila 8 končnih neodvisnih spremenljivk oziroma glavnih komponent: struktura financiranja, dobičkonosnost, pozicija na trgu, struktura sredstev, blokada transakcijskega računa, pravnoorganizacijska oblika podjetja, število blokiranih podjetij v panogi in prihodki panoge. Spremenljivke so bile v analizo vključene postopoma po nivojih.

Za primerljivost med modeli sem uporabila -2 Log-Likelihood statistiko ter alternativno AIC statistiko. Za obe je značilno, da njuna nižja vrednost pomeni boljše prilaganje podatkov oziroma izboljšanje modela. Multipla linearna regresija ni zanesljiva, saj ne upošteva predpostavke o neodvisnosti opazovanj. Izvedla sem jo le z namenom primerjave z MLM, da sem lahko dokazala, da je analiza panelnih podatkov uspešnejša z uporabo metode MLM. Z namenom prikaza pomembnosti upoštevanja časovne odvisnosti sem izvedla tudi multiplo linearno regresijo, ki

upošteva časovno odvisnost. Model 0a, ki upošteva časovno odvisnost, je namreč začetni model pri izgradnji večnivojskega linearnega modela. Ker nima predhodnega modela za primerjavo, težko prikažem pomembnost upoštevanja časovne odvisnosti, zato sem to prikazala s primerjavo med modeloma multiple linearne regresije. Oba modela multiple linearne regresije vključujeta vseh 8 pojasnjevalnih spremenljivk. Z upoštevanjem časovne odvisnosti se pojasnjevalna moč modela močno izboljša, saj vrednost AIC statistike pade s 44.211 na 19.678.

Nato sem izvedla postopno izgradnjo modela večnivojske linearne regresije, katerega razvoj je prikazan s postopno integracijo šestih modelov: model 0a–model 4. Modela 0a in 0b sta modela brez pojasnjevalnih spremenljivk, pri čemer model 0a upošteva samo časovno odvisnost med opazovanji, model 0b pa tudi presečno odvisnost. Čeprav presečna odvisnost podatkov ni bila problematična, je bila kljub temu delno prisotna. Zato sem se odločila preizkusiti, če se pojasnjevalna moč modela z njenim upoštevanjem izboljša. Presečno odvisnost sem v modelu 0b upoštevala tako, da sem omogočila prosto variiranje regresijske konstante v skupinah na višjih nivojih, tj. panogah. -2 Log-Likelihood statistika se ob upoštevanju števila stopinj prostosti z upoštevanjem presečne statistike izboljša, saj njena vrednost pade z 20.493 na 20.349. S tem sem dokazala, da se napovedovalna moč modela poleg upoštevanja časovne odvisnosti izboljša tudi z upoštevanjem presečne odvisnosti med opazovanji. Nato sem v večnivojski model z modelom 1 vključila neodvisne spremenljivke na prvem nivoju, to so spremenljivke na ravni podjetja, ki se v času spreminjajo: struktura financiranja, dobičkonosnost, pozicija na trgu, struktura sredstev in blokada. Z njihovo vključitvijo se napovedovalna moč modela izboljša, saj vrednost -2 Log-Likelihood statistika pade na 19.449. Z modelom 2 sem v analizo vključila neodvisno spremenljivko drugega nivoja, tj. pravnoorganizacijska oblika podjetja, ki je merjena na ravni podjetja in se v času ne spreminja. -2 Log-Likelihood statistika se ob upoštevanju števila stopinj prostosti ne izboljša. Vključitev spremenljivke pravnoorganizacijska oblika podjetja ne pripomore k izboljšanju napovedovalne moči modela, zato sem jo izključila iz nadaljnje analize. Z modelom 3 sem v analizo vključila neodvisni spremenljivki tretjega nivoja, to sta spremenljivki na ravni panoge: blokada panoge in prihodki panoge. Z njuno vključitvijo se napovedovalna moč modela izboljša, saj vrednost -2 Log-Likelihood statistike pade na 19.366. Zadnji model 4 je po strukturi enak modelu 3, le da je namesto predhodno uporabljene AR(1) uporabljena nestrukturirana kovariančna matrika ostankov. Z njeno vključitvijo se napovedovalna moč modela izboljša, vrednost -2 Log-Likelihood statistika pade na 18,848.

S postopnim razvojem večnivojske linearne regresije se napovedovalna moč modela izboljša, saj se vrednost -2 Log-Likelihood statistike z razvojem modela zmanjša. To je razvidno iz primerjave vrednosti -2 Log-Likelihood statistike prvega modela 0a, ki znaša 20.493 (oziroma AIC 20.497) in vrednosti -2 Log-Likelihood statistike končnega modela 4, ki znaša 18.848 (oziroma AIC 18.870). Še bolj vidno je izboljšanje napovedovalne moči modela, če primerjamo AIC statistiko začetnega modela multiple linearne regresije, ki ne upošteva časovne odvisnosti med opazovanji in znaša 44.211 ter AIC statistiko modela 4, ki znaša 18.870. Vrednost AIC statistike občutno pade. Zanimiva je tudi primerjava modela multiple linearne regresije z modelom 0a. Model multiple linearne regresije, ki ne upošteva časovne odvisnosti, vključuje vseh 8 pojasnjevalnih spremenljivk, medtem ko model 0a ne vključuje pojasnjevalnih spremenljivk in upošteva časovno odvisnost. Vrednost AIC modela multiple linearne regresije znaša 44.211, modela 0a pa 20.497. Iz tega sledi, da z upoštevanjem časovne odvisnosti pojasnimo večji del variabilnosti odvisne

spremenljivke kot z vključitvijo pojasnjevalnih spremenljivk, saj je AIC statistika modela 0a občutno nižja od AIC statistike modela multiple linearne regresije, ki ne upošteva časovne odvisnosti.

Upoštevanje časovne in presečne odvisnosti med opazovanji se izkaže za pomemben dejavnik raziskav, ki vključujejo panelne podatke. V mojem modelu je bolj kot presečna odvisnost, ki je sicer tudi delno prisotna, problematična časovna odvisnost, ki nastane zaradi opazovanja pojava v času. Obe odvisnosti uspešno upoštevam z uporabo večnivojske linearne regresije. Zaključim lahko, da mi je uspelo dokazati statistično povezavo med plačilno disciplino podjetij in dejavniki, ki vplivajo nanjo; ter da sem z raziskavo potrdila osrednjo hipotezo, saj se napovedovalna moč modela za napovedovanje plačilne discipline slovenskih podjetij bistveno izboljša z uporabo tehnike MLM.

LITERATURA IN VIRI

1. Agarwal, V., & Taffler, R. (2008). Comparing the performance of market-based and accounting-based bankruptcy prediction models. *Journal of Banking & Finance*, 32(8), 1541–1551.
2. Aitkin, M., & Longford, N. (1986). Statistical modelling in school effectiveness studies. *Journal of the Royal Statistical Society*, 149, 1–43.
3. Ajpes – Agencija Republike Slovenije za javnopravne evidence in storitve. (2014). *Baza podatkov letnih poročil gospodarskih družb v Sloveniji 2011–2014*. Ljubljana: Agencija Republike Slovenije za javnopravne evidence in storitve.
4. Ajpes – Agencija Republike Slovenije za javnopravne evidence in storitve. (2017). *Poslovni subjekti z začetimi postopki zaradi insolventnosti v letih 2008 do 2017*. Ljubljana: Agencija Republike Slovenije za javnopravne evidence in storitve.
5. Ajpes – Agencija Republike Slovenije za javnopravne evidence in storitve. (2018a). *Poslovni subjekti z dospelimi neporavnanimi obveznostmi po dnevih v letih 2007 do 2018*. Ljubljana: Agencija Republike Slovenije za javnopravne evidence in storitve.
6. Ajpes – Agencija Republike Slovenije za javnopravne evidence in storitve. (2018b). *Poslovni subjekti z dospelimi neporavnanimi obveznostmi po področjih dejavnosti v letih 2012 do 2018*. Ljubljana: Agencija Republike Slovenije za javnopravne evidence in storitve.
7. Altman, I. E. (1968). Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy. *Journal of Finance*, 23(4), 589–609.
8. Altman, I. E., & Saunders, A. (1998). Credit risk measurement: Developments over the last 20 years. *Journal of Banking & Finance*, 2(11/12), 1721–1742.
9. Apergis, N., Sorros, J., Artikis, P., & Zizis, V. (2011). Bankruptcy Probability and Stock Prices: The Effect of Altman Z-Score Information on Stock Prices Through Panel Data. *Journal of Modern Accounting and Auditing*, 7(7), 689–696.
10. Aziz, M. A., & Dar, H. A. (2004). *Predicting Corporate Bankruptcy: whither do we stand?* Loughborough: Department of Economics, University of Loughborough.
11. Banka Slovenije. (2015). *Poročilo o finančni stabilnosti*. Ljubljana: Banka Slovenije.
12. Berg, D. (2005). *Bankruptcy Prediction by Generalized Additive Models*. Oslo: University of Oslo.
13. Bergant, Ž. (2002). *Kritična presoja tradicionalnega analiziranja računovodskih podatkov v zvezi s plačilno sposobnostjo organizacije* (doktorska disertacija). Ljubljana: Ekonomska fakulteta.
14. Bergant, Ž. (2012). *Plačilna sposobnost in kapitalska ustreznost podjetja (računovodska analiza)*. Ljubljana: Inštitut za poslovodno računovodstvo.
15. Berk, A. (2004a). Plačilna sposobnost slovenskih podjetij in neposredni učinki njenega zakonodajnega urejanja. *Revizor: revija o reviziji*, 15(3), 79–91.
16. Berk, A. (2004b). Reševanje problematike plačilne nesposobnosti in finančne nediscipline kliče po večji preglednosti. *Revizor: revija o reviziji*, 15(9), 78–82.
17. Berk, A. (2005, 5. april). Dodatni ukrepi za izboljšanje finančne discipline v Sloveniji. *Finance*. Najdeno 19. avgusta 2015 na spletnem naslovu <http://www.finance.si/116708/Dodatni-ukrepi-za-izbolj%C5%A1anje-finan%C4%8Dne-discipline-v-Sloveniji>

18. Bernhardsen, E. (2001). *A Model of Bankruptcy Prediction* (Working paper No. 2001/10). Oslo: Norges Bank.
19. Bertoneclj, M. (2015, 23. september). Kaj storiti, da vam kupci nakažejo denar. *Finance*, str. 12 in 13.
20. Black, F., & Scholes, M. (1973). The pricing of options and corporate liabilities. *Journal of Political Economy*, 81(3), 637–654.
21. Bonfim, D. (2006). *Credit risk drivers: Evaluating the contribution of firm level information and of macroeconomic dynamics* (Financial Stability Report 2006, str. 147–161). Lisbon: Economics and Research Department, Banco de Portugal.
22. Bonitetna hiša i, d.o.o., Ljubljana. (2015). *Povprečno število dni zamude za slovenska podjetja med leti 2012–2015* (interno gradivo). Ljubljana: Bonitetna hiša i, d.o.o.
23. Brezigar-Masten, A., Masten, I., & Volk, M. (2015). *Discretionary credit rating and bank stability in a financial crisis*. Ljubljana: Banka Slovenije.
24. Brown, K., & Moles, P. (2014). *Credit Risk Management*. Edinburgh: Edinburgh Business School, Heriot-Watt University.
25. Campbell, J. Y., Hilscher, J., & Szilagyi, J. (2008). In Search of Distress Risk. *Journal of Finance*, 63(6), 2899–2939.
26. Carling, K., Jacobson, T., Lindé, J., & Roszbach, K. (2007). Corporate Credit Risk Modeling and the Macroeconomy. *Journal of Banking & Finance*, 31(3), 845–868.
27. CRIBIS D&B. (2017). *Payment Study 2017*. Milano: CRIBIS D&B.
28. Dempster, A. P., Rubin, D. B., & Tsutakawa, R. K. (1981). Estimation in covariance components models. *Journal of the American Statistical Association*, 76, 341–353.
29. Euler Hermes. (2017). *Economic Outlook no. 1235–1236. Summer 2017. Business Insolvency Worldwide*. Paris: Euler Hermes.
30. Euler Hermes. (2018). *Insolvencies. February 2018. Economic Research*. Paris: Euler Hermes.
31. Evropska komisija. (2012). *Zaradi zamud pri plačilih se zapira preveč evropskih podjetij*. Luksemburg: Urad za publikacije Evropske unije.
32. Evropska komisija. (2015, 20. november). *Ex-post evaluation of Late Payment Directive*. Bruselj: Evropska komisija.
33. Evropski ekonomsko–socialni odbor. 458. plenarno zasedanje evropskega ekonomsko–socialnega odbora 16. in 17. decembra 2009. (2010). *Uradni list Evropske unije*. (C 255, 22. september 2010).
34. Feinstein, C. H., & Thomas, M. (2002). *Making history count: a primer in quantitative methods for historians*. Cambridge: Cambridge University Press.
35. Ferrell, O. C., & Hirt, G. (2003). *Business: a changing world* (4th ed.). Boston: McGraw-Hill.
36. Field, A. (2009). *Discovering Statistics Using SPSS*. London: Sage.
37. Frank, M. Z., & Goyal, V. K. (2008). Trade-Off and Pecking Order Theories of Debt. V E. Eckbo (ur.), *The Handbook of Empirical Corporate Finance* (str. 135–197). Amsterdam: Elsevir Science.
38. Frank, M. Z., & Goyal, V. K. (2009). Capital Structure Decisions: Which Factors are Reliably Important? *Financial Management*, 38(1), 1–37.
39. FURS – Finančna uprava Republike Slovenije. (2015). *Insolvenčni postopki in drugi načini prenehanja pravne osebe*. Ljubljana: Finančna uprava Republike Slovenije.

40. Garson, G. D. (2013). Fundamentals of Hierarchical Linear and Multilevel Modeling. V G. D. Garson (ur.), *Hierarchical Linear Modeling: Guide and Applications* (str. 3–26). Los Angeles: Sage.
41. Gelman, A., & Hill, J. (2007). *Data Analysis Using Regression and Multilevel/Hierarchical Models*. Cambridge: Cambridge University Press.
42. Hair, J. F. Jr., Black, W. C, Babin, B. J., & Anderson, R. E. (2010). *Multivariate Data Analysis* (7th ed.). Upper Saddle River, NJ: Prentice Hall.
43. Hillegeist, S. A., Keating, E. K., Cram, D. P., & Lundstedt, K. G. (2004). Assessing the probability of bankruptcy. *Review of Accounting Studies*, 9(1), 5–34.
44. Intrum Justitia. (2016). *European Payment Report 2016*. Stockholm: Intrum Justitia.
45. Javoršek, M. (2007). *Napovedovanje zamude pri plačilu obveznosti do dobaviteljev v slovenskih podjetjih* (magistrsko delo). Ljubljana: Ekonomska fakulteta.
46. Jolliffe, I. T. (2002). *Principal component analysis* (2nd ed.). New York: Springer.
47. Jurčič, D. (2006). Zaznavanje nevarnosti plačilne nesposobnosti. *Naše gospodarstvo*, 52(3/4), 135–139.
48. Kealhofer, S. (2003). Quantifying Credit Risk I: Default Prediction. *Financial Analysts Journal*, 59(1), 30–44.
49. Komisija Evropskih skupnosti (2009, 8. april). *Spremni dokument k predlogu Direktive Evropskega parlamenta in sveta o boju proti zamudam pri plačilih v trgovinskih poslih (prenovitev)*. Delovni dokument služb komisije. Bruselj: Komisija Evropskih skupnosti, 2009.
50. Košmelj, B., & Rován, J. (2006). *Statistični obrazci in tabele* (2nd ed.). Ljubljana: Ekonomska fakulteta.
51. Krašovec, J. (2008, 15. julij). Kako zmanjšati posojilno tveganje in neplačila kupcev? *Finance*. Najdeno 19. julija 2015 na spletnem naslovu: <http://www.finance-akademija.si/218459/Kako-zmanj%C5%A1ati-posojilno-tveganje-in-nepla%C4%8Dila-kupcev>
52. Kreft, I. G. G. (1996). *Are Multilevel Techniques Necessary? An Overview, Including Simulation Studies*. Los Angeles: California State University.
53. Lindley, D. V., & Smith, A. F. (1972). Bayes estimates for the linear model. *Journal of the Royal Statistical Society*, 34(1), 1–41.
54. Marinšek, D. (2015a). *The impact of indebtedness on a firm's performance: Evidence from European countries* (doktorska disertacija). Ljubljana: Ekonomska fakulteta.
55. Marinšek, D. (2015b). *Multivariatna analiza: Zbirka rešenih primerov s komentarji*. Ljubljana: Ekonomska fakulteta.
56. Merton, R.C. (1974). On the Pricing of Corporate Debt The Risk Structure of Interest Rates. *Journal of Finance*, 29(2), 449–470.
57. Moti, A. (2013, 5. avgust). Vse o izvršbah na računu in bančnih stroških. *Delo*. Najdeno 4. januarja 2016 na spletnem naslovu <http://www.delo.si/gospodarstvo/finance/vse-o-izvrshah-na-racunu-in-bancnih-stroskih.html>
58. Možina, D. (2011). Pravo EU in plačilna nedisciplina v Sloveniji. *Pravna praksa: časopis za pravna vprašanja*, 30(11), 9–11.
59. Mramor, D., Košiček, A., Pahor, M., Prusnik, M., Valentinčič, A., & Verbovšek, P. (1998). *Napovedovanje plačilne sposobnosti slovenskih podjetij v obdobju 1994–1997 : skupno končno poročilo o svetovalno-raziskovalnih nalogah*. Ljubljana: Ekonomska fakulteta.
60. Mramor, D., & Valentinčič, A. (2003). Forecasting the Liquidity of Very Small Private Companies. *Journal of Business Venturing*, 18(6), 745–771.

61. Newman, D., Newman, I., & Salzman, J. (2010). Comparing OLS and HLM Models and the Questions They Answer: Potential Concerns for Type VI Errors. *Multiple Linear Regression Viewpoints*, 36(1), 1–8.
62. NLB d.d. (2014). *Posledica blokade je tudi poslabšanje plačilnih pogojev*. Najdeno 12. oktobra 2015 na spletnem naslovu <https://www.nlb.si/posledica-blokade-je-tudi-poslabsanje-placilnih-pogojev>
63. *Nov instrument zoper plačilno nedisciplino*. (2012, 20. maj). Najdeno 1. avgusta 2015 na spletnem naslovu <http://www.siol.net/novice/slovenija/nov-instrument-zoper-placilno-nedisciplino-178881>
64. O'Dwyer, L. M., & Parker, C. E. (2014). *A primer for analyzing nested data: multilevel modeling in SPSS using an example from a REL study*. Washington, DC: U. S.: Regional Educational Laboratory Northeast & Islands.
65. Oderda, G., Dacorogna, M., & Jung, T. (2003). Credit Risk Models - Do They Deliver Their Promises? A Quantitative Assessment. *Economic Notes*, 32(2), 177–195.
66. Ohlson, J. A. (1980). Financial ratios and the probabilistic prediction of bankruptcy. *Journal of Accounting Research*, 18(1), 109–131.
67. Osbourne, J. W., & Waters, E. (2002). Four Assumptions of Multiple Regression That Researchers Should Always Test. *Practical Assessment, Research & Evaluation*, 8(2), 1–9.
68. Pahor, M. (1999). Zveza med plačilno sposobnostjo oziroma dobičkonosnostjo in finančnimi kazalci. *Zbornik referatov 31. simpozija o sodobnih metodah v računovodstvu, financah in reviziji* (str. 357–365). Portorož: Zveza ekonomistov Slovenije in Zveza računovodij, finančnikov in revizorjev Slovenije.
69. Petersen, M. A. (2005). *Estimating standard errors in finance panel data sets: comparing approaches* (NBER Working Paper No. 11280). Cambridge: National Bureau of Economic Research.
70. Prašnikar, J., Pahor, M., & Cirman, A. (2004). Late payments in Accession Countries: Causes and International Comparison. *The Journal of Entrepreneurial Finance*, 9(1), 51–72.
71. Psillaki, M., Tsolas, I. E., & Margaritis, D. (2010). Evaluation of credit risk based on firm performance. *European Journal of Operational Research*, 201(3), 873–881.
72. Raktelj, P. (2011, 18. maj). Zaradi plačilne nesposobnosti lahko odškodninsko odgovarjate. *Primorske.si*. Najdeno 26. januarja 2016 na spletnem naslovu <http://primorske.si/Priloge/ABC-podjetnistva/Zaradi-placilne-nesposobnosti-lahko-odskodninsko-o.aspx>
73. Raudenbush, S. W., & Bryk, A. S. (2002). *Hierarchical Linear Models: Applications and data analysis methods* (2nd ed.). Thousand Oaks, CA: Sage Publications.
74. Reisz, A., & Perlich, C. (2007). A market based framework for bankruptcy prediction. *Journal of Financial Stability*, 3(2), 85–131.
75. Slovenski inštitut za revizijo. (1996). *Kodeks poslovnofinančnih načel*. Ljubljana: Slovenski inštitut za revizijo.
76. Smrekar, T. (2015, 21. maj). Plačaj ali odidi. *Finance*. Najdeno 15. februarja 2016 na spletnem naslovu <http://www.finance.si/8822501/Pla%C4%8Daj-ali-odidi>
77. STA. (2009, 6. oktober). Plačilna nedisciplina hromi mala podjetja. *Dnevnik*. Najdeno 23. septembra 2015 na spletnem naslovu <https://www.dnevnik.si/1042304948>
78. Statistični urad Republike Slovenije. (2010). *Standardna klasifikacija dejavnosti 2008*. Najdeno 25. oktobra 2015 na spletnem naslovu <https://www.stat.si/doc/pub/skd.pdf>

79. Šalamon, T. (2014). *Vpliv etične klime in etične kulture na neetično poslovno prakso plačilne nediscipline* (doktorska disertacija). Maribor: Ekonomsko-poslovna fakulteta.
80. Šalamon, T., & Meško, M. (2015). Vpliv dejavnikov na ravni podjetja in ravni dejavnosti na plačilno disciplino podjetij. *Revija za univerzalno odličnost*, 4(2), 33–46.
81. Šimac, J. (2015, 6. oktober). Število stečajev septembra eksplodiralo in še precej jih prihaja. *Finance*. Najdeno 8. oktobra 2015 na spletnem naslovu <http://www.finance.si/8836682/%C5%A0tevilno-ste%C4%8Dajev-septembra-eksplodiralo-in-%C5%A1e-precej-jih-prihaja>
82. Štrancar, P. (2011, 24. oktober). DDV po plačani realizaciji ne izboljšuje likvidnosti podjetij. *Finance*. Najdeno 12. septembra 2015 na spletnem naslovu <http://www.finance.si/328163>
83. Tabachnick, B. G., & Fidell, L. S. (2012). *Using Multivariate Statistics* (6th ed.). New York: Pearson.
84. Urad RS za makroekonomske analize in razvoj. (2017). *Jesenska napoved gospodarskih gibanj 2017*. Ljubljana: Urad RS za makroekonomske analize in razvoj.
85. Vassalou, M., & Xing, Y. (2004). Default Risk in Equity Returns. *Journal of Finance*, 59(2), 831–868.
86. Vlada Republike Slovenije. (2011, 17. februar). *Predlog zakona o preprečevanju zamud pri plačilih*. Najdeno 12. decembra 2015 na spletnem naslovu <http://imss.dz-rs.si/imis/27c494fcfc6938b1d575.pdf>
87. Volk, M. (2014). Estimating probability of default and comparing it to credit rating classification by banks. Ljubljana: Banka Slovenije.
88. Weiss, M. (2013, 27. januar). Se dolžniki uspešno izogibajo obveznega pobota? *Finance*. Najdeno 10. septembra 2015 na spletnem naslovu <http://www.finance.si/8332000/Se-dol%C5%BEniki-uspe%C5%A1no-izogibajo-obveznega-pobota>
89. Weiss, M., Grapulin, T., & Šimac, J. (2014, 1. februar). Čemu služijo zombi podjetja in zakaj se jih država ne loti hitreje? *Finance*. Najdeno 10. septembra 2015 na spletnem naslovu <http://www.finance.si/8356156/%C4%8Cemu-slu%C5%BEijo-zombi-podjetja-in-zakaj-se-jih-dr%C5%BEava-ne-loti-hitreje>
90. Weygandt, J., Kimmel, P., & Kieso, D. (2011). *Financial accounting* (10th ed.). Hoboken, N. J.: Wiley.
91. Woltman, H., Feldstain, A., MacKay, J. C., & Rocchi, M. (2012). An introduction to hierarchical linear modeling. *Tutorials in Quantitative Methods for Psychology*, 8(1), 52–69.
92. World Bank Group. (2018). *Global Economic Prospects: Broad-Based Upturn, but for How Long?* Washington: The World Bank.
93. Zakon o davčnem postopku. *Uradni list RS* št. 13/2011-UPB4, 32/2012, 94/2012, 101/2013-ZDavNepr, 111/2013, 25/2014-ZFU, 40/2014-ZIN-B, 90/2014, 91/2015.
94. Zakon o finančnem poslovanju, postopkih zaradi insolventnosti in prisilnem prenehanju. *Uradni list RS* št. 13/2014-UPB8, 10/2015-popr., 27/2016, 31/2016-odl. US, 38/2016-odl. US, 63/2016-ZD-C.
95. Zakon o finančnem poslovanju podjetij. *Uradni list RS* št. 54/1999, 110/1999, 97/2000 Odl.US: UI 264/99-40, 50/2002 Skl. US: U-I-135/00-60, 93/2002 Odl. US: U-I-135/00-77, 117/2006–ZDDPO-2, 31/2007, 33/2007–ZSReg-B, 38/2007 Skl. US: U-I-117/07-7, 126/2007–ZFPPIPP.

96. Zakon o izvršbi in zavarovanju. *Uradni list RS* št. 3/2007-UPB4, 93/2007, 37/2008-ZST-1, 45/2008-ZArbit, 28/2009, 51/2010, 26/2011, 17/2013 Odl. US, 45/2014 Odl. US, 53/2014, 54/2014 Odl. US, 54/2015, 76/2015 Odl. US.
97. Zakon o plačilnih storitvah in sistemih. *Uradni list RS* št. 58/2009, 34/2010, 9/2011, 32/2012, 81/2015.
98. Zakon o plačilnih storitvah, storitvah izdajanja elektronskega denarja in plačilnih sistemih. *Uradni list RS* št. 7/2018, 9/2018-popr.
99. Zakon o preprečevanju zamud pri plačilih. *Uradni list RS* št. 18/2011, 57/2012.
100. Zakon o prisilni poravnavi, stečaju in likvidaciji *Uradni list RS* št. 67/1993, 74/1994 Odl. US, 8/1996 Odl. US: U-I-114/95, 25/1997-ZJSRS, 39/1997, 1/1999-ZNIDC, 52/1999, 101/2001 Odl. US: Up-148/01, 42/2002-ZDR, 58/2003-ZZK-1, 10/2006 Odl. US: U-I-253/04-11, 126/2007-ZFPPIPP.
101. Zaman Groff, M., Hočevar, M., & Igljučar, A. (2007). *Temelji računovodstva*. Ljubljana: Ekonomska fakulteta.

PRILOGE

KAZALO PRILOG

Priloga 1: Seznam kratic	1
Priloga 2: Multikolinearnost.....	2
Priloga 3: Metoda glavnih komponent: korelacijska matrika	4

Priloga 1: Seznam kratic

Angl.	angleško
Ajpes	Agencija Republike Slovenije za javnopravne evidence in storitve
BDP	Bruto domači proizvod
EUR	Evro
DURS	Davčna uprava Republike Slovenije
DUTB	Družba za upravljanje terjatev bank
FURS	Finančna uprava Republike Slovenije
KPFN	Kodeks poslovnofinančnih načel
MLM	Večnivojsko linearno modeliranje
ZDA	Združene države Amerike
ZDavP-2	Zakon o davčnem postopku
ZFPPIPP	Zakon o finančnem poslovanju, postopkih zaradi insolventnosti in prisilnem prenehanju
ZIZ	Zakon o izvršbi in zavarovanju
ZPlaSS	Zakon o plačilnih storitvah in sistemih
ZPlaSSIED	Zakonom o plačilnih storitvah, storitvah izdajanja elektronskega denarja in plačilnih sistemih
ZPreZP-1	Zakon o preprečevanju zamud pri plačilih
-2LL	-2 Log-Likelihood statistika

Priloga 2: Multikolinearnost

Korelacije

		Plačilni rok	Log prihodki	Blokada	Računi	Dolg	Finančni dolg	Kapital	Pospeš. koef.	ROE	ROA	Koeficient obračanja	Kratkor. sredstva	Rast prihodko	Dobičkon. prihodko	Prihodki zaposlen.	DD	Blokada panoge	Prihodki panoge
Plačilni rok	Pearsonova korelacija	1	0,286**	-0,064**	0,172**	-0,038**	-0,015**	-0,001	-0,046**	0,028**	-0,037**	-0,061**	0,006	0,006	-0,020**	0,019**	0,153**	0,008	0,035**
	Sig. (2-str.)		0,000	0,000	0,000	0,000	0,006	0,854	0,000	0,000	0,000	0,000	0,229	0,295	0,000	0,000	0,000	0,148	0,000
	N	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438
Log prihodki	Pearsonova korelacija	0,286**	1	-0,060**	0,502**	-0,076**	0,031**	-0,033**	-0,063**	0,095**	-0,023**	-0,078**	0,009	0,111**	0,070**	0,425**	0,285**	-0,163**	0,114**
	Sig. (2-str.)	0,000		0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,082	0,000	0,000	0,000	0,000	0,000	0,000
	N	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438
Blokada	Pearsonova korelacija	-0,064**	-0,060**	1	0,076**	0,209**	0,186**	-0,162**	-0,143**	-0,085**	-0,067**	-0,034**	-0,106**	-0,045**	-0,115**	-0,082**	0,021**	0,011*	-0,054**
	Sig. (2-str.)	0,000	0,000		0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,035	0,000	0,000
	N	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438
Računi	Pearsonova korelacija	0,172**	0,502**	0,076**	1	0,020**	0,157**	-0,078**	-0,078**	0,014**	-0,072**	-0,164**	-0,079**	-0,022**	-0,017**	0,121**	0,278**	-0,122**	0,000
	Sig. (2-str.)	0,000	0,000	0,000		0,000	0,000	0,000	0,000	0,009	0,000	0,000	0,000	0,000	0,002	0,000	0,000	0,000	0,945
	N	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438
Dolg	Pearsonova korelacija	-0,038**	-0,076**	0,209**	0,020**	1	0,575**	-0,681**	-0,473**	-0,386**	-0,112**	0,375**	0,048**	0,027**	-0,265**	-0,001	-0,046**	0,080**	0,071**
	Sig. (2-str.)	0,000	0,000	0,000	0,000		0,000	0,000	0,000	0,848	0,000	0,000	0,000	0,000	0,000	0,871	0,000	0,000	0,000
	N	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438
Finančni dolg	Pearsonova korelacija	-0,015**	0,031**	0,186**	0,157**	0,575**	1	-0,471**	-0,319**	-0,215**	-0,188**	-0,124**	-0,322**	-0,029**	-0,197**	-0,045**	0,031**	-0,030**	-0,012*
	Sig. (2-str.)	0,006	0,000	0,000	0,000	0,000		0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,024
	N	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438
Kapital	Pearsonova korelacija	-0,001	-0,033**	-0,162**	-0,078**	-0,682**	-0,471**	1	0,440**	0,218**	0,102**	-0,185**	-0,018**	-0,041**	0,200**	-0,035**	0,025**	-0,036**	-0,056**
	Sig. (2-str.)	0,854	0,000	0,000	0,000	0,000	0,000		0,000	0,006	0,000	0,000	0,001	0,000	0,000	0,000	0,000	0,000	0,000
	N	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438
Pospešeni koeficient	Pearsonova korelacija	-0,046**	-0,063**	-0,143**	-0,078**	-0,473**	-0,319**	0,440**	1	0,100**	0,107**	-0,154**	0,232**	-0,045**	0,188**	0,010	-0,010	0,006	-0,065**
	Sig. (2-str.)	0,000	0,000	0,000	0,000	0,000	0,000	0,000		0,000	0,000	0,000	0,000	0,000	0,000	0,065	0,058	0,272	0,000
	N	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438
ROE	Pearsonova korelacija	-0,028**	0,095**	-0,085**	0,014**	-0,386**	-0,215**	0,218**	0,100**	1	0,501**	-0,034**	0,030**	0,140**	0,490**	0,072**	-0,014**	-0,015	-0,029
	Sig. (2-str.)	0,000	0,851	0,000	0,009	0,000	0,000	0,000	0,000		0,000	0,000	0,000	0,000	0,000	0,007	0,004	0,05	
	N	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438

se nadaljuje

nadaljevanje

		Plačilni rok	Log prihodki	Blokada	Računi	Dolg	Finančni dolg	Kapital	Pospeš. koef.	ROE	ROA	Koeficient obračanja	Kratkor. sredstva	Rast prihodkov	Dobičkon. prihodkov	Prihodki zaposlen.	DD	Blokada panoge	Prihodki panoge
ROA	Pearsonova korelacija	-0,037**	-0,023**	-0,067**	-	-0,112**	-0,188**	0,102**	0,107**	0,501**	1	0,337**	0,120**	0,210**	0,705**	0,040**	-	0,041**	-0,042**
	Sig. (2-str.)	0,000	0,000	0,000	0,072**	0,000	0,000	0,000	0,000	0,000		0,000	0,000	0,000	0,000	0,000	0,044**	0,000	0,000
	N	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438
Koeficient obračanja	Pearsonova korelacija	-0,061**	-0,078**	-0,034**	-	0,375**	-0,124**	-0,185**	-0,154**	-0,034**	0,337**	1	0,315**	0,148**	0,030**	0,115**	-	0,130**	0,103**
	Sig. (2-str.)	0,000	0,000	0,000	0,164**	0,000	0,000	0,000	0,000	0,000	0,000		0,000	0,000	0,000	0,000	0,084**	0,000	0,000
	N	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438
Kratkor. sredstva	Pearsonova korelacija	0,006	0,009	-0,106**	-	0,048**	-0,322**	-0,018**	0,232**	0,030**	0,120**	0,315**	1	0,036**	0,035**	0,197**	-	0,132**	0,220**
	Sig. (2-str.)	0,229	0,082	0,000	0,079**	0,000	0,000	0,001	0,000	0,000	0,000	0,000		0,000	0,000	0,000	0,082**	0,000	0,000
	N	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438
Rast prihodkov	Pearsonova korelacija	0,006	0,111**	-0,045**	-	0,027**	-0,029**	-0,041**	-0,045**	0,140**	0,210**	0,148**	0,036**	1	0,197**	0,150**	-	-0,011*	-0,046**
	Sig. (2-str.)	0,295	0,000	0,000	0,022**	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000		0,000	0,000	0,019**	0,038	0,000
	N	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438
Dobičkon. prihodkov	Pearsonova korelacija	-0,020**	0,070**	-0,115**	-	-0,265**	-0,197**	0,200**	0,188**	0,490**	0,705**	0,030**	0,035**	0,197**	1	0,063**	-	-0,023**	-0,057**
	Sig. (2-str.)	0,000	0,000	0,000	0,017**	0,002	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000		0,000	0,032**	0,000	0,000
	N	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438
Prihodki zaposlen.	Pearsonova korelacija	0,019**	0,425**	-0,082**	0,121**	-0,001	-0,045**	-0,035**	0,010	0,072**	0,040**	0,115**	0,197**	0,150**	0,063**	1	0,002	0,055**	0,285**
	Sig. (2-str.)	0,000	0,000	0,000	0,000	0,871	0,000	0,000	0,065	0,000	0,000	0,000	0,000	0,000	0,000		0,641	0,000	0,000
	N	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438
DD	Pearsonova korelacija	0,153**	0,285**	0,021**	0,278**	-0,046**	0,031**	0,025**	-0,010	-0,014**	-0,044**	-0,084**	-0,082**	-0,019**	-0,032**	0,002	1	-0,105**	-0,068**
	Sig. (2-str.)	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,058	0,007	0,000	0,000	0,000	0,000	0,000	0,641		0,000	0,000
	N	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438
Blokada panoge	Pearsonova korelacija	0,008	-0,163**	0,011*	-	0,080**	-0,030**	-0,036**	0,006	-0,015**	0,041**	0,130**	0,132**	-0,011*	-0,023**	0,055**	-	1	0,389**
	Sig. (2-str.)	0,148	0,000	0,035	0,122**	0,000	0,000	0,000	0,272	0,004	0,000	0,000	0,000	0,038	0,000	0,000	0,105**	0,000	0,000
	N	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438
Prihodki panoge	Pearsonova korelacija	0,035**	0,114**	-0,054**	0,000	0,071**	-0,012*	-0,056**	-0,065**	-0,029**	-0,042**	0,103**	0,220**	-0,046**	-0,057**	0,285**	-	0,389**	1
	Sig. (2-str.)	0,000	0,000	0,000	0,945	0,000	0,024	0,000	0,000	0,00	0,000	0,000	0,000	0,000	0,000	0,000	0,068**	0,000	0,000
	N	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438	35438

Priloga 3: Metoda glavnih komponent: korelacijska matrika

		Plačilni rok	Log prihodki	Računi	Dolg	Finančni dolg	Kapital	Pospeš. koef.	ROE	ROA	Koeficient obračanja	Kratkor. sredstva	Rast prihodkov	Dobičkon. prihodkov	Prihodki zaposlen.
Korelacije	Plačilni rok	1	0,286	0,172	-0,038	-0,015	-0,001	-0,046	0,028	-0,037	-0,061	0,006	0,006	-0,020	0,019
	Log prihodki	0,286	1	0,502	-0,076	0,031	-0,033	-0,063	0,095	-0,023	-0,078	0,009	0,111	0,070	0,425
	Računi	0,172	0,502	1	0,020	0,157	-0,078	-0,078	0,014	-0,072	-0,164	-0,079	-0,022	-0,017	0,121
	Dolg	-0,038	-0,076	0,020	1	0,575	-0,681	-0,473	-0,386	-0,112	0,375	0,048	0,027	-0,265	-0,001
	Finančni dolg	-0,015	0,031	0,157	0,575	1	-0,471	-0,319	-0,215	-0,188	-0,124	-0,322	-0,029	-0,197	-0,045
	Kapital	-0,001	-0,033	-0,078	-0,681	-0,471	1	0,440	0,218	0,102	-0,185	-0,018	-0,041	0,200	-0,035
	Pospešeni koeficient	-0,046	-0,063	-0,078	-0,473	-0,319	0,440	1	0,100	0,107	-0,154	0,232	-0,045	0,188	0,010
	ROE	0,028	0,095	0,014	-0,386	-0,215	0,218	0,100	1	0,501	-0,034	0,030	0,140	0,490	0,072
	ROA	-0,037	-0,023	-0,072	-0,112	-0,188	0,102	0,107	0,501	1	0,337	0,120	0,210	0,705	0,040
	Koeficient obračanja	-0,061	-0,078	-0,164	0,375	-0,124	-0,185	-0,154	-0,034	0,337	1	0,315	0,148	0,030	0,115
	Kratkor. sredstva	0,006	0,009	-0,079	0,048	-0,322	-0,018	0,232	0,030	0,120	0,315	1	0,036	0,035	0,197
	Rast prihodkov	0,006	0,111	-0,022	0,027	-0,029	-0,041	-0,045	0,140	0,210	0,148	0,036	1	0,197	0,150
	Dobičkon. prihodkov	-0,020	0,070	-0,017	-0,265	-0,197	0,200	0,188	0,490	0,705	0,030	0,035	0,197	1	0,063
Prihodki zaposlen.	0,019	0,425	0,121	-0,001	-0,045	-0,035	0,010	0,072	0,040	0,115	0,197	0,150	0,063	1	
Sig. (1-str.)	Plačilni rok		0,000	0,000	0,000	0,003	0,427	0,000	0,000	0,000	0,000	0,114	0,148	0,000	0,000
	Log prihodki	0,000		0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,041	0,000	0,000	0,000
	Računi	0,000	0,000		0,000	0,000	0,000	0,000	0,005	0,000	0,000	0,000	0,000	0,001	0,000
	Dolg	0,000	0,000	0,000		0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,436
	Finančni dolg	0,003	0,000	0,000	0,000		0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000
	Kapital	0,427	0,000	0,000	0,000	0,000		0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000
	Pospešeni koeficient	0,000	0,000	0,000	0,000	0,000	0,000		0,000	0,000	0,000	0,000	0,000	0,000	0,033
	ROE	0,000	0,000	0,000	0,000	0,000	0,000	0,000		0,000	0,000	0,000	0,000	0,000	0,000
	ROA	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000		0,000	0,000	0,000	0,000	0,000
	Koeficient obračanja	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000		0,000	0,000	0,000	0,000
	Kratkor. sredstva	0,114	0,041	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000		0,000	0,000	0,000
	Rast prihodkov	0,148	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000		0,000	0,000
	Dobičkon. prihodkov	0,000	0,000	0,001	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000		0,000
Prihodki zaposlen.	0,000	0,000	0,000	0,436	0,000	0,000	0,033	0,000	0,000	0,000	0,000	0,000	0,000		