

UNIVERZA V LJUBLJANI
EKONOMSKA FAKULTETA

MAGISTRSKO DELO

**MODELIRANJE VERJETNOSTI NEPLAČILA V PODJETJU ZA
TRGOVANJE Z ELEKTRIKO**

Ljubljana, marec 2018

ANA BREZAVŠČEK

IZJAVA O AVTORSTVU

Podpisana Ana Brezavšček, študentka Ekonomske fakultete Univerze v Ljubljani, avtorica predloženega dela z naslovom Modeliranje verjetnosti neplačila v podjetju za trgovanje z elektriko, pripravljenega v sodelovanju s svetovalcem izr. prof. dr. Alešem Berkom Skokom

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 TVEGANJA NA TRGU ELEKTRIČNE ENERGIJE.....	3
1.1 Značilnosti elektroenergetskega trga	4
1.2 Vrste tveganj na trgu električne energije	5
1.3 Kreditno tveganje.....	6
1.3.1 Opredelitev kreditnega tveganja.....	6
1.3.2 Merjenje kreditnega tveganja	7
1.3.3 Upravljanje kreditnega tveganja.....	7
1.4 Modeli kreditnega tveganja	9
2 MODELI KREDITNEGA TOČKOVANJA.....	11
2.1 Diskriminantni model	12
2.2 Linearni verjetnostni model	13
2.3 Logistična regresija (logit model).....	15
3 LOGIT MODEL	18
3.1 Zbiranje in priprava podatkov.....	19
3.2 Modeliranje	19
3.2.1 Transformacije vhodnih podatkov	19
3.2.1.1 WOE transformacija.....	20
3.2.2 Grupiranje podatkov (angl. <i>binning</i>)	20
3.2.2.1 Monoton algoritem grupiranja	21
3.2.3 Izbira kazalnikov	21
3.2.3.1 Multikolinearnost	21
3.2.3.2 Informacijska vrednost	23
3.2.4 Sestavljanje modela in računanje koeficientov	24
3.2.4.1 Statistična značilnost spremenljivk	24
3.2.4.2 Statistična značilnost modela	25
3.2.5 Točke in verjetnost neplačila.....	25
3.2.5.1 Uteži spremenljivk v modelu	26
3.2.5.2 Meja med »dobrim« in »slabim«	26
3.2.6 Validacija.....	27
3.2.6.1 Korelacija med spremenljivkami	27
3.2.6.2 Matrika napake modela (angl. <i>Misclassification matrix</i>).....	28
3.2.6.3 CAP krivulja (angl. <i>Cumulative Accuracy Profile</i>)	30
3.2.6.4 ROC krivulja (angl. <i>Receiver Operating Characteristic curve</i>)	30
3.2.6.5 K-S graf (angl. <i>Kolmogorov-Smirnov graph</i>)	31

4	PRIMER MODELA NAPOVEDI NEPLAČILA STRANK	32
4.1	Analiza podatkov	32
4.1.1	Neodvisne spremenljivke	32
4.1.2	Odvisna spremenljivka	33
4.2	Izbira kazalnikov	34
4.2.1	Manjkajoči podatki	34
4.2.2	Multikolinearnost	34
4.2.3	Informacijska vrednost	35
4.3	Končni nabor kazalnikov	36
4.3.1	Definicije kazalnikov	36
4.3.2	Transformacija in grupiranje spremenljivk	38
4.4	Sestavljanje modela in računanje koeficientov	45
4.5	Dosežene točke in verjetnost neplačila	47
4.6	Validacija – Test modela napovedi neplačila	48
4.6.1	Test povezanosti odvisne in neodvisnih spremenljivk	49
4.6.2	CAP krivulja	50
4.6.3	ROC krivulja	51
4.6.4	K-S graf	51
4.6.5	Matrika napake modela	52
	SKLEP	55
	LITERATURA IN VIRI	57
	PRILOGA	

KAZALO TABEL

Tabela 1: Makroekonomski kazalnik po letih	33
Tabela 2: Neplačila po letih.....	34
Tabela 3: Tabela multikolinearnosti spremenljivk	35
Tabela 4: Informacijska vrednost spremenljivk	36
Tabela 5: Delež osnovnih sredstev v sredstvih.....	39
Tabela 6: Delež dolgov v financiranju	40
Tabela 7: Servisiranje dolga	41
Tabela 8: Obračanje kratkoročnih poslovnih terjatev.....	42
Tabela 9: Dnevi vezave kratkoročnih poslovnih obveznosti.....	43
Tabela 10: Čista donosnost sredstev.....	44
Tabela 11: Čisti kratkoročni obratni kapital	45
Tabela 12: Prvi primer sestavljenega modela.....	46
Tabela 13: Končni logit model	46
Tabela 14: Uteži kazalnikov	48
Tabela 15: Korelacija.....	49
Tabela 16: Matrika napake za testni vzorec pri mejni točki 591.053	54
Tabela 17: Matrika napake za testni vzorec pri mejni točki 246.....	54

KAZALO SLIK

Slika 1: Delitev modelov kreditnega tveganja	11
Slika 2: Standardizirana logistična funkcija z zalogo vrednosti med (0,1).	17
Slika 3: Graf verjetnosti plačila v odvisnosti od točk	27
Slika 4: Matrika napake modela.....	29
Slika 5: CAP krivulja	30
Slika 6: ROC krivulja.....	31
Slika 7: Kolmogorov-Smirnov graf.....	32
Slika 8: Delež osnovnih sredstev v sredstvih	39
Slika 9: Delež dolgov v financiranju.....	40
Slika 10: Servisiranje dolga.....	41
Slika 11: Obračanje kratkoročnih poslovnih terjatev	42
Slika 12: Dnevi vezave kratkoročnih poslovnih obveznosti	43
Slika 13: Čista donosnost sredstev	44
Slika 14: Čisti kratkoročni obratni kapital	45
Slika 15: Graf doseženih točk	47
Slika 16: Graf doseženih točk testnega vzorca.....	49
Slika 17: CAP krivulja testnega vzorca.....	50
Slika 18: ROC krivulja testnega vzorca	51
Slika 19: K-S graf testnega vzorca	52
Slika 20: Prikaz dobička glede na mejne dosežene točke	53
Slika 21: Kazalnik pravilnosti glede na mejo verjetnosti neplačila	55

UVOD

Slovenski trg električne energije se je ob koncu devetdesetih let pričel spreminjati s procesom deregulacije in liberalizacije. Podjetja, ki so bila vključena v elektroenergetski sistem, je postavil pred vrsto novih izzivov, ki jih prejšnji trg ni ponujal, saj so bile cene regulirane s strani države. Zaradi večje dostopnosti trga se začne pojavljati večja konkurenca, posledično potreba po novih prodajnih pristopih, tržno oblikovanje cen, fleksibilnejša ponudba ter soočenje z raznovrstnimi tveganji, ki bistveno vplivajo na financiranje in poslovanje podjetij (Prapotnik Sabol, 2009).

Izkušnje iz že vzpostavljenih trgov električne energije kažejo, da je nestanovitnost cene električne energije največja med vsemi standardnimi primarnimi dobrinami. Urne cene se lahko na dnevnem trgu med seboj razlikujejo za nekajkrat in v posebnih primerih dosežejo ekstremno visoke vrednosti. Vzrok takega nihanja leži v nepredvidljivosti in spremenljivosti že omenjenih ključnih faktorjev, ki vplivajo na ponudbo (nenapovedani izpadi, hidrološke razmere in tehnične omejitve) in povpraševanje (vremenske spremenljivke in večji družbeni dogodki). Nezmožnost skladiščenja električne energije, ki je neizogibna posebnost trga električne energije, pa le še dodatno poveča nestanovitnost njene cene. Lep primer ekstremnih razmer so urne cene na dnevnem trgu v januarju 2017, saj so poskočile tudi do 190 €/MWh zaradi nadpovprečno nizkih temperatur. Podjetja v tej dejavnosti se vedno bolj zavedajo pomembnosti procesa obvladovanja tveganj za zagotavljanje stabilnega in varnega poslovanja. Med najpomembnejša tovrstna tveganja spadajo cenovno, količinsko ter kreditno tveganje. Prvi dve tveganji nastaneta zaradi fizikalnih posebnosti električne energije ter operativnih posebnosti elektroenergetskega sistema. Kreditno tveganje pa je povezano s plačilno sposobnostjo kupca električne energije in tako predstavlja še posebej veliko izpostavljenost podjetja zaradi izredno visokih finančnih tokov ob relativno nizkih maržah.

Negotove gospodarske razmere še dodatno krepijo potrebo po natančnem obvladovanju tveganja v podjetjih, ki trgujejo z električno energijo (Eydeland & Wolyniec, 2003). Hitro naraščanje kompleksnosti poslovnih procesov in povečanje pojava tveganjih dogodkov je pospešilo aktivnosti upravljanja tveganja. Tako se povečuje tudi uporaba kvantitativnih metod v podjetjih in njihovem upravljanju poslovanja, saj se povečuje potreba po naprednih sistemih, ki morajo biti konkurenčni in usklajeni s pravili energetskega trga ter dodatno podprti z večjo razpoložljivostjo podatkov, tehnologijo in znanjem (Management Solutions, 2014).

Podjetja so začela razvijati oddelke za tveganja ter delati na organizaciji, modelih, procesih in tehnologiji, ki bi podpirala upravljanje tveganja in njegov nadzor. Pridobivanje čim večje dodane vrednosti iz razvoja najboljših tržnih praks je privedlo do vidnega napredka pri odnosu do tveganja (Management Solutions, 2014).

Eno izmed pomembnih tveganj, ki se praktično tiče vseh podjetij, ki poslujejo s potrošniki, je kreditno tveganje. V poslu so skoraj vsa podjetja izpostavljena temu tveganju predvsem

zato, ker za ponujene produkte ali storitve ne zahtevajo takojšnjega plačila, ampak pristajajo na odložena plačila (Prapotnik Sabol, 2009).

Poslovni rezultat podjetja za prodajo električne energije je zelo odvisen od rednih plačil strank, saj se z njimi pokrivajo stroški nabave električne energije. V takšnem podjetju ima upravljanje kreditnega tveganja zelo pomembno vlogo. Stranke, s katerimi so podpisane pogodbe, predstavljajo veliko tveganje, zato se podjetja za prodajo električne energije zatekajo k različnim načinom pridobivanja najboljših informacij o finančnem stanju strank.

Le-ta lahko uporabijo različne metode in modele za oceno verjetnosti neplačila za prodano energijo. V literaturah se pojavljajo različne delitve modelov kreditnega tveganja. Saunders in Millon Cornett (2008) razvrščata modele v tri širše skupine, kot so: kvalitativni modeli, modeli kreditnega točkovanja in novejši modeli. Kvalitativni modeli se v večini naslanjajo na kvalitativne informacije. Zaradi pomanjkanja javno dostopnih informacij o kvaliteti posojilojemalcev morajo podjetja zbrati informacije iz zasebnih virov ali plačati za te podatke kreditnim agencijam. Modeli kreditnega točkovanja so kvantitativni modeli, ki uporabijo opazovane lastnosti podjetja za izračun točk. Ta predstavlja posojilojemalčevo verjetnost neplačila oziroma njihovo razvrstitev po različnih razredih. Novejši modeli pa se osredotočajo na različna področja kreditnega tveganja in v osnovi sledijo finančni teoriji ter širše dostopnim tržnim podatkom, s katerimi uspejo oceniti verjetnost neplačila (Saunders & Millon Cornett, 2008).

Po mnenju Sandre Soršak (2010) vsak nov model prinaša drugačne načine in nov pogled na modeliranje tveganja. Vsak poslovni portfelj je unikaten in se različno odziva na poslovne dražljaje, zaradi česar bi lahko bilo toliko modelov kreditnega tveganja, kot je teh portfeljev. Nemogoče je natanko predvideti gibanje prihodnjih terjatev poslovnega portfelja, cilj individualnih modelov pa se je le približati tem vrednostim in v tem se skriva ves napor modeliranja kreditnih tveganj (Soršak, 2010).

Najustreznejši način je tako sestava lastnega modela za ocenjevanje strank na podlagi podatkov, ki jih ima podjetje v interakciji z njimi, saj so to najbolj pristne informacije, ki običajno privedejo do najboljših rezultatov. Zato sem se odločila za sestavo svojega modela. Uporabila sem metodo kreditnega točkovanja s pomočjo logistične regresije, saj so po mnenju Saunders (2000) ti modeli najprimernejši za uporabo pri izračunih verjetnosti neplačila in za razvrščanje kreditnojemalcev v skupine z enako verjetnostjo neplačila. Z izbiro in povezovanjem različnih finančnih značilnosti strank lahko ugotovimo, kateri dejavniki so pomembni za kreditno tveganje, in tako lažje izločimo stranko, ki nosi previsoko tveganje (Saunders, 2000).

Podjetja s prodajo električne energije potrebujejo zaradi narave poslovanja predvsem hitreje, bolj konsistentne in učinkovite odločitve pri izbiri strank, saj morajo biti taka podjetja karseda konkurenčna na trgu. S to vrsto modelov pa je možna obravnava večjega števila strank v krajšem času.

Magistrsko delo je sestavljeno iz teoretičnega in raziskovalnega dela. V teoretičnem delu preučujem domačo in tujo strokovno literaturo s področja energetskega trga in upravljanja s tveganji – s poudarkom na kreditnih tveganjih. V magistrskem delu želim podrobno opisati kreditno tveganje in vrste njegovega merjenja. Posvetila se bom predvsem opredelitvi različnih vrst modelov, s katerimi se lahko meri kreditno tveganje. Izbrala bom najprimernejšega za izračun verjetnosti neplačila strank za izbrano področje ter se posvetila praktičnim problemom, ki se pojavljajo pri modeliranju.

Z magistrskim delom želim sestaviti model, s katerim bi podjetje, ki trguje z električno energijo, določalo verjetnosti neplačila posameznih poslovnih uporabnikov in izbor primernih strank iz segmenta večjih poslovnih odjemalcev za nadaljnje poslovno sodelovanje. Na podlagi tega bi se podjetje lažje odločilo ali je pripravljeno skleniti pogodbo z določeno stranko ali ne. Tako bi podjetje lahko bolj učinkovito obvladovalo kreditno tveganje, saj je bolje iz portfelja odstraniti kreditno slabo stranko, kot pa imeti velik portfelj strank, ki so finančno nesigurne. V magistrskem delu opisujem probleme, ki lahko nastanejo pri generiranju vzorca in kvaliteti podatkov. Opisani so način izbora in transformacije finančnih kazalnikov ter na njih uporabljena logistična funkcija in »logit« model.

Empirični del magistrskega dela prikazuje praktično uporabo kreiranega modela na realnih podatkih. Pridobljene podatke analiziram s pomočjo programskega paketa Matlab, s pomočjo kvantitativne validacije pa preverim kvaliteto napovedne moči oblikovanega modela. V zaključnem delu predstavim še sintezo dobljenih rezultatov.

1 TVEGANJA NA TRGU ELEKTRIČNE ENERGIJE

Tveganje je verjetnost, da bo uresničitev naše poslovne odločitve drugačna od pričakovane. Cilj podjetja je doseči načrtovani poslovni izid, vendar nam dejavniki tveganja to pogosto preprečijo. Pri načrtovanju poslovanja je potrebno upoštevati vse zaznane vrste tveganja, ki jim je podjetje izpostavljeno, predvideti možni vpliv na uresničevanje poslovnega načrta ter sprejeti ustrezne ukrepe za zmanjšanje možnih škodljivih vplivov. V podjetju je potrebno vzpostaviti mehanizem, ki bo dovolj zgodaj odkrival nove, še neznane, dejavnike tveganja oziroma zaznaval zgodnje opozorilne znake krize (Peterlin, 2005).

Obvladovanje tveganj lahko definiramo kot optimizacijo poslovnih procesov ob upoštevanju tveganj in odnosa podjetja do tveganj z namenom njihovega nadzora (Wengler, 2001). Obvladovanje tveganj zajema skupek tehnik, ki vključujejo določanje vplivnih faktorjev tveganja, njihovo meritev, določanje ukrepov za nadzor nad tveganji in njihovo izvajanje. Pri tem podjetja v elektroenergetiki gradijo na izkušnjah bančne industrije iz konca osemdesetih in devetdesetih let prejšnjega stoletja. Proces obvladovanja tveganj zajema tri korake (Paravan, 2004):

- Razpoznavanje negotovosti kot vzroka tveganj;
- Merjenje (ocena) vpliva tveganj na končni rezultat;
- Upravljanje tveganj (izbira optimalne strategije).

V nadaljevanju se bom najprej bolj podrobno posvetila značilnostim elektroenergetskega trga, nato pa obvladovanju tveganj na trgu električne energije.

1.1 Značilnosti elektroenergetskega trga

V Sloveniji se je trg električne energije postopoma pričel odpirati v devetdesetih letih, saj je bil takrat za državo primarni cilj, da pristopi k Evropski uniji (v nadaljevanju EU). EU je s svojimi direktivami od držav članic zahtevala, da postopoma odprejo trg z električno energijo. Slovenija je bila tako obvezana uskladiti svojo zakonodajo na področju energetike z zakonodajo EU (Evropski parlament in Svet, 1996).

Trg električne energije se je odpiral postopoma, s prvim odločilnim korakom v letu 2001, ko se je začelo prehodno obdobje možnosti sklepanja pogodb za večje odjemalce o nakupu električne energije po tržnih pogojih. Odjemalci so dobili pravico do svobodne izbire dobavitelja, soočili pa so se tudi z novim načinom določanja cen, ki se je razdelil na plačilo uporabe elektroenergetskih omrežij Sistemskemu operaterju distribucijskega omrežja (v nadaljevanju SODO) in plačilo za dobavljeno električno energijo dobavitelju energije.

Do popolnega odprtja trga električne energije je prišlo z Energetskim zakonom (Ur.l. RS, št. 79/99, 2007) v letu 2007, saj so z njim tudi gospodinjstva dobila pravico do proste izbire dobavitelja. To je predstavljalo mejnik pri oblikovanju polno delujočega energetskega trga, saj so na eni strani vsi odjemalci dobili možnost izbire dobavitelja električne energije na podlagi cene, pogodbenih pogojev, ugleda dobavitelja, možnosti plačevanja računov ali možnosti pridobivanja električne energije iz različnih virov. Na drugi strani, pa so se dobavitelji srečali z novimi izzivi, ki so jih spodbujali k razvijanju novih produktov in storitev po meri odjemalcev (Prapotnik Sabol, 2009).

Električna energija je za življenje in delovanje celotne družbe tako pomembna, da si življenja brez nje praktično ne moremo več predstavljati. To dobroto je mogoče prosto tržiti, a se razlikuje od vseh ostalih dobrin po nekih bistvenih lastnostih (Fabijan, 2007):

- Električna energija je dobrina, ki je ni mogoče shranjevati (vsaj ne v omembe vrednih količinah). To pomeni, da morata biti proizvodnja in poraba (z upoštevanimi izgubami) električne energije v posameznem zaprtem elektroenergetskem sistemu vedno enaki (proizvodnja in poraba mora biti v istem trenutku in enakih količinah);
- Obstajajo ovire vstopa za nove ponudnike v obliki omejenih lokacij za proizvodnjo, omejenega dostopa do primarnih virov, zamudnega pridobivanja dovoljenj za gradnjo novih proizvodnih enot ali daljnovodov. Vse naštetu povzroča, da med odločitvijo za novo investicijo v večjo proizvodno enoto in začetkom njenega obratovanja najpogosteje preteče med tri do pet let;

- Električna energija ni prosto prenosljiva, ampak jo pri tem omejujejo zmogljivosti daljnovodov. Tako električne energije ni mogoče prenesti med dvema točkama tudi v primeru, da bi se to ekonomsko izplačalo, če za to ni na voljo prostih čezmejnih prenosnih zmogljivosti. Trg električne energije zato ni globalen, temveč je sestavljen iz množice samostojnih manjših subnacionalnih, nacionalnih in regionalnih trgov, ki so bolj ali manj neodvisni drug od drugega;
- Povpraševanje po električni energiji je zelo neelastično. Večina kupcev nivoja povpraševanja po električni energiji ne prilagaja gibanju cen na trgu, za kar obstajata dva glavna razloga. Prvič, v večini procesov, kjer se električna energija porablja, je ni mogoče nadomestiti z drugimi oblikami energije ali pa je to povezano z velikim povečanjem stroškov ali zmanjšanjem udobja. Drugi razlog pa je ta, da višina plačila stroškov za porabo električne energije pri večini končnih porabnikov vsaj kratkoročno ni odvisna od gibanja cen na trgu električne energije. Porabniki imajo namreč z dobavitelji sklenjene pogodbe o dobavi električne energije po določenih cenah, ki kratkoročno niso odvisne od gibanj cen električne energije na trgu na debelo.

1.2 Vrste tveganj na trgu električne energije

Podobno kot na vsakem trgu obstaja tudi na trgu električne energije vrsta negotovosti. Poraba odjemalcev je negotova zaradi odvisnosti od vremenskih vplivov, proizvodnja pa je na drugi strani negotova zaradi naključnih okvar agregatov in negotovosti hidroloških razmer. Ker v tržnih razmerah ceno določata ponudba in povpraševanje, je posledično negotova tudi cena električne energije. Zaradi tovrstnih negotovosti je izid praktično vedno drugačen od pričakovanj, odločitve, ki jih na trgu podjetje sprejema za doseganje zastavljenih ciljev, pa so tvegane (Higle & Wallace, 2002).

Udeleženci trgovanja se na trgu električne energije srečujejo z naslednjimi tveganji (Kokol, 2002):

- Cenovno tveganje, ki nastaja zaradi nestanovitnosti cene električne energije. Cene imajo na različnih trgih različno stopnjo nihajnosti, obenem pa so v različnih obdobjih ročnosti različno korelirane. Cena in drugi parametri se spreminjajo s časom, zato vrednotenje finančnih instrumentov za zavarovanje pred tveganjem in s tem dobiček ali izguba pri trgovanju zavisijo od natančnosti napovedi cene;
- Količinsko tveganje, ki nastane v danem trenutku zaradi razlike med proizvodnjo električne energije v elektrarnah in odjemom odjemalcev v portfelju. Negotovost proizvodnje zajema predvsem vprašanje, koliko energije bo proizvedene v določeni elektrarni. Ta je pri hidroelektrarnah povezana z negotovostjo hidroloških razmer, pri plinskih elektrarnah z zunanjo temperaturo zraka, pri jedrskih elektrarnah, ki za kondenzacijo pare uporabljajo reko, pa s temperaturo reke. Pomemben vpliv na negotovost proizvodnje ima tudi razpoložljivost agregatov, ki jo zaznamujejo načrtovani in nenačrtovani izpadi. Negotovost odjema pa je na drugi strani posledica vremenskih vplivov, elastičnosti obremenitve, sezonskih ciklov in rasti porabe;

- Kreditno tveganje, ki nastaja zaradi možnosti neplačila pogodbene stranke. Pogodbeni stranka morda nima zadostnih sredstev oziroma ima likvidnostne težave, zaradi česar nima dostopa do drugih virov sredstev. Gre torej za nepredviden izostanek plačila za dobavljeno električno energijo;
- Operativno tveganje, ki predstavlja možnost izgube zaradi neustreznega ali neuspešnega izvajanja notranjih postopkov, procesov, ljudi in sistemov ali pa zaradi zunanjih dogodkov. V elektrogospodarstvu nastaja zaradi nezmožnosti dobave pogodbenih količin električne energije. Do tega prihaja zaradi tehničnih napak, namernih špekulacij ipd.

1.3 Kreditno tveganje

V svojem magistrskem delu se bom povsem posvetila kreditnemu tveganju v podjetju, ki trguje z električno energijo, oziroma bolj specifično verjetnosti neplačila odjemalcev (angl. *Probability of Default*, v nadaljevanju PD), zato je najprej potrebno opredeliti osnovne pojme kreditnega tveganja.

1.3.1 Opredelitev kreditnega tveganja

V strokovni literaturi najdemo več definicij kreditnega tveganja. Saunders in Cornett (Saunders & Millon Cornett, 2008, str. 173) pravita, da je kreditno tveganje negotovost, da se obljubljeni denarni tokovi finančnih terjatev ne poplačajo v celoti. Kendall (1998) pa ga definira kot verjetnost, da bo transakcija z nasprotno stranko zaradi njene nezmožnosti poravnave svojih finančnih obveznosti neizvršena. Brealey in Stewart (2000) opredeljujeta kreditno tveganje kot možnost, da kupec ne bo mogel ali ne bo hotel poravnati svojih pogodbenih obveznosti, to je plačila svojih obveznosti ob zapadlosti in v skladu s sklenjeno prodajno pogodbo. V podjetju Elektro energija pa pravijo (Elektro energija d.o.o., 2015), da kreditna tveganja nastajajo zaradi zamujanja s plačili, stečajev ali prisilnih poravnav partnerjev s trga na debelo ali drobno, nespoštovanja pogodbenih določil poslovnih partnerjev ter kakovosti kreditnih in bonitetnih ocen.

S tem tveganjem se praktično najbolj spopadajo vse finančne institucije, doleti pa lahko tudi vsako podjetje, ki zajema dejavnosti prodaje blaga in storitev z odlogom plačil. V splošnem kreditna tveganja spremljajo naslednji dejavniki (Smithson, 1998):

- Zapadlost (dospelost) transakcije: kreditnemu tveganju so bolj izpostavljene dolgoročne kot pa kratkoročne pogodbe, saj je pri daljšem obdobju zapadlosti plačila več verjetnosti, da se pogodbenemu partnerju zgodijo negativni dogodki, ki privedejo do nezmožnosti plačila obveznosti;
- Kreditna boniteta odjemalca: nižja kot je bonitetna ocena odjemalca, večja je verjetnost neizpolnitve obveznosti;
- Nestanovitnost cene produkta: večja nestanovitnost cene produkta povečuje možnost, da bodo neugodne spremembe gibanja cen odjemalcu onemogočile izpolnitev obveznosti.

1.3.2 Merjenje kreditnega tveganja

Pri merjenju kreditnega tveganja je potrebno biti pozoren na naslednje tri komponente (Kendall, 1998):

- Vrednost (velikost) terjatve, ki je izpostavljena izostanku plačila;
- Delež vrednosti, ki ga bo mogoče dobiti nazaj v primeru izostanka plačila, ter
- verjetnost izostanka plačila.

Po mnenju Saunders in Millon Cornett (2008) mora podjetje izmeriti verjetnost neplačila stranke, če želi oceniti izpostavljenost podjetja, kar pa je zelo odvisno od količine informacij, ki jih ima o stranki. Za manjše stranke je potrebno zbrati interne informacije ali jih kupiti od kreditnih agencij. Za večje poslovne stranke so te informacije javno dostopne, kot so revidirani računovodski izkazi, tržne cene delnic in obveznic podjetja, poročila analitikov. Tako je za podjetja, ki trgujejo na borzi, dostopnih več informacij kot za manjša podjetja. Večja dostopnost podatkov in nižji povprečni stroški pridobivanja teh informacij podjetju dopuščajo, da uporablja zapletene in kvantitativne metode za ocenjevanje verjetnosti neplačila za večje stranke, vedno bolj pa tudi za manjše, saj postajajo te metode bolj učinkovite in cenejše (Saunders & Millon Cornett, 2008, str. 312).

1.3.3 Upravljanje kreditnega tveganja

Tveganja so del poslovnih procesov in informacij, ki jih mora vodstvo upoštevati pri sprejemanju poslovnih odločitev. V kolikor so podlaga za poslovne odločitve nepopolne informacije in napačna ocena razvoja dogodkov, je večja možnost odmika od načrtovanih ciljev družbe in posledično manjša gospodarska korist družbe (Berk Skok, Peterlin, & Ribarič, 2005).

Negotovost glede plačila s strani podjetja otežuje planiranje potreb po denarnih sredstvih za prihodnost. V primeru slabe finančne discipline oziroma porasta višine zapadlih terjatev mora imeti podjetje pripravljenih več denarnih sredstev za ohranjanje normalnega poslovanja, poleg tega mora sredstva za financiranje poslovanja ter servisiranje obveznosti pridobivati drugje (npr. se zadolževati, kar pomeni dodatne stroške). Visoka stopnja neplačevanja terjatev lahko v skrajnem primeru ogrozi solventnost podjetja (Pike & Neale, 2009).

Podjetje mora skrbno zbirati in spremljati informacije o strankah, ki jih ima v portfelju. Učinkovitost spremljanja strank in strategija upravljanja tveganja direktno vplivata na dobiček in tveganje portfelja, posledično tudi podjetja. Eden najboljših načinov zmanjšanja tega tveganja je razpršenost portfelja na različna sredstva in s tem povečanje verjetnosti delnega ali celotnega poplačila obveznosti.

Če niso izplačane vse obveznosti portfelja, bo povprečen dobiček portfelja manjši, kot je največji možni dobiček. Razpršenost vpliva na omejitev verjetnosti neplačil v portfelju, saj zmanjša kreditna tveganja, ki so specifična za vsako stranko.

Pomembno je, da ima podjetje izoblikovano politiko aktivnega upravljanja s kreditnim tveganjem. Ta naj bi zajemala preverjanje kreditne sposobnosti odjemalca, sprotno spremljanje odprtih terjatev podjetja, omejevanje izpostavljenosti posameznemu odjemalcu, ugodnosti v primeru predplačila, zamudne obresti, zavarovanje terjatev ter politiko izterjave terjatev. Pri tem je potrebno poudariti, da prestroga politika upravljanja s kreditnim tveganjem zmanjšuje konkurenčnost podjetja, saj lahko le-to zaradi nje izgubi določen del strank. Po drugi strani pa preveč sproščena politika zvišuje stopnjo kreditnega tveganja (Harrington, 1993).

Podjetje načeloma lahko uporabi podobne metode in modele za oceno verjetnosti neplačila za dana posojila, obveznice ali dejansko pogodbo, ki obljublja fiksna (ali indeksirana) plačila, ob rednih in točno določenih intervalih v prihodnosti. Te pogodbe vključujejo dogovore, ki omejujejo ali spodbujajo različne aktivnosti, da povečajo verjetnost plačila, ki lahko vključujejo omejitve sklepanja novih pogodb za odjem. Njihov namen je pogosto preprečiti, da pride do večjih sprememb pri strankinih finančnih kazalnikih, kot sta pospešeni koeficient in finančni vzvod. Jasno je, da če se lastnikom izplačajo visoke dividende, potem ostane manj denarnega toka za poplačila obveznosti. Dodatno pa marže odražajo premije za tveganje, ki se spreminjajo s kvaliteto kreditne sposobnosti odjemalca in z zavarovanjem.

V enem izmed podjetij, ki trgujejo z električno energijo v Sloveniji, pravijo (Elektro energija d.o.o., 2015): »Tveganje nespoštovanja pogodbenih določil poslovnih partnerjev negativno vpliva na poslovni izid družbe, zato je njegovo obvladovanje nujno. Za zmanjševanje tveganja nespoštovanja pogodbenih določil poslovnih partnerjev smo pri trgovanju na trgu na debelo uporabljali standardizirane krovne pogodbe EFET (angl. *European Federation of Energy Traders*), ki urejajo celoten proces od sklenitve pogodbe do dobave/prezema energenta ter postopke ob kršitvah, ki vključujejo tudi načine povrnitve škode. Za zmanjševanje tveganja pri prodaji končnim odjemalcem pa smo v kupoprodajnih pogodbah uporabljali pogodbene člene, ki opredeljujejo pogodbene kazni in odškodnine ob kršitvah.« Za potrebe upravljanja s kreditnimi tveganji se poleg zunanjih bonitetnih ocen v tem podjetju uporablja tudi lastne bonitetne ocene, pri čemer se upošteva njim znane formalne in neformalne informacije. Za zmanjšanje kreditnih tveganj veliko pozornosti namenjajo spremljanju dolžnikov in upravljanju s terjatvami. Kreditna tveganja pri kupcih na trgu na drobno obvladujejo z vnaprejšnjim plačevanjem oziroma zavarovanjem, omejevanjem plačilnih rokov ter z uvedbo pogodbenih kazni in odškodnin ob predčasni odpovedi pogodbe. Pri poslovanju na trgu na debelo pa kreditna tveganja omejujejo s preverjanjem bonitete partnerja, z določitvijo kreditnih limitov, ustreznim zavarovanjem in s spremljanjem vseh drugih razpoložljivih informacij (Elektro energija d.o.o., 2015).

Prof. dr. Aleš Ahčan v enem izmed intervjujev pravi (Montel Energetika.NET d.o.o., 2015): »Slovenski trgovci z električno energijo po mojih izkušnjah ne upoštevajo kreditnega tveganja strank, torej tveganja, da bodo podjetja tudi dejansko poplačala svoje obveznosti. Podjetja svojih strank ne bi smela obravnavati le skozi prizmo prodajne marže, saj je ta navzgor omejena in nizka, na drugi strani pa so tveganja navzdol neomejena in visoka.« Po njegovem mnenju morajo podjetja, ki se ukvarjajo s prodajo električne energije, za vzpostavitev zdravih temeljev poslovanja pri izračunu cene elektrike uporabljati modele, ki omogočajo celovito obravnavo stranke. Modeli, ki ne premorejo analize tveganj, niso le nepopolni, so nevarni, ker povečujejo verjetnost propada (Montel Energetika.NET d.o.o., 2015).

Neplačilo terjatev povzroča prodajalcu izpad prihodka, poleg tega pa lahko utrpi dodatne stroške, ki so posledica neplačila terjatev, če želi izterjavo po sodni poti. Ti stroški lahko v primeru neopredeljene politike izterjave in neustreznih notranjih kontrol presežejo vrednost terjatve. Obremenitev prodajalca v primeru neplačila je davek na dodano vrednost (v nadaljevanju DDV), ki ga plača davčnemu organu, ne glede na to, ali je terjatev plačana ali ne. Ob predložitvi dokazil, da je uporabil vsa možna sredstva za izterjavo, dobi plačani DDV v določenih primerih povrnjen. Glede na kasnejšo povrnitev DDV-ja je prodajalec oškodovan zaradi časovne vrednosti denarja (Rogač & Mlinarič, 2014).

Kot pravi prof. dr. Ahčan (Montel Energetika.NET d.o.o., 2015), je z vidika ohranjanja stabilnosti poslovanja in maksimizacije vrednosti podjetja ključno, da se pravilno izračuna lastna cena in doda marža za tveganja. Večina podjetij se ne zaveda, da je bolje izgubiti »slabo stranko« v smislu tveganj, ki je velik odjemalec, kot imeti največji portfelj potencialno nevarnih strank.

1.4 Modeli kreditnega tveganja

Glede na opisana dejstva lahko podjetja uporabijo več spodaj opisanih modelov, ki analizirajo verjetnosti neplačila.

Modeli kreditnega tveganja se v osnovi ločijo na modele za ocenjevanje kreditnega tveganja izpostavljenosti do posameznikov, ki merijo kreditno tveganje v obliki izračuna njegovih komponent (predvsem PD) za posameznike. Na drugi strani pa so modeli, ki merijo kreditno tveganje celotnega portfelja. V nadaljevanju se bom bolj skoncentrirala na modele, ki ocenjujejo izpostavljenost podjetja do posameznikov.


Saunders in Millon Cornett (2008) pravita, da ekonomisti, analitiki in upravljalci tveganj za ocenjevanje verjetnosti neplačila uporabljajo veliko različnih modelov, ki segajo od relativno kvalitativnih do izrazito kvantitativnih modelov. Hkrati se lahko uporablja več modelov za določanje kreditne ocene ali racionalnega obsega dolga. Po njunem mnenju je bilo največ časa in truda vloženega v razvoj izrazito tehničnih modelov za kreditna tveganja (Saunders & Millon Cornett, 2008, str. 313).

Saunders in Millon Cornett (2008, str. 313) razvrščata modele v tri širše skupine, kot so: kvalitativni modeli (angl. *qualitative models*), novejši modeli (angl. *newer models*) in modeli kreditnega točkovanja (angl. *credit scoring models*). **Kvalitativni modeli** se v večini naslanjajo na kvalitativne informacije. Zaradi pomanjkanja javno dostopnih informacij o kvaliteti posojilojemalcev morajo podjetja zbrati informacije od zasebnih virov ali plačati za te podatke kreditnim agencijam. S temi podatki lahko podjetja pravilno presodijo verjetnost neplačila stranke in ceno posojila. Na odločitev vpliva veliko dejavnikov, ki pa vključujejo dejavnike, specifične za vsakega posojilojemalca (angl. *borrower – specific factors*: ugled, finančni vzvod ali kapitalska struktura, stabilnost zaslužka, zavarovanje ...), ter dejavnike, ki vplivajo na vsa podjetja v gospodarstvu (angl. *market – specific factors*: poslovni cikel, nivo obrestnih mer ...). Analitik v podjetju se na podlagi teh dejavnikov subjektivno odloči, kateri dejavnik je pomembnejši in mu bo dal večjo utež, ter se tako odloči ali sklene pogodbo s stranko ali ne. **Novejši modeli** se osredotočajo na različna področja kreditnega tveganja in v osnovi sledijo finančni teoriji ter širše dostopnim tržnim podatkom, s katerimi uspejo oceniti verjetnost neplačila. Ti modeli so večinoma primernejši za ocenjevanje tveganja večjih posojilojemalcev v podjetniškem sektorju. Avtorja med novejše pristope uvrščata RAROC model, Opcijske modele (KMV model), izpeljave kreditnih tveganj s terminsko strukturo (angl. *Term Structure Derivation of Credit Risk*) in izpeljave kreditnih tveganj s stopnjo umrljivosti (angl. *Mortality Rate Derivation of Credit Risk*). **Modeli kreditnega točkovanja** pa so kvantitativni modeli, ki uporabijo opazovane lastnosti podjetja za izračun točk. Ta predstavlja posojilojemalčevo verjetnost neplačila oziroma za njihovo razvrstitev po različnih razredih. To vrsto modelov bom podrobneje opisala v nadaljevanju (Saunders & Millon Cornett, 2008).

Na drugi strani so avtorji knjige *Credit Derivatives* (Chacko, Sjöman, Motohashi, & Dessain, 2006, str. 65) razdelili kreditne modele v tri glavne razrede: **strukturni** (angl. *structural models*), **empirični** (angl. *empirical models*) in **nestrukturni modeli** (angl. *reduced form models*). Po njihovih besedah imajo strukturni modeli skupen pristop, ki pravi, da podjetje ne uspe poplačati svojega dolga, če vrednost sredstev pade pod določeno mejo. Model napove, da se neplačilo lahko prej zgodi, če pade vrednost delnic. Glede na to logiko, je možno napovedati verjetnost neplačila, pod pogojem, da ima model potrebne informacije. Empirični modeli predpostavljajo, da je v modelu pretežno pravilno upoštevati podatke podjetja in okolja, zato raje izberejo drugi pristop. Izberejo podjetja, ki v preteklosti niso izpolnila vseh obveznosti, ter pregledajo in ovrednotijo njihove finančne podatke z določenimi točkami. Nato se primerja točke med slabimi (finančno nestabilnimi podjetji) in dobrimi (finančno stabilna podjetja) podjetji. Ideja nestrukturnih modelov je čisto drugačna, saj model namesto informacije o podjetju upošteva, da je neplačilo vezano na zunanji signal, kot sta statistična in ekonometrična vrednost. Ti modeli so zgrajeni na predpostavki, da se neplačilo pojavi kot naključen dogodek.

Pri svoji delitvi modelov sem upoštevala dve različni delitvi, ki sta se mi zdeli najbolj smiselni in sta že zgoraj opisani.

Slika 1: Delitev modelov kreditnega tveganja



V nadaljevanju bom podrobneje opisala model kreditnega točkovanja, ki ga bom tudi uporabila pri raziskavi. Na ta model se bom osredotočila predvsem, ker se ta model uporablja za izračun verjetnosti neplačila ali za razvrščanje odjemalcev v skupine (razrede) z enako verjetnostjo neplačila. Z izbiro in povezovanjem različnih ekonomskih in finančnih značilnosti odjemalcev spoznamo, kateri dejavniki so pomembni za kreditno tveganje, ovrednotimo pomembnost posameznega dejavnika, lažje izločimo odjemalca s previsokim kreditnim tveganjem, pomaga pa nam tudi pri izračunavanju potrebnih rezerv za prihodnje izgube. Sisteme kreditnega točkovanja najdemo praktično v vseh tipih kreditnih analiz. Temeljijo na isti ideji – vnaprej identificirati določene ključne dejavnike, ki vplivajo na verjetnost neplačila kot nasprotja poplačilu, in jih kombinirati oziroma ponderirati v kvantitativne točke. V posameznih primerih lahko točke dobesedno interpretiramo kot verjetnost neplačila; v drugih se lahko točke uporabljajo kot sistem kvalifikacije posameznega odjemalca, ki jih uvrstijo v dobro ali slabo skupino (Križnik, 2005). Na ta način se lahko množično obdelava večje število strank v zelo kratkem času, zato je ta model kreditnega obvladovanja zelo primeren za podjetja, ki prodajajo električno energijo, saj je njihov portfelj potencialnih odjemalcev zelo obširen in raznolik.

2 MODEL KREDITNEGA TOČKOVANJA

Modeli kreditnega točkovanja so modeli, ki identificirajo verjetnost neplačila s kvantitativnimi točkami. Po mnenju Saunders in Millon Cornett (2008, str. 316), ti modeli uporabljajo opazovane lastnosti podjetij za izračun točk, ki predstavlja njihovo verjetnost neplačila in jih tako razvrščajo po različnih razredih. Analitik z izbiranjem in primerjanjem različnih ekonomskih in finančnih lastnosti stranke uspe:

- Numerično ugotoviti, kateri dejavniki so relevantni pri razlagi tveganja neplačila;
- Ovrednotiti, koliko je vsak dejavnik pomemben;
- Izboljšati oceno tveganja neplačila;
- Bolje prepoznati finančno slabe stranke;
- Boljše izračunati rezervacije, ki bi bile v prihodnosti potrebne zaradi morebitnih izgub.

Najpomembnejša korist modelov kreditnega točkovanja je, da se lahko pravilneje napove strankino finančno stanje brez dodatnih virov informacij. Potrebno pa je določiti objektivne ekonomske in finančne mere tveganja za vsak rang kreditne ocene strank. Objektivne karakteristike naj bi vsebovale prihodek, sredstva, leta, dejavnost, lokacijo, iz katerih dobimo finančne kazalnike, ki so ključni dejavniki. Iz njih se s pomočjo statističnih tehnik točkuje verjetnost tveganja neplačil ali njegova ocena. Modele kreditnega točkovanja na splošno ločimo v tri vrste: diskriminantni modeli (angl. *linear diskriminant models*), linearni verjetnostni modeli (angl. *linear probability model*) in logistični modeli (angl. *logit/probit model*) (Saunders & Millon Cornett, 2008).

2.1 Diskriminantni model

Diskriminantni model temelji na diskriminantni analizi (angl. *Discriminant analysis*), ki napoveduje izid na podlagi proučevanja odvisnosti ene spremenljivke – odvisne spremenljivke – od ene ali več drugih spremenljivk – pojasnjevalnih spremenljivk. Namen modela je oceniti povprečno populacijsko vrednost odvisne spremenljivke ob danih vrednostih pojasnjevalnih spremenljivk. Rezultat odvisne spremenljivke so kategorične vrednosti (Burns & Burns, 2008).

Model ločuje odjemalce glede na njihove opazovane karakteristike le v dva razreda, prvega z veliko verjetnostjo neplačila in drugega z nizko verjetnostjo neplačila. Ta model uporablja historične podatke, da lahko razloži (ne)plačila preteklih terjatev. Uporabi se le relativno pomembne dejavnike, ki so nato ključnega pomena pri napovedovanju, ali je posel, sklenjen s stranko, dober ali slab.

Nameni diskriminantne analize so glede na Burns in Burns (2008) naslednji:

- Raziskati razlike med skupinami na osnovi atributov posameznih opazovanj, ki nakazujejo, kateri atributi najbolj vplivajo na razliko med skupinami;
- Napovedna diskriminantna analiza poskuša določiti, v katero skupino se razvrstijo novi primeri na osnovi vrednosti pojasnjevalnih spremenljivk;
- Določitev najbolj optimalnega načina ločevanja med skupinami;
- Razvrščanje primerov v skupine – s pomočjo statističnih testov vidimo, kako dobro funkcija ločuje med skupinami;
- Testiranje, ali so primeri razvrščeni, kot je bilo predvideno.

V diskriminantni analizi se določi linearna enačba, ki bo predvidela, kateri skupini pripada posamezen primer, in pri tem minimizirala verjetnost razvrstitve primerov v napačne skupine.

Altman (1968) je razvil diskriminantni model za večja podjetja, ki trgujejo na borzi v ZDA. V tem modelu je spremenljivka Z splošna mera klasifikacije tveganja neplačila, ki je odvisna od različnih finančnih kazalnikov stranke. Vsak kazalnik pa ima svojo utež, ki je dobljena z diskriminantno analizo zgodovinskih podatkov. Altmanov model ima obliko izraženo z enačbo (1).

$$Z = 1.2X_1 + 1.4X_2 + 3.3X_3 + 0.6X_4 + 1.0X_5 \quad (1)$$

Kjer je:

- X_1 razmerje med delovnim kapitalom in celotnimi sredstvi;
- X_2 razmerje med zadržanim dobičkom in celotnimi sredstvi;
- X_3 razmerje med poslovnim izidom pred obrestmi in davki ter celotnimi sredstvi;
- X_4 razmerje med tržno vrednostjo delnic in računovodsko vrednostjo dolgoročnega dolga;
- X_5 razmerje med celotno prodajo in celotnimi sredstvi.

Model (1) ločuje podjetja glede na vrednosti odvisne spremenljivke Z :

- $Z < 1.81$: velika verjetnost neplačil;
- $1.81 < Z < 2.99$: srednja verjetnost neplačila;
- $2.99 < Z$: majhna verjetnost neplačila.

Po mnenju Saunders in Millon Cornett (2008, str. 319) pa ima Altmanov model tudi nekaj pomanjkljivosti:

- Model loči le med dvema ekstremnima primeroma, uspešna ali neuspešna podjetja, v realnosti pa obstaja tudi dosti primerov vmes. Ena izmed možnih rešitev je definicija več razredov uspešnosti v tem modelu (ne le kategorične vrednosti);
- Model ne upošteva nobene ekonomske spremenljivke;
- Model tudi ne upošteva nekaterih zelo pomembnih kvantitativnih spremenljivk, ki ključno vplivajo na uspeh podjetja.

2.2 Linearni verjetnostni model

Medtem ko model linearne diskriminante le loči stranke na razreda z visoko verjetnostjo neplačila in nizko verjetnostjo neplačila, model linearne verjetnosti izračuna pričakovano verjetnost neplačila.

Ta model uporablja pretekle podatke, kot so finančni kazalniki za vhodne podatke modela, da lahko pojasni plačilno disciplino strank zapadlih dolgov. Dejavnike, ki so bili pomembni pri razlagi preteklih dogodkov, se tudi uporabi za napovedovanje za sklepanje novih pogodb s strankami. Iz zgodovinskih podatkov se lahko izračuna verjetnost plačila in neplačila strank. Stare terjatve se loči v dve opazovalni skupini: na tiste, ki niso bile povrnjene (z verjetnostjo neplačila enaka 1), in tiste, ki so bile plačane (verjetnost neplačila enaka 0) (Wooldridge, 2002).

Linearna regresija je pristop, ki se uporablja za modeliranje odvisnosti med odvisno spremenljivko Y in eno ali več pojasnjevalnih (neodvisnih) spremenljivk X . Povezava med odvisno in neodvisnimi spremenljivkami je zmodelirana s pomočjo linearne funkcije, kjer so nepoznani parametri ocenjeni s pomočjo zgodovinskih podatkov. Odvisne spremenljivke pa nosijo merljivo informacijo o podjetju (Wooldridge, 2002, str. 22).

Linearna regresija se pri izdelavi bonitetnih modelov zelo redko uporablja, saj ima kar nekaj omejitev in predpostavk, ki v realnosti ne držijo (Anderson, 2007):

- Linearnost: regresijska enačba predpostavlja, da se neodvisne spremenljivke povečujejo linearno;
- Neodvisno in normalno porazdeljeno spremenljivko napake (v modelu u_i) – (njena povprečna vrednost je enaka 0);
- Homoskedastičnost – predpostavka o normalni porazdelitvi spremenljivke napake (v modelu u_i) – (ta spremenljivka ima enako varianco pri vseh neodvisnih spremenljivkah);
- Obstoj nizke korelacije med neodvisnimi spremenljivkami.

V povezavi z modeliranjem bonitetnih sistemov se velikokrat uporablja tudi t. i. model linearne verjetnosti, (angl. *linear probability modeling*) na podlagi katerega ocenjujemo verjetnost, da bo posameznik poravnal svoje obveznosti v rokih. Model linearne verjetnosti je zelo podoben, vendar namesto absolutnih števil uporablja odstotke (Anderson, 2007).

Model linearne verjetnosti je sestavljen po enačbi (2) za i -to podjetje.

$$P(bad)_i = \beta_0 + \beta_1 X_{1,i} + \beta_2 X_{2,i} + \beta_3 X_{3,i} + \dots + \beta_m X_{m,i} + u_i \quad (2)$$

Kjer je:

- $X_{j,i}$ j -ti finančni kazalnik i -tega podjetja kot neodvisna spremenljivka;
- β_j ocenjena utež j -tega kazalnika glede na zgodovinske podatke;
- u_i napaka v regresijskem modelu.

Če uteži pomnožimo z opazovanimi $X_{j,i}$ za določeno stranko in dobljene zneske seštevamo, lahko dobimo verjetnost $P(bad)_i$. To vrednost si lahko razlagamo tudi kot verjetnost neplačila i -tega podjetja. Spremenljivka u_i predstavlja motnjo v regresijskem modelu in tako

ovira stabilno razmerje med odvisno in neodvisnimi spremenljivkami. Obstaja več razlogov za motnjo, pri čemer je najpreprostejša razlaga, da nikoli ne moremo z neodvisnimi spremenljivkami 100 % vplivati na odvisno spremenljivko. Zaradi tega običajno te napake ne upoštevamo pri uporabi regresijske enačbe (Greene, 2002).

Za uporabo tega modela (2) je potrebno definirati, da je odvisna spremenljivka binarna, torej da ima vrednosti le 0 in 1. S takšnim preoblikovanjem podatkov nastopijo nekatere druge težave, ki kršijo zgoraj opisane predpostavke veljavnosti modela. Najbolj problematični sta predpostavki o normalno porazdeljeni spremenljivki u_i in homoskedastičnost, saj ima odvisna spremenljivka lahko le dve možni vrednosti.

2.3 Logistična regresija (logit model)

Logistični regresijski model, podobno kot linearni model, izračuna pričakovano verjetnost neplačila. Je eden izmed najbolj priljubljenih statističnih orodij za razvrščanje problemov, saj se za razliko od drugih (diskriminanten model, linearna regresija ...) lahko uporablja tudi v primerih, ko porazdelitev neodvisnih spremenljivk ni normalna (Ong, Huang, & Tzeng, 2005).

Podobno kot linearna regresija, tudi logistična regresija pri modeliranju uporablja pristop odvisnosti med odvisno spremenljivko Y in eno ali več pojasnjevalnih (neodvisnih) spremenljivk X_j . Povezava med odvisno in neodvisnimi spremenljivkami pa je zmodelirana s pomočjo logistične funkcije (Hilbe, 2009).

Ta način izračuna po linearni regresiji je dokaj enostaven, dokler so dostopni trenutni podatki za neodvisne spremenljivke X_{ij} , šibka točka pa so izračunane vrednosti odvisne spremenljivke, ki padejo izven intervala od 0 do 1. Logistični model reši prav to težavo tako, da zalogo vrednosti linearne regresije omeji le na območje med 0 in 1. Želene vrednosti dobimo z logistično funkcijo (3) (Menard, 2010):

$$F(t) = \frac{e^t}{e^t + 1} = \frac{1}{1 + e^{-t}} \quad (3)$$

Predpostavimo, da je t linearna funkcija s samo eno neodvisno spremenljivko X . V primeru, da ima funkcija t več neodvisnih spremenljivk, jo podobno upoštevamo. Sedaj lahko izrazimo funkcijo t kot:

$$t = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \dots + \beta_m X_m \quad (4)$$

In logistično funkcijo (3) lahko izpišemo tudi kot:

$$P(bad)_i = F(X_1, X_2, \dots, X_m) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_m X_m)}} \quad (5)$$

Kjer je:

- $F(X_1, X_2, \dots, X_m)$ logistično transformirana funkcija odvisnih spremenljivk $X_1, X_2, \dots, X_m$ in se jo interpretira kot verjetnost, da se opazovan dogodek (neplačilo) zgodi;
- e konstanta 2.718 in predstavlja eksponentno funkcijo.

Ta model spada v skupino posplošenih linearnih modelov (angl. *generalized linear regression*), kjer se direktno ne modelira ciljne spremenljivke, ampak njeno funkcijo. Ekvivalentno zgornjemu zapisu lahko logit model izrazimo kot:

$$\text{logit}(p_i) = \ln\left(\frac{p_i}{1-p_i}\right) = \beta_0 + \beta_1 x_{1,i} + \dots + \beta_m x_{m,i} = \beta * x_i \quad (6)$$

Zgoraj opisan model ima določene predpostavke, na katere se navezuje tudi notacija (Rodriguez, 2007):

- p_i je verjetnost neplačila stranke;
- n je število opazovanih podjetij;
- Vsako podjetje i opisuje m pojasnjevalnih spremenljivk $x_{1,i}, \dots, x_{m,i}$;
- Vsako podjetje i mora imeti podatek o izhodni spremenljivki Y_i , ki je binarna, torej ima le vrednosti 0 (plačilo) in 1 (neplačilo);
- Odvisna spremenljivka Y_i je porazdeljena po Bernoulliju s spodnjimi lastnostmi:

$$Y_i | x_{1,i}, \dots, x_{m,i} \sim \text{Bernoulli}(p_i) \quad (7)$$


$$E[Y_i | x_{1,i}, \dots, x_{m,i}] = p_i \quad (8)$$

$$P[Y_i = y_i | x_{1,i}, \dots, x_{m,i}] = \begin{cases} p_i & \text{če } y_i = 1 \\ 1 - p_i & \text{če } y_i = 0 \end{cases} \quad (9)$$

$$P[Y_i = y_i | x_{1,i}, \dots, x_{m,i}] = p_i^{y_i} (1 - p_i)^{(1-y_i)} \quad (10)$$

- za $p_i \geq 0.5$ (oz. ko $\beta_0 + \beta_1 x_{1,i} + \dots + \beta_m x_{m,i} \geq 0$) napoveduje $Y_i = 1$ in $p_i < 0.5$ oz. $\beta_0 + \beta_1 x_{1,i} + \dots + \beta_m x_{m,i} < 0$ napoveduje $Y_i = 0$.
- Primeri v vzorcu morajo biti med sabo neodvisni (tako podjetja kot neodvisne spremenljivke med sabo).

Slika 2: Standardizirana logistična funkcija z zalogo vrednosti med (0,1).



Ocena parametrov

Regresijske koeficiente se običajno oceni s pomočjo funkcije največjega verjetja (angl. *maximum likelihood function*). Za razliko od linearne regresije, ki ima napake normalno porazdeljene, pri logit modelu ni mogoče najti dokončnega izraza za koeficiente, ki bi maksimiziral funkcijo verjetja, zato je potrebno uporabiti iterativne metode (Newtonovo metodo, ki začne z neko približno rešitvijo, pogleda, če se jo da izboljšati in ponavlja postopek, dokler ne najde konvergenčne rešitve) (Menard, 2002).

Kot sem že omenila, ima odvisna spremenljivka Y_i Bernoullijevo porazdelitev z verjetnostmi (11) in (12).

$$P(y_i = 1) = \pi(x_i), \quad (11)$$

$$P(y_i = 0) = 1 - \pi(x_i) \quad (12)$$

Če so primeri med sabo neodvisni in enako porazdeljeni, lahko uporabimo funkcijo verjetja, ki je odvisna od vektorja $\beta = (\beta_0, \beta_1, \dots, \beta_m)$:

$$L(\beta) = \prod_{i=1}^N p_i^{y_i} * (1 - p_i)^{1-y_i} \quad (13)$$

Za lažjo obravnavo uporabimo logaritem od te funkcije:

$$l(\beta) = \ln(L(\beta)) = \sum_{i=1}^N [y_i * \ln(p_i) + (1 - y_i)\ln(1 - p_i)] \quad (14)$$

V naslednjem koraku je potrebno to funkcijo maksimizirati in poiskati najbolj optimalno rešitev. Poiskati moramo odvod te funkcije in ga enačiti z nič. Če je v vzorcu več neodvisnih spremenljivk, je potrebno parcialno odvajati glede na vsak $\beta_0, \beta_1, \dots, \beta_m$ (prvi odvod).

Iz tega dobimo sistem $m + 1$ enačb in jih rešimo. Dobimo najbolj optimalno rešitev $\hat{\beta}$, ki je vektor ocen koeficientov in posledično najboljšo oceno verjetnosti za p_i , kar označimo s $\hat{p}_i$ (Menard, 2002).

3 LOGIT MODEL

Odločila sem se, da sestavim model, ki bo uporaben za ugotavljanje kreditnega tveganja v podjetju, ki prodaja električno energijo. Za namen raziskave se bom osredotočila le na kreditna tveganja, ki jih imajo ta podjetja v direktnem odnosu do svojih strank (gospodinjstva, podjetja ...). V podjetju, ki prodaja električno energijo, je pomembno dobro ovrednotiti plačilno sposobnost kupcev, saj so marže zelo nizke in nabavna vrednost relativno visoka. V takih primerih lahko pride zaradi neplačil do večjih izgub v podjetju. Stranke takega podjetja so lahko vse možne entitete, saj je električna energija dobrina, ki jo vsaka zgradba potrebuje (Prapotnik Sabol, 2009). Za namen raziskave sem se odločila, da bom uporabila le večje stranke, saj je pri manjših (gospodinjstva, fizične osebe ...) težje priti do oprijemljivih finančnih informacij, ki bi jih lahko uporabila v svojem modelu.

Za svoj portfelj bom uporabila točkovni model z logistično regresijo, ki ima po mnenju Lorette Mester (1997, str. 8) veliko pozitivnih in praktičnih lastnosti, zaradi katerih se njihova uporaba povečuje:

- Hitrejši: model kreditnega točkovanja se lahko uporabi v avtomatskem sistemu, kar omogoča, da je vsaka stranka lahko obravnavana in točkovana zelo hitro;
- Cenejši: ker model varčuje s časom, lahko rečemo, da varčuje tudi z denarjem podjetja in strank. Potrebno je le pridobiti informacije o strankah, ki se jih uporablja v modelu, tako so obravnave strank lahko krajše in zato tudi cenejše;
- Objektivnejši: objektivnost modela pomaga posojilodajalcem, da pri odločanju o njihovi kreditni sposobnosti obravnavajo svoje stranke pod enakimi pogoji, ne glede na raso, spol, in druge faktorje.

Seveda ima ta model tudi določene omejitve, ki se jih je treba zavedati. Po besedah Lorette Mester (1997, str. 10) so to naslednje:

- Vprašljiva pravilnost rezultatov za skupine, ki so manjšinsko zastopane v modelu;
- Model vrne rezultate na podlagi njegovih vhodnih podatkov, ki morajo vključevati bogat nabor dobrih in slabih strank. Podatki morajo biti osveženi in pogosto ponovno ocenjeni, da zagotovo ujamejo pravo odvisnost med faktorji in rezultatom;
- V vzorec je potrebno vključiti ne le stranke, s katerimi so bile podpisane pogodbe, ampak tudi tiste, ki so bile zavrnjene že na podlagi slabih finančnih rezultatov. Brez te predpostavke se lahko napačno ocenijo uteži modela;
- Noben točkovni model ni sposoben točno napovedati (ne)plačil strank, je pa pomembno, da uspe vsaj v povprečju pravilno napovedati dobiček iz danih posojil.

Model kreditnega točkovanja je eden izmed najširše uporabljenih analitskih orodij za kreditna tveganja. Njegov namen je sortirati podjetja glede na njihovo kreditno sposobnost. Kreditno točkovanje uspe različne karakteristike podjetja (dejavnost, starost, ceno delnic ...) ali posameznika (leta, čas zaposlitve, čas trenutnega naslova ...) predstaviti kot točke. Skupno število točk predstavlja kreditno oceno podjetja, ki se pokaže kot kreditna sposobnost posameznika – običajno visoka ocena pomeni nizko kreditno tveganje, ter obratno (Kralj, 2011).

V svojem modelu se bom posluževala izrazov »dober« in »slab«, kjer se njun pomen nanaša na dobro in slabo finančno stanje podjetja. Slabo finančno stanje podjetja pomeni, da ima leto pomanjkanje sredstev za vzdrževanje svojih stroškov in dolgov, blokade finančnih računov, likvidnostne in solventne težave ali da je podjetje v stečaju. Dobro finančno stanje podjetja pa pomeni, da podjetje uspe pravočasno poravnati vse svoje obveznosti.

3.1 Zbiranje in priprava podatkov

V prvi fazi je potrebno zbrati vse podatke o strankah v vzorcu in jih preoblikovati v uporabno obliko za naprej. Posebno je potrebno paziti na manjkajoče podatke in ekstremne vrednosti. Podatke je potrebno razporediti v tabelo, kjer vrstice predstavljajo podjetja, stolpci pa spremenljivke. V naslednjem koraku je potrebno vzorec podatkov ločiti na dva dela, na učni vzorec (angl. *training data*) in testni vzorec (angl. *validation data*), v razmerju 80 % :20 %. Pred začetkom modeliranja je potrebno ta dva vzorca ločiti, za modeliranje uporabiti le učni vzorec, testni vzorec pa šele na koncu pri validaciji (Refaat, 2006).

3.2 Modeliranje

V fazi modeliranja je zaradi lažjega razlikovanja med uspešnimi in neuspešnimi podjetji potrebno vrednosti vsake spremenljivke razdeliti v razrede (angl. *binning*). Te skupine podatkov je nato priporočljivo transformirati z WOE (angl. *Weight of Evidence*) pristopom, ki ga bom opisala v nadaljevanju. Za pomoč pri izboru spremenljivk, pa se še dobro izkažejo izračuni drugih statističnih podatkov, kot so informacijska vrednost (angl. *information value*), multikolinearnost (angl. *multicollinearity*) in koreliranost (angl. *correlation*) (Anderson, 2007).

3.2.1 Transformacije vhodnih podatkov

Transformacija vhodnih spremenljivk služi optimizaciji njene vrednosti in uporabnosti. Spremenljivke je običajno potrebno transformirati, saj se v podatkih lahko pojavijo ekstremne vrednosti, ki ne prispevajo dodatne informacije, ali pa se v podatkih pojavlja šum, kar znižuje napovedno moč modela.

3.2.1.1 WOE transformacija

S to transformacijo ne uvajamo novih spremenljivk vendar le obstoječe vrednosti transformiramo v nove, tako da še vedno ohranimo informacijsko vrednost spremenljivke. Ta transformacija je tudi dovolj robustna za manjkajoče in ekstremne vrednosti. V vsakem primeru pa je potrebno vrednosti spremenljivke razdeliti v določene razrede. Iz tega se potem lahko izračuna vrednost napovedne moči WOE (angl. *weight of evidence*, v nadaljevanju WOE) vsakega razreda posebej. WOE nam pove, v kolikšni meri se določena karakteristika razlikuje med dobrimi in slabimi primeri. Za vsak i -ti razred vsake spremenljivke izračunamo (Refaat, 2011):

$$WOE_i = \ln \left(\frac{g_i \%}{b_i \%} \right) = \ln \left(\frac{g_i / G}{b_i / B} \right) = \ln \left(\frac{g_i}{G} \right) - \ln \left(\frac{b_i}{B} \right) \quad (15)$$

Kjer je:

- g_i število dobrih ($y = 0$) v i -tem razredu;
- $g_i \%$ delež dobrih v i -tem razredu glede na skupno število dobrih primerov:

$$\frac{g_i}{G} * 100 \% \quad (16)$$

- b_i število slabih ($y = 1$) v i -tem razredu;
- $b_i \%$ delež slabih v i -tem razredu glede na skupno število slabih primerov:

$$\frac{b_i}{B} * 100 \% \quad (17)$$

- G število vseh dobrih primerov;
- B število vseh slabih primerov.

Pomen vrednosti WOE:

- $WOE > 0$: Razred, v katerem je razmerje dobri/slabi > 1 ;
- $WOE < 0$: Razred, v katerem je razmerje dobri/slabi < 1 .

3.2.2 Grupiranje podatkov (angl. *binning*)

Zaradi lažjega razlikovanja med uspešnimi in neuspešnimi podjetji je potrebno vrednosti vsake spremenljivke porazdeliti v določene razrede. Obstaja več različnih algoritmov, ki razvrščajo vrednosti, dva preprostejša sta (Anderson, 2007):

- Grupiranje glede na število primerov v razredu: algoritem loči podatke v določeno število razredov, tako da je v vsakem razredu približno enako število primerov;

- Grupiranje glede na meje razreda: algoritem loči podatke v določeno število razredov glede na območje, na katerem obstajajo vrednosti, tako da so meje razredov enakomerno postavljene.

3.2.2.1 Monoton algoritem grupiranja

Algoritem, ki je nekoliko bolj zapleten, a hkrati praktično bolj uporaben, je algoritem, ki išče monoton trend spremenljivke WOE. Poznan je tudi kot MLMCC algoritem (angl. *Maximum Likelihood Monotone Coarse Classifier*). Ta algoritem poskuša čim bolj optimalno določiti meje razredov tako, da ima vrednost WOE vsakega razreda monoton naraščajoč ali padajoč trend. Algoritem predpostavlja, da so združene lahko le sosednje vrednosti (Thomas, Crook, & Edelman, 2002).

V začetni fazi podamo željeno začetno število razredov in algoritem nepolne razrede z enakim številom primerov. Nato za vsak razred izračuna vrednost WOE. Cilj algoritma je, da poišče monoton trend vrednosti WOE. Pri naraščajočem trendu WOE mora imeti prvi razred najnižjo vrednost – če jo ima, je prva meja določena. Algoritem deluje v iteracijah. Če je potrebno, lahko tudi razrede združuje ali ločuje (Thomas et al., 2002).

3.2.3 Izbira kazalnikov

Ko je faza grupiranja vrednosti spremenljivk zaključena, lahko začnemo s fazo izbiranja kazalnikov. Iz množice kazalnikov je potrebno izbrati spremenljivke, ki najbolj napovedujejo neplačilo. Spremenljivke morajo smiselno vplivati na neplačila, imeti morajo dobro napovedno moč (morajo dobro razlikovati med plačili in neplačili) in dovolj smiselnih vrednosti.

Iz statističnega vidika je potrebno preveriti, če imajo neodvisne spremenljivke visoko korelacijo med sabo. Multikolinearnost slabo vpliva na stabilnost modela in ne doprinese dodatne informacije za napoved neplačila. Kako dobro vplivajo pojasnjevalne spremenljivke na odvisno, nam pove korelacijska matrika. Dober pokazatelj je tudi informacijska vrednost, saj pove, koliko informacije nosi pojasnjevalna spremenljivka za odvisno (Anderson, 2007).

3.2.3.1 Multikolinearnost

Podobno kot korelacija, je multikolinearnost statističen pojav, kjer sta dve ali več neodvisnih spremenljivk v regresijskem modelu tako zelo povezani, da je mogoče eno spremenljivko linearno napovedati s pomočjo drugih. V tem primeru nam prilagajajoči model napove nezanesljive koeficiente, ki imajo veliko varianco, kar vpliva na nestabilnost modela (Anderson, 2007).

Multikolinearnost je mogoče preveriti na več načinov. V programskem orodju Matlab je vgrajena funkcija »collintest«, ki testira multikolinearnost neodvisnih spremenljivk s

pomočjo analitičnega pristopa po Belsleyu (Belsley, Kuh, & Welsch, 1980). Ta pristop je opisan za linearno regresijo, vendar se uporablja tudi pri posplošenih linearnih modelih.

Nestabilnost ocenjenih koeficientov je mogoče opaziti pri majhnih lastnih vrednostih produkta matrik $X^T X$, ki se pojavi v sistemu enačb:

$$\hat{\beta} = (X^T X)^{-1} X^T y \quad (18)$$

Belsley preoblikuje sistem lastnih vrednosti $X^T X$ v singularne vrednosti matrike X , ki jo lahko z večjo numerično točnostjo direktno analizira. Če so singularne vrednosti X označene z $\mu_1, \mu_2, \dots, \mu_n$, kjer je n število spremenljivk, je torej pogojno število N (angl. *Condition number*) matrike X :

$$N = \frac{\mu_{max}}{\mu_{min}} \quad (19)$$

Belsley (Belsley et al., 1980) definira spekter indeks pogojenosti (angl. *Condition Index*, v nadaljevanju CI) kot:

$$\eta_j = \frac{\mu_{max}}{\mu_j} \quad (20)$$

za vsak $j=1, \dots, n$ in pokaže, da visoki indeksi nakazujejo na posamezne bližnje odvisnosti med podatki.

Belsley (Belsley et al., 1980) v nadaljevanju razvije še metodo, ki točno poišče spremenljivke, vpletene v medsebojno odvisnost, ter sestavi mero, ki pove, koliko te odvisnosti vplivajo na ocenjene koeficiente. Če ima X razkroj singularnih vrednosti USV^T , kjer je $V = (v_{ij})$, potem velja:

$$Var(\hat{\beta}_i) = \sigma^2 \sum_{j=1}^n \frac{v_{ij}^2}{\mu_j^2} \quad (21)$$

kjer je σ^2 varianca.

Delež razkroja variance (angl. *variance decomposition proportion*, v nadaljevanju VarDP) π_{ji} je definiran kot:

$$\pi_{ji} = \frac{\phi_{ij}}{\phi_i} \quad (22)$$

$$\phi_{ij} = \frac{v_{ij}^2}{\mu_j^2} \quad (23)$$

$$\phi_i = \sum_{j=1}^n \phi_{ij} \quad (24)$$

Enačba (22) pove delež $Var(\hat{\beta}_i)$, ki je povezan s singularno vrednostjo μ_j .

Za razumevanje zgornjih enačb je potrebno nekoliko več algebrskega znanja, vendar so te formule interpretirane kot spodnje trditve:

- Število visokih pogojnih indeksov razkrije število odvisnosti med spremenljivkami;
- Velikost pogojnega indeksa pove, kako močna je vsaka odvisnost med spremenljivkami;
- Visoka vrednost deleža variance v vrstici visokega pogojnega indeksa nakazuje na korelacijo spremenljivke;
- Vrednost deleža variance pa pove stopnjo poslabšanja ocene koeficientov zaradi multikolinearnosti.

Belslyjeve (Belsley et al., 1980) raziskave pravijo, da je potrebno določiti meje tolerance, ki so v praksi zelo dobrodošle:

- $5 < CI < 10$: šibka kolinearnost;
- $10 < CI < 30$: šibka do zmerna kolinearnost;
- $30 < CI < 100$: zmerna do močna kolinearnost;
- $CI > 100$: zelo močna kolinearnost;
- Kjer je VarDP večji od 0.5, je potrebno preveriti spremenljivke.

Če je zaznana multikolinearnost med spremenljivkami, je priporočljivo odstraniti spremenljivko, ki kaže najvišjo odvisnost, ter ponovno preveriti vrednosti CI in VarDP.

3.2.3.2 Informacijska vrednost

Informacijska vrednost pojasnjevalne spremenljivke je po mnenju Siddiqi (2006, str. 81–82) najpomembnejše merilo za količino informacije o neplačilih, ki jo nosi ta spremenljivka, torej je informacijska vrednost spremenljivke njena celotna moč lastnosti, ki jo vsebuje. Izračuna se za vsak razred spremenljivke posebej in se na koncu sešteje v celoto. Informacijska vrednost je predvsem odvisna od WOE, deleža dobrih in slabih podjetij v vzorcu. Izračuna se po naslednji formuli:

$$IV_i = \left(\frac{g_i}{G} - \frac{b_i}{B} \right) * WOE_i \quad (25)$$

$$IV = \sum_{i=1}^k IV_i \quad (26)$$

Kjer je:

- IV_i informacijska vrednost i-tega razreda;
- IV pa informacijska moč celotne spremenljivke.

Vrednosti IV imajo naslednje napovedovalne moči:

- $IV < 0.02$: zelo šibka (neuporabna);
- $0.02 \leq IV < 0.1$: šibka;
- $0.1 \leq IV < 0.3$: srednja;
- $0.3 \leq IV < 0.5$: močna;
- $IV > 0.5$: zelo močna (predobra).

Za izbor spremenljivk je priporočljivo, da le-ta nosi čim večjo količino informacij. Zgornje vrednosti niso obvezujoče. Analitik se lahko sam odloči, katere spremenljivke bo vključil v model (Siddiqi, 2006).

3.2.4 Sestavljanje modela in računanje koeficientov

Na točki, ko so izbrane vse napovedne spremenljivke, lahko začnemo sestavljati model. Z izbranimi spremenljivkami je potrebno s pomočjo logistične regresije izračunati vrednosti koeficientov vsake neodvisne spremenljivke. Za ta namen sem uporabila vgrajeno funkcijo programskega orodja Matlab z ukazom »fitmodel«. Ta funkcija izračuna vrednosti koeficientov spremenljivk $\beta = (\beta_0, \beta_1, \dots, \beta_m)$, njihove standardne napake in statistično značilnost vsake spremenljivke posebej, ter celotnega modela, saj je potrebno dobljene vrednosti še preveriti (Refaat, 2011).

3.2.4.1 Statistična značilnost spremenljivk

Funkcija operira z WOE transformiranimi vrednostmi spremenljivke. Zaiontz (2013) v svojih nasvetih za uporabo statistike pravi, da se pri testiranju koeficientov uporabi Waldovo statistiko, ki je podana s formulo: $Wald = \frac{\beta}{SE(\beta)}$, kjer je $SE(\beta)$ standardna napaka koeficienta i-te spremenljivke.

Waldova statistika je normalno porazdeljena, zato se lahko uporablja za testiranje koeficientov v logistični regresiji. Za vsako spremenljivko j se izvede test statistične značilnosti naslednje hipoteze:

- $H_0: \beta_j = 0$;
- $H_A: \beta_j \neq 0$;

- Če obstaja zadosten dokaz za zavrnitev ničelne hipoteze, se te spremenljivke ne odstrani iz modela.

Za vsak koeficient se izračuna testno statistiko in P-vrednost s 5 % stopnjo značilnosti. Spremenljivke, ki imajo P-vrednost višjo od 0.05, statistično niso primerne za vključitev v model (Zaiontz, 2013).

3.2.4.2 Statistična značilnost modela

Pri preverjanju statistične značilnosti celotnega modela se uporabi Chi-kvadrat test najboljšega prilaganja (angl. *Chi-squared Goodness-of-fit test*). Test preverja, kako se logistični regresiji prilagajajo vrednosti, ki jih vrne kreiran model. Testira se:

- H_0 : napovedani model je enak konstantnemu modelu;
- H_A : napovedani model je različen od konstantnega modela.

Testna statistika Chi-kvadrat je definirana z:

$$X^2 = \frac{\sum_{i=1}^n (o_i - e_i)^2}{e_i} \quad (27)$$

kjer so o_i opazovane vrednosti, e_i pa ocenjene (izračunane) vrednosti. Če je vrednost statistike X^2 večja od kritične vrednosti pri 5 % stopnji značilnosti, potem lahko zavrnemo ničelno hipotezo.

Vrednosti izračunanih koeficientov je potrebno tudi ročno preveriti, da je vpliv neodvisnih spremenljivk na neplačil smiseln (Anderson, 2007).

3.2.5 Točke in verjetnost neplačila

Za izračun kreditne ocene strank potrebujemo ocenjene koeficiente β_j za vsako v modelu uporabljeno spremenljivko j . Izračunane vrednosti vstavimo v logistično formulo, ki smo jo že prej opisali in tako dobimo verjetnosti neplačila vsakega podjetja posebej:

$$PD = \frac{1}{1 + e^{-(\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_m X_m)}} \quad (28)$$

Kjer je:

- PD verjetnost neplačila;
- $\beta_0, \beta_1, \beta_2, \dots, \beta_m$ koeficienti neodvisnih spremenljivk;
- $X_1, X_2, \dots, X_m$ vrednosti neodvisnih spremenljivk.

Za lažjo predstavbo, kolikšno kreditno oceno je podjetje doseglo, pa se uporablja še izračun točk vsakega podjetja posebej z naslednjo formulo (Anderson, 2007):

$$\begin{aligned} \text{Skalirane točke} &= \\ &= \text{Premik} + \text{Naklon} * (\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_m X_m) \end{aligned} \quad (29)$$

Kjer sta:

- *Premik* in *Naklon* konstanti, ki se uporabljata za skaliranje;

Če se uporabi *Premik* enak 0 in *Naklon* enak 1, dobimo spodnjo enačbo:

$$\text{Točke} = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_m X_m \quad (30)$$

Točke predstavljajo verjetnost neplačila linearne regresije in ga lahko direktno uporabimo v formuli za izračun verjetnosti neplačila logit modela. Torej velja zveza:

$$PD = \frac{1}{1 + e^{-\text{Točke}}} \quad (31)$$

Moj model uporablja transformirane spremenljivke WOE, zato za izračun točk in verjetnosti neplačila posameznika *i* velja spodnja zveza (Anderson, 2007):

$$\text{Točke}(i) = \beta_0 + \beta_1 \text{WOE}_1(i) + \beta_2 \text{WOE}_2(i) + \dots + \beta_m \text{WOE}_m(i) \quad (32)$$

$$PD(i) = \frac{1}{1 + e^{-\text{Točke}(i)}} \quad (33)$$

Kjer so:

- $\text{WOE}_m(i)$ je WOE vrednost spremenljivke *m* za posameznika *i* (pogleda se vrednost spremenljivke *m* za posameznika *i* in se vzame pripadajočo WOE vrednost razreda te spremenljivke, v katerega ta vrednost pade).

3.2.5.1 Uteži spremenljivk v modelu


Iz izračunanih točk lahko tudi preverimo, kolikšno utež ima vsaka spremenljivka oziroma kolikšen doprinos točk ima vsaka spremenljivka za vsakega posameznika ali v povprečju. Uteži spremenljivk so definirane kot razpon točk, ki jih ima vsaka spremenljivka, deljeno s skupnim razponom točk vseh spremenljivk. Ta način izračuna uteži je zelo dober, saj pri izračunu točk upošteva vrednosti koeficientov ter vrednosti WOE (Refaat, 2011).

3.2.5.2 Meja med »dobrim« in »slabim«

Na koncu, ko je že vse izračunano, nam preostane še izbira meje med dobrimi in slabimi podjetji. Lahko določimo mejo med plačili in neplačili na podlagi vrednosti verjetnosti neplačila. Običajno je ta meja 0.5 – nižja vrednost predstavlja uspešna podjetja, višja pa neuspešna.

Lahko pa se določi mejo na podlagi točk. Glede na dosežene točke je možno zelo hitro razbrati uspešnost podjetja. Za lažjo predstavbo si lahko tudi omejimo točke na določene vrednosti, na primer od 0 do 100, kjer so najslabša podjetja dosegla 0 točk, najboljša pa 100.

Slika 3: Graf verjetnosti plačila v odvisnosti od točk



Pri teh odločitvah je potrebno imeti v mislih, da lahko pride do dveh vrst napak:

- Da je slabo posojilo označeno za dobrega;
- Da je dobro posojilo označeno za slabega.

Od politike kreditorja je odvisno, kaj je bolj pomembno, čim manj slabih kreditov ali čim več dobljenih poslov. Pri tem je potrebno več pozornosti posvetiti validaciji modela, saj analizira dobljene rezultate in pomaga pri odločanju, če ti rezultati dovolj dobro opisujejo podatke. Za preverjanje kvalitete zgrajenega modela obstaja več načinov, uporabila sem le najpogostejše: CAP, ROC krivuljo, Kolmogorov-Smirnov graf in matriko napake modela (Anderson, 2007).

3.2.6 Validacija

3.2.6.1 Korelacija med spremenljivkami

Korelacija je statistična mera, ki predstavlja moč povezanosti med dvema spremenljivkama. Kot je zapisano v knjigi Ann Lehman (2005), jo lahko merimo z različnimi koeficienti, vendar je za naš model in tip podatkov najbolj primeren Spearmanov koeficient korelacije, saj meri neparametrično stopnjo povezanosti dveh spremenljivk, kjer ni strogih pogojev za uporabo (linearna povezanost, enakomerna porazdeljenost in zveznost spremenljivk) (Lehman, 2005).

Podatke je potrebno pred izračunom razporediti v razrede, nato pa se uporabi razlika vrednosti med dvema razredoma spremenljivk, za katere se računa korelacijski koeficient. Enačba Spearmanovega koeficienta je naslednja:

$$\rho = 1 - \frac{6 \sum d_i^2}{N(N^2 - 1)} \quad (34)$$

Kjer je:

- d_i razlika med dvema razredoma dveh obravnavanih spremenljivk za i -ti primer;
- N število vseh primerov.

Vrednosti korelacijskega koeficienta pomenijo:

- 0.00–0.09 – ni povezanosti;
- 0.10–0.19 – neznatna povezanost;
- 0.20–0.39 – nizka/šibka povezanost
- 0.40–0.69 – srednja/zmerna povezanost
- 0.70–0.89 – visoka/močna povezanost
- 0.90–0.99 – zelo visoka/zelo močna povezanost
- 1.00 – popolna (funkcijska) povezanost.

V našem primeru iščemo povezanost med neodvisnimi spremenljivkami (kazalniki) in odvisno spremenljivko (neplačilom). Testiramo s Studentovo t -porazdelitvijo testne statistike ($t = \frac{r\sqrt{n-2}}{1-r^2}$) z $n-2$ prostorskimi stopnjami. Če test pokaže, da določen kazalnik nima vpliva na stopnjo neplačila, torej da je koeficient korelacije nizek, je neuporaben za nadaljnjo obravnavo (Lehman, 2005).

3.2.6.2 Matrika napake modela (angl. *Misclassification matrix*)

Za pregled natančnosti modela je potrebno preveriti, koliko primerov smo klasificirali pravilno in koliko napačno. Anderson (2007) pravi, da za izračun matrike napačne klasifikacije potrebujemo mejno točko, ki na podlagi števila doseženih točk ločuje slabe kredite od dobrih. Krediti, ki so zbrali manjše število točk, kot je mejna točka, jih klasificiramo kot slabe, ostale pa kot dobre (Anderson, 2007).

Pravilno klasificirani so tisti, ki imajo vrednost vhodne odvisne spremenljivke enako kot napovedane. To so:

- Pravilen pozitiven (angl. *true positive*, v nadaljevanju TP; naša vrednost slabega = 1): primer je dejansko slab in je tudi napovedan kot slab;
- Pravilen negativen (angl. *true negative*, v nadaljevanju TN; naša vrednost dobrega = 0): primer je dejansko dober in je tudi napovedan kot dober.

Napačno klasificirani pa so vsi ostali:

- Napačen pozitiven (angl. *false positive*, v nadaljevanju FP) – napaka tipa I, kar predstavlja napačno klasificirane slabe, ki so po modelu napovedani kot dobri krediti ter
- napačen negativen (angl. *false negative*, v nadaljevanju FN) – napaka tipa II, kar predstavlja napačno klasifikacijo dobrih, ki so po modelu napovedani kot slabi.

Najbolj optimalno je mejno točko postaviti tja, kjer je naš dobiček maksimalen. Meje ne smemo postaviti previsoko, saj bo zavrnjenih preveč dobrih kreditov, niti ne prenizko, saj bi bilo sprejetih preveč slabih kreditov, ki bi nam prinesli izgube (Anderson, 2007).

Oceno modela pa merimo z več karakteristikami, glede na klasifikacijo kreditov:

$$TP \text{ delež} = \frac{TP}{FN + TP} = \frac{\text{pravilno določeni slabi krediti}}{\text{vsi slabi krediti}} = \text{Občutljivost} \quad (35)$$

$$TN \text{ delež} = \frac{TN}{TN + FP} = \frac{\text{pravilno določeni dobri krediti}}{\text{vsi dobri krediti}} = \text{Specifičnost} \quad (36)$$

$$FP \text{ delež} = \frac{FP}{TN + FP} = 1 - \text{Specifičnost} \quad (37)$$

$$FN \text{ delež} = \frac{FN}{FN + TP} = 1 - \text{Občutljivost} \quad (38)$$

$$\begin{aligned} \text{Pravilnost} &= \frac{\text{pravilno napovedani dobri in slabi krediti}}{\text{vsi krediti}} = \\ &= \frac{TN + TP}{TP + TN + FP + FN} \end{aligned} \quad (39)$$

Klasifikacijo kreditov pa predstavimo v matriki:

Slika 4: Matrika napake modela

		Resnična vrednost		
		Slab	Dober	
Napovedana vrednost	Napovedan slab	Pravilen slab (TP)	Napačen slab (FP) (napaka tipa I)	Napovedani slabi
	Napovedan dober	Napačen dober (FN) (napaka tipa II)	Pravilen dober (TN)	Napovedani dobri
		Resnično slabi	Resnično dobri	Vsi

3.2.6.3 CAP krivulja (angl. *Cumulative Accuracy Profile*)


CAP krivulja je znana tudi kot Gini krivulja. Točke na tej krivulji so sortirane od najbolj tveganih do najbolj varnih. Za določen delež vseh primerov višina te krivulje predstavlja občutljivost modela (angl. *sensitivity*) pri določeni oceni. Točka na krivulji pove, da ob zavrnitvi 43 % slabih, zavrnemo skupaj 29 % vseh primerov (Basel Committee on Banking Supervision, 2005).

Na grafu (Slika 5) sta prikazani še dve krivulji. Prva krivulja predstavlja idealen model (črta, ki ločuje belo in zeleno območje), kjer so vsa neplačila točkovana z najnižjimi točkami in tako dobro ločena od plačil. Druga krivulja pa je naključni model (diagonala), kjer so točke naključne in je tako delež neplačil ter plačil neodvisen od točk. Koeficient AR (angl. *accuracy ratio*) je definiran kot:

$$AR = \frac{\text{območje med CAP krivuljo in diagonalo}}{\text{območje med idealno CAP krivuljo in diagonalo}} \quad (40)$$

Torej, bolj kot je AR blizu 1, boljši je zgrajen model.


Slika 5: CAP krivulja



3.2.6.4 ROC krivulja (angl. *Receiver Operating Characteristic curve*)

Merjenje napovedne pravilnosti je po besedah B. Engelmann in drugih (Engelmann, Hayden, & Tasche, 2003) najbolj pogost pristop v bonitetni industriji in temelji na CAP krivulji (angl. *Cumulative Accuracy Profile*) ter njeni ključni oceni AR (angl. *Accuracy Ratio*) oziroma ROC krivulji (angl. *Receiver Operating Characteristic*) in njenem indeksu AUROC (angl. *Area under ROC*).

Slika 6: ROC krivulja



ROC je krivulja, ki prikazuje, kako uspe modelu razlikovati med plačili in neplačili. Prikazuje krivuljo občutljivosti (35) (angl. *Sensitivity*) v odvisnosti od FP deleža (37) (angl. *false positive rate*). Preračunavanje ROC krivulje ima podoben pomen kot preračunavanje konfuzijske matrike (angl. *confusion matrix*) za vsako oceno (Satchell & Xia, 2006).

Podobno kot za CAP, je tudi za ROC krivuljo definirana ploščina pod krivuljo kot AUROC, iz katere izračunamo koeficient AR, ki je definiran kot:

$$AR = 2(AUROC) - 1 \quad (41)$$

AR koeficient ima enak pomen kot zgoraj pri CAP krivulji – bliže kot je številu ena, boljši je točkovni model.


3.2.6.5 K-S graf (angl. *Kolmogorov-Smirnov graph*)

K-S graf je znan tudi kot ribje oko in je pogosto uporabljena statistika za merjenje napovedne moči modela. Prikazuje porazdelitev plačnikov in neplačnikov na istem grafu.

Porazdelitev neplačil prikazuje delež neplačil do določenega števila točk (35), prav tako tudi porazdelitev plačil prikazuje delež plačil do določenega števila točk (37).

Mero, ki jo pri tej krivulji iščemo, je KS vrednost in prikazuje maksimalno razliko med tema dvema porazdelitvama. Oceno, pri kateri je dosežena KS vrednost, pa lahko imenujemo točka preloma med slabimi in dobrimi krediti ter jo lahko uporabimo pri izbiranju kreditov (Basel Committee on Banking Supervision, 2005).

Slika 7: Kolmogorov-Smirnov graf



4 PRIMER MODELA NAPOVEDI NEPLAČILA STRANK

4.1 Analiza podatkov

V podjetju, ki prodaja električno energijo, je pomembno dobro ovrednotiti plačilno sposobnost kupcev, saj so marže zelo nizke in lahko v primeru neplačil pride do večjih izgub. Stranke takega podjetja lahko predstavljajo vse možne entitete, saj je električna energija dobrina, ki jo vsaka zgradba potrebuje. Za namen raziskave pa sem se odločila, da bom uporabila le večje stranke, saj je pri manjših (gospodinjstva, fizične osebe ...) težje priti do oprijemljivih finančnih informacij, ki bi jih lahko uporabila v svojem modelu.

Moj portfelj zajema le segment poslovnega odjema. Uporabila sem finančne podatke naključno izbranih podjetij iz različnega obdobja, od leta 2012 do 2015. Za potrebo sestavljanja modela sem na učni množici podatkov uporabila le podatke od leta 2012 do 2014 (6720 primerov), podatke iz leta 2015 (2120 primerov) pa sem pustila za testiranje zgrajenega modela. To se mi zdi zelo smiselno, saj se na ta način opravi tudi test obstojnosti modela v prihodnjih letih, in sicer pod drugačnimi ekonomskimi okoliščinami.

Model logistične regresije potrebuje za vhodne podatke eno ali več neodvisnih in eno odvisno spremenljivko. Za neodvisne spremenljivke sem izbrala finančne kazalnike in kazalnik dejavnosti vsakega podjetja ter makroekonomski kazalnik. Za odvisno spremenljivko pa sem uporabila podatke o (ne)plačilih strank.

4.1.1 Neodvisne spremenljivke

V model sem vključila finančne kazalnike, ki sem jih pridobila od podjetja Bisnode ter z njihove internetne strani »Bonitete.si«. Finančni kazalniki obsegajo različne segmente

poslovanja: investiranje, financiranje, plačilno sposobnost, obračanje, dneve vezave, donosnost in denarni tok. Kazalniki, ki so bili pri raziskavi uporabljeni, so prikazani v prilogi. Za vsak kazalnik so priložene izračunane osnovne statistične mere, kot so npr. srednja vrednost, standardni odklon, varianca ter izračunan delež manjkajočih podatkov in razpon vrednosti vsakega finančnega kazalnika.

Na vrednosti finančnih kazalnikov (predvsem na kazalnike gospodarnosti in donosnosti) lahko vplivajo tudi makroekonomski dejavniki, zato je potrebno vključiti tudi te. Uporabila sem rast bruto domačega proizvoda na prebivalca, ki ima po letih spodnje vrednosti:

Tabela 1: Makroekonomski kazalnik po letih

Makroekonomski kazalnik v letu	Rast BDP na prebivalca v %
2012	-2.7
2013	-1.1
2014	3
2015	2.9

4.1.2 Odvisna spremenljivka

Na drugi strani imamo podatke o neplačilih strank. Neplačilo (angl. *Default*) je definirano kot dogodek, ko stranka zamudi plačilo obveznosti v določenem obdobju. V svojem vzorcu imam stranke, ki kupujejo električno energijo. Običajni rok plačila na računu je 30 dni, po preteku roka plačila se pošlje prvi opomin, po preteku 60 dni od datuma valute pa drugi opomin. Ultimativni ukrep za neplačnike je predlog za odklop električne energije, ki se ga pošlje SODO-tu, če stranka zamuja več kot 90 dni od datuma valute. Električna energija je dobrina, ki je obvezna za delovanje in obstoj, zato sem predpostavila, da je pri večini strank prva prioriteta na seznamu plačil. Vsaki stranki se lahko zgodi, da pomotoma zamudi rok plačila in prejme prvi opomin, redkeje pa pride do odklopa elektrike. Odločila sem se za neko srednjo mejo in za toleranco zamude plačila obveznosti določila 60 dni od datuma valute, ob zamudi več kot 60 dni, pa obveznost označila za neplačilo. Stranki sem pripisala neplačilo obveznosti, če je vsaj enkrat v letu dni zamudila s plačilom. Stranke, ki jim je bil pripisan ta dogodek, imajo vrednost odvisne spremenljivke za določeno leto enako 1, ostale ki so bolj redno plačevale obveznosti pa 0.

Model se uporablja za napoved neplačila strank v prihodnjem letu, zato sem finančnim podatkom iz obdobja od 2012 do 2014 pripisala stanje plačil iz obdobja od 2013 do 2015. Za testni vzorec sem pustila finančne podatke iz leta 2015, s stanjem neplačil iz 2016. Kot se izkaže, je stanje neplačil po letih naslednje:

Tabela 2: Neplačila po letih

Neplačila po letih	Delež
2013	3.83 %
2014	2.86 %
2015	5.44 %
2016	8.21 %

Za dober napovedni model se priporoča imeti v vzorcu vsaj 20 % pozitivnih dogodkov. Glede na zgornjo tabelo jih je v mojem primeru dosti manj. Obstaja več različnih načinov, kako dopolniti vzorec, vendar se za njih nisem odločila in sem ostala pri originalnem vzorcu, saj le-ta še vedno odraža neko realno situacijo v podjetju, s katero se je potrebno spopasti.

4.2 Izbira kazalnikov

Potem ko sem imela zbrane že vse podatke, sem začela z izbiro vhodnih neodvisnih spremenljivk. Pri vključevanju kazalnikov (predvsem finančnih) sem upoštevala naslednje lastnosti:

- Zadostno število opazovanj (vrednosti);
- Nizko medsebojno kolinearnost;
- Visoko informacijsko vrednost;
- Vključenost različnih segmentov poslovanja;
- Smiselni vpliv na neplačilo.

4.2.1 Manjkajoči podatki

Analiza podatkov je pokazala, da imam med finančnimi kazalniki veliko manjkajočih podatkov. Odstranila sem tiste, ki so imeli več kot 20 % manjkajočih vrednosti, tako mi je od 34-ih ostalo le še 26 finančnih kazalnikov.

4.2.2 Multikolinearnost

V naslednjem koraku sem multikolinearnost kazalnikov pogledala s pomočjo »collintest« funkcije v programskem paketu Matlab. Ta funkcija mi vrne singularne vrednosti, pogojni indeks ter deleže razgradnje variance vsakega kazalnika. V spodnjo tabelo (Tabela 3) so vključeni le rezultati pri spremenljivkah, ki so pokazale medsebojno kolinearnost.

Prvi pokazatelj multikolinearnosti je indeks pogojenosti z vrednostjo nad 30 in vrednost deleža razgradnje variance nad 0.5. V tabelo so vključeni vsi kazalniki, ki zadoščajo tem pogojem in tako nakazujejo na prisotnost multikolinearnosti med spremenljivkami. V mojem primeru sem se odločila, da odstranim enega izmed kazalnikov, pri katerih je bil indeks pogojenosti višji od dovoljene vrednosti. Pri tem sem tudi upoštevala, da morajo biti

vse skupine kazalnikov še naprej zastopane v vzorcu. V tem koraku sem odstranila kazalnike, ki so izpisani s krepkim tiskom, tako mi je ostalo le še 22 finančnih kazalnikov.

Tabela 3: Tabela multikolinearnosti spremenljivk

Spremenljivke	Delež			
Delež dolgov v financiranju	0.00	0.00	1.00	0.00
Kratkoročni koeficient likvidnosti	0.96	0.03	0.00	0.00
Pospešeni koeficient likvidnosti	0.96	0.03	0.00	0.00
Koeficient obračanja sredstev	0.01	0.90	0.00	0.08
Koeficient obračanja sredstev na celotne prihodke	0.00	0.12	0.00	0.88
Proizvodnost sredstev	0.00	0.03	0.00	0.96
Delovni kapital	0.00	0.00	1.00	0.00
INDEKS POGOJENOSTI	67.56	83.94	125.07	179.21

4.2.3 Informacijska vrednost

Na tej točki sem dodala še makroekonomski kazalnik. Pri tem naboru spremenljivk sem se odločila, da preverim njihovo informacijsko vrednost, ki pove, kolikšen del informacije o plačilni sposobnosti nosi vsak finančni kazalnik (bolj podrobno opisano v poglavju 3.2.3.2). Dobljeni rezultati so prikazani v spodnji tabeli (Tabela 4) in so sortirani po velikosti informacijske vrednosti (zadnji stolpec).

Iz teh podatkov razberem, da se na splošno najboljše izkažejo kazalniki iz področja donosnosti, gospodarnosti in dohodkovnosti. Ti kazalniki so merilo prave produktivnosti sredstev podjetja in so zelo primerni za analize, ki raziskujejo področje (ne)uspeha podjetja, saj je obstoj podjetja v glavnem odvisen le od donosnosti sredstev.

Če bi želela, da je moj model sestavljen iz spremenljivk, ki nosijo največ informacij o neplačilih, bi vključila tiste, ki imajo informacijsko vrednost nad 0.3, kar pove, da spremenljivke nosijo že kar veliko informacijo glede neplačil. V tem primeru bi lahko prišlo do multikolinearnosti med spremenljivkami in do neželene nestabilnosti modela.

Ubrala sem drugi pristop in raje izbrala kazalnike, ki imajo v določeni skupini finančnega kazalnika najvišjo informacijsko vrednost in nimajo informacijske vrednosti pod 0.1, saj ta vrednost pove, da spremenljivka nosi premajhno količino informacij. Izbrane spremenljivke so v tabeli prikazane z odebeljenim tiskom.

Tabela 4: Informacijska vrednost spremenljivk

Vrsta kazalnika	Ime kazalnika	Informacijska vrednost
Kazalnik investiranja	Delež Osnovnih Sredstev V Sredstvih	0.15
	Delež Obratnih Sredstev V Sredstvih	0.01
Kazalnik financiranja	Delež Dolgov V Financiranju	0.64
Kazalnik plačilne sposobnosti	Servisiranje Dolga	0.48
	Pospešeni Koefficient Likvidnosti	0.34
	Kreditna Izpostavljenost	0.21
Kazalnik obračanja	Obračanje Kratkoročnih Poslovnih Terjatev	0.25
	Koefficient Obračanja Sredstev Na Celotne Prihodke	0.10
	Obračanje Obratnih Sredstev	0.07
	Koefficient Obračanja Osnovnih Sredstev	0.03
Kazalnik dni vezave	Dnevi Vezave Kratkoročnih Poslovnih Obveznosti	0.70
	Dnevi Vezave Kratkoročnih Poslovnih Terjatev	0.28
	Dnevi Vezave Zalog 1	0.09
Kazalnik donosnosti	Čista Donosnost Sredstev	0.57
	Poslovna Donosnost Sredstev	0.47
	Neto Prodajna Marža	0.47
	Celotna Dobičkovnost Prihodkov Iz Poslovanja	0.46
	Celotna Gospodarnost	0.45
	Dobičkovnost Prihodkov Iz Poslovanja	0.36
	Gospodarnost Poslovanja	0.33
Kazalnik denarnega toka	Čisti Kratkoročni Obratni Kapital	0.41
	Enostavni Denarni Tok	0.36
Makroekonomski kazalnik	BDP	0.08

4.3 Končni nabor kazalnikov

4.3.1 Definicije kazalnikov

Vključeni so spodaj opisani kazalniki, kjer so formule povzete s spletne strani »Bonitete.si« (Bisnode, d.o.o.), definicije pa iz magistrskega dela Bernarde Šenk (2004):

Kazalnik investiranja - Delež osnovnih sredstev v sredstvih:

Formula:

$$\frac{\text{Opredmetena osnovna sredstva}}{\text{Sredstva}} * 100 \quad (42)$$

Kazalniki investiranja omogočajo presojo ugodnosti sestave sredstev gospodarske družbe za odločanje o investicijah. Vrednost kazalnika je odvisna od dejavnosti, ki jo gospodarska družba opravlja. V predelovalnih industrijah je vrednost tega kazalnika večja kot v delovno intenzivnih panogah (trgovine, storitve itd.), saj imajo ta podjetja več neopredmetenih osnovnih sredstev (dolgoročno odloženi stroški razvijanja itd.). Zmanjševanje vrednosti kazalnika lahko pomeni, da gospodarska družba hitro raste in da so se povečala gibljiva sredstva, ali da je zmanjšano investiranje osnovnih sredstev.

Kazalnik financiranja - Delež dolgov v financiranju:

Formula:

$$\frac{\text{Finančne in poslovne obveznosti}}{\text{Obveznosti do virov sredstev}} * 100 \quad (43)$$

Kazalniki financiranja omogočajo presojo ugodnosti sestave obveznosti do virov sredstev. Financiranje sredstev z dolгови vpliva na finančno tveganje ter donosnost gospodarske družbe, saj bolj kot se zadolžuje, bolj je finančno tvegana za upnike. Večanje vrednosti deleža dolgov v financiranju pomeni, da se obveznosti povečujejo, ali da se celotne obveznosti do virov sredstev (tudi kapital in rezervacije) zmanjšujejo.

Kazalnik plačilne sposobnosti – Servisiranje dolga:

Formula:

$$\frac{\text{Čisti poslovni izid obračunskega obdobja} + \text{Odpisi vrednosti z amortizacijo}}{\text{Celotni odhodki}} \quad (44)$$

Kazalniki plačilne sposobnosti so zanimivi za posojilodajalce, saj si želijo čim bolj plačilno sposobnih podjetij. Vrednost kazalnika ne sme biti nižja od določene kritične vrednosti.

Kazalnik obračanja - Obračanje kratkoročnih poslovnih terjatev:

Formula:

$$\frac{\text{Čisti prihodki od prodaje} + \text{Drugi poslovni prihodki}}{\left(\frac{\text{Kratkoročne poslovne terjatve} + \text{Kratkoročne poslovne terjatve iz prejšnjega leta}}{2} \right)} \quad (45)$$

Kazalniki obračanja sredstev izražajo, koliko prihodkov gospodarska družba ustvari glede na obstoječa sredstva. Obračanje kratkoročnih poslovnih terjatev pove, kolikokrat letno se terjatve iz poslovanja obrnejo v denarna sredstva. Večja vrednost tega kazalnika pomeni hitrejšo obračanje terjatev iz poslovanja v denarna sredstva.

Kazalniki dnevi vezave - Dnevi vezave kratkoročnih poslovnih obveznosti:

Formula:

$$\frac{(\text{Kratkoročne poslovne obveznosti} + \text{Kratkoročne poslovne obveznosti iz prejšnjega leta})}{2} \cdot 365$$
$$\frac{\text{Stroški blaga, materiala in storitev} + \text{Stroški dela} + \text{Drugi poslovni odhodki}}{\text{Stroški blaga, materiala in storitev} + \text{Stroški dela} + \text{Drugi poslovni odhodki}} \quad (46)$$

Kazalniki dni vezave imajo podoben pomen kot kazalniki obračanja. Dnevi vezave kratkoročnih poslovnih obveznosti kažejo, v koliko dneh gospodarska družba poravna kratkoročne obveznosti iz poslovanja. Povečevanje števila dni vezave v daljšem časovnem obdobju lahko kaže na slabšanje plačilne sposobnosti podjetja.

Kazalnik donosnosti - Čista donosnost sredstev:

Formula:

$$\frac{\text{Čisti poslovni izid obračunskega obdobja}}{(\frac{\text{Sredstva} + \text{Sredstav iz prejšnjega leta}}{2})} * 100 \quad (47)$$

Kazalniki donosnosti, gospodarnosti in dohodkovnosti so kazalniki poslovne uspešnosti. Pojasnjujejo dosežene poslovne rezultate glede na ugotovljene stroške. Kazalnik čiste donosnosti sredstev kaže, kako uspešno je bilo poslovodstvo pri upravljanju sredstev. Čim večja je njihova pozitivna vrednost, tem uspešnejša je gospodarska družba.

Kazalnik denarnega toka - Čisti kratkoročni obratni kapital

Formula:

$$\begin{aligned} & \text{Denarna sredstva} + \text{Kratkoročne poslovne terjatve} + \text{Zaloge} \\ & - \text{Kratkoročne poslovne obveznosti do dobaviteljev} \end{aligned} \quad (48)$$

Kazalnik denarnega toka pove, koliko denarja ima družba na razpolago v določenem času. Čisti kratkoročni obratni kapital sešteje vsa denarna sredstva, kratkoročne poslovne terjatve, zaloge in odšteje vse kratkoročne poslovne obveznosti do dobaviteljev. Višji je kazalnik, boljša je plačilna sposobnost podjetja.

4.3.2 Transformacija in grupiranje spremenljivk

Izbrane spremenljivke je potrebno za računanje koeficientov prilagoditi algoritmu,. Sama sem uporabila programski paket Matlab in njegov modul kreditnega točkovanja (angl. *Credit Scorecard*), ki zahteva, da so vrednosti vsake spremenljivke razvrščene po razredih. Za razvrščanje sem uporabila metodo avtomatskega razvrščanja (angl. *autobinning*), ki je v mojem primeru temeljil na monotonem algoritmu. Ta algoritem razvršča vrednosti spremenljivke po razredih tako, da WOE vrednosti razredov monotonno naraščajo oziroma

padajo. Avtomatsko razvrščanje ni vedno najbolj optimalno, zato je potrebno narediti tudi ročne popravke mej razredov.


Spodaj so prikazani rezultati grupiranja spremenljivk:

Delež osnovnih sredstev v sredstvih:

Tabela 5: Delež osnovnih sredstev v sredstvih

Razred	Dobri (v %)	Slabi (v %)	Dobri/Slabi	WOE	Informacijska vrednost
[-Inf, 4.1)	91.3	8.7	10.50	-0.80	0.08
[4.1, 9.97)	93.5	6.5	14.31	-0.49	0.01
[9.97, 27.58)	94.9	5.1	18.56	-0.23	0.01
[27.58, 31.25)	96.0	4.0	24.29	0.04	0.00
[31.25, 62.63)	96.6	3.4	28.35	0.19	0.01
[62.63, 73.01)	96.8	3.2	30.12	0.25	0.01
[73.01, Inf]	97.0	3.0	32.72	0.34	0.03
Skupaj	95.9	4.1	23.36	NaN	0.15

Slika 8: Delež osnovnih sredstev v sredstvih




Delež dolgov v financiranju:

Tabela 6: Delež dolgov v financiranju

Razred	Dobri (v %)	Slabi (v %)	Dobri/Slabi	WOE	Informacijska vrednost
[-Inf, 47.82)	98.7	1.3	74.50	1.16	0.33
[47.82, 61.32)	96.5	3.5	27.20	0.15	0.00
[61.32, 79.18)	95.7	4.3	22.49	-0.04	0.00
[79.18, 89.34)	94.3	5.7	16.60	-0.34	0.01
[89.34, 96.62)	92.6	7.4	12.58	-0.62	0.03
[96.62, 100)	92.0	8.0	11.50	-0.71	0.02
[100, 111.56)	90.6	9.4	9.63	-0.89	0.05
[111.56, Inf]	81.8	18.2	4.50	-1.65	0.20
Skupaj	95.9	4.1	23.36	NaN	0.64

Slika 9: Delež dolgov v financiranju




Servisiranje dolga:

Tabela 7: Servisiranje dolga

Razred	Dobri (v %)	Slabi (v %)	Dobri/Slabi	WOE	Informacijska vrednost
$[-\text{Inf}, -0.03)$	87.8	12.2	7.22	-1.17	0.22
$[-0.03, 0.01)$	91.9	8.1	11.31	-0.72	0.03
$[0.01, 0.05)$	94.3	5.7	16.45	-0.35	0.02
$[0.05, 0.56)$	97.2	2.8	35.27	0.41	0.09
$[0.56, 0.96)$	98.9	1.1	87.00	1.32	0.07
$[0.96, \text{Inf}]$	99.4	0.6	175.00	2.01	0.06
Skupaj	95.9	4.1	23.36	NaN	0.48

Slika 10: Servisiranje dolga




Obračanje Kratkoročnih Poslovnih Terjatev:

Tabela 8: Obračanje kratkoročnih poslovnih terjatev

Razred	Dobri (v %)	Slabi (v %)	Dobri/Slabi	WOE	Informacijska vrednost
$[-\text{Inf}, 0.54)$	89.6	10.4	8.61	-1.00	0.05
$[0.54, 2)$	91.1	8.9	10.23	-0.83	0.10
$[2, 3)$	94.3	5.7	16.54	-0.35	0.01
$[3, 3.5)$	95.2	4.8	20.00	-0.16	0.00
$[3.5, 15.3)$	96.9	3.1	31.79	0.31	0.04
$[15.3, 23.16)$	97.2	2.8	35.10	0.41	0.01
$[23.16, 70.66)$	97.5	2.5	39.69	0.53	0.02
$[70.66, \text{Inf}]$	97.7	2.3	43.00	0.61	0.01
Skupaj	95.9	4.1	23.36	NaN	0.25

Slika 11: Obračanje kratkoročnih poslovnih terjatev




Dnevi Vezave Kratkoročnih Poslovnih Obveznosti:

Tabela 9: Dnevi vezave kratkoročnih poslovnih obveznosti

Razred	Dobri (v %)	Slabi (v %)	Dobri/Slabi	WOE	Informacijska vrednost
[-Inf, 53.93)	99.1	0.9	112.29	1.57	0.39
[53.93, 74.82)	97.5	2.5	39.00	0.51	0.03
[74.82, 108.1)	96.7	3.3	29.38	0.23	0.01
[108.1, 118.29)	95.5	4.5	21.00	-0.11	0.00
[118.29, 208.99)	93.3	6.7	14.00	-0.51	0.04
[208.99, 732.55)	91.3	8.7	10.56	-0.79	0.12
[732.55, 1628.87)	90.3	9.7	9.35	-0.92	0.04
[1628.87, Inf]	89.2	10.8	8.26	-1.04	0.06
Skupaj	95.9	4.1	23.36	NaN	0.70

Slika 12: Dnevi vezave kratkoročnih poslovnih obveznosti




Čista Donosnost Sredstev:

Tabela 10: Čista donosnost sredstev

Razred	Dobri (v %)	Slabi (v %)	Dobri/Slabi	WOE	Informacijska vrednost
[-Inf, -19.96)	84.7	15.3	5.52	-1.44	0.14
[-19.96, -10.00)	86.4	13.6	6.33	-1.31	0.11
[-10.00, -5.47)	92.1	7.9	11.64	-0.70	0.02
[-5.47, 0.13)	93.8	6.3	15.00	-0.44	0.04
[0.13, 0.27)	95.5	4.5	21.13	-0.10	0.00
[0.27, 4.50)	96.8	3.2	30.55	0.27	0.03
[4.50, 8.30)	98.3	1.7	57.67	0.90	0.07
[8.30, Inf]	98.9	1.1	87.10	1.32	0.17
Skupaj	95.9	4.1	23.36	NaN	0.57

Slika 13: Čista donosnost sredstev




Čisti Kratkoročni Obratni Kapital:

Tabela 11: Čisti kratkoročni obratni kapital

Razred	Dobri (v %)	Slabi (v %)	Dobri/Slabi	WOE	Informacijska vrednost
[-Inf, -296316)	82.4	17.6	4.68	-1.61	0.18
[-296316, -130590)	89.8	10.2	8.78	-0.98	0.05
[-130590, -30228)	91.8	8.2	11.17	-0.74	0.05
[-30228, -5709)	93.8	6.3	15.00	-0.44	0.02
[-5709, -508)	96.6	3.4	28.33	0.19	0.00
[-508, Inf]	97.3	2.7	35.51	0.42	0.11
Skupaj	95.9	4.1	23.36	NaN	0.41

Slika 14: Čisti kratkoročni obratni kapital



4.4 Sestavljanje modela in računanje koeficientov

V naslednjem koraku lahko kreiramo model transformiranih spremenljivk s pomočjo vgrajene funkcije »fitmodel« programskega orodja Matlab. Ta funkcija na podlagi vhodnih spremenljivk, neodvisnih in odvisne, izračuna koeficiente neodvisnih tako, da se model čim bolje prilega logistični regresiji. Za neodvisne spremenljivke se uporabi finančne kazalnike, transformirane s pomočjo WOE transformacije (bolj podroben opis v poglavju 3.2.1.1), tako se namesto vrednosti finančnega kazalnika za določeno stranko vzame pripadajočo WOE

vrednost razreda, v katerega pade vrednost kazalnika (vrednosti iz prejšnjega poglavja). Dobimo spodnje rezultate:

Tabela 12: Prvi primer sestavljenega modela

Spremenljivka	Ocena koeficienta	St. napaka	T statistika	P - vrednost
B₀	-3.131	0.081	38.799	0.000
Delež osnovnih sredstev v sredstvih	-0.738	0.178	4.155	0.000
Delež dolgov v financiranju	-0.375	0.103	3.636	0.000
Servisiranje dolga	-0.370	0.134	2.764	0.006
Obračanje kratkoročnih poslovnih terjatev	-0.206	0.155	1.323	0.186
Dnevi vezave kratkoročnih poslovnih obveznosti	-0.575	0.120	4.802	0.000
Čista donosnost sredstev	-0.408	0.136	3.003	0.003
Čisti kratkoročni obratni kapital	-0.447	0.114	3.912	0.000

Opazimo, da je le ena spremenljivka statistično neznčilna, saj ima p vrednost 0.19, kar pa je krepko nad 0.05. V izogib slabšim rezultatom in nestabilnemu modelu, sem se odločila, da jo odstranim iz modela¹.

Sedaj mi je ostalo le 6 finančnih kazalnikov, s katerimi bom sestavila model.

Tabela 13: Končni logit model

Spremenljivka	Ocena koeficienta	St. napaka	T statistika	P- vrednost
B₀	-3.161	0.084	37.663	0.000
Delež Osnovnih Sredstev V Sredstvih	-0.799	0.174	4.606	0.000
Delež Dolgov V Financiranju	-0.305	0.110	2.767	0.006
Servisiranje Dolga	-0.426	0.131	3.252	0.001
Dnevi Vezave Kratkoročnih Poslovnih Obveznosti	-0.672	0.112	6.020	0.000
Čista Donosnost Sredstev	-0.404	0.138	2.931	0.003
Čisti Kratkoročni Obratni Kapital	-0.416	0.118	3.517	0.000

Sedaj so vse P vrednosti spremenljivk pod vrednostjo 0.05, kar pomeni da so vse spremenljivke statistično značilne. Pri tem koraku so pomembne tudi vrednosti koeficientov vsake spremenljivke, saj opisujejo, kako spremenljivka vpliva na odvisno spremenljivko. Opazimo, da so vsi koeficienti negativni, kar pomeni, da transformirane vrednosti finančnih kazalnikov pravilno vplivajo na verjetnost neplačila. Če zopet pogledamo formulo modela:

¹ Koeficienti modela in njihove statistične značilnosti, s spremenljivko ali brez nje, niso bistveno drugačni.

$$PD(i) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 WOE_1(i) + \beta_2 WOE_2(i) + \dots + \beta_m WOE_m(i))}} \quad (49)$$

Opazimo, da ima finančno dobra stranka višje (pozitivne) WOE vrednosti vsakega koeficienta, kar nam da zelo nizko verjetnost neplačila (PD). Obratno velja za finančno tvegane stranke, ki imajo nizke (negativne) WOE vrednosti vsakega koeficienta, kar pa vrne visoko verjetnost neplačila.

Za test celotnega modela (da obstaja odvisnost med pojasnjevalnimi spremenljivkami in odzivno spremenljivko) določimo ničelno hipotezo:


H_0 : Finančni kazalniki ne vplivajo na pojav neplačil strank.

Testiramo s Chi-kvadrat statistiko in dobimo vrednost 272, ki s 5015 prostorskimi stopnjami vrne P vrednost 9.95 E-56. To pomeni, da lahko s 95 % intervalom zaupanja zavrneemo ničelno hipotezo. Z drugimi besedami, model je statistično značilen in odvisen od vključenih spremenljivk, torej vključeni finančni kazalniki vplivajo na verjetnost neplačila stranke.

4.5 Dosežene točke in verjetnost neplačila

Vsi potrebni parametri za izračun kreditnih točk so sedaj znani. Za lažjo predstavbo sem dosežene točke posameznikov razporedila po intervalu od 0 do 1000, kjer 1000 točk predstavlja najvišjo možno kreditno oceno. Spodaj so prikazani rezultati doseženih točk učnega vzorca.

Slika 15: Graf doseženih točk



Z vijolično barvo je prikazan histogram doseženih točk, z modro črto pa je prikazana porazdelitev verjetnosti neplačila glede na dosežene točke. Najnižja dosežena vrednost je 48 točk, kjer so v povprečju stranke dosegale 559 točk pri mediani 572. Pripadajoče verjetnosti neplačila strank pa se gibajo med 0 in 57 %, kjer povprečna vrednost znaša 5 % in mediana 3 %. Ti rezultati so nekoliko nepričakovani, saj bi morala najvišja verjetnost neplačila teoretično znašati blizu 100 %. Glede na to, da je pri mojem vzorcu najvišja verjetnost neplačila le 57 %, lahko sklepam, da so bile v analizo vključene večinoma stranke z boljšim finančnim stanjem, ki so tako redno plačevale svoje račune.

Vpliv kazalnikov na izračun točk

Vsaka vključena spremenljivka vpliva na doseženo število točk. Za model sem izračunala uteži, s katerimi neodvisne spremenljivke vplivajo na odvisno. Uteži so določene kot koeficient med doseženimi točkami spremenljivke in med najvišjim možnim doseženim številom točk vseh spremenljivk. Pri izračunu točk se upoštevajo vrednosti beta in WOE.

Spremenljivke imajo spodnje uteži pri računanju točk v modelu:

Tabela 14: Uteži kazalnikov

Spremenljivka	Utež
Delež osnovnih sredstev v sredstvih	14.87
Delež dolgov v financiranju	12.74
Servisiranje dolga	20.13
Dnevi vezave kratkoročnih poslovnih obveznosti	23.26
Čista donosnost sredstev	17.49
Čisti kratkoročni obratni kapital	11.51
Skupaj	100

Kot je razvidno iz tabele, kazalnik Dnevi vezave kratkoročnih poslovnih obveznosti najbolj vpliva na končni rezultat točk in tako podjetjem doprinese največ točk.


4.6 Validacija – Test modela napovedi neplačila

Zgrajeni napovedni model je potrebno še preveriti na realnih podatkih. Za testiranje modela bom uporabila preostalih 20 % podatkov, ki sem jih že na začetku odstranila iz učnega vzorca. Podatke vstavim v zgrajeni model in dobim rezultate na spodnjem grafu (Slika 16).

Z vijolično barvo je zopet prikazan histogram doseženih točk testnega vzorca, z modro črto pa porazdelitev verjetnosti neplačila glede na dosežene točke. Najnižja dosežena vrednost je 44, najvišja pa 968 točk, kjer so se vrednosti v povprečju gibale pri 586 točkah. Pripadajoče verjetnosti neplačila strank pa se gibajo med 0 in 56 %, kjer povprečna vrednost znaša 5 %.

Rezultati testnega vzorca so zelo podobni rezultatom učnega vzorca, kar pomeni, da je tudi tu najvišja verjetnost neplačila dokaj nizka. Tako lahko sklepam, da so bile v analizo nenamerno večinoma vključene stranke z boljšim finančnim stanjem, ki so zelo malo zamujale s svojimi plačili. Iz tega lahko tudi sklepam, da je podjetje že pri izbiri strank pazilo na njihova finančna stanja in praviloma podpisovalo pogodbe le s strankami, ki so imele zdravo finančno sliko.

Slika 16: Graf doseženih točk testnega vzorca



4.6.1 Test povezanosti odvisne in neodvisnih spremenljivk

Spearmanov koeficient korelacije je neparametrična stopnja povezanosti dveh spremenljivk in predstavlja kakovost povezanosti med spremenljivkama. Primeren je za merjenje stopnje povezanosti nelinearnih in tudi nezveznih spremenljivk.

Vrednosti povezanosti odvisne spremenljivke in kazalnikov (netransformirane vrednosti) so predstavljene v naslednji tabeli:

Tabela 15: Korelacija


Spremenljivka	Vpliv na neplačilo	P - vrednost
Delež osnovnih sredstev v sredstvih	-0.074	0.0006
Delež dolgov v financiranju	0.124	0.0000
Servisiranje dolga	-0.098	0.0000
Dnevi vezave kratkoročnih poslovnih obveznosti	0.154	0.0000
Čista donosnost sredstev	-0.097	0.0000
Čisti kratkoročni obratni kapital	-0.065	0.0029

Če dobljene rezultate primerjam s tabelo iz teoretičnega dela, se opazi, da so stopnje povezanosti kazalnikov z neplačili bolj nizke, a vseeno vplivajo na odvisno spremenljivko. Nizka stopnja korelacije se pojavi predvsem zaradi odvisne spremenljivke, saj so njene vrednosti le 0 ali 1, kar vpliva na slabšo odvisnost med neodvisnimi in odvisno spremenljivko. Bolj realna slika bi bila, če bi bila odvisna spremenljivka zvezna. Vpliv neodvisnih spremenljivk na odvisno je lahko pozitiven ali negativen, torej se verjetnost neplačila lahko s spremenljivko veča (drugi in četrti kazalnik) ali manjša (vsi ostali kazalniki). Kazalniki smiselno vplivajo na neplačila.

4.6.2 CAP krivulja

Ta krivulja se uporablja za prikaz pravilno identificiranih dobrih in slabih primerov. V idealnem svetu bi se moralo rumeno območje krivulje prekrivati z zelenim (idealna krivulja). Krivulja prikazuje delež neplačnikov glede na skupno število strank.

Slika 17: CAP krivulja testnega vzorca



Točka na krivulji pove, da ob zavrnitvi 56 % slabih, zavrnemo skupaj 30 % vseh primerov. Na tem testnem vzorcu kazalnik točnosti meri 0.437, kar je razmerje med rumenim območjem in skupnim rumenim ter zelenim območjem. Večje kot bi bilo rumeno območje, bolj bi se kazalnik točnosti pomikal proti 1 (idealni svet). To krivuljo si lahko razlagamo tudi kot napovedno moč modela pri ločevanju med dobrimi in slabimi strankami. Moj model je nekje na polovici.


4.6.3 ROC krivulja

ROC krivulja je zelo podobna CAP krivulji, le da prikazuje delež neplačnikov v odvisnosti od deleža plačnikov. Simetrala lihih kvadrantov (premica $y = x$) bi predstavljala klasifikacijo brez modela:

verjetnost dobre klasifikacije = verjetnost slabe klasifikacije = 50 %

Torej bi za dobro napovedno moč modela morala biti krivulja čim bolj odmaknjena od simetrale, vrednost kazalnika AUROC pa čim višja. V mojem primeru je vrednost tega kazalnika 0.719, kar pomeni dober napovedni model.

Slika 18: ROC krivulja testnega vzorca




4.6.4 K-S graf

K-S graf (Slika 19) prikazuje dve krivulji, porazdelitev plačnikov in neplačnikov. Na x osi so dosežene točke strank, na y osi pa kumulativna porazdelitev v (%) (range od 0 do 100 %).

Lahko vidimo, da sta porazdelitvi skupin plačnikov in neplačnikov drugačni. Z vrednostjo statistike KS prikažemo največjo razliko med krivuljama slabih in dobrih podjetij. Vrednost KS je 34.6 % in je dosežena pri točkah 591.05. To pomeni, da bi bila to najbolj optimalna meja za ločitev plačnikov in neplačnikov.

Slika 19: K-S graf testnega vzorca



4.6.5 Matrika napake modela

Matrika napake modela preverja natančnost modela s pregledom pravilno in napačno razporejenih primerov. Zanj je najprej potrebno izbrati najbolj optimalno mejno točko.

Določitev mejne točke na primeru podjetja

Mejo sem poskušala določiti glede na maksimalni dobiček podjetja oziroma njegovo minimalno izgubo. Pri tem je bilo potrebno upoštevati tudi »uteži«, ki jo imajo dobre in slabe stranke.

Poslovni rezultat podjetja, ki trguje z električno energijo, je zaradi relativno nizkih marž zelo odvisen od rednih plačil strank, saj se z njimi pokrivajo stroški nabave električne energije. Postavljanje meje med sprejetimi in zavrženimi strankami ima zato v takem podjetju večji pomen, saj je lahko izguba ob neplačilu stranke za celotno energijo dosti večja kot pa oportunitetni strošek izgube marže.


Določitev prave mejne vrednosti mora biti vedno kompromis med pravilno napovedanimi pozitivnimi izidi in pravilno napovedanimi negativnimi izidi. Rešitev za ta problem sta K-S analiza in podatek, pri katerih točkah se pojavi največja razlika med porazdelitvijo plačnikov in neplačnikov. Ta vrednost bi bila teoretično najbolj optimalna, v našem primeru 591.053 točke, če bi plačniki in neplačniki imeli enako utež. V realnosti pa se večkrat zgodi, da sta dobička dobre in slabe stranke zelo različna.

Kot primer te dileme je dobiček skupnega portfelja odjemalcev pri podjetju za prodajo električne energije. Glede na to, da lahko stranke odjemajo različne količine energije, bom izračun poenostavila in računala dobiček v €/MWh (evrih na megavatno uro). Za namen izračuna dobička sem si izmislila maržo in stroške podjetja ter predpostavila, da:

- Stranka, s katero se ni sklenilo pogodbe, ni imela vpliva na končni dobiček (njihov dobiček je 0 €/MWh);
- Stranka, s katero je bila sklenjena pogodba in je redno plačevala račune, je podjetju ustvarila dobiček zaradi marže – 0.4€/MWh;
- Stranka, s katero je bila sklenjena pogodba in računov ni plačevala, je podjetju ustvarila izgubo zaradi financiranja – v mojem primeru -2 €/MWh.

V naslednjem koraku sem preračunala dobiček celotnega portfelja za vsako vrednost doseženih točk. Najboljša izbira mejne točke bi bila tista, kjer je dobiček najvišji. Za ta konkreten primer pa pridem do rezultata 559.20 €/MWh za celoten portfelj, kar znaša približno 0.27 €/MWh na stranko v portfelju (le sprejete stranke).

Slika 20: Prikaz dobička glede na mejne dosežene točke



S črno piko na zgornjem grafu je prikazan maksimalni dobiček, ki je dosežen pri meji 246 točk, kar pomeni 23 % verjetnosti neplačila. Kot je bilo razvidno že pri grafu prikaza doseženih točk in verjetnosti neplačil, je meja pomaknjena nekoliko nižje, saj so v vzorec vključene večinoma stranke, ki redno plačujejo račune in tako nekoliko »pokvarijo« realno sliko finančnega stanja. Tako lahko rečem, da je glede na krivuljo dobička portfelja skoraj vseeno, če bi sploh izločili kakšno stranko s pomočjo mejne točke, ali pa bi vzeli v portfelj kar vse stranke.

Pregled matrike

Za izračun matrike napake je potrebno uporabiti mejno točko. Za namen primerjave sem uporabila kar obe, saj je zgolj odločitev podjetja, kako se bo odločilo glede izbire mejne točke.

Pri meji 591.053 točke (meja iz KS analize) izgleda matrika napake tako:

Tabela 16: Matrika napake za testni vzorec pri mejni točki 591.053

Napovedana vrednost	Celotna populacija	Resnična vrednost		
		Slab	Dober	
		TP= 4.29 %	33.77 %	38.07 %
Napovedana vrednost	Napovedan slab	1.79 %	TN= 60.14 %	61.93 %
	Napovedan dober	6.08 %	93.92 %	100.00 %

Kot vidimo, bi bila pri tej meji večina slabih strank izločena, kar pa pomeni, da bi na ta račun morali izločiti tudi veliko dobrih strank. To nam pokaže kazalnik točnosti (TP+TN), vsota točno napovedanih slabih in dobrih primerov, ki znaša 64.43 %.

Pri meji 246 točk (najvišji dobiček podjetja) pa izgleda matrika napake tako:

Tabela 17: Matrika napake za testni vzorec pri mejni točki 246

Napovedana vrednost	Celotna populacija	Resnična vrednost		
		Slab	Dober	
		TP= 0.99 %	2.50 %	3.49 %
Napovedana vrednost	Napovedan slab	5.09 %	TN= 91.42 %	96.51 %
	Napovedan dober	6.08 %	93.92 %	100.00 %


Kot vidimo v tem primeru, bi pri tej meji večino slabih strank obdržali v portfelju. Na ta način bi lahko obdržali tudi večino dobrih strank. Točnost napovedi pri teh točkah nam pove kazalnik točnosti, ki pa v tem primeru znaša 92.41 %, kar je veliko več kot pri prejšnji matriki.

Glede na to, da je kazalnik točnosti (AR) zelo odvisen od meje, ki se jo postavi pri izločanju slabih strank, si moramo ogledati še spodnji graf (Slika 21).

Kazalnik AR sem preračunala tako, da sem za mejo za dosežene točke plačnikov in neplačnikov postavila vse možne dosežene točke strank (od 0 do 1000). Kot je razvidno iz grafa, se kazalnik AR glede na postavljeno mejo le niža. Kazalnik je odvisen predvsem od deleža pravilno zaznanih slabih in dobrih primerov, kjer pa se s pomikanjem meje višje število resnično slabih strank počasneje povečuje kot pa število resnično dobrih strank niža. Optimalno bi bilo poiskati maksimum AR krivulje, ki ga v teoriji (pri lepi zvončasti obliki

krivulje) dosega nekje na sredini (pri 500 točkah). V našem primeru je maksimum te krivulje pomaknjen skrajno levo, kar pomeni, da je pri nas najbolj optimalna poteza, da se za neplačnike vzame čim nižjo mejo in se tako vključi večina strank, ne glede na njihovo finančno stanje.

Slika 21: Kazalnik pravilnosti glede na mejo verjetnosti neplačila



SKLEP

Uspešnost poslovanja podjetja, ki trguje z električno energijo, ni odvisna le od kakovosti opravljenih storitev oddaje električne energije, znanja in strokovnosti zaposlenih, temveč je ključnega pomena aktivno upravljanje s tveganji. Tako podjetje ima v svojem portfelju nabor zelo različnih strank, pri katerih je izpostavljeno kreditnemu tveganju, to je tveganje, da odjemalec ne bo poravnal obveznosti iz naslova dobavljene energije. Za navedena podjetja lahko to predstavlja velik problem, saj so morala pravočasno poravnati zakupljeno električno energijo od proizvajalcev ali na borzi, zaradi strogih pravil na nabavni strani za sodelujoče akterje. Zaradi specifičnih značilnosti električne energije pa se v takem podjetju pojavlja še določeno odstopanje. Električna energija je dobrina, ki je nujno potrebna za vsakdanje življenje, gospodinjstva, kot tudi vseh vrst podjetij. Tega se vsi udeleženci dobro zavedajo, zato se trudijo bolj skrbno poravnati svoje obveznosti, ki nastanejo z odjemom električne energije.

V magistrskem delu sem se osredotočila predvsem na to, kako naj se podjetje, ki trguje z električno energijo, sploh odloči, ali bo s stranko sklenilo pogodbo o dobavi električne energije na podlagi podatkov, ki so javno dostopni o vsaki stranki posebej. Natančneje sem poskušala ugotoviti, ali lahko na podlagi določenih finančnih podatkov, ki jih dobavitelj pridobi iz javnih virov za vsako stranko posebej, napravim model, ki bo v največji možni meri pravilno izračunal verjetnost neplačila vsake stranke. Vhodni podatki, na podlagi katerih model izračuna verjetnost neplačila vsake stranke posebej, so predvsem finančni

kazalniki, ki odražajo njeno jasno finančno stabilnost. Iz praktičnih razlogov sem se odločila za sestavo modela, ki napoveduje neplačila večjih strank, torej za vse poslovne odjemalce na slovenskem trgu, saj sem imela dostop do finančnih podatkov in izračunanih računovodskih kazalnikov le za njih. Raziskava je temeljila na dejanskih podatkih podjetja, ki prodaja električno energijo, ter javno dostopnih podatkih o finančnem stanju podjetij od leta 2012 do 2015.

Za sestavo modela sem uporabila vrsto modela kreditnega točkovanja s pomočjo logistične regresije, ki je ena izmed najbolj priljubljenih statističnih orodij za reševanje tovrstnih problemov. Model za vsako stranko posebej izračuna verjetnost neplačila vsaj enega njenega računa za dobavo električne energije v naslednjem obdobju.

Na podlagi izračunov s statističnim paketom Matlab, prikazanih grafov in kazalnikov za namen validacije, lahko zaključim, da moj nabor izbranih finančnih kazalnikov dobro razlikuje med dobrimi in slabimi podjetji, ki so bila uporabljena pri testiranju modela – dobljeni rezultati zanesljivo napovejo neplačila strank.

V magistrskem delu sem tako pokazala, da je možno sestaviti model, ki bo podjetju v pomoč pri odločanju o sklepanju pogodb za odjem energije in je prilagojen specifikam elektroenergetskega trga ter tako popolnoma zadošča potrebam in omejitvam podjetja. Tako podjetje lahko izračunano verjetnost neplačila uporabi kot pomoč pri zniževanju kreditnega tveganja pri novo sklenjenih pogodbah. Izračunane vrednosti modela lahko tudi bistveno doprinesejo k uspehu podjetja, saj se le-to lahko spretno izogne finančno slabim strankam, ki bi prinesle večjo izgubo podjetju, in tako poskrbi za boljši poslovni rezultat. Seveda pa se obvladovanje tveganja ne zaključi le pri odločitvi o sklenitvi pogodbe, ampak je potrebno prav tako vzpostaviti ustrezen sistem rednega spremljanja strank in njihovega finančnega stanja.

Za nadaljnjo možnost preučevanja bi izpostavila dodatno analiziranje vplivov makroekonomskih dejavnikov ter dodatnih dejavnikov, ki prav tako bistveno vplivajo na finančno stanje podjetij. To so njihova plačilna disciplina, informacije o njihovem poslovanju ter stres testi podjetij (kako bi se podjetja odzivala v težkih razmerah na trgu). Na ta način bi se lahko v model vključilo še več podatkov o strankinem finančnem stanju in bi lahko posledično sestavili model, ki bi tudi v drugačnih okoliščinah pravilno napovedal neplačila strank.

LITERATURA IN VIRI

1. Altman, E. I. (1968). Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy. *The Journal of Finance*, 23(4), 589–609.
2. Anderson, R. (2007). *The Credit Scoring Toolkit: Theory and Practice for Retail Credit Risk Management and Decision Automation*. New York: Oxford University Press.
3. Basel Committee on Banking Supervision. (Maj 2005). *Studies on the Validation of Internal Rating Systems*. Basel: Bank for International Settlements.
4. Belsley, D. A., Kuh, E., & Welsch, R. E. (1980). *Regression diagnostics*. Hoboken, NJ: John Wiley & Sons.
5. Berk Skok, A., Peterlin, J., & Ribarič, P. (2005). *Obvladovanje tveganja: skrivnosti celovitega pristopa*. Ljubljana: GV Založba.
6. Bisnode, d.o.o. (b.l.). *Kazalniki*. Najdeno decembra 2016 na spletnem naslovu https://bonitete.bisnode.si/BoniteteCE/Files/FAQ_Kazalniki_SLO_sl-SI.pdf
7. Brealey, A. R., & Stewart, M. C. (2000). *Principles of Corporate Finance* (6th ed.). New York: McGraw-Hill.
8. Burns, R. B., & Burns, R. A. (2008). Business Research Methods and Statistics using SPSS. Najdeno 28. oktobra 2017 na spletnem naslovu <https://studysites.uk.sagepub.com/burns/website%20material/Chapter%2025%20-%20Discriminant%20Analysis.pdf>
9. Chacko, G., Sjöman, A., Motohashi, H., & Dessain, V. (2006). *Credit derivatives: A primer on credit risk, modeling, and instruments*. Upper Saddle River, New Jersey: Wharton School Publishing.
10. Elektro energija d.o.o. (2015). *Letno poročilo podjetja Elektro energija za leto 2014*. Ljubljana: Elektro energija d.o.o.
11. Energetski zakon. (2007). *Uradni list RS št. 79/99*.
12. Engelmann, B., Hayden, E., & Tasche, D. (2003). Testing Rating Accuracy. *Risk*, 16, 82–86.
13. Evropski parlament in Svet. (1996). Direktiva o skupnih pravilih notranjega trga z električno energijo, 96/92/ES. *Uradni list EU L027*.
14. Eydeland, A., & Wolyniec, K. (2003). *Energy and Power Risk Management - New Developments in Modeling, Pricing and Hedging*. New Jersey: John Wiley & Sons, Inc.
15. Fabijan, D. (2007). *Investicije energetske družbe v pogojih odprtega trga električne energije*. Maribor: Univerza v Mariboru, Ekonomsko-poslovna fakulteta.
16. Greene, W. H. (2002). *Econometric Analysis* (5th ed.). New Jersey: Prentice Hall.
17. Harrington, D. R. (1993). *Corporate Financial Analysis: Decisions in a Global Environment*. Boston: Irwin.
18. Higle, J., & Wallace, S. W. (April 2002). Managing risk in the new power business: a sequel. *IEEE Computer Applications in Power*, 15, 12–19.
19. Hilbe, J. M. (2009). *Logistic regression models*. USA: Chapman & Hall/CRC Press.
20. Kendall, R. (1998). *Risk Management for Executives: A Practical Approach to Controlling Business Risks*. London, UK: Pitman.

21. Kokol, M. (2002). Trading experiences and opportunities in the region. Ljubljana: Conference on Slovenian organized electricity market.
22. Kralj, B. (2011). *Kreditno tveganje pri novo izdanih plačilnih karticah - primer slovenskega izdajatelja plačilnih kartic*. Ljubljana: Univerza v Ljubljani, Ekonomska fakulteta.
23. Križnik, T. (2005). *Model obvladovanja kreditnega tveganja za slovenske banke*. Maribor: Univerza v Mariboru, Ekonomsko-poslovna fakulteta.
24. Lehman, A. (2005). *Jmp For Basic Univariate And Multivariate Statistics: A Step-by-step Guide*. Cary, NC: SAS Press.
25. Management Solutions. (2014). *Operational risk management in the energy industry*. Spain: Management Solutions.
26. Menard, S. (2002). *Applied Logistic Regression Analysis (Quantitative Applications in the Social Sciences) (2nd ed.)*. USA: SAGE.
27. Menard, S. (2010). *Logistic Regression: From Introductory to Advanced Concepts and Applications*. USA: SAGE.
28. Mester, L. J. (September 1997). What's the Point of Credit Scoring? *Business Review*, 3–16.
29. Montel Energetika.NET d.o.o. (11. Maj 2015). *Prof. dr. Aleš Ahčan: (Pre)nizke cene električne energije so nevarne (za vse)*. Najdeno 10. oktobra 2017 na spletnem naslovu <https://www.energetika.net/novice/o-nas/prof-dr-ales-ahcan-prenizke-cene-elektricne-energije-so-neva>
30. Ong, C.-S., Huang, J.-J., & Tzeng, G.-H. (2005). Building credit scoring models using genetic programming. *Expert Systems with Applications*, 29, 41–47.
31. Paravan, D. (2004). *Srednjeročno obvladovanje tveganj proizvajalcev na trgu električne energije*. Ljubljana: Univerza v Ljubljani, Fakulteta za elektrotehniko.
32. Peterlin, J. (2005). *Obvladovanje finančnih tveganj*. Ljubljana: Zveza računovodij, finančnikov in revizorjev Slovenije.
33. Pike, R., & Neale, B. (2009). *Corporate finance and investment: Decisions and Strategies (6th ed.)*. United Kingdom: Financial Times Prentice Hall.
34. Prapotnik Sabol, V. (2009). *Model obvladovanja kreditnega tveganja v podjetju za distribucijo električne energije*. Maribor: Univerza v Mariboru, Ekonomsko-poslovna fakulteta Maribor.
35. Refaat, M. (2006). *Data Preparation for Data Mining Using SAS*. San Francisco: Morgan Kaufmann.
36. Refaat, M. (2011). *Credit Risk Scorecards: Development and Implementation Using SAS*. United States: Lulu Press.
37. Rodriguez, G. (2007). Logit Models for Binary Data. *Lecture Notes on Generalized Linear Models*. Najdeno septembra 2017 na spletnem naslovu <http://data.princeton.edu/wws509/notes/c3.pdf>
38. Rogač, J., & Mlinarič, F. (2014). Cena obvladovanja kreditnega tveganja. *Naše gospodarstvo*; 60(1–2), 81–88.

39. Satchell, S., & Xia, W. (2006). *Analytic Models of the ROC Curve: Applications to Credit Rating Model Validation*. Sydney: Quantitative finance research centre.
40. Saunders, A. (2000). *Financial Institutions Management: A Modern Perspective (3rd ed.)*. New York: Irwin.
41. Saunders, A., & Millon Cornett, M. (2008). *Financial Institutions Management: A Risk Management Approach (6th ed.)*. New York: McGraw-Hill/Irwin.
42. Siddiqi, N. (2006). *Credit Risk Scorecards: Developing and Implementing Intelligent Credit Scoring*. New Jersey: John Wiley & Sons, Inc.
43. Smithson, W. C. (1998). *Managing Financial Risk - A Guide to Derivative Products, Financial Engineering and Value Maximization*. New York: McGraw-Hill.
44. Soršak, S. (2010). *Multifaktorski model kreditnega tveganja bančnega portfelja*. Maribor: Univerza v Mariboru, Ekonomsko-poslovna fakulteta Maribor.
45. Šenk, B. (2004). *Kvantitativna analiza kazalnikov bonitete podjetij*. Kranj: Univerza v Mariboru, Fakulteta za organizacijske vede.
46. Thomas, L. C., Crook, J. N., & Edelman, D. B. (2002). *Credit scoring and its applications*. Philadelphia: Society for Industrial and Applied Mathematics.
47. Wengler, J. (2001). *Managing Energy Risk: A Nontechnical Guide to Markets and Trading*. Tulsa, ZDA: Pennwell.
48. Wooldridge, J. M. (2002). *Introductory Econometrics: A Modern Approach (2nd ed.)*. New York: South-Western.
49. Zaiontz, C. (2013). Real Statistics Using Excel: Significance Testing of the Logistic Regression Coefficients. Najdeno 22. januarja 2017 na spletnem naslovu <http://www.real-statistics.com/logistic-regression/significance-testing-logistic-regression-coefficients/>

PRILOGA

PRILOGA 1: Seznam uporabljenih finančnih kazalnikov

KAZALNIKI INVESTIRANJA								
Ime kazalnika	Delež manjkajočih podatkov	Najmanjša vrednost	Največja vrednost	Razpon	Povprečje	St. napaka	St. odklon	Varianca
Delež osnovnih sredstev v sredstvih ²	0.00	0.00	100.00	100.00	49.47	0.38	30.91	955.40
Delež obratnih sredstev v sredstvih	0.00	-83.45	100.00	183.45	35.27	0.33	27.37	749.01
Delež finančnih naložb v sredstvih	0.22	0.00	100.00	100.00	13.09	0.30	21.94	481.41
KAZALNIKI FINANCIRANJA								
Ime kazalnika	Delež manjkajočih podatkov	Najmanjša vrednost	Največja vrednost	Razpon	Povprečje	St. napaka	St. odklon	Varianca
Delež kapitala v financiranju	0.22	-1,215.15	100.00	1,315.15	32.09	0.76	55.14	3,040.49
Delež dolgov v financiranju ³	0.00	0.00	82,681.56	82,681.56	71.86	12.36	1,011.43	1,022,987.84
Kapitalska pokritost dolgoročnih sredstev	0.24	-22,179.33	4,292,322.22	4,314,501.55	973.00	837.70	59,970.42	3,596,451,768.67
Finančni vzvod (celotne obveznosti do kapitala)	0.22	-820,689.67	1,149,348.65	1,970,038.32	775.72	324.37	23,511.77	552,803,213.84

² Definicija kazalnika je opisana na strani 36.

³ Definicija kazalnika je opisana na strani 37.

KAZALNIKI PLAČILNE SPOSOBNOSTI								
Ime kazalnika	Delež manjkajočih podatkov	Najmanjša vrednost	Največja vrednost	Razpon	Povprečje	St. napaka	St. odklon	Varianca
Kratkoročni koeficient likvidnosti	0.02	0.00	3,756.00	3,756.00	4.69	0.64	51.78	2,680.91
Pospešeni koeficient likvidnosti	0.02	0.00	3,756.00	3,756.00	4.29	0.64	51.78	2,680.85
Servisiranje dolga ⁴	0.00	-1.15	113.45	114.60	0.24	0.03	2.19	4.81
Kreditna izpostavljenost	0.02	0.00	535,251.50	535,251.50	117.19	87.94	7,154.77	51,190,768.78
Delovni kapital	0.00	-825.82	1.00	826.82	-0.09	0.12	10.10	101.94
KAZALNIKI OBRAČANJA								
Ime kazalnika	Delež manjkajočih podatkov	Najmanjša vrednost	Največja vrednost	Razpon	Povprečje	St. napaka	St. odklon	Varianca
Obračanje obratnih sredstev	0.00	-70.59	3,545.14	3,615.74	4.64	0.56	45.77	2,094.59
Obračanje zalog 1	0.29	0.00	660,084.00	660,084.00	404.65	174.58	12,018.35	144,440,828.60
Obračanje kratkoročnih poslovnih terjatev ⁵	0.02	0.00	141,428.57	141,428.57	38.25	21.48	1,744.83	3,044,431.65
Koeficient obračanja osnovnih sredstev	0.03	0.00	85,208.22	85,208.22	25.02	13.15	1,059.20	1,121,899.39
Koeficient obračanja sredstev	0.00	0.00	414.59	414.59	1.25	0.07	5.38	28.93
Koeficient obračanja sredstev na celotne prihodke	0.00	0.00	414.59	414.59	1.29	0.07	5.38	28.96

⁴ Definicija kazalnika je opisana na strani 37.

⁵ Definicija kazalnika je opisana na strani 37.

KAZALNIKI DNI VEZAVE								
Ime kazalnika	Delež manjkajočih podatkov	Najmanjša vrednost	Največja vrednost	Razpon	Povprečje	St. napaka	St. odklon	Varianca
Dnevi vezave zalog 1	0.00	0.00	136,492.31	136,492.31	107.24	23.27	1,905.83	3,632,182.37
Dnevi vezave kratkoročnih poslovnih terjatev	0.02	0.00	97,776,382.50	97,776,382.50	28,736.84	19,439.94	1,581,579.78	2,501,394,610,073.54
Dnevi vezave kratkoročnih poslovnih obveznosti ⁶	0.00	0.00	2,539,959,080.00	2,539,959,080	395,522.53	379,055.02	31,040,880.31	963,536,250,718,227.00
KAZALNIKI GOSPODARNOSTI, DONOSNOSTI IN DOHODKOVNOSTI								
Ime kazalnika	Delež manjkajočih podatkov	Najmanjša vrednost	Največja vrednost	Razpon	Povprečje	St. napaka	St. odklon	Varianca
Dodana vrednost na zaposlenega	0.22	-5,784,042.67	16,910,166.67	22,694,209.34	59,344.20	5,192.48	376,409.91	141,684,418,351.18
Celotna gospodarnost	0.00	0.00	97.09	97.09	1.10	0.02	1.95	3.80
Gospodarnost poslovanja	0.00	0.00	535.71	535.71	1.23	0.09	7.01	49.09
Čista dobičkovnost skupnih prihodkov	0.22	-361,485.71	100.00	361,585.71	-479.23	125.55	9,069.13	82,249,060.01
Proizvodnost sredstev	0.00	0.00	414.59	414.59	1.28	0.07	5.38	28.96
Čista donosnost sredstev ⁷	0.00	-520.33	929.90	1,450.22	1.91	0.29	23.73	563.34
Čista donosnost kapitala	0.22	-49,216.59	135,150.00	184,366.59	4.05	30.84	2,238.38	5,010,328.68

⁶ Definicija kazalnika je opisana na strani 38.

⁷ Definicija kazalnika je opisana na strani 38.

Ime kazalnika	Delež manjkajočih podatkov	Najmanjša vrednost	Največja vrednost	Razpon	Povprečje	St. napaka	St. odklon	Varianca
Dobičkovnost prihodkov iz poslovanja	0.02	-567,833.00	100.00	567,933.00	-303.59	124.70	10,133.85	102,695,007.93
Celotna dobičkovnost prihodkov iz poslovanja	0.02	-178,311,700.00	18,327.83	178,330,027.83	-27,157.01	27,000.65	2,194,207.82	4,814,547,978,344.20
Neto prodajna marža	0.02	-44,390.34	10,611.10	55,001.44	-39.49	11.07	899.05	808,286.12
Poslovna donosnost sredstev	0.00	-5.19	12.40	17.59	0.03	0.00	0.28	0.08
KAZALNIKI DENARNEGA TOKA								
Ime kazalnika	Delež manjkajočih podatkov	Najmanjša vrednost	Največja vrednost	Razpon	Povprečje	St. napaka	St. odklon	Varianca
Enostavni denarni tok	0.00	-125,657,500.00	236,139,000.00	361,796,500.00	645,745.05	95,445.05	7,815,428.35	61,080,920,286,820.30
Čisti kratkoročni obratni kapital ⁸	0.00	-112,175,000.00	636,859,000.00	749,034,000.00	2,401,789.76	232,813.76	19,063,736.91	363,426,065,076,750.00

⁸ Definicija kazalnika je opisana na strani 38.