

UNIVERZA V LJUBLJANI  
EKONOMSKA FAKULTETA

**MAGISTRSKO DELO**

Ljubljana, junij 2016

SANJA FILIPI



UNIVERZA V LJUBLJANI  
EKONOMSKA FAKULTETA

MAGISTRSKO DELO

**STATISTIČNI MODEL ZA DOLOČEVANJE KREDITNEGA LIMITA**

Ljubljana, junij 2016

SANJA FILIPIČ

## IZJAVA O AVTORSTVU

Podpisana Sanja Filipič, študentka Ekonomske fakultete Univerze v Ljubljani, avtorica predloženega dela z naslovom Postopek za modeliranje kreditnih limitov, pripravljenega v sodelovanju s svetovalcem red. prof. dr. Markom Pahorjem

### 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,
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 študenta(-ke): \_\_\_\_\_

# KAZALO

|                                                     |           |
|-----------------------------------------------------|-----------|
| <b>UVOD .....</b>                                   | <b>1</b>  |
| <b>1 PRODAJA NA KREDIT .....</b>                    | <b>3</b>  |
| 1.1 Splošna definicija .....                        | 3         |
| 1.2 Prvi zgodovinski zapisi.....                    | 4         |
| 1.3 Motivi za uporabo.....                          | 4         |
| 1.3.1 Teorije finančnega motiva .....               | 5         |
| 1.3.2 Teorije komercialnega motiva .....            | 6         |
| 1.3.3 Teorije operativnega motiva.....              | 8         |
| 1.3.4 Pomanjkljivosti teh teorij .....              | 9         |
| 1.4 Splošni pomen za gospodarstvo .....             | 10        |
| 1.5 Dejavniki, ki vplivajo na uporabo .....         | 11        |
| 1.5.1 Značilnosti posameznega podjetja.....         | 12        |
| 1.6 Terjatve kot posledica prodaje na kredit.....   | 15        |
| 1.7 Pasti uporabe .....                             | 15        |
| <b>2 UPRAVLJANJE .....</b>                          | <b>18</b> |
| 2.1 Načrtovanje.....                                | 20        |
| 2.2 Kreditna politika .....                         | 20        |
| 2.2.1 Pomen .....                                   | 21        |
| 2.2.2 Možne oblike .....                            | 22        |
| 2.2.3 Kreditni pogoji.....                          | 23        |
| 2.2.4 Ocena kreditnega tveganja.....                | 24        |
| 2.2.4.1 Verjetnost neplačila .....                  | 25        |
| 2.2.4.2 Kreditna izpostavljenost .....              | 29        |
| 2.2.4.3 Potencialna izguba .....                    | 30        |
| 2.2.5 Kreditna vrednost .....                       | 32        |
| 2.2.6 Učinkovitost kreditne politike .....          | 32        |
| 2.3 Politika nadzora .....                          | 35        |
| 2.4 Politika unovčenja .....                        | 36        |
| <b>3 KREDITNI LIMIT.....</b>                        | <b>37</b> |
| 3.1 Splošna definicija .....                        | 38        |
| 3.2 Upravljanje .....                               | 38        |
| 3.3 Določanje.....                                  | 39        |
| 3.3.1 Strokovni pristop .....                       | 40        |
| 3.3.1.1 Metoda neto sedanje vrednosti .....         | 40        |
| 3.3.1.2 Stopnjevalna metoda .....                   | 41        |
| 3.3.1.3 Metoda pričakovanega dobička.....           | 42        |
| 3.3.1.4 Metoda kazalnikov donosnosti .....          | 43        |
| 3.3.1.5 Metoda točk tveganj .....                   | 44        |
| 3.3.2 Modelirni pristop .....                       | 45        |
| 3.3.2.1 Metode klasificiranja oz. razvrščanja ..... | 46        |

|          |                                     |           |
|----------|-------------------------------------|-----------|
| 3.3.2.2  | Regresijske metode .....            | 50        |
| <b>4</b> | <b>MODELIRANJE .....</b>            | <b>51</b> |
| 4.1      | Podatki.....                        | 52        |
| 4.1.1    | Pregled.....                        | 53        |
| 4.1.2    | Izbira obdobja.....                 | 55        |
| 4.2      | Določitev kreditnega limita.....    | 56        |
| 4.3      | Kazalniki .....                     | 57        |
| 4.3.1    | Transformacija .....                | 58        |
| 4.3.2    | Metoda glavnih komponent.....       | 59        |
| 4.4      | Izdelava modela.....                | 61        |
| 4.4.1    | Linearna regresija .....            | 62        |
| 4.4.1.1  | Kratka teoretska predstavitev ..... | 62        |
| 4.4.1.2  | Opis postopka .....                 | 63        |
| 4.4.1.3  | Rezultati .....                     | 64        |
| 4.4.2    | Naive Bayesian klasifikator .....   | 69        |
| 4.4.2.1  | Kratka teoretska predstavitev ..... | 69        |
| 4.4.2.2  | Opis postopka .....                 | 70        |
| 4.4.2.3  | Rezultati .....                     | 71        |
| <b>5</b> | <b>UGOTOVITVE .....</b>             | <b>74</b> |
|          | <b>SKLEP.....</b>                   | <b>75</b> |
|          | <b>LITERATURA IN VIRI .....</b>     | <b>78</b> |
|          | <b>PRILOGE</b>                      |           |

## KAZLO SLIK

|           |                                                             |    |
|-----------|-------------------------------------------------------------|----|
| Slika 1:  | Shema za upravljanje prodaje na kredit .....                | 19 |
| Slika 2:  | Vpliv kreditiranja na končni dobiček.....                   | 22 |
| Slika 3:  | Pregled možnih zavarovanj v primeru prodaje na kredit ..... | 31 |
| Slika 4:  | Možni načini unovčenja terjatev .....                       | 37 |
| Slika 5:  | Prikaz čiščenja podatkov.....                               | 53 |
| Slika 6:  | Pregled podjetij po dejavnosti (v odstotkih) .....          | 53 |
| Slika 7:  | Pregled računov z vidika roka in časa plačila .....         | 54 |
| Slika 8:  | Strukturni pregled računov .....                            | 54 |
| Slika 9:  | Pregled računov in njihove vrednosti po podjetjih .....     | 54 |
| Slika 10: | Predstavitev časovnega izbora .....                         | 55 |
| Slika 11: | Shema za določitev kreditnega limita .....                  | 56 |
| Slika 12: | Porazdelitev relativiziranega kreditnega limita .....       | 57 |
| Slika 13: | Prikaz izbora kazalnikov .....                              | 58 |
| Slika 14: | Celotna varianca razložena po komponentah – PCA.....        | 60 |
| Slika 15: | Predstavniki posameznih komponent – PCA.....                | 61 |
| Slika 16: | Rezultati backward selekcije za predelovalno dejavnost..... | 65 |

|                                                                                             |    |
|---------------------------------------------------------------------------------------------|----|
| Slika 17: Izbrani regresijski model za predelovalno dejavnost .....                         | 66 |
| Slika 18: Rezultati backward selekcije za dejavnost gostinstva.....                         | 67 |
| Slika 19: Izbrani regresijski model za dejavnost gostinstva.....                            | 67 |
| Slika 20: Rezultati backward selekcije za strokovne, znanstvene in tehnične dejavnosti..... | 68 |
| Slika 21: Izbrani klasifikacijski model za predelovalno dejavnost .....                     | 72 |
| Slika 22: Izbrani klasifikacijski model za dejavnost gostinstva .....                       | 73 |



## UVOD

V poslovnem svetu se pod pojmom kreditni limit razume maksimalno vrednost, za katero se je upnik pripravljen do nekoga kreditno izpostaviti. Ta vrednost je običajno določena na podlagi plačilne sposobnosti tistega, do katerega velja kreditna izpostavljenost. Kreditne limite se uporablja za potrebe kreditnih kartic, revolving kreditov, kavcijskih zavarovanj in prodaje na kredit.

Za potrebe magistrskega dela bomo obravnavali kreditne limite z vidika prodaje na kredit. Prodaja na kredit je takšna, za katero ob času nastanka ne prejmemo poplačila, zato nastane terjatev, za katero čaka poplačilo.

Za prodajalca je največji motiv nudenja prodaje na kredit v možnosti povečanja prodaje in s tem same vrednosti podjetja. Na drugi strani predstavlja tak nakup za kupca zelo pomemben kratkoročni vir financiranja, še posebej, za tistega ki nima dostopa do druge oblike financiranja.

Pri prodaji na kredit podjetje proda proizvod ali storitev in namesto plačila sprejme obljubo, da bo v določenem roku poplačano. S tem odlogom plačila se kupcu odobri kredit. Biais in Gollier (1997) sta izpostavila, da s tako prodajo zaupamo svojim kupcem, da so ti dovolj plačilno sposobni in da bodo ob dospelosti tudi voljni poravnati svojo obveznost.

Toda za tem zaupanjem se skriva negotovost o poplačilu za prodajo. To negotovost imenujemo kreditno tveganje. Pomembno je, da se podjetje, ki ponuja prodajo na kredit, zaveda, da ob taki prodaji ni le poslovni partner kupca, temveč postane tudi njegov upnik. S tem pa vstopa v svet financiranja, kjer je ključnega pomena, da se obvladuje kreditno tveganje, ker če se ga ne, lahko to vodi v zelo velike težave.

Ključ dobrega obvladovanja kreditnega tveganja je v njegovem upravljanju. V primeru prodaje na kredit se to izrazi preko upravljanja s terjatvami, ki so nastale kot posledica take prodaje. Pri terjatvah se je treba zavedati, da so v njih vezana sredstva, ki jih je treba financirati, zato je ključnega pomena, da ohranjajo likvidnost.

To pomeni, da se skuša z upravljanjem terjatev zagotoviti, da te ohranijo sposobnost hitrega preoblikovanja v denarno obliko. To pa na tak način, da poskuša zmanjšati tveganje neplačil na najmanjšo možno stopnjo. Zagotovitev tega je mogoče z izvajanjem tistih naporov in ukrepov, ki omogočijo, da se terjatve pravočasno poravnajo. Vsaka dobra politika upravljanja terjatev vsebuje ukrepe na dveh ključnih segmentih, in sicer na kurativnem in preventivnem.

Z vidika kurative je ključnega pomena, da vzpostavimo za kupce pravo kreditno politiko, del katere so tudi kreditni limiti. Glavni namen določanja kreditnih limitov pa je predvsem

v tem, da se podjetje v primeru neplačila zavaruje pred večjimi izgubami. Zato kreditni limit mora izražati vrednost, za katero se je še do posameznega kupca pripravljeno kreditno izpostaviti. Če želi kreditni limit služiti svojemu namenu, zavarovati pred nezaželenimi izgubami, mora ta izražati kupčevo plačilno sposobnost, predvsem pa njegovo sposobnost generiranja zadostnega denarnega toka.

Dodeljevanje pravih vrednosti kreditnih limitov in skrb, da ne presegajo določene meje, je ključnega pomena za notranji sistem obvladovanja terjatev do kupcev (Saunders, 1999, str. 19–20). Načini in postopki določanja kreditnih limitov se lahko v osnovi delijo na strokovne in modelirane.

Strokovni pristopi temeljijo na izkušnjah posameznikov in običajno na konceptu pričakovanih realiziranih donosov, izraženih kot razlika med realiziranim dobičkom pri prodaji in potrebnimi stroški za izterjavo. Modelirani pristopi pa temeljijo na konceptu ugotavljanja zneska, ki ga je v določenem obdobju posamezni kupec sposoben pravočasno poravnati (Dun & Bradstreet, 2011, str. 20–25).

Cilj magistrske naloge je predstaviti, kako lahko za potrebe prodaje na kredit po modeliranem pristopu izdelamo model za določevanje kreditnih limitov. Ob pregledovanju strokovne literature smo našli veliko člankov na temo, kako izdelati model za določevanje kreditnih limitov za potrebe kreditnih kartic in kar nekaj člankov, kako izdelati model, ki skuša napovedati, koliko posojila lahko nekomu odobrimo.

Toda na temo, kako izdelati model za določevanje kreditnega limita za potrebe prodaje na kredit, nismo našli nobenega prispevka. Razlog se skriva v tem, da so ti postopki običajno poslovna skrivnost podjetij, saj jih izdelajo sami, ali od bonitetnih hiš, ki same tržijo izdelave takih modelov svojim strankam, zato jim ni v interesu, da so ti javno dostopni.

Vsi pregledani strokovni članki imajo skupni imenovalec, in sicer, da so bile pri vseh modelih, ne glede na kakšen namen je bil izdelan, uporabljene različne metode z *data mining* področja, predvsem tiste, ki so primerne za napovedovanje.

Tudi v primeru modela za določevanje kreditnega limita za potrebe prodaje na kredit gre pravzaprav za napovedovanje določene vrednosti – skuša se napovedati denarni tok, ki ga je kupec sposoben v določenem obdobju ustvariti. To pa se lahko napove z različnimi metodami za napovedovanje, najbolj pogosto uporabljene so regresijske in klasifikacijske (Dun & Bradstreet, 2011, str. 20–22).

Za potrebe modeliranja bi bilo najbolj ustrezno pridobiti podjetje, ki posluje v okolju B2B, ki ima zadostno velik portfelj kupcev in hkrati razpolaga s kakovostno bazo podatkov o izpostavah do kupcev ter njihovih plačilnih navadah. Toda takšnega podjetja nismo našli. Glavna razloga sta bila, da imajo podjetja premalo različnih števil kupcev, če pa so imela

teh dovolj, niso imela take podatkovne baze, da bi jo lahko posredovala hitro in brez dodatnih stroškov.

Iz tega razloga smo se obrnili na bonitetno hišo Bisnode, ki od leta 2006 na mesečni ravni s pomočjo slovenskih podjetij zbira plačila računov. V 10 letih se je število računov povzpelo na preko 48 milijonov. Na podlagi teh računov smo za slovensko gospodarstvo poskusili izdelati splošni model za določevanje kreditnih limitov, ki bi ga lahko uporabili za namene prodaje na kredit.

V nadaljevanju dela bo predstavljeno, kaj je prodaja na kredit, kateri so glavni motivi za njeno uporabo in kaj na vse vpliva nanjo. Nato bomo prikazali pasti prodaje na kredit in kako se lahko kreditno tveganje, ki nastane zaradi prodaje na kredit, obvladuje. Med ključnimi dejavniki obvladovanja bomo izpostavili določitev prave višine kreditnega limita kot najboljše zavarovanje pred neželenimi izgubami. Na koncu bomo predstavili postopek izdelave modela za določevanje kreditnih limitov.

## **1 PRODAJA NA KREDIT**

### **1.1 Splošna definicija**

Po Slovenskih računovodskih standardih (SRS 5, 2016) je prodaja na kredit oz. na up vsaka prodaja blaga ali storitev, ki ga (jo) kupec v trenutku prenosa nanj še ne plača. To pomeni, da se izvede prodajo z odloženim plačilom. V praksi se uporablja za tak način prodaje tudi izraz komercialni ali blagovni kredit, v angleščini ga najdemo pod izrazom *trade credit*. Nekateri avtorji ga imenujejo tudi prodaja na odprto.

Poenostavljeno bi lahko rekli, da odlog plačila za prodajalca v resnici predstavlja dani kredit kupcu za celotno obdobje odloga plačila – zato prodaja na kredit. Kar pomeni tudi, da prodajalec kupcu zaupa, da bo pravočasno poravnal svojo terjatev – od tod prodaja na up. Medtem ko se v očeh kupca ta isti odlog plačila dojame kot dobljeni komercialni oz. blagovni kredit, saj dobi v uporabo blago, za katerega pa še ni poravnal svoje obveznosti.

Prodaja z odlogom plačila je torej posledica časovne vrzeli, ki nastane med časom dobave in časom plačila. Z vidika računovodstva se ta na strani prodajalca evidentira kot terjatev do kupca, na strani kupca pa kot obveznost do dobavitelja.

Značilnosti prodaje z odlogom plačila niso fiksne ali pravno opredeljene, saj variirajo v odvisnosti od številnih dejavnikov: od poslovnih ter pravnih značilnosti okolja do same značilnosti posameznega podjetja (Ziane, 2011, str. 3).

## 1.2 Prvi zgodovinski zapisi

Odlog plačila je ena najstarejših oblik financiranja podjetij, ki jo zagotavljajo prodajalci svojim kupcem (Wei & Zee, 1997, str. 65). Že leta 1458 je Ben Kotruljevič<sup>1</sup> v delu *Della mercatura et del mercante perfetto* opisal lastnosti prodaje z odlogom plačila.

»V knjigi je zapisal, da se je ta začela predvsem zaradi pomanjkanja denarja, saj trgovci niso imeli dovolj denarja, da bi plačali prejeta blago. Prodaja z odloženim plačilom se je torej začela zaradi uvoza večjih količin dobrin iz daljnih krajev. Trgovci niso imeli dovolj denarja, da bi v naprej poravnali velike količine blaga, ki so ga natovorili na svoje ladje oz. karavane. Zato so kupili blago z odlogom plačila. Ko je trgovec prodal to blago, ga je poplačal z obrestmi vred. Že takrat sta prodajalec in kupec sklenila pisni dogovor, v katerem sta navedla čas poplačila in velikost dolga (glavnica plus dodatek za odloženo plačilo). Pisni dogovor sta overila pri notariatu oz. ob prisotnosti prič – odvisno od poslovnega običaja, ki so ga imeli v kraju, kjer sta naredila zapisnik. Toda že takrat so prodajalci postavljali čim krajši čas plačila, saj so se morali zavarovati pred nenapovedanimi dogodki, kot so vojne, smrt dolžnika, bolezni itn. Preden so odobrili odlog plačila neznanemu kupcu, so se tudi pozanimali pri ostalih, kakšen je. Predvsem so jih zanimale njegove plačilne navade in morebitni nepoplačani dolgovi itn. Če so ugotovili, da je bil kupec na slabem glasu, so mu prodali drugorazredno blago, saj tako v primeru neplačila niso utrpeli prevelike škode. Če pa kupca niso poznali ali pa niso pridobili nobene informacije, so mu najprej posredovali manjše količine blaga, da se ne bi preveč izpostavljali ali utrpeli preveliko izgubo v primeru izginotja oz. neplačila« (Planinšič, 2008, str. 29).

## 1.3 Motivi za uporabo

Glede prodaje na kredit je avtorje predvsem zanimalo, zakaj so prodajalci pripravljeni ponuditi odlog plačila oz. prodajo na kredit in zakaj so kupci sploh pripravljeni uporabljati tako drage oblike financiranja. Zato se teorije motivov uporabe prodaje na kredit v grobem delijo na tiste, ki poskušajo podati odgovor za prodajalce, in tiste, ki poskušajo podati odgovor za kupce.

Prispevki v sklopu ponudbe (Deloof & Jegers, 1996; Long, Malitz & Ravid, 1993; Ng, Kiholm-Smith & Smith, 1999; Pike, Cheng, Cravens & Lamminmaki, 2005; Wei & Zee, 1997) v glavnem izhajajo iz tega, da je glavni motiv za uporabo prodaje na kredit v možnosti povečanja vrednosti lastnega podjetja (Michalski, 2007, str. 42–47). Vendar, kot so že leta 1980 opozorili Lewellen, McConnell in Scott, da to velja le v primerih, ko obstaja nepopolna konkurenca in ko so finančni trgi neučinkoviti.

---

<sup>1</sup>Italijansko: Benedetto Cotrugli ali latinsko Benedictus de Cotrullis.

V primeru popolne konkurence in učinkovitih finančnih trgov prodaja z odlogom plačila ne doprinaša konkurenčne prednosti. Kupci si lahko na finančnih trgih izposojajo po bolj konkurenčnih obrestnih merah ali pa bodo zaradi popolne konkurence vsi ponujali enake prodajne pogoje (Blazenko & Vandezande, 2003, str. 457–459).

Prispevki v sklopu povpraševanja pa temeljijo predvsem na trditvi, da podjetja povprašujejo po odlogu plačila, kadar so njihovi alternativni viri financiranja omejeni. V tem sklopu literature se najpogosteje obravnava odlog plačila kot alternativa bančnim posojilom (Alphonse, Ducret & Eric, 2004; Danielson & Scott, 2004; Deloof & Jegers, 1999; Niskanen J. & Niskanen M., 2006; Petersen & Rajan, 1994; Petersen & Rajan, 1995).

Poznamo tudi avtorje, Petersen in Rajan (1997) ter Marotta (2005), ki so poskušali podati razlago uporabe odloga plačila tako z vidika povpraševanja kot ponudbe. Marotta (2005) je napravil tudi študijo, v kateri je obrazložil odlog plačila s pomočjo gotovinskih popustov in kazni za zamudo.

Ne glede na to, kateri vidik povpraševanja ali ponudbe obravnava posamezna teorija, se lahko povzame, da obstajajo trije prevladujoči motivi za uporabo prodaje na kredit. Ti so lahko finančni, komercialni in operativni (Peterson & Rajan, 1997, str. 663–665). V nadaljevanju se bo za potrebe magistrskega dela predstavilo le motive, ki veljajo za ponudbo, torej za prodajalca, ki nudi prodajo na kredit.

### **1.3.1 Teorije finančnega motiva**

Pri finančnem motivu kot glavni razlog za nudenje prodaje na kredit izpostavljamo plačilno sposobnost in samo sposobnost pridobivanja finančnih virov. Skladno s to teorijo lahko predpostavljamo, da prodajalci, ki imajo lažji dostop do kapitalskega in finančnega trga, beležijo večji obseg prodaje na kredit, kot tisti, ki imajo otežen dostop.

Schwartz (1974) je prvi razvil teorijo, da imajo lahko prodajalci določeno prednost pri preverjanju dejanske kreditne sposobnosti pred tradicionalnimi posojilodajalci. Ta pa se kaže predvsem preko lažje možnosti nadzorovanja in ukrepanja v primeru neplačila. Vse to pa nosi stroškovno prednost v primerjavi s finančnimi institucijami.

Skozi čas so številni avtorji s svojimi študijami potrdili ta vidik in dodali, da se prednost kaže predvsem v treh vidikih (Demirguc-Kunt & Maksimovic, 2001; Emery, 1984; Garcia-Teruel & Martinez-Solano, 2010a; Kohler, Britton & Yates, 2000; Petersen & Rajan, 1997):

**Prvi:** prodajalci lahko enostavneje ocenijo finančno stanje in plačilno sposobnost svojega kupca preko dinamike skupnega poslovanja. Zaradi tega lahko beležijo manjše tveganje pri

odobravanju prodaje na kredit v primerjavi s finančnimi institucijami (Petersen & Rajan, 1997; Garcia-Teruel & Martinez-Solano, 2010a).

**Drugi:** prodajalci, predvsem pa dobavitelji, imajo večjo moč za izterjavo plačila, in sicer preko grožnje zmanjšanja prihodnje dobave. To velja predvsem na trgih, kjer imajo dobavitelji večjo tržno moč oz. kjer ne obstaja konkurenca med njimi. V nasprotju imajo lahko finančne institucije omejitve zaradi insolventne zakonodaje ali pa težave zaradi dolgih sodnih procesov, ko želijo unovčiti svoje zavarovanje (Demirguc-Kunt & Maksimovic, 2001; Emery, 1984). Zaradi tega so predvsem dobavitelji pripravljeni ponuditi oz. zagotoviti višji komercialni kredit, kot bi ga bile pripravljene ponuditi same finančne institucije (Cunat, 2007, str. 491–496).

**Tretji:** obstajajo dejavnosti, v katerih lahko prodajalci v primeru neplačila enostavno prevzamejo blago nazaj in ga ravno tako hitro preprodajo naprej. Na drugi strani pa finančne institucije tega ne zmorejo, saj nimajo izdelanih tovrstnih prodajnih kanalov (Li, 2011, str. 10–12).

Brick in Fung (1984) pa sta izpostavila, da je glavni finančni motiv za uporabo prodaje na kredit v davčnem učinku. Hipoteza avtorjev je, da podjetja v visokem davčnem razredu običajno ponudijo več komercialnega kredita od tistih v nižjih davčnih razredih. To pa zato, ker lahko na tak način znižajo stroške financiranja prodaje na kredit, saj so obresti davčno priznani stroški.

### 1.3.2 Teorije komercialnega motiva

Pri komercialnem motivu kot glavni razlog za nudenje prodaje na kredit izpostavljamo možnost povečanja prodaje. Predvsem pomeni dober instrument, ki omogoča cenovno diskriminacijo, lojalnost kupcev in posredni marketing za izpostavljanje kakovosti.

**Teorija cenovne diskriminacije** pravi, da motiv za nudenje prodaje na kredit leži v tem, da omogoči med kupci cenovno diskriminacijo. Cenovna diskriminacija pa omogoča hitrejšo in večjo prodajo, kar so v svojih raziskavah potrdili tudi Petersen in Rajan (1997) ter Ng et al. (1999).

Vendar sta Fisman in Love (2003) izpostavila, da se lahko prodajo na kredit uporablja kot orodje za cenovno diskriminacijo le v treh primerih:

- Povpraševanje kupcev, ki uporabljajo komercialni kredit, mora biti manj elastično od povpraševanja kupcev, ki plačujejo z denarnimi sredstvi. Manj elastičnosti implicira konstantno povpraševanje, zatorej stabilen odnos med kupci in dobavitelji.

- Na trgu mora obstajati asimetričnost informacij. Le v takih situacijah, ko kupec ne beleži vseh informacij o določen izdelku ali storitvi, in le v takih situacijah si lahko prodajalec s pomočjo prodaje na kredit poveča prodajo.
- Med prodajalci mora obstajati konkurenca, kar pomeni, da prodajalec tekmuje s svojimi konkurenti s pomočjo prodaje na kredit.

Brennan, Miksimovic in Zechner so že leta 1988 izpostavili, da se tudi v primerih, ko obstajajo enaki kreditni pogoji za vse kupce, v resnici že izvaja cenovna diskriminacija. Tisti kupci, ki imajo dostop do drugih cenejših virov, naj bi namreč poskušali realizirati predplačila in tako pridobiti prihranek. Kupci, ki nimajo dostopa do drugih cenejših virov, bodo verjetno plačali na dan zapadlosti, da bodo preprečili nastanek stroškov zaradi zamudnih obresti.

Tako so že takrat podali tezo, da sta samo obdobje odloga plačila in podani popust za predčasna plačila orodji za cenovno diskriminacijo. Na podlagi te teorije sta leta 2002 Wilson in Summers dodala, da uporabljeni dejanski kreditni pogoji s strani kupca v resnici določijo dokončno ceno blaga.

**Teorija zvestobe** pravi, da motiv za nudenje prodaje na kredit leži v tem, da omogoči zvestobo kupcev, kar pa zagotovi permanentno prodajo in konstantno rast. Ng et al. (1999) so med prvimi podali potrditve, da dobavitelji lahko podaljšajo odlog plačila ali ponudijo večji popust na podlagi dolgoročnega sodelovanja s kupcem.

Cheng in Pike (2003) pa sta izpostavila, da obstaja velika razlika med podjetji v motivih, zakaj nudijo prodajo na kredit. Med vsemi pa prevladuje motiv, ki vidi tak način prodaje kot dober pripomoček, ki poda možnost izgradnje tesnega sodelovanja oz. močne vezi s kupci.

Na koncu je treba povzeti še Li (2011), ki dodaja, da čeprav je prodaja na kredit veja kratkoročnega načina financiranja, se lahko na to gleda tudi kot na del dolgoročne strategije obstoja, saj edino vzdrževanje odnosov s strankami omogoča permanentno prodajo in rast.

**Teorija kakovosti** izpostavlja, da se lahko prodajo na kredit obravnava kot orodje, ki pokaže kakovost blaga, in sicer v smislu, da se dopusti kupcu čas, da lahko sam oceni kakovost pred dejanskim plačilom (Garcia-Teruel & Martinez-Solano, 2010a; Smith, 1987).

Lee in Stowe (1993) sta povezala višino popusta, ki ga dobavitelj ponuja ob takojšnjem plačilu, s kakovostjo proizvoda. Ugotovila sta, da prodajalci, ki ponujajo proizvode nižje

kakovosti, ponujajo višje popuste za takojšnje plačilo. Na koncu pa sta zaključila, da proizvajalci, ki s popusti spodbujajo takojšnje plačilo, prevalijo del kvalitetnega tveganja na kupca.

Tudi Long et al. (1993) so v raziskavi potrdili, da je odobravanje daljših odlogov plačila substitut za zagotovilo kakovosti. Še posebej pa so izpostavili, da je odlog plačila pomemben za podjetja, ki šele vstopajo na trg.

Do podobnih spoznanj so prišli tudi Garcia-Teruel in Martinez-Solano (2010a) ter Smith (1987). Ti so ugotovili, da so prodajalci za izdelke, ki potrebujejo več časa, da se oceni njihova kakovost, pripravljene ponuditi daljše plačilne odloge plačila. Zato so zaključili, da podjetja, ki ponujajo visoko kakovostne izdelke, nudijo daljše odloge plačila, kot tista, ki ponujajo izdelke nižje kakovosti. To še posebej velja za podjetja, ki so nova na trgu.

### 1.3.3 Teorije operativnega motiva

Pri operativnem motivu se kot glavni razlog za nudenje prodaje na kredit izpostavlja možnost biti bolj stroškovno učinkovit. Leta 1981 je Ferris podal teorijo, ki pravi, da je glavni motiv za nudenje odloga plačila v namenu znižanja stroškov, ki so povezani s transakcijami. S tem so se strinjali tudi Emery (1984) ter Frank in Maksimovic (2004).

Sčasoma so se razvile tudi teorije, ki obravnavajo operativni motiv z vidika drugih stroškov. Danes lahko rečemo, da obstajata dve osnovni teoriji: prva temelji na administrativnih stroških, druga pa na sezonski komponenti.

**Teorija administrativnih stroškov** temelji na transakcijski teoriji. In sicer, kot so Kohler et al. (2000) izpostavili, da je pravi motiv za časovno delitev dostave in plačila v nižjih administrativnih stroških, ki nastanejo tako na strani dobavitelja kot kupca, če jih primerjamo s stroški v primerjavi s plačilom ob vsaki dostavi.

**Teorija sezonske komponente** pravi, da se podjetja, ki imajo sezonsko komponento, soočajo z dvema velikima stroškoma, in sicer stroškom skladiščenja in financiranja zaloge. Ob tem še obstaja tveganje, da zaloge v sledeči sezoni ne bodo prodajljive (Bougheas, Mateut & Mizen, 2009, str. 300–301).

Zaradi tega tveganja zagovorniki teorije pravijo, da se je bolje izpostaviti tveganju prodaje na kredit v času, ko je prodaja slabša, ker se s tem znižajo stroški financiranja zalog in skladiščenja. Na podlagi te teorije se tudi pričakuje, da se podjetja s hitro rastočo prodajo bolj zatekajo k financiranju prodaje na kredit, kakor da financirajo svoje zaloge (Bougheas et al., 2009, str. 301).

Emery (1984) izpostavlja, da operativni motiv obstaja samo takrat, ko povpraševanje s strani kupcev ni konstantno. Ko torej zaradi negotovosti in sezonskih nihanj povpraševanje po blagu ni redno, se mora dobavitelj ustrezno odzvati ob nihanju povpraševanja s spremembo cene in ravnijo proizvodnje. Toda oba ukrepa doprinašata dodatne stroške. Zato je boljša rešitev v takih obdobjih uporaba bolj sproščene politike odobravanja prodaje na kredit, ker omogoči ublažitev učinka nihanja v povpraševanju.

#### **1.3.4 Pomanjkljivosti teh teorij**

Čeprav vse predstavljene teorije poskušajo pojasniti obstoj oz. motiv prodaje na kredit na različne načine in z različnih vidikov, pa ne zmore nobena zagotoviti popolne razlage, saj se ta spreminja glede na poslovno okolje, dejavnost in tip podjetja (Burkart & Ellingsen, 2004, str. 569–571).

Frank in Maksimovic (2004) sta izpostavila, »da obstoječe teorije kažejo le učinke, ki bi lahko bili pomembni le v določenih okoliščinah, vendar nobena ne zajame bistva za razlago vsestranske uporabe prodaje na kredit in njenih ponavljajočih vzorcev«.

Največ očitkov med vsemi teorijami je bila deležna teorija finančne prednosti. Burkart in Ellingsen (2004) sta opozorila predvsem na dve glavni pomanjkljivosti: »Prva je ta, da so banke bolj specializirane pri ocenjevanju kreditne sposobnosti posojilojemalcev kot prodajalci, in potem takem ni logično, da te ne bi pridobile dovolj informacij. Druga pomanjkljivost pa leži v tem, če so prodajalci oz. dobavitelji tako dobri pri oceni plačilne sposobnosti kupca, zakaj potem ne posojajo denarja direktno, namesto da ga posojajo preko dobave?«.

Frank in Maksimovic (2004) pa sta še dodatno izpostavila, da v primeru, ko dobavitelj ne dobi plačila za svoje blago, ga lahko izterja v naravi in preproda naprej, vendar le takrat, ko to blago ni že spremenjeno v končni izdelek. Če je že spremenjeno ali integrirano v končni izdelek, to potemtakem ni več mogoče. S tega vidika se prednost v zavarovanju dobavitelja pred finančnimi institucijami zmanjša. Burkart in Ellingsen (2004) sta še izpostavila, da prednost prodajalca, da lahko znova prevzame blago nazaj in ga preproda naprej, ne velja v storitvenih dejavnostih.

Tudi davčni vidik ima svoje pomanjkljivosti, saj ne velja oz. ne zadostuje v primerih, ko so podjetja v istem davčnem razredu (Bastos & Pindado, 2008, str. 2635).

Z vidika komercialnega motiva se teoriji cenovne diskriminacije očita, da ne velja v okoljih popolne konkurence oz. v zelo konkurenčnih panogah. Burkart in Ellingsen (2004) sta izpostavila, da se v dejavnostih, kjer obstaja veliko konkurence, uporablja prodajo na kredit le kot marketinški instrument. Ob tem sta avtorja opozorila tudi na to, da teorija

kakovosti izdelka ni primerna za homogene proizvode in da teorija zvestobe ne pride v poštev pri posameznih poslovnih transakcijah oz. enkratnih nakupih.

Teoriji kakovosti blaga se tudi očita, da ne pojasni, zakaj nekatera podjetja sploh ne ponujajo odloga plačila in zakaj nekatera podjetja celo zahtevajo od svojih kupcev, da plačajo vnaprej (Bastos & Pindado, 2008, str. 2635).

Pri operativnem motivu se predvsem teoriji transakcijskih stroškov očita, da prodaja na kredit ni zgolj operativno orodje. Če bi se prodajo na kredit uporabljalo samo kot operativno orodje, ki omogoča znižanje stroškov transakcij, bi se pričakovalo, da bi se obseg prodaje na kredit znižal na račun izboljšav v informacijski tehnologiji. Vendar tega ni opaziti (Bastos & Pindado, 2008, str. 2635).

## **1.4 Splošni pomen za gospodarstvo**

Čeprav v literaturi ni skupne razlage, zakaj so podjetja pripravljena ponuditi prodajo na kredit, pa se vendar večina nastalih teorij združi v prepričanju, da odlog plačila pomaga rešiti nepopolnost oz. neučinkovitost finančnega trga in tako omogoča normalno poslovanje (Blazenko & Vandezande, 2003; Burkart & Ellingsen, 2004; Rodriguez-Rodriguez, 2006; Van der Wijst & Hol, 2002).

Normalno poslovanje pa omogoča, ker prodajalec s prodajo na kredit prevzame finančno posredno vlogo med kupci in finančnimi institucijami. Prodaja na kredit je najbolj priljubljena alternativa bančnim kreditom predvsem zaradi hitre dostopnosti in zaradi asimetrije informacij, ki obstaja med prodajalcem in kupcem (Jain, 2001, str. 89–91).

Finančna posredna vloge pride še bolj do izraza v gospodarstvih, v katerih se vodi restriktivna monetarna politika ali v katerih finančni sistemi temeljijo na bankah. Že leta 1974 je Schwartz poudaril, da je restriktivna monetarna politika tista, ki spodbuja prodajo na kredit. V obdobju restriktivne monetarne politike so podjetja, ki še imajo dostop do zunanjih finančnih virov, edina pripravljena ponuditi prodajo na kredit svojim kupcem. In ti ga bodo sprejeli, saj bodo stroški nižji od kreditov, ki bi mu jih ponudile banke, če bi le-tega sploh odobrile.

Nilsen (2002) je tudi poudaril, da je uporaba komercialnega kredita povezana z načinom vodenja monetarne politike. Po njegovem mnenju so komercialni krediti zamenjava za bančne, čeprav ti niso najboljša izbira. To je potrdil z raziskavo, v kateri je ugotovil, da ne glede na velikost uporabljajo več komercialnih kreditov v restriktivni monetarni politiki. To pa zato, ker jim v takem okolju ti predstavijo edini dostopen zunanji vir financiranja. Pred začetkom raziskave je predpostavljal, da imajo večja podjetja več različnih možnosti dostopa do zunanjih virov in se zaradi tega ne poslužujejo tovrstnih virov financiranja. Toda izkazalo se je ravno obratno. V času restriktivne monetarne politike tudi velika

podjetja povečajo obseg komercialnega kredita, in sicer še v večjem obsegu kot majhna podjetja.

Nilsen (2002) je na koncu raziskave navedel, da se skuša večina podjetij običajno izogniti komercialnemu kreditu, ko so njihovi stroški višji od bančnih. Iz tega je povzel, da podjetja uporabijo komercialni kredit samo takrat, ko beležijo finančne omejitve in nimajo drugega razpoložljivega vira za financiranje.

Garcia-Teruel in Martinez-Solano (2007) sta izpostavila, da imajo podjetja, ki poslujejo v finančnih sistemih, kjer prevladujejo banke, zelo malo možnosti oz. alternativ, da pridobijo zunanja financiranja. Zato se bolj zanašajo na kratkoročne vire financiranja, med katerimi pa prevladuje komercialni kredit, dan s strani dobaviteljev.

Emery je že leta 1984 navedel, da morajo imeti dobavitelji, če želijo ustvarjati dobiček v poslovnih okoljih, kjer finančni trgi niso dobro razviti, več likvidnostnih rezerv, da lahko vodijo za svoje kupce bolj sproščeno kreditno politiko.

Demirguc-Kunt in Maksimovic (2001) navajata, da v državah, kjer finančni trgi niso dobro razviti, podjetja zlahka finančno trpijo zaradi težjega dostopa do zunanjih virov financiranja. Zato se vir za dodatno financiranje premakne na dobavitelje, ki pa v resnici niso finančne institucije.

## **1.5 Dejavniki, ki vplivajo na uporabo**

Glede na rezultate najdenih raziskav ugotavljamo, da je na uporabo prodaje na kredit vezanih veliko različnih dejavnikov, oz. da lahko nanjo vplivajo različni dejavniki tako na strani povpraševanja kot ponudbe (Demirguc-Kunt & Maksimovic, 2001; Garcia-Teruel & Martinez-Solano, 2010b; Huyghebaert, 2006; Nilsen, 2002; Niskanen J. & Niskanen M., 2006; Petersen & Rajan, 1997).

Nekateri od teh dejavnikov so povezani z razvojem posameznega gospodarstva, na primer BDP, obrestne mere, razvoj finančnih sistemov in pravnih struktur. Našteti dejavniki sodijo v t.i. makroekonomske dejavnike, ki jih podjetja ne morejo nadzirati (Demirguc-Kunt & Maksimovic, 2001, str. 1–7).

Na drugi strani pa obstajajo dejavniki, ki so podani s strani panoge, v kateri podjetje posluje. Fisman in Love (2003) ter Ng et al. (1999) so dokazali, da se uporaba prodaje na kredit oz. odloga plačila zelo razlikuje med panogami, medtem ko je znotraj panoge razlike redkeje zaznati. Panoge, v katerih ne potrebujejo materialnih zalog, ne potrebujejo prodaje na kredit, medtem ko tiste panoge, ki zaloge potrebujejo, le-to uporabljajo (Niskanen J. & Niskanen M., 2006, str. 82–85).

Smith (1987) je pripomnil, da so znotraj posamezne panoge pogoji za prodajo na kredit konstantni tako za prodajalce kot za kupce. Torej so v isti panogi kreditni pogoji enaki za vse udeležence. Zato je Smith (1987) prepričan, da je treba usmeriti razpravo dejavnikov, ki vplivajo na prodajo na kredit, na značilnosti posameznega podjetja.

Podobno sta tudi Brigham in Houston (2009) izpostavila, da so dejavniki, kot so makroekonomski pogoji, poslovni običaji in stopnja konkurence, že vnaprej dani. Zaradi tega je edini pravi dejavnik, ki vpliva na obseg prodaje na kredit posameznega podjetja, njegova specifičnost.

S tem je na eni strani mišljena predvsem vrsta politike, ki jo vodi podjetje na področju prodaje in obratnega kapitala, na drugi pa možnosti podjetja, da ohranja likvidnost, in sposobnosti pridobivanja zadostnih virov financiranja (Vernimmen, Quiry, Dallochio, Le Fur & Salvi, 2005, str. 217–232).

### **1.5.1 Značilnosti posameznega podjetja**

Wilson in Summers (2002) sta poudarila, da pri prodaji na kredit obstaja dvosmernost, saj enkrat podjetje ponuja prodajo na kredit, drugič pa jo sprejema. Tudi Niskanen J. in Niskanen M. (2006) ter Petersen in Rajan (1997) so poudarili, da obseg prodaje na kredit pri določenem podjetju ni odvisen samo od njegovih kupcev, torej povpraševanja po njem, temveč tudi od finančne situacije njegovih dobaviteljev.

Obseg prodaje na kredit ni odvisen le od lastne sposobnosti podjetja, torej kolikšen obseg prodaje na kredit lahko zagotavlja, temveč tudi od tega, koliko so dobavitelji pripravljeni in sposobni financirati njegovo prodajo na kredit. Skladno z Garcia-Teruel in Martinez-Solano (2010a), Petersen in Rajan (1997) ter Wilson in Summers (2002) se predlaga 8 značilnosti podjetja, ki določajo odobreni obseg prodaje na kredit:

- dolžina proizvodnega cikla,
- odvisnost od kupcev,
- potreba po rasti prodaje,
- zmožnost ustvarjanja dovolj visoke marže,
- ustvarjanje zadostnega denarnega toka,
- izbrana politika obratnega kapitala,
- kreditna sposobnost,
- strošek vzdrževanja finančnega dolga.

**Dolžina proizvodnega cikla:** kot prvo značilnost je treba izpostaviti potrebno dolžino proizvodnega cikla za izdelavo določenega proizvoda. Dolžina proizvodnega cikla je sinonim za kakovost. Zato so podjetja pripravljena za izpostavitve svoje kakovosti nuditi

daljše odloge plačila in večje obsege prodaje na kredit. Garcia-Teruel in Martinez-Solano (2010a) sta privzela, da je obrat sredstev brez terjatev sinonim za dolžino proizvodnega cikla, in dobila rezultat, da je ta negativno povezan s poslovnimi terjatvami, in tako potrdila zgornjo tezo.

**Odvisnost od kupcev:** kot drugo značilnost se izpostavi odvisnost od svojih kupcev. Podjetja, ki poslujejo v zelo konkurenčni dejavnosti, so pripravljena ponuditi večje obsege prodaje na kredit, kakor tista, ki nimajo konkurence. Petersen in Rajan (1997) sta poudarila, da so odnosi med dobavitelji in kupci tisti, ki najbolj vplivajo na obseg prodaje na kredit, predvsem pa njuna medsebojna poslovna odvisnost.

**Potreba po rasti prodaje:** kot tretjo značilnost se izpostavi potrebo po rasti. Emery je že leta 1984 dokazal, da lahko podjetja uporabljajo prodajo na kredit kot marketinško orodje za povečanje prodaje. Tudi Petersen in Rajan (1997) sta izpostavila, da kdor želi povečati rast prodaje, mora nuditi večji obseg prodaje na kredit. Enako sta potrdila Niskanen J. in Niskanen M. (2006), in sicer, da lahko podjetja pospešijo svojo prodajo tako, da nudijo bolj sproščeno kreditno politiko in daljše odloge plačila, kot jih nudi konkurenca.

Kot zanimivost se lahko izpostavi raziskavi avtorjev Garcia-Teruel in Martinez-Solano (2010a) ter Petersen in Rajan (1997). V prvi ugotavljajo pozitivno povezavo med rastjo prodaje in poslovnimi terjatvami, v drugi pa negativno ter pozitivno le v primeru, ko prodaja pada.

Nastala razlika je posledica različnega časovnega obdobja, v katerem sta bili raziskavi napravljeni. Prva je bila izvedena v obdobju cvetočega gospodarstva, medtem ko druga v obdobju krize. Iz tega se lahko povzame, da ko nastopi kriza, se terjatve začnejo kopičiti, prodaja pa začne padati. Komur uspe, da še vedno raste, pa v takih časih ni pripravljen vsakemu ponujati prodaje na kredit.

**Zmožnost ustvarjanja dovolj visoke marže:** kot četrto značilnost se izpostavi zmožnost ustvariti dovolj visoke marže. Med vsemi značilnostmi je ta tudi najbolj pogosto izpostavljena. Emery je že leta 1984 ugotovil, da podjetja z višjo maržo nudijo večje obsege prodaje na kredit in tako dosegajo večjo prodajo kot tista z nižjo.

Tudi Garcia-Teruel in Martinez-Solano (2010a) ter Petersen in Rajan (1997) so ugotovili, da podjetja, ki dosegajo višjo maržo, ponujajo večji obseg prodaje na kredit, kot tista, ki dosegajo nižjo. Ob tem so pojasnili še, da višja marža omogoča podjetjem, da lažje sprejmejo nižji zaslužek oz. celo kakšno izgubo v primeru neplačila, zaradi česar nudijo večje obsege prodaje na kredit.

**Ustvarjanje zadostnega denarnega toka:** kot peta značilnost je izpostavljena zmožnost ustvarjanja lastnega denarnega toka. To pomeni, da je prodaja na kredit, odvisna predvsem od količine denarnega toka, ki ga lahko podjetje ustvari v določenem obdobju.

Predpostavlja se, da obstaja negativna povezava med lastnim denarnim tokom in poslovnimi obveznostmi, medtem ko obstaja pozitivna s terjatvami. To sta z raziskavo prva dokazala Garcia-Teruel in Martinez-Solano (2010a). Podjetja z višjo stopnjo ustvarjanja lastnih denarnega tokov potrebujejo manj zunanega financiranja, torej manj poslovnih obveznosti, ob tem pa lahko nudijo večje obsege prodaje na kredit, kar poveča obseg terjatev (Garcia-Teruel & Martinez-Solano, 2010a, str. 230–231).

**Izbrana politika obratnega kapitala** vključuje odločitve, ki so predvsem povezane z obsegom zalog in poslovnih terjatev. Zato je politika obratnega kapitala pravzaprav politika kratkoročnega investiranja, ki se odloča, koliko bo investirala v terjatve in koliko pa v zaloge.

Podjetje lahko vodi tri različne politike obratnega kapitala: omejevalno, sproščeno in zmerno. Omejevalna politika beleži minimalni obseg vezanih sredstev, kar pomeni, da ne spodbuja prodaje na kredit, medtem ko sproščena beleži velik obseg, kar pomeni, da bolj spodbuja prodajo na kredit. Zmerna politika pa beleži zmerni obseg vezanih sredstev, kar potemtakem velja tudi za uporabo prodaje na kredit (Berk et al., 2006, str. 246).

**Kreditna sposobnost** pomeni imeti možnost pridobivanja zunanjih finančnih virov. Ta sposobnost je povezana s starostjo in velikostjo podjetja. Schwartz (1974) navaja, da imajo starejša in večja podjetja boljši kreditni ugled za plačevanje svojih obveznosti – in to predvsem zaradi časa obstoja in večjega obsega ekonomije.

Petersen in Rajan (1997) sta prav tako predpostavljala, da večja in starejša podjetja ponujajo večji obseg prodaje na kredit, saj imajo lažji dostop do bančnih virov v primerjavi z majhnimi in mladimi podjetji. Ob tem sta pripomnila, da imajo lahko lažji dostop do bančnih virov tudi nekatera manjša podjetja, pa kljub temu ne beležijo velikih obsegov prodaje na kredit, in to predvsem zaradi manjšega obsega ekonomije.

Zato so Bougheas et al. (2009), Garcia-Teruel in Martinez-Solano (2010a), Niskanen J. in Niskanen M. (2006) ter Petersen in Rajan (1997) predpostavljali, da sta starost in velikost podjetja pozitivno povezani z obsegom poslovnih terjatev. Iz tega bi se lahko sklepalo, da starejša in večja podjetja nudijo več prodaje na kredit svojim kupcem in imajo posledično tudi večji obseg terjatev do njih. Toda Garcia-Teruel in Martinez-Solano (2010a) tega niso mogli dokazati za vse države. Tako so ugotovili, da obstaja pozitivna povezava le v državah, kjer so finančni sistemi dobro razviti in banke nimajo glavne vloge. V državah s finančnimi sistemi, z banko v glavni vlogi se te povezave ni moglo dokazati.

**Strošek vzdrževanja finančnega dolga:** kot osmo lastnost se je izpostavil strošek vzdrževanja lastnega finančnega dolga. Petersen in Rajan (1997) sta to obrazložila tako, da imajo podjetja z večjo možnostjo pridobivanja finančnega dolga zmožnost odobritve več prodaje na kredit, medtem ko podjetja, ki se soočajo z višjimi stroški financiranja, niso pripravljene financirati svojih kupcev. V primeru poslovnih terjatev se potemtakem predpostavlja pozitivna povezava z možnostjo pridobivanja finančnega dolga in negativna s stroški financiranja.

## **1.6 Terjatve kot posledica prodaje na kredit**

Terjatve do kupcev so tiste, ki nastanejo kot posledica odobritve prodaje na kredit. To pomeni, da sta bila blago ali storitev že prenesena na kupca, ta pa še ni poravnal svoje obveznosti, zaradi česar ima potem prodajalec pravico terjati poplačilo. Na splošno bi lahko opredelili, da so terjatve opredeljene kot pravica zahtevati od neke osebe poplačilo določenega dolga, dobavo stvari ali izvršitev neke storitve.

»Terjatve so na premoženjskopравnih in drugih razmerjih zasnovane pravice zahtevati od določene osebe plačilo dolga, ali v primeru danih predplačil dobavo kakih stvari ali opravitev kake storitve. V vsakem primeru, razen v primeru danih predplačil, gre za vzporejanje pogodbene pravice ene stranke, da dobi denar, z ustrežno obveznostjo druge pogodbene stranke, da izpolni obveznost. Terjatve se pojavljajo večinoma do kupcev ali prevzemnikov terjatev ali drugih financerjev prodanih proizvodov in opravljenih storitev, lahko pa tudi do dobaviteljev prvin poslovnega procesa, zaposlenih, udeležencev pri razporejanju poslovnega izida, financerjev, uporabnikov finančnih naložb in do države. Vključujejo tudi poslovne terjatve iz poslovanja za tuj račun, za odškodnine ter terjatve iz drugih poslovnih razmerij« (SRS 5, 2016).

Terjatve se glede na zapadlost v plačilo razčlenjujejo na dolgoročne in kratkoročne. Za potrebe konsolidacije se razčlenjujejo še na tiste, ki se nanašajo na organizacije v skupini, pridružene organizacije in druge. Za potrebe obračunavanja davkov in valutnega tveganja pa se lahko terjatve delijo še na tiste, ki se nanašajo na stranke v državi, in na tiste, ki se nanašajo na stranke v tujini.

Z vidika prepoznavanja se terjatve v knjigovodskih razvidih in bilanci stanja prepozna kot sredstvo, če obstaja verjetnost, da bodo pritekale gospodarske koristi, povezane z njo, in če je mogoče njeno izvirno vrednost zanesljivo izmeriti (SRS 5, 2016).

## **1.7 Pasti uporabe**

Prodaja na kredit posredno vpliva na proces kroženja denarja vsakega podjetja. Zaradi takšne prodaje nastanejo terjatve do kupcev, na drugi strani pa se obstoječe zaloge

zmanjšajo. Obe postavki sta del obratnega kapitala in njuna hitrost obračanja vpliva na denarni tok vsakega podjetja (Lamberg, 2009, str. 20).

Vsebinsko gledano predstavlja obratni kapital razkorak med izdatki za nabavljene prvine in prejemki za prodane izdelke. Zato je neposredno povezan s procesom kroženja denarja (Shin & Soenen, 1998, str. 37–38).

Pass in Pike (1987) sta poudarila, da sta neustrezno načrtovanje in nadzor obratnega kapitala glavna vzroka, da podjetja postanejo insolventna. Ob tem pa je Kolay (1991) tudi dodal, da ko nastopijo problemi v obratnem kapitalu, ti nastopijo po eksponentni poti. To pomeni, da problemi iz preteklosti stopnjujejo probleme v sedanosti in v sledečih fazah.

Petersen in Rajan (1997) sta izpostavila, da gre pri prodaji na kredit pravzaprav za razpravo o terjatvah do kupcev, saj na sam obseg zalog vpliva še veliko drugih dejavnikov. Če so zaloge tista komponenta obratnega kapitala, pri kateri nimamo veliko manevrskega prostora zaradi narave posla, ki ga izvajamo, so potem takem terjatve tiste, kjer to možnost imamo.

Izmed vseh komponent obratnega kapitala so terjatve do kupcev tiste, ki tudi najhitreje vplivajo na denarni tok. Ko se te poravnajo v bolj ali manj dogovorjenih rokih, proces kroženja denarja ni ogrožen. Če se pospeši njihova unovčitev, se sproščajo dodatna denarna sredstva, saj se potreben čas kroženja denarja skrajša.

Problemi nastopi, ko kupci iz različnih razlogov ne poravnajo svojih obveznosti v dogovorjenem roku. Vzroki za neplačilo so lahko različni. Kupec lahko izkorišča svoj položaj in ne plača računa ob dogovorjenem roku, temveč kasneje. Lahko pa se zgodi, da kupec ni tehnično plačilno sposoben, vendar namerava plačati kasneje. Če dejansko ni plačilno sposoben, saj je začel enega od insolventnih postopkov, se lahko zgodi, da terjatev ne bo poravnana (Repovž, 1994, str. 113–114).

Vsaka neplačana terjatev negativno vpliva na denarni tok podjetja, saj se potreben čas kroženja denarja podaljša. Če so v podjetju s temi prilivi načrtovali plačilo svojih obveznostih, se lahko podjetje znajde v tehnični plačilni nesposobnosti (Kristanc, 2010, str. 55–65).

Če je obseg zapadlih neplačanih terjatev velik, bo moralo podjetje najti drugačne vire financiranja za ponovni zagon sledečega proizvodnega cikla. Ali z najemom dodatnih virov financiranja ali pa zmanjševanjem investicijske dejavnosti. Prva možnost poslabša plačilno sposobnost, druga pa zavira rast podjetja (Kristanc, 2010, str. 58).

Terjatve do kupcev, ki so nastale zaradi prodaje na kredit, predstavljajo tudi obliko premoženja, v kateri so vezana denarna sredstva. Te zaradi časovne oddaljenosti od

trenutka nastanka do trenutka njene unovčitve beležijo tveganje, da lahko izgubijo na vrednosti, in to predvsem zaradi (Rebernik & Repovž 2000, str. 110):

- **padajoče časovne vrednosti denarja**, in to predvsem v času večje inflacije, ali pa samo zaradi valutnega tveganja, ko je poslovanje mednarodno;
- **tveganja neplačila**, ki v skrajnih primerih pripelje do delnega ali pa celotnega odpisa posameznih terjatev.

Terjatve, zaradi padajoče časovne vrednosti denarja, in tveganja neplačil, ne prinašajo nobenega donosa (Repovž, 1994, str. 114). Ravno nasprotno, če se izkaže, da terjatev ne bo plačana, jo lahko podjetje odpiše in tako zabeleži le izgubo (Igličar & Hočevár, 2011, str. 107).

Barry (1997) je izpostavil, da v takih primerih nastopijo tudi stroški izgubljene priložnosti ker sredstva se ima vezana v terjatvah in se jih ne more uporabiti za svoje poslovanje. Brigham in Ehrhardt (2011) pa sta še dodala, da prodaja na kredit, poleg stroškov izgubljene priložnosti nosi še dodatne stroške, kot so:

- stroški za pridobivanje informacij in ocena tveganja,
- strošek odobritve prodaje na kredit,
- administrativni in režijski stroški, povezani s spremljanjem in nadzorom,
- stroški financiranja terjatev,
- stroški, povezani z unovčenjem in izterjavo.

Bolj kot je kreditna politika pri upravljanju terjatev sproščena, boljša je za prodajo, vendar pa lahko povzroči večje stroške za podjetje (Dolenc & Stubelj, 2011, str. 191).

Zato je za vsako podjetje smotno, da obvladuje svojo prodajo na kredit, in to ne samo zato, ker je možnost, da se izgubi na vrednosti vloženih sredstev, temveč tudi zaradi tveganja nelikvidnosti in delanja izgube. Prevelik obseg neporavnanih zapadlih terjatev negativno vpliva na likvidnost podjetja, saj upočasni njegov krogotok denarja in to lahko v določenem trenutku privede do potrebe po najemanju dodatnih zunanjih virov, ki pa imajo svojo ceno.

Če se to ponavlja v nedogled, lahko taka situacija pripelje do velikega finančnega bremena. Ob morebitnem padcu prodaje ali negativnem izrednem dogodku pa lahko postane takšno finančno breme dolgoročno nevzdržno (Selan, 2004, str. 10).

Obseg terjatev vpliva na stroške financiranja obratnega kapitala, medtem ko kakovost, izražena preko hitrosti obračanja, vpliva na likvidnost posameznega podjetja. Zaradi tega mora podjetje ukrepati v smeri, da se obseg terjatev ohranja na želenem obsegu. To pa je

mogoče le tako, da se skuša zagotoviti čim manjše tveganje neplačila in izgube že ob samem nastanku terjatve (Kristanc, 2009, str. 72). To z drugimi besedami pomeni, da mora podjetje s prodajo na kredit upravljati.

## 2 UPRAVLJANJE

Upravljanje prodaje na kredit je zelo kompleksen in zahteven proces, in če ga želimo obvladovati, je treba voditi točno definirano politiko tudi na tem področju. To pomeni, da je treba vzpostaviti t.i. **politiko upravljanja terjatev**.

Terjatve do kupcev so tiste, ki nastanejo kot posledica odobritve prodaje na kredit. Nepravilno upravljanje s prodajo na kredit povečuje tveganost neplačanih terjatev. Velik delež neplačanih terjatev lahko vpliva na finančno moč vsakega podjetja, saj se tako podaljšuje obdobje trajanja denarnega cikla, to pa poveča potrebo po dodatnem financiranju svojega poslovnega procesa (Ademovič, 2008, str. 1).

Namen te politike je zagotoviti optimalni obseg terjatev v primerjavi z obsegom prodaje, ob tem pa še zagotoviti, da se ohranja likvidnost, da ne bi prišlo do težav pri lastni plačilni sposobnosti. Njen temeljni cilj pa je, da se terjatvam ohrani lastnost likvidnosti.

To pomeni, da se skuša zagotoviti, da terjatve ohranijo sposobnost hitrega preoblikovanja v denarno obliko. To pa na način, da se poskuša zmanjšati tveganje neplačila na najmanjšo možno mero. To pa se lahko zagotovi le tako, da se izvaja tiste napore in ukrepe, ki omogočajo pravočasno poravnavo terjatev. Vsaka dobra politika upravljanja prodaje na kredit vsebuje ukrepe na dveh ključnih segmentih, povezanih z upravljanjem terjatev do kupcev, in sicer:


- **na preventivi:** pomeni, da deluje na tistih segmentih, ki skrbijo za terjatve, ki bodo šele nastale. Tu se predvsem določa tiste ukrepe, ki bodo zagotovili čim hitrejšo unovčevanje terjatev, ki bodo še nastale.
- **na kurativi:** pomeni, da deluje na tistih segmentih, ki skrbijo za terjatve, ki so že nastale. Tu se predvsem določa tiste ukrepe, ki bodo zagotovili čim hitrejšo unovčevanje že nastalih terjatev.

Za učinkovito upravljanje s terjatvami do kupcev je temeljnega pomena, da se razvije procese upravljanja na obeh segmentih.

**Na strani preventive** je treba delati tako na področju planiranja kot na kreditni politiki. Pri planiranju se skuša načrtovati tisti obseg terjatev v razmerju do prodaje, ki še vedno omogoča nemoteno poslovanje, tudi če pride do zakasnitve pri njihovem unovčevanju oz.

plačilu. Ob tem je treba izdelati takšno kreditno politiko, ki točno določa pravila, komu in pod kakšnimi pogoji se lahko odobri prodajo z odloženim plačilom in do katere višine.

*Slika 1: Shema za upravljanje prodaje na kredit*



Vir: Povzeto in prirejeno po Ademovič, 2008; Brigham & Daves, 2013; Brigham & Ehrhardt, 2011; Brigham & Houston, 2009; Šeligo, 1997.

**Na strani kurative** sta pomembna nadzor in možnost hitrega unovčenja. Na področju nadzora je treba nenehno spremljati gibanje nastalih terjatev in dejanski potreben čas njihovega unovčevanja z namenom pravočasnega odziva oz. ukrepanja. Na področju unovčevanja terjatev pa je treba definirati proces, kako ukrepati v primeru, ko se želi pospešiti unovčitev določenih terjatev in kako nastopiti v primeru, ko se ugotovi, da določene terjatve postanejo dvomljive ali pa se ne poravnajo ob njihovi zapadlosti.

Kako učinkovita bo politika upravljanja terjatev, je predvsem odvisno od sodelovanja med prodajnim in finančnim oddelkom. Prodajni oddelok se mora namreč zavedati, da je prodaja zares zaključena šele s plačilom prodanega. Na drugi strani pa mora finančni oddelok razumeti, da predstavlja prodaja edino pravo zagotovilo za redne prilive podjetja.

Ključnega pomena je, da se izpostavi konstantne metode komuniciranja med finančnim in prodajnim oddelkom. Finančni oddelok posreduje prodajnemu za vsakega kupca povezano tveganje in s tem pogoje za odobritev prodaje na kredit. Prodajni oddelok pa mora skladno z ugotovljenim tveganjem poskrbeti za primerno zavarovanje ali morebitne predujme. Oba oddelka pa morata poskrbeti za pravočasno plačilo (Šeligo, 1997, str. 127–130).

## **2.1 Načrtovanje**

Pri načrtovanju obsega prodaje na kredit je ključnega pomena vprašanje, koliko sredstev se bo namenilo za vzdrževanje terjatev do kupcev. To pomeni odločitev, koliko obratnega kapitala bo namenjenega za vzdrževati take prodaje.

Obseg terjatev je namreč ključen za ohranjanje obratnega kapitala na želenem nivoju, s tem pa tudi za njegove stroške financiranja. V primeru, da se tega ne določi, se lahko hitro zgodi, da se podjetje zaplanira, zaradi česar se lahko znajde v likvidnostnih težavah.

Prav zato je pomembno, da se poišče tak obseg terjatev, ki omogoča nemoteno poslovanje, ki ga je še možno vzdrževati z minimalno potrebnimi stroški. Išče se torej optimalen obseg, ki omogoča, da je ekonomska korist, ki se jo doseže s prodajo na kredit, višja od vseh morebitnih kasnejših izgub, ki lahko nastopijo zaradi prevelikega obsega zapadlih neplačanih terjatev. Iz tega sledi, da je optimalni obseg terjatev tisti, ki ga podjetje lahko obvladuje.

Zato je pri načrtovanju obsega prodaje na kredit ključnega pomena, da podjetje najprej ugotovi, kateri obseg terjatev lahko še obvladuje. To pa lahko ugotovi le na podlagi pridobljenih izkušenj in ciljev, ki jih želi doseči.

Kljub vsemu se mora podjetje zavedati, da bo na koncu dejanski obseg terjatev predvsem odvisen od dejanske realizirane prodaje na kredit in dejansko potrebne časa za poplačilo (Brigham & Houston, 2009, str. 722–724).

Če želi podjetje ohranjati obseg terjatev skladno z načrtovanim obsegom, je ključnega pomena, da ima izdelano tako politiko kreditiranja svojih kupcev in mehanizem nadzora, ki mu to omogočata.

## **2.2 Kreditna politika**

Kreditna politika je skupek pravil, ki določajo postopek in pogoje odobravanja prodaje na kredit. Po Westonu in Copelandu (2000) gre pri kreditni politiki za skupek odločitev o ročnosti in višini kredita, ki ga bo podjetje odobrilo, kreditnih standardih in ponujenih diskontih.

Vzpostavljena kreditna politika je tisti dejavnik, ki bo imel končni vpliv na to, kakšna terjatev bo nastala. Zato je del kurativnega področja upravljanja s terjatvami. Ob tem pa je tudi sestavni del celotne politike podjetja, saj mora biti usmerjena v povečevanje sedanje neto vrednosti podjetja, oz. maksimiranje te ob določeni stopnji tveganja (Edwards, 1993, str. 22).

Izdelava ustrezne kreditne politike je ključ za optimalno upravljanje s terjatvami do kupcev (Selan, 2004, str. 8), saj vpliva na samo kakovost terjatev, ki jih bo podjetje pridobilo. Od načina vodenja kreditne politike pa bo na koncu odvisno, ali bodo terjatve ohranile lastnost preoblikovanja v denarno obliko in kakšna bo na koncu dejanska ekonomska korist odobrene prodaje na kredit.

Ustrezna kreditna politika je tista, ki temelji na optimalnem razmerju med funkcijo stroškov, ki jih povzroča, in koristmi, ki jih prinaša. To pomeni, da je za podjetje ustrezna tista kreditna politika, ki omogoča maksimalno prodajo ob še sprejemljivi (pričakovani) ravni odpisanih oz. neizterljivih terjatev. Ali pa nasprotno, da omogoča minimalno raven neizterljivih terjatev ob še sprejemljivi rasti prodaje, vendar se v takšnih primerih pojavijo stroški izgubljene priložnosti (Barry, 1997, str. 6).

Osnovna cilja kreditne politike sta torej maksimalna prodaja in dobiček na eni ter minimalne zapadle in neizterljive terjatve na drugi strani. Zato se lahko osnovno načelo kreditne politike opredeli preko maksimalnega dobička izraženega kot seštevek maksimalne možne prodaje, pravočasnega plačila in minimalne neizterljive terjatve.

Podjetje mora pri vzpostavitvi ustrezne kreditne politike poleg svojih ciljev upoštevati še poslovne običaje panoge, v kateri posluje. Kako bo uspešno pri vzpostavitvi ustrezne kreditne politike, pa je predvsem odvisno od: virov za izvedbo, strokovnega znanja, podpore vodstva in razumevanja prodajnega oddelka. Postavitev kreditne politike ne pomeni samo trdne in brezkompromisne politike, temveč predvsem organizirano in kontrolirano politiko, ki stremi k najbolj donosni prodaji (Barry, 1997, str. 10–12).

### **2.2.1 Pomen**


Kreditna politika je pomembna, ker posredno vpliva na končni realizirani dobiček. Predvsem pa stopnja njene zaostrenosti vpliva na obseg prodaje, na čas trajanja vezave terjatev in na sam obseg slabih terjatev. Vse to troje pa vpliva na končni realizirani dobiček (Van Horne, 1993, str. 448).

Kot je razvidno s Slike 2, manjša kot je stopnja zaostrenosti kreditne politike, višji obseg prodaje se lahko pričakuje. Vendar sta ob tem pričakovana tudi daljša vezava terjatev in večji obseg slabih terjatev, zaradi česar se lahko na koncu ne realizira največjega možnega dobička.

Na drugi strani tudi večja stopnja zaostrenosti kreditne politike ne doprinese nujno največjega možnega dobička, čeprav je vezava terjatev hitrejša in obseg slabih terjatev minimalen. Razlog je v tem, da taka politika povzroča prenizek obseg prodaje.

To pomeni, da je maksimalen dobiček možen le takrat, ko se izvaja tako stopnjo zaostrenosti kreditne politike, ki še vedno omogoča maksimalen obseg prodaje ob še dopustnem možnem času vezave terjatev in v minimalnem možnem obsegu slabih terjatev.

*Slika 2: Vpliv kreditiranja na končni dobiček*



Vir: Van Horne, 1993, str. 448

Ob kakršnihkoli spremembah kreditne politike je zelo verjetno, da bo prišlo do spremembe obsega prodaje, deleža slabih terjatev ter stroškov izterjave, kar se na koncu vedno izrazi v realiziranem dobičku (Berk et al., 2006, str. 283).

### 2.2.2 Možne oblike

Običajno sama značilnost proizvoda ali storitev, ki ga podjetje ponuja, določa obliko kreditne politike. Ta je predvsem odvisna od prodajljivosti samega proizvoda ali storitve in od dolžine proizvodnega cikla, ki ga je treba financirati (Maness & Zietlow, 2002, str. 150–152).

V teoriji so omenjene tri možne oblike kreditne politike, ki jih podjetja lahko izvajajo ob različnih poslovnih pogojih v primerjavi s svojo konkurenco (Edwards, 1993, str. 22–24) in te so predstavljene v nadaljevanju.

- **Kreditna politika v normalnih pogojih** je tista politika, ko podjetje beleži enake kreditne pogoje kot konkurenca. To pomeni, da ustvarja zadovoljivo stopnjo dobička in ima dobro načrtovano prodajo za prihodnjih nekaj let; ob tem pa še zadovoljivo finančno strukturo.
- **Sproščeno kreditno politiko** podjetje izvaja, kadar beleži prenizek obseg prodaje ali prevelik obseg zaloge od načrtovanega, skratka, kadar beleži padec povpraševanja.

Take politike se lahko poslužuje tudi, kadar skuša tržiti nov proizvod in išče zanj nov trg. Ali pa ravno obratno, ko se podjetje že približuje točki preloma in s pospešeno prodajo skuša nadomestiti izgube visokih fiksnih stroškov.

- **Omejevalna kreditna politika** je tista, ko podjetje od postavljenih pravil ne odstopa in je zanj bolje, da kupca ni, kot da ne izpolnjuje zahtevanih pogojev. Podjetje lahko posluje omejevalno, ko je že preveč kreditno izpostavljeno in nadaljnje izpostavljanje ogroža njegov obstoj. Ali pa v primerih, ko posluje z izdelkom ali storitvijo, ki nima nadomestka ali prave konkurence.

### 2.2.3 Kreditni pogoji

V primeru, ko se gleda na kreditne pogoje le kot odobreni čas plačila in možne dane popuste za predčasna plačila, so ti v določeni panogi bolj ali manj enaki za vsa podjetja, in to predvsem iz dveh razlogov. Prvi leži v stopnji prisotnosti konkurence, saj večja kot je, bolj so si kreditni pogoji na koncu podobni. Drugi razlog leži v sami naravi izdelka ali storitve, saj bolj kot so ti trajne narave, bolj silijo v daljše odloge plačila in večje popuste za predčasna plačila; velja pa tudi obratno.

Ta dva pogoja sta običajno dana vnaprej in sta odvisna od samih poslovnih običajev, ki jih je v praksi težko spremeniti, saj lahko to povzroča nezadovoljstvo pri kupcih in zmanjša konkurenčnost. Če želi podjetje prodajati, mora delovati v danih okvirjih, ki jih določa okolje, v katerem podjetje posluje.

Moč vpliva na spreminjanje omenjenih pogojev je odvisna od tržnega deleža in značilnosti strukture panoge, v kateri podjetje posluje. Predvsem pa je odvisna od pomembnosti podjetja pri kupcih, torej od njene prednosti pred konkurenco (Maness & Zietlow, 2002, str. 15).

Če pa se gleda na kreditne pogoje kot na možnost določitve kreditnega standarda, ki ga mora kupec dosegati, da mu je lahko odobrena prodaja na kredit, potem ima podjetje zelo velik vpliv na to, kakšne kreditne pogoje bo določilo. Saj mora podjetje ne glede na poslovne običaje zagotoviti lastno likvidnost in donosnost. In to lahko zagotovi le, če določi maksimalno višino tveganja, pri katerem je še vedno pripravljeno odobriti prodajo na kredit.

Kreditne pogoje po mnenju večine avtorjev sestavljajo poleg časa plačila in popusta še **kreditni standardi oz. kriteriji za kreditiranje** (Brigham & Ehrhardt, 2011; Dun & Bradstreet, 2011; Šeligo, 1997).

Kreditni standardi predstavljajo merila, na osnovi katerih se podjetje odloči, kateremu kupcu bo omogočilo prodajo na kredit in kolikšna je lahko njegova najvišja odobrena

vrednost. Ob tem mora določiti še, komu se lahko prodaja odobri pogojno, kar pomeni, da je treba zagotoviti še dodatno zavarovanje.

Zato je pomembno, da podjetje določi takšne kreditne standarde, ki ne bodo zavirali obsega prodaje, ob tem pa zagotavljali še čim nižje stroške vzdrževanja terjatev do kupcev. To je možno le z vedenjem, kakšno tveganje prinaša posamezna prodaja na kredit. Zato bi lahko rekli, da so kreditni standardi v bistvu najpomembnejša sestavina politike kreditiranja kupcev in ti morajo biti zasnovani na podlagi ugotovljenega tveganja (Dun & Bradstreet, 2011, str. 2–3).

Ob tem se je treba zavedati, da se prava prodaja ne bo zmanjšala, če prevzamemo nadzor nad tveganjem prodaje na kredit. Vendar bo to bistveno doprineslo k zmanjšanju izgubljene prodaje in stroškov, ki nastopijo zaradi nepravočasnega poplačila. Jasno mora biti, da je prodaja, do katere ne pride, ker kupec ne pristaja na oceno svojega tveganja, velikokrat tista, ki bi bila tako ali tako izgubljena (Selan, 2002, str. 6–7).

#### **2.2.4 Ocena kreditnega tveganja**

Čeprav je prodaja na kredit odličen instrument za pospeševanje prodaje, je njena slaba stran v tem, da dopušča časovno oddaljenost od trenutka nastanka do trenutka plačila. Podjetje z odobritvijo prodaje na kredit v resnici kreditira kupca za celotno obdobje odloga plačila. Zaradi tega se prodajalec pri prodaji na kredit izpostavi tveganju<sup>2</sup>, t.i. kreditnemu tveganju, ker beleži negotovost poplačila terjatve (Sanchez, 2003, str. 31–32).

V literaturi je največkrat uporabljena definicija, ki pojmuje kreditno tveganje kot možnost, da posojilojemalec, v našem primeru kupec, ne bo mogel ali ne bo hotel poravnati svojih pogodbenih obveznosti, zaradi česar lahko utrpí izgubo (Holliwell, 1998; Jorion, 2006). Iz tega sledi, da je kreditno tveganje sestavljeno iz treh komponent (Brealey & Myers, 2011; Kendall, 1998; Basel II, 2006):

- **verjetnost neplačila (PD),**
- **kreditna izpostavljenost ob trenutku neplačila (EAD),**
- **potencialna izguba on nastanku neplačila (LGD).**

To pomeni, da je tudi v primeru prodaje na kredit treba pri določevanju kreditnega tveganja oceniti verjetnost neplačila. Ta se lahko poda z vidika, ali bo kupec sposoben poplačati ob dogovorjenem roku, ali pa z vidika, ali je kupec sploh sposoben poplačati svojo obveznost.

---

<sup>2</sup> Tveganje lahko opredelimo kot možnost nepričakovanih in nezaželenih odmikov od pričakovanega rezultata (Galitz, 1995; Jorion, 2006).

Na podlagi dobljene ocene verjetnosti neplačila je treba določiti, kakšna bo maksimalna kreditna izpostavljenost v primeru nastopa neplačila. Na koncu obeh komponent je treba podati še oceno, kakšna izguba lahko nastopi.

#### 2.2.4.1 Verjetnost neplačila

Če kupcu prodajamo na kredit, pomeni, da mu zaupamo, v nasprotnem primeru bi bila tovrstna odločitev napačna. Toda to zaupanje, kot je izpostavil Selan (2002), se mora vzpostaviti na podlagi ocene verjetnosti neplačila in ne na podlagi poznanstva. Preden se poda zaupanje kupcu, da bo poravnal svojo obveznost, je treba oceniti njegovo verjetnost neplačila. Po oceni takšnega tveganja lahko podjetje sprejme odločitev, ali bo kupcu zaupalo ali pa ne.

Ocena tveganja poda verjetnost, ali se bo zgodil določen nezaželeni dogodek. V primeru kreditnega tveganja se ocenjuje verjetnost, da se bo posojilojemalec, v našem primeru kupec, v prihodnosti obnašal na način, zaradi katerega bo nastopilo neplačilo. Torej se predvsem skuša oceniti kupčevo sposobnost in pripravljenost za poplačilo obveznosti (Lessmann, Seow, Baesens & Thomas, 2013, str. 1–5).

Cilj ocene kreditnega tveganja je, da se na podlagi značilnosti kupca oceni stopnja tveganja, na podlagi katere se kupca opredeli kot dobrega ali slabega plačnika. Glavna ideja je, da se za vsakega določi plačilna sposobnost, na podlagi katere je nato možno podati verjetnost neplačila (Dun & Bradstreet, 2009, str. 32).

Splošni modeli za ocenjevanje tveganja so obstajali že v 19. stoletju, vendar pa začetki znanstvenega obravnavanja kreditnega tveganja segajo v pozna 30. leta 20. stoletja, ko sta Fisher (1936) in Durand (1941) uporabila linearno in kvadratno diskriminantno analizo za razvrstitev kreditnih zahtevkov na dobre in slabe.

Na podlagi njunega dela sta v poznih 60. letih 20. stoletja nadaljevala Beaver (1967) in Altman (1968). Beaver je v svojem delu predlagal metodologijo za samovrednotenje računovodskih podatkov za potrebe napovedovalne moči. Altman pa je s pomočjo diskriminantne analize razvil prvi model za napovedovanje neplačila na podlagi ugotavljanja verjetnosti stečaja.

Običajno je rezultat modelov za ocenjevanje verjetnosti neplačila »indeks« kreditne sposobnosti, izražen kot numerični rezultat, ki se lahko interpretira kot doseženo število točk, te pa povedo, kakšna verjetnost neplačila obstaja (Keramati & Yousefi, 2011, str. 416).

V zadnjih desetletjih je zaradi razvoja finančnih trgov in posledične porasti obsega kreditnega tveganja prišlo do razvoja številnih modelov. V zadnjih nekaj letih pa se je

razvoj na tem področju še pospešil. Glavna razloga za to sta po mnenju Cespedesa (2002) Basel II in razvoj sintetičnega listinjenja, ki sta povzročila porast trga kreditnih derivativov. Oba dogodka sta poudarila pomen kvantitativnih ocen kreditnega tveganja.

#### 2.2.4.1.1 Modeli kreditnega tveganja

Modeli kreditnega tveganja se v osnovi ločijo na **individualne** in na **portfeljske**. Cilj prvih je, da na nivoju posamezne izpostavljenosti kvantificirajo kreditno tveganje v obliki izračuna vrednosti vseh treh komponent, zlasti verjetnosti neplačila. Portfeljski modeli pa merijo skupno kreditno tveganje celotnega portfelja, kjer je treba poleg izračuna posameznih komponent kreditnega tveganja upoštevati še korelacijo in koncentracijo posameznih produktov ali segmentov (Cespedes, 2002, str. 58–60).

Obe vrsti modelov se delita z vidika uporabljenih podatkov na **Prijavne** (v angl. *Application*), **Vedenjske** (v angl. *Behavioural*) in **Prevzemne** (v angl. *Collection*) ter **na Modele odkrivanje goljufij** (v angl. *Fraud detection models*). Prvi uporabljajo le splošne podatke, kot so gospodarski, demografski in finančni kazalniki. Običajno so primerni za nove prosilce, za katere ni podatkov o njihovem obnašanju. V primeru, ko se v model vključi tudi takšne podatke, pa se uporablja tako imenovane *Behavioural* oz. vedenjski modele, ki so primerni za že poznane prosilce.

Ko nas zanima, kateri odobreni krediti potrebujejo več nadzora in ostrejša ukrepa, uporabimo tako imenovane *Collection* modele, ki temeljijo na ugotavljanju verjetnosti nastopa insolventnosti. Modele za *Fraud detection* pa uporabljamo, ko želimo ugotoviti, ali bo prosilec morda goljufal.

Vse naštetje modele kreditnega tveganja lahko delimo tudi iz vidika, kako je v model vključena verjetnost nastanka nezaželenega dogodka. Na podlagi tega jih razdelimo na **modele določanja vrednosti** (v angl. *Credit pricing models*) in **modele tvegane vrednosti** (v angl. *Credit value at risk -VaR*). Prvi so izdelani na podlagi implicirane verjetnosti nastanka nezaželenega dogodka, drugi pa na podlagi dejanske verjetnosti nastanka nezaželenega dogodka.

**Modeli reduciranja:** osnovna ideja teh modelov je, da neplačilo oz. neizpolnjevanje obveznosti ni odvisno od same finančne strukture, temveč od več zunanjih dejavnikov. Ti se lahko delijo še na Strukturne (v angl. *Structural models*) in na Modele reduciranja (v angl. *Reduced form models*).

- **Strukturni modeli** temeljijo na Mertonovem strukturnem modelu (1974). Od takrat dalje je bilo predstavljenih več kot 15 nadgrajenij prvotnega modela, ki so postopoma opuščale nerealne predpostavke in se približevale realnemu dogajanju na finančnih trgih. Vsi strukturni modeli si delijo skupen pristop obravnavanja podjetja, ki temelji na

njegovi finančni strukturi. Osnovna ideja, ki je skupna vsem strukturnim modelom kreditiranja, je, da podjetje ne poravnava svojih obveznosti, ko je tržna vrednost njegovih sredstev nižja od njegovega dolga. Za njih je temelj ocenjevanje tržne vrednosti sredstev, zato jih tudi določeni avtorji uvrščajo v tako imenovane modele za vrednotenje podjetij. Strukturni modeli merijo verjetnost neplačila, in sicer z izračunom verjetnosti, da vrednost sredstev pade pod vrednost dolga. Pri tem pa uporabljajo metodologijo, ki izvira iz teorije vrednotenja opcij (Chacko, Sjöman, Motohashi & Dessain, 2006, str. 65–66). Iz tega sledi, da so ti modeli bolj primerni za podjetja, ki kotirajo na trgih, saj potrebujejo za oceno neplačila podatek o vrednosti podjetja.

- **Modeli reduciranja:** osnovna ideja teh modelov je, da neplačilo oz. neizpolnjevanje obveznosti ni odvisno od same finančne strukture, temveč od več zunanjih dejavnikov. Ti modeli predvsem predpostavljajo, da je čas neplačila v resnici nepredvidljiv oz. nedostopen, ker je ta posledica neplačilne intenzivnosti, ki je funkcija različnih latentnih spremenljivk stanja, npr. kreditnega razpona. (Arora, Bohn & Zhu, 2005, str. 3–5). To pomeni, da se v teh modelih neplačilo podjetij modelira kot naključni stohastični proces. Jarrow in Turnbull (1995) sta prva predlagala model reduciranja in izdelala model za ugotavljanje tveganja spremembe kreditnega razpona (v angl. *credit spreads*) na podlagi bonitetnih ocen. Sledili so Lando (1998), Madan in Unal (1998) ter ostali. Tudi ti modeli so bolj primerni za podjetja, ki kotirajo na trgih, saj za oceno neplačila potrebujejo podatke o kreditnem razponu.

**Modeli tvegane vrednosti (v nadaljevanju VaR):** ti modeli temeljijo predvsem na verjetnosti nastanka dejanskih dogodkov neplačila. Ti pa se lahko delijo na modele neplačila (v angl. *Default mode models* - DM), ki predvsem preučujejo posledice plačilne nesposobnosti, in na modele vrednotenja glede na tržne razmere (v angl. *Mark to market* - MTM), ki pa bolj preučujejo vzroke, ki podjetja silijo vanj. Ti temeljijo na osnovnih idejah modelov določanja vrednosti, le da uporabljajo dejanske podatke o verjetnosti neplačila.

- **Modeli neplačila** (v nadaljevanju DM) ali tako imenovani aktuarski modeli, v katerih ocenjujemo, ali se bo nezaželeni dogodek zgodil ali pa ne. V teh modelih se torej pričakuje samo dva izida: ali nastopi neplačilo ali pa ne. Ob tem pa se predpostavlja, da se spremenljivka neplačila porazdeljuje skladno s Poissonovo porazdelitvijo. Osnovna ideja leži v tem, da se oceni posteriorno verjetnost  $p(+1|x)$ . Naj bo  $x_i = (x_{i1}, x_{i2}, \dots, x_{im}) \in R^m$ , kjer je  $m$ -dimenzionalni vektor, ki opisuje vlogo za določen kreditni produkt, v našem primeru prodajo na kredit. Izidi predhodno odobrenih kreditov so znani, zato naj bo  $y_i \in \{-1, +1\}$  binarna odvisna spremenljivka, ki opredeljuje, ali je bilo ugotovljeno neplačilo pri  $i$ -tem kreditu. V nadaljevanju se predpostavi, da  $-1$  in  $1$  predstavljata izida, poplačila oziroma neplačila. Ko se odločamo, ali odobrimo kredit z značilnostjo  $x$ , je pomembno, da ocenimo posteriorno verjetnost  $p(+1|x)$ , ki izraža verjetnost, da se odobreni kredit ne bo poplačal. Na podlagi te verjetnosti se lahko odločimo, ali kredit odobrimo ali ne, in to na tak način

da se  $p(+1|x)$  primerja z določeno mejno vrednostjo, označeno z  $\tau$ . In če potem velja  $p(+1|x) \leq \tau$ , se kredit lahko odobri, v primeru ko velja obratno, pa prošnjo zavržemo. Iz tega sledi, da je problem ocenjevanja  $p(+1|x)$  pravzaprav področje analize razvrščanja na podlagi nabora podatkov  $D = (y_i, x_i)_{i=1}^n$  preteklih odobrenih kreditov (Dun & Bradstreet, 2009; Hastie, Tibshirani & Friedman, 2008). Najbolj komercialno poznana modela sta CreditRisk+ in CreditPortfolioView.

- **Modeli vrednotenja glede na tržne razmere (MTM)** modeli imajo lahko v primerjavi z DM iz vidika kreditne sposobnosti več kot dva izida. Predpostavljajo predvsem, da ni nujno, da podjetje zabeleži dogodek neplačila, saj izguba lahko nastopi že, ko se sama kreditna sposobnost ali vrednost podjetja spremeni. To pomeni, da se skozi čas tveganje neplačila spremeni ob vsakokratni spremembi določene vrednosti. Najbolj uporabljena modela v praksi sta CreditMetrics<sup>TM</sup> (J.P. Morgan, 1997) in KMV Portfolio Manager.

Ne glede na tip **VaR** modelov je njihova značilnost v tem, da uporabljajo različne dejanske podatke iz preteklosti, na podlagi katerih skušajo oceniti verjetnost neplačila. Torej se ocenjevanje neplačila izvaja na podlagi dejanskih podatkov o neplačilih in ne na podlagi predpostavk ali izvedenih opazovanj. Ti modeli so predvsem primerni za vse vrste podjetij, tudi za fizične osebe (Dun & Bradstreet, 2009, str. 61–62).

Za izdelavo VaR modelov lahko uporabimo različne metode. Izbrana definira razmerje med vhodnimi podatki in dobljeno verjetnostjo neplačila. V preteklosti sta se za izdelavo modela kreditnega tveganja najbolj pogosto uporabljali diskriminantna analiza in logistična regresija.

Sčasoma so se razvile tudi druge metode, kot so probit analiza, neparametrične metode glajenja (v angl. *smoothing methods*), matematično programiranje, večparametrsko odločanje, markov modeli, survival analiza, ekspertni sistemi, genetski algoritmi, nevronske mreže in modeli za razvrščanje ali pa sami ekonometrični modeli in Monte Carlo simulacije (Hand & Henley, 1997, str. 524–525).

Iz zapisanega je razvidno, da so modeli kreditnega tveganja zgrajeni na podlagi statističnih modelov ali s pomočjo metod umetne inteligence (IA) ali pa na podlagi strojnega učenja. Ali pa celo na podlagi različnih kombinacij le-teh, kot so hibridne in ensemble metode (Li & Zhong, 2012, str. 181–182).

Ocenjevanje verjetnosti neplačila oz. kreditnega tveganja je pravzaprav področje podatkovnega rudarjenja (v angl. *data mining*). Skladno z Giudici (2003) lahko podatkovno rudarjenje opredelimo kot proces izbire, raziskovanja in modeliranja velikih

količin podatkov, z namenom odkrivanja zakonitosti odnosov, na podlagi katerih pridobiva jasne in uporabne rezultate.

Obstajajo torej zelo različni načini, kako oceniti verjetnost neplačila, vendar bo na koncu izbira odvisna predvsem od subjektivnosti analitika, in od njegovega strokovnega znanja, katero metodo bo izbral (Dun & Bradstreet, 2009, str. 85).

Na trgu obstajajo tudi bonitetne hiše, ki ponujajo bonitetne ocene, ki temeljijo na zgoraj omenjenih modelih. Toda pri uporabi takih ocen moramo biti previdni, saj se je treba pozanimati, kaj v resnici ocenjujejo, na podlagi katere metode so bile zgrajene in za koga so primerne.

Tudi v akademskem svetu se je razvilo kar nekaj uveljavljenih modelov, ki se jih večkrat uporablja za ocenjevanje tveganja neplačila. Vendar je tudi te modele treba razumeti v smislu, kako so bili sestavljeni, kaj ocenjujejo in za kakšna podjetja so primerni.

Za potrebe prodaje na kredit se svetuje, da se razvije svoj model za ocenjevanje verjetnosti neplačila, saj večina dostopnih komercialnih in akademskih modelov na slovenskem trgu ocenjuje verjetnost nastanka stečaja. To pa ni najbolj primerno za ocenjevanje tveganja pri prodaji na kredit, saj je sam dogodek nastanka stečaja skoraj že prepozen dogodek za samega prodajalca.

V primeru ocenjevanja verjetnosti neplačila za potrebe prodaje na kredit pridejo v poštev predvsem VaR modeli, in sicer modeli neplačila (DM). Prednost izdelave lastnega modela je v tem, da ga razumemo in poznamo njegove pomanjkljivosti. In če so nam pomanjkljivosti kreditnega modela znane, se potemtakem tudi ve, v katerih primerih ga ni primerno uporabljati, s čimer zmanjšamo tveganje nepravilnih odločitev.

#### 2.2.4.2 Kreditna izpostavljenost

Kreditna izpostavljenost je vrednost, ki je izpostavljena neplačilu. V primeru prodaje na kredit je to vrednost terjatev, katera nosi tveganje, da ne bo poravnana v celoti. Če se želi podjetje v primeru prodaje na kredit najboljše zavarovati pred kreditno izpostavljenostjo, mora za vsakega kupca določiti maksimalno vrednost izpostavljenosti, do katere je še pripravljeno tvegati (Dun & Bradstreet, 2011, str. 2–3).

Maksimalna vrednost pravzaprav mora določati maksimalno vrednost kredita, ki smo ga pripravljeno odobriti določenemu kupcu za potrebe prodaje na kredit. Za vsakega kupca se tako postavi kreditno mejo ali limit, do katerega se je podjetje pripravljeno kreditno izpostaviti (Kristanc, 2009, str. 43).

Zato gre pri **določitvi višine kreditne izpostavljenosti pravzaprav za določanje kreditnih limitov** posameznim kupcem. Ti se morajo določiti za vsakega kupca posamezno, in to ne le na podlagi realizacije prometa, temveč na podlagi njegove sposobnosti generiranja denarnega toka in verjetnosti neplačila (Dun & Bradstreet, 2011, str. 8–9).

V literaturi in praksi je znanih več načinov, kako določiti te limite. Več informacij v povezavi s to temo bo podanih v poglavju o kreditnem limitu.

Glavni namen določanja kreditnih limitov je predvsem v tem, da se podjetje v primeru neplačila zavaruje pred večjimi izgubami. Na kreditne limite se lahko torej gleda kot na enostaven način zavarovanja pred zapadlimi neplačanimi terjatvami.

Zato sta dodeljevanje pravih vrednosti kreditnih limitov in skrb, da ne presegajo določene meje, ključnega pomena za notranji sistem obvladovanja terjatev do kupcev (Dun & Bradstreet, 2011, str. 10).

Podjetje, ki prodaja na kredit, si mora izdelati pravi postopek za določanje višine limita, ob tem pa si mora izdelati še mehanizme nadzora, s katerimi bo poskrbelo, da se kreditna izpostavljenost ne povečuje preko tiste, ki je bila ocenjena kot še sprejemljiva (Selan, 2004, str. 18).

#### 2.2.4.3 Potencialna izguba

Potencialna izguba je tista, ki jo lahko pričakujemo ob morebitnem neplačilu. Preden kupcem odobrimo prodajo na kredit, je zelo pomembno, da ocenimo, kakšno izgubo lahko zabeležimo, če se posel odobri. To lahko izračunamo s pomočjo preproste enačbe:

$$EL = PD * LGD * EAD \quad (1)$$

$$EL = PD * (1 - RR) * EAD \quad (2)$$

$$EL = PD * (1 - (VC/EAD)) * EAD \quad (3)$$

Kjer velja, da je:

- PD: verjetnost neplačila,
- LGD: odstotek potencialne izgubljene vrednosti,
- RR: stopnja izterjave,
- VC: vrednost, ki je zavarovana oz. bo lahko izterjana ob nastanku neplačila,
- EAD: vrednost, ki je izpostavljena izgubi v morebitnem nastanku neplačila.

Iz enačbe (4) lahko razberemo, da je potencialna izguba vsake prodaje na kredit odvisna od verjetnosti neplačila, odobrene višine kreditne izpostavljenosti in zavarovane vrednosti. To

pomeni, da lahko ob določeni stopnji verjetnosti neplačila potencialno izgubo zmanjšamo le preko nižje kreditne izpostavljenosti ali preko višine zavarovane vrednosti, ki nam zagotavlja poplačilo.

Ob visokem tveganju neplačila je najboljšje zavarovanje, da se ne odobri prodaje na kredit. V nasprotnem primeru je drugo najboljšje zavarovanje nižja odobrena kreditna izpostavljenost ob primernem pridobljenem zavarovanju. Toda dobra zavarovanja imajo svojo ceno, medtem ko se tista, ki nimajo cene, lahko na koncu izkažejo kot neučinkovita.

Katero obliko zavarovanja bo podjetje pridobilo za zavarovanje posla, je odvisno od poslovnih običajev, konkurence, pogajalske moči podjetja in same pomembnosti podjetja pri kupcu ter seveda od virov, ki jih ima podjetje za te namene.

Ne glede na to pa mora biti pri vsakemu podjetju ugotovljeno tveganje neplačila vodilo za ustrezno obliko zavarovanja, saj le-to poda možnost znižanja potencialne izgube. Vprašanje, koliko želimo znižati potencialno izgubo, je bistveno pri odločitvi, kateri instrument je pravi.

*Slika 3: Pregled možnih zavarovanj v primeru prodaje na kredit*

| Pogodbena zavarovanja                                                                                                                                                                                                                                            | Osebna zavarovanja                                                                       | Stvarna zavarovanja                                                                                                                                                                                       | Plačilni mehanizmi                                                                                                                                                                                           |
|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| <ul style="list-style-type: none"> <li>• Pogodbene kazni</li> <li>• Penali</li> <li>• Odškodnina</li> <li>• Pridržana pravica</li> <li>• Zamudne obrsti</li> <li>• Določitev are</li> <li>• Zaustavitev dobave</li> <li>• Klavzula <i>del credere</i></li> </ul> | <ul style="list-style-type: none"> <li>• Poroštva</li> <li>• Bančna garancija</li> </ul> | <ul style="list-style-type: none"> <li>• Hipoteke</li> <li>• Zastavna pravica</li> <li>• Zastava vrednostnih papirjev</li> <li>• Zastava depozita</li> <li>• Zastava življenjskega zavarovanja</li> </ul> | <ul style="list-style-type: none"> <li>• Ček</li> <li>• Menica</li> <li>• Akcepti nalog</li> <li>• Dokumentarni inkaso</li> <li>• Dokumentarni akreditiv</li> <li>• Zavarovanja pri zavarovalnici</li> </ul> |

*Vir: Povzeto in prirejeno po Ademovič, 2008; Brigham & Daves, 2013; Brigham & Ehrhardt, 2011; Brigham & Houston, 2009; Šeligo, 1997.*

Pred vsako odobritvijo prodaje na kredit je treba ugotoviti tveganje, ki ga sprejemamo. V primerih, ko ugotovimo, da obstaja velika možnost neplačila ali je vrednost prodaje z odloženim plačilom višja od dodeljenega kreditnega limita, mora imeti podjetje izdelano kreditno politiko, ki točno določi, kakšno zavarovanje je treba pridobiti, da bi lahko sklenili posel z minimalno izgubo.

Ob tem pa se mora podjetje zavedati, da je v primeru, ko ne pridobi primerne zavarovanja ob ugotovljenem tveganju neplačila ali pa so stroški potrebnega zavarovanja

višji od možne realizirane ekonomske koristi, bolje odstopiti od takšne prodaje, ker je ta že na začetku izgubljena.

### 2.2.5 Kreditna vrednost

Cilj vsake kreditne politike mora biti, da za vsakega kupca oceni svojo kreditno vrednost. Kreditna vrednost pomeni znesek, za katerega je podjetje pripravljeno sprejeti tveganje, da ne bo poplačan. Ta znesek izračunamo na podlagi tveganja neplačila in ocenjene potencialne izgube, kot je predstavljeno v enačbi (4).

$$\text{Kreditna vrednost} = \text{Tveganje neplačila (PD)} * \text{Potencialna izguba (EL)} \quad (4)$$

Na podlagi izračunane kreditne vrednosti je treba določiti pogoje, po katerih lahko odobrimo prodajo z odloženim plačilom. To vrednost za vsakega kupca je treba vedno preverjati, kar pomeni, da je kar se da ažurno določena (Selan, 2004, str. 34).

### 2.2.6 Učinkovitost kreditne politike

Učinkovita kreditna politika je tista, ki poleg doseganja osnovnega cilja skrbi še za učinkovito upravljanje z obratnim kapitalom, in to na tak način, da omogoča minimalno kreditno izpostavljenost (Edwards, 1993, str. 245).

Dejansko učinkovitost kreditne politike ocenjujemo predvsem preko dejanske nastale izgube. Izgubo, ki je nastala kot posledica sprejetih napačnih odločitev, povezanih s kreditiranjem kupcev, pa lahko ovrednotimo kot seštevek vseh odpisanih terjatev in povezanih stroškov izterjave. Višja kot je vrednost, manj učinkovita je kreditna politika in težje je ohranjati likvidnost in vzdrževati finančna bremena obratnega kapitala.

Toda pri ugotavljanju učinkovitosti kreditne politike je treba vključiti v obravnavo še strošek izgubljene priložnosti, kar pravzaprav pomeni izgubljeno možnost ponovnega naročila – v primeru, da podjetje predpostavi, da obstaja neka verjetnost, da bo kupec lahko napravil še drugi nakup. Potem takem si lahko pomaga pri odločitvi s splošno enačbo o pričakovanem dobičku, kjer upošteva dve časovni obdobji.

Osnovna enačba pričakovanega dobička je izražena kot seštevek dveh možnih izidov. Prvi izid predpostavlja, da bo kupec plačal (p), potem takem podjetje pridobi dodaten prihodek, zabeleži pa lahko nekaj stroškov v povezavi z izterjavo. To pomeni, da je v tem primeru pričakovani dobiček sedanja vrednost (PV), izražena kot razlika nastalih prihodkov (REV) in stroškov (COST). Drugi izid pa predpostavi, da kupec ne bo plačal (1-p). V takem primeru podjetje zabeleži le stroške, povezane z izterjavo. To pa se lahko izrazi s sledečo enačbo (Brealey & Myers, 2011, str. 762):

$$\text{Pričakovani dobiček} = p * PV(REV - COST) - (1 - p) * PV(COST) \quad (5)$$

Skladno s to enačbo se odobri prodajo na kredit, ko se kot rezultat dobi pozitivno vrednost. V nasprotnem primeru se zavrne. Medtem ko je v primeru, ko obstaja neka verjetnost ponovnega naročila, potrebno za oba dogodka izračunati pričakovani dobiček in nato preko skupnega seštevka izraziti končni pričakovani dobiček.

$$\text{Pričakovani dobiček prvega naročila} = p_1 * PV(REV_1 - COST_1) - (1 - p_1) * PV(COST_1) \quad (6)$$

$$\text{Pričakovani dobiček ponov. naročila} = p_2 * PV(REV_2 - COST_2) - (1 - p_2) * PV(COST_2) \quad (7)$$

$$\begin{aligned} \text{Skupni pričakovani dobiček} = \\ \text{pričakovani dobiček prvega naročila} + \text{verjetnost ponovnega plačila} \\ * \text{sedanja vrednost prihodnjega pričakovanega dobička ponovnega naročila} \end{aligned} \quad (8)$$

Tudi v primeru, ko pričakujemo več kot eno ponovno naročilo, lahko uporabimo zgornji koncept, le da enačbo razširimo za vsakokratno pričakovano ponovno naročilo. V primeru, da dobimo končni pozitiven rezultat in je prodaja na kredit zavrnjena, bi to pomenilo izgubljeno priložnost (Brealey & Myers, 2011, str. 764–765). Toda pri odločitvah je treba upoštevati še koncept potencialne izgube, ki ni upoštevan v tej enačbi in je ključnega pomena pri kreditni izpostavljenosti.

V primerih, ko podjetje želi ugotoviti, ali so bile določene vpeljane novosti v procesu kreditne politike učinkovite, mora poleg opazovanja sprememb v realizirani donosnosti opazovati tudi nastale spremembe v obsegu stroškov povezanih z vzdrževanjem samih terjatev. To pomeni, da se lahko presoja tako z vidika dosežene koristi kot z vidika potrebnega financiranja. Korist se lahko meri preko realizirane donosnosti, medtem ko potrebno financiranje z vidika nastalih stroškov, povezanih z vzdrževanjem le-teh.

**Z vidika donosnosti** učinkovitost kreditne politike merimo preko donosnosti naložbe, ki je investirana v terjatve do kupcev. S kazalnikom primerjamo, kako je bila določena uveljavljena novost v kreditni politiki donosna. To pa se lahko ugotovi preko spremembe realizirane donosnosti ( $\Delta NI$ ), izražene preko spremembe obsega terjatev ( $\Delta TK$ ). Zapišemo jo lahko s sledečo enačbo (Berk et al., 2006, str. 283):

$$\text{Donosnost kreditne politike} = \Delta NI / \Delta TK \quad (9)$$

S tem kazalnikom primerjamo dodatno ustvarjeni dobiček iz naslova spremenjene kreditne politike s potrebno spremembo obsega terjatve. Čim večja je dosežena pozitivna sprememba v donosnosti, bolj učinkovita je bila vpeljana sprememba. Iz tega sledi, da je

učinkovita sprememba tista, ki omogoči večji dobiček ob enakem obsegu terjatev ali enaki dobiček ob manjšem obsegu terjatev.

**Z vidika stroškov financiranja** se učinkovitost politike meri preko nastalih stroškov, ki so povezani z vzdrževanjem terjatev. Ti pa so v glavnem povezani s časom vezave terjatev, z dnevno kreditno izpostavljenostjo, s stroški izterjave in s ceno finančnega vira, ki je bil najet za financiranje prodaje na kredit. Zato se lahko strošek financiranja terjatev opredeli kot zmnožek povprečnih dni vezave terjatev (DVTK), skupne vrednosti prodaje na kredit (TEAD), povprečnih spremenljivih stroškov izterjave (AVC) in obrestne mere ( $r$ ), ki jo banka nudi za posojila obratnega kapitala (Berk et al., 2006, str. 284).

$$SF = DVTK * TEAD * AVC * r \quad (10)$$

Tista kreditna politika, ki beleži nižje skupne stroške financiranja upravljanja s terjatvami do kupca, je bolj učinkovitejša. Tudi to enačbo lahko uporabljamo za ocenjevanje učinkovitost vpeljanih novosti. V primeru, da se skupna vrednost stroškov zniža, lahko opredelimo, da je bila uveljavljena novost učinkovita.

Mayr (2003) pa je izpostavil, da imajo v poslovnem svetu viri financiranja svojo ceno, zaradi česar je treba v primeru prodaje na kredit strošek financiranja le-te zrcaliti v postavljeni prodajni ceni. Avtorje predlagal, da bi se morala prodajna cena spreminjati v odvisnosti dolžine odobrenih rokov plačila. Zato mora biti cena prodanega izdelka z odlogom plačila višja od cene istega izdelka ob takojšnjem plačilu. Na koncu dodaja, da se lahko preko različne višine odobrenih popustov za različne plačilne roke na posreden način prenese na kupce stroške financiranja terjatev.

Če podjetje želi ugotoviti, ali izbrani kreditni pogoji, izraženi le preko odobrenih rokov plačila in pripadajočega popusta, ustrezajo ceni financiranja terjatve, mora izračunati lastno interno obrestno mero financiranja.

Ker se v finančnem svetu obrestna mera predstavlja kot strošek najetega finančnega vira, lahko interno obrestno mero definiramo kot strošek za odobritev prodaje na kredit. Če predpostavimo še, da se lahko ta strošek izrazi s pridobljeno višino popusta za hitrejše plačilo, lahko to interno obrestno mero izrazimo na sledeč način (Mayr, 2003, str. 70–71):

$$\begin{aligned} & \text{Intr. obret. mera kupca} \\ = & \frac{\% \text{ Popusta}}{100 - \% \text{ Popusta}} * \frac{360 \text{ dni}}{\text{Št. dni odloga} - \text{Št. dni popusta}} \end{aligned} \quad (11)$$

Kot rezultat dobimo odstotek, ki ga lahko interpretiramo kot interno obrestno mero za financiranje prodaje na kredit ob točno določenih dodeljenih kreditnih pogojih. Če so letne obrestne mere potrebnih finančnih virov za financiranje terjatev višje od dobljene interne

obrestne mere, potem takem ni ekonomsko upravičeno, da bi odobrili prodajo na kredit z dodeljenimi kreditnimi pogoji. Če pa so obrestne mere potrebnih finančnih virov nižje, je taka prodaja na kredit ekonomsko upravičena (Mayr, 2000, str. 72–73).

## **2.3 Politika nadzora**

Politika nadzora je skupek pravil, ki določajo postopke nadzorovanja terjatev, nastalih zaradi odobritve prodaje na kredit. Naloge te politike je, da izdelava takšne mehanizme, ki omogočajo spremljanje odstopanja dejanskega obsega terjatev od načrtovanega.

To pomeni, da je politika nadzora zadolžena za spremljanje že nastalih terjatev. Zato je del kurativnega področja upravljanja s terjatvami s temeljnim ciljem, da obseg terjatev in stroški njihovega vzdrževanja ostanejo na načrtovanem nivoju.

Ključna naloga politike nadzora je v tem, da spremlja obseg terjatev, predvsem pa njihovo kakovostno strukturo iz vidika likvidnosti. Za spremljanje te strukture je potrebno opazovati obsega terjatev tako na agregatnem nivoju kot po različnih presekih (z vidika vrst kupcev ali po proizvodih). Na vseh nivojih pa je treba slediti še gibanju deleža terjatev v primerjavi z različnimi postavkami, kot so npr. prodaja oz. realizirani promet, sredstva, obratnim kapitalom, obveznosti do dobaviteljev itn. (Rebernik & Repovž, 2000, str. 110).

Znotraj samega obsega terjatev je tudi potrebno za vse izbrane segmente vedeti, koliko terjatev je nezapadlih in koliko zapadlih, a ne plačanih. Ob tem pa še za vsaki segment opazovati, koliko časa potrebujejo terjatve, da se pretvorijo nazaj v denarno obliko. Pri nezapadlih terjatvah je pomembno po vseh segmentih še opazovati njihovo starostno strukturo, med zapadlimi, a ne plačanimi, pa je treba opazovati še nastale stroške izterjave in nastale izgube (Brigham & Daves, 2013, str. 61–63).

Na podlagi vseh teh opazovanj je možno sestaviti poročila, iz katerih se da ugotoviti, kolikšen je odstop od načrtovanega nivoja in v katerih segmentih je to odstopanje največje. In prav preko velikosti tega odstopanja se lahko poda oceno, ki pove, koliko je podjetje v resnici učinkovito pri samem upravljanju terjatev.

Namen poročil je v tem, da se razkrijejo pomanjkljivosti v procesu vodenja kreditne politike s temeljnim ciljem, da sprožijo njene izboljšave. Poročila so pomembna tudi za načrtovanje bodočih potrebnih virov financiranja, saj se iz njih pridobi informacijo o morebitnih izpadih pričakovanih prilivov.

Vendar so vsa ta opazovanja in poročila pomembna tudi zato, ker so podlaga za izdelavo mehanizmov, ki lahko pravočasno obvestijo, katera terjatev bo postaja kmalu ali pa je že dvomljiva.

Le pravočasno opozarjanje namreč zagotovi, da se lahko podjetje najbolje zaščiti pred potencialno izgubo kreditiranja kupca. Zato se učinkovitost politike nadzora meri preko časa, ki je potreben za pridobitev informacije, ki sproži procese, ki bodo poskrbeli za čim hitrejšo unovčenje dvomljive terjatve.

## 2.4 Politika unovčenja


Politika unovčevanja je skupek pravil, ki določajo postopke, ki omogočijo že nastalim terjatvam, da se čim hitreje preoblikujejo v denarno obliko. Deluje na kurativnem področju upravljanja terjatev s temeljnim ciljem, da se tveganje potencialne izgube kreditiranja kupca zniža na najnižjo možno raven.

Politika unovčevanja ne pomeni samo procesa izterjatve zapadlih neplačanih terjatev, temveč proces, ki omogoča hitrejšo unovčenje vseh vrst terjatev. Na splošno bi lahko rekli, da mora politika unovčevanja izdelati procese za hitrejšo unovčenje vsaj treh različnih skupin terjatev:

- **za običajne nezapadle terjatve:** to pomeni, da ima podjetje točno definiran postopek, kako lahko čim hitreje unovči nezapadle terjatve. To je pomembno v primerih, ko podjetje potrebuje dodatna denarna sredstva, da ne bi najemalo dodatnih zunanjih virov financiranja.
- **za dvomljive terjatve:** to pomeni, da ima podjetje točno definiran postopek, kako lahko čim hitreje unovči terjatev, ki je bila preko postopkov nadzora definirana kot dvomljiva, čeprav ta še ni zapadla. V takih primerih se lahko uporabi procese, ki so bili izdelani za običajne terjatve, ali pa se izdelajo postopke, kako s kupcem poiskati najboljšo primerno rešitev za poplačilo svoje dvomljive terjatve. Tukaj je pomembno, da se določi pravila, s katerimi se v primerih dvomljivih terjatev podjetje ne izpostavi še k večji potencialni izgubi.
- **za zapadle neplačane:** to pomeni, da ima podjetje točno definiran postopek, kako lahko čim hitreje izterja zapadle neplačane terjatve. Ob tem se mora zavedati, da se z daljšanjem obdobja neplačila eksponentno povečuje možnost, da terjatev ne bo nikoli poplačana (Rebernik & Repovž, 2000, str. 112–114).

Zelo pomembno je, da je postopek izterjave učinkovit tako s finančnega kot tržnega vidika. To pomeni, da se skuša z minimalnimi stroški izterjati čim več, ob tem pa čim manj negativno vplivati na odnos s kupcem, da se ne bi zamajala možnost ponovnega naročila oz. prodaje (Šeligo, 1997, str. 111). Toda ob tem se je treba zavedati, da noben kupec ni v resnici dober oz. kakovosten, če ne poravnava svojih obveznosti, brez da bi nad njim sprožili postopek izterjave.

Slika 4: Možni načini unovčenja terjatev



Vir: Povzeto in prirejeno po Ademovič, 2008; Brigham & Daves, 2013; Brigham & Ehrhardt, 2011; Brigham & Houston, 2009; Šeligo, 1997.

### 3 KREDITNI LIMIT

Odobritev prodaje na kredit pravzaprav pomeni odobritev kredita za celotno obdobje odloga plačila. Zato je ključnega pomena, da podjetje pred odobritvijo take prodaje oceni kupčevo kreditno sposobnost, na podlagi katere se odloči, kakšna bo njegova maksimalna kreditna izpostavljenost.

Za potrebe prodaje na kredit je pomembno, da se poleg ocene verjetnosti neplačila oceni še, koliko je kupec sploh sposoben plačati ob roku zapadlosti, torej njegovo kreditno sposobnost. To pa zato, ker mora pri prodaji na kredit kupec tako imenovani dobljeni kredit s strani prodajalca običajno vrniti z enkratnim nakazilom v relativno kratkem času (Dun & Bradstreet, 2011, str. 9).

Torej, na podlagi ocene kreditne sposobnosti kupca se določi maksimalno vrednost, za katero se je še pripravljeno tvegati. To pomeni, da se vsakemu kupcu določi tako imenovani kreditni limit, ki določi maksimalno vrednost, do katere smo pripravljeni se kreditno izpostaviti za namene prodaje na kredit. Torej za vsakega kupca se določi kreditno mejo oz. limit, katere njegove odprte kontne postavke oz. vrednosti terjatev ne smejo presegati (Scherr, 1996, str. 72–73).

Pri določanju kreditnih limitov se je treba zavedati, da gre za več-obdobni koncept. Ta mora biti določen tako, da bo poleg sedanje prodaje omogočal prodajo tudi v prihodnosti. Medtem ko mora biti z vidika financiranja določen tako, da bo poleg zaščite sedanje

kreditne izpostavljenosti tudi v prihodnosti omogočal zmanjševanje potencialne kreditne izgube (Dun & Bradstreet, 2011, str. 15).

Z drugimi besedami, pravilna določitev kreditnega limita je ključnega pomena za zmanjševanje kreditnih izgub pri prodaji na kredit. Zato je kreditni limit zelo dobro orodje za obvladovanje terjatev do kupcev, ob tem pa omogoča še ohranjanje likvidnosti.

### **3.1 Splošna definicija**

Kreditni limit je vrednost, ki mora teoretično predstavljati kreditno sposobnost kupca. Ta je izražena tako, da kupec v določenem obdobju ustvari dovolj denarnega toka, da bo sposoben pravočasno poplačati svojo obveznost.

Zato je kreditni limit dober instrument za obvladovanje kreditnega tveganja, saj določa maksimalno kreditno izpostavljenost, katera nas obvaruje pred nezaželenimi izgubami, zaradi izvajanja prodaje na kredit.

Z vidika obvladovanja kreditnega tveganja, ki nastopi zaradi prodaje na kredit, se lahko kreditni limit definira kot maksimalna vrednost, ki nam jo kupec v določenem obdobju še lahko dolguje; ali pa kot maksimalni znesek odprtih postavk, ki ga kupec lahko doseže v določenem obdobju (Dun & Bradstreet, 2011, str. 5).

### **3.2 Upravljanje**

Pri upravljanju kreditnih limitov se mora podjetje zavedati, da kreditni limiti ne zavirajo prodaje, temveč so tisto orodje, ki na koncu omogoči prodaji, da ostaja donosna. Tako v primerih, ko se izkaže, da vrednost prodaje na kredit presega določeni kreditni limit, take prodaje ni primerno odobriti, če podjetje ne pridobi dodatnega zavarovanja, ki mu bi omogočilo znižanje kreditne izpostavljenosti.

Pri upravljanju kreditnih limitov je zelo pomembno, da se dodeljenih kreditnih limitov ne obravnava, kot da so permanentni. Različni avtorji menijo, da je lahko najdaljše trajanje limita eno leto, vendar le za kupce, ki niso kritični in so dovolj kreditno sposobni. Medtem ko se problematičnim kupcem oz. kupcem, ki se jim ne zaupa, določi krajše trajanje kreditnega limita, ki se jih večkrat pregleda in oceni.

Ne glede na čas trajanja odobritve določenega kreditnega limita je treba za vse kupce dosledno spremljati stanje odprtih postavk, plačilno disciplino, realiziran promet in tako na podlagi novih pridobljenih informacij prilagoditi kreditne limite na primerno raven. V primeru, ko odprte postavke do posameznega kupca presežejo določen kreditni limit, se moramo vprašati:

- Ali je kupec svoje obveznosti redno v roku poravnal in je vzrok za presežni limit povečanje prometa?
- Ali kupec obveznosti ni poravnal v roku in ob nespremenjenem prometu presegal limit zaradi svoje plačilne nesposobnosti?

V prvem primeru je treba ponovno oceniti kupca in mu dodeliti višji kreditni limit, v drugem primeru pa moramo kreditni limit znižati, ustaviti dobavo in povečati aktivnosti za izterjavo zapadlih terjatev (Kester, Hoover & Pirkle, 2004, str. 49).

### 3.3 Določanje

Načini in postopki določanja kreditnih limitov so predvsem odvisni od potreb, razpoložljivosti podatkov, virov in strokovnega znanja. Najbolj pogosto si podjetja priskrbijo lastne izračune ali pa uporabijo referenčne vrednosti, ki so predlagane s strani bonitetnih agencij.

Pri izdelavi lastnih izračunov je ključnega pomena, da podjetje razume, kaj v resnici kreditni limit pomeni in kaj mora izražati. V tradicionalnem smislu se je določevalo kreditne limite le na podlagi preproste enačbe (13), ki temelji na ustvarjenem prometu s kupcem in na podlagi odobrenega odloga plačila.

$$\text{Kreditni limit} = \text{vrednost ali predvidena vrednost mesečne prodaje} * \text{rok plačila} \quad (12)$$

A težava te enačbe je, da ne izraža kupčeve kreditne sposobnosti, ne z vidika tveganja neplačila in ne z vidika, do katere vrednosti je kupec sploh sposoben pravočasno poplačati. Da bi se poskusilo rešiti to težavo, so posamezni analitiki dodali različne finančne varovalke, ki jih izračunan kreditni limit ne sme presegati. Kot varovalke se običajno izbere od 5 do 20 % vrednosti izbranih finančnih postavk. Te postavke so lahko obratni kapital, prodaja, neto vrednost podjetja, kratkoročne obveznosti ali različna kombinacija le-teh.

Torej, tradicionalna enačba za izračun kreditnega limita ne vključuje kreditnega tveganja. To pomeni, da predpostavlja, da ta ne obstaja, iz česar izhaja, da se verjetnost neplačila zmanjša na nič (Leippold, Vanini & Ebnoether, 2003, str. 2–3). Ob tem pa tudi predpostavlja, da je vrednost odobrene prodaje na kredit enaka sposobnosti, da jo lahko tudi pravočasno poravna.

Toda kot vemo, v realnosti ni tako in vedno obstaja neka verjetnost neplačila. Ob tem se ve tudi, da je plačilna sposobnost kupca lahko večja ali manjša od same odobrene vrednosti prodaje na kredit. Iz tega razloga so se razvili zelo različni pristopi določanja vrednosti kreditnih limitov, ki so poskusili na različne načine integrirati verjetnost neplačila v upoštevanju koncepta pričakovanih donosov.

Toda tudi taki pristopi ne podajo odgovora na vprašanje, kolikšen je znesek, ki ga je v določenem obdobju posamezni kupec sposoben pravočasno poravnati, temveč le podajo odgovor, koliko lahko znaša pričakovana vrednost poplačila oz. donosa v primeru nastopa neplačila (Bazzi & Hasna, 2015, str. 207).

Zato se danes pristope za določevanja kreditnih limitov v osnovi loči na strokovne in modelirane. Strokovni pristopi temeljijo na konceptu pričakovanih realiziranih donosov, običajno izraženih kot razlika med realiziranim dobičkom pri prodaji in potrebnimi stroški za izterjavo. Modelirani pristopi pa temeljijo na konceptu ugotavljanju zneska, ki ga je v določenem obdobju posamezen kupec sposoben pravočasno poravnati.

### 3.3.1 Strokovni pristop

Obstaja več strokovnih metod, kako določiti kreditni limit. Te so neskončno raznolike, tako z vidika nabora kazalnikov kot pravil, ki so ob tem določena. Lahko bi rekli, da obstaja toliko različnih strokovnih metod, kolikor je različnih analitikov.

Vendar pa imajo eno skupno točko, in sicer pomanjkljivost v teoretični utemeljitvi (Bazzi & Hasna, 2015, str. 203). V nadaljevanju bomo predstavili nekaj najbolj uveljavljenih metod, ki temeljijo na konceptu pričakovanih realiziranih donosov, ki so odvisni od verjetnosti neplačila.

#### 3.3.1.1 Metoda neto sedanje vrednosti

Leta 1970 sta Bierman in Hausman predstavila idejo, da je kupčev kreditni limit lahko določen le na podlagi pričakovanih bodočih koristi. Skladno s to idejo se lahko določanja kreditnih limitov oblikuje kot dinamični program, ki upošteva vpliv preteklih izkušenj pridobljenih koristi in izgub za določanje verjetnosti bodočih nastalih koristi in izgub.

Kreditni limit se lahko tako ob dani verjetnosti neplačila izrazi kot funkcijo maksimalnih pričakovanih diskontiranih realiziranih donosov. To relacijo pa se lahko izrazi na sledeči način (Bierman & Hausman, 1970, str. 520):

$$CL_{max} = f_i(P_{1i}) \quad (13)$$

$$f_i(P_{1i}) = \text{Max} [(P_{1i}k_1) - (P_{2i}k_2), 0] \quad (14)$$

Kjer velja, da je

- $F_i(P_{1i})$ : največja diskontirana pričakovana vplačila na enoto od  $i$  do  $\infty$ , ob dani spremenljivki  $P_{1i}$ ,
- $P_{1i}$ : verjetnost plačila v obdobju  $i$ ,

- $P_{2i}$ : verjetnost neplačila v obdobju  $i$ ,
- $k_1$ : diskontirani dobiček iz prodaje, izračunan kot  $s \cdot a^{-c_1} - v \cdot a^{-c_2}$ , kjer je  $s$  prodaja in  $v$  stroški. Medtem ko  $a$  je diskontni faktor,  $c_1$  je povprečni prodajni cikel in povprečni cikel obveznosti.

Srinivasan in Kim (1987) sta nato izpostavila, da je v praksi v primeru prodaje na kredit zelo težko oz. skoraj nemogoče točno kvantitativno oceniti bodoče koristi in izgube. Zato sta predlagala, da se koncept bodočih koristi in izgube izključi iz modela, saj to omogoči, da dinamični program določevanja kreditnih limitov postane eno obdobjna formulacija, ki jo je lažje modelirati in obvladovati.

Avtorja sta zaključila, da postane iz vidika enega obdobja zgornji izraz za določanje vrednosti kreditnega limita le enostavna enačba pričakovane neto sedanje vrednosti –  $E(NPV)$ . Zaradi enostavnosti sta predlagala tudi, da se spremenljivko stroškov ( $v$ ) izrazi kot delež v prodaji ( $s$ ). Skladno s tem se lahko zgornji izraz zapiše na sledeči način:

$$P_{1i}k_1 - P_{2i}CL_{max} \left( \frac{v}{s} \right) = 0 \quad (15)$$

$$CL_{max} = \frac{P_{1i}k_1}{P_{2i} \left( \frac{v}{s} \right)} \quad (16)$$

$CL_{max}$  predstavlja najvišjo vrednost kreditnega limita, ki se ga lahko odobri določenemu kupcu. To metodo različni avtorji imenujejo splošna enačba za določevanje maksimalne vrednosti kredita, na podlagi katere se je razvilo več različic. Pri izračunu je ključnega pomena, s kakšno zanesljivostjo se oceni verjetnost neplačila in možne stroške izterjave. Ob tem se je treba zavedati, da ta enačba temelji na sedanji vrednosti pričakovanih donosov, nič pa ne pove o tem, ali je kupec sploh sposoben generirati dovolj denarnega toka, da bo lahko pravočasno plačal in realiziral te pričakovane donose.

### 3.3.1.2 Stopnjevalna metoda

Skladno s to metodo kreditni limit določimo na podlagi ustvarjenega in pričakovanega prometa, popravljenega s tveganostjo neplačila in odprtimi postavkami.

$$L = \frac{SD * T}{1 + \frac{R*T}{12}} \quad (17)$$

Kjer velja, da je:

- $SD = BP * \beta_1$ ,  $BP = D * \beta_2 - OL$ ,  $D = DCI + \beta_3 * UCI$ ,
- $L$ : kreditni limit,
- $SD$ : pričakovana izpostava,

- T: rok plačila,
- $\beta_1$ : koeficient, ki izraža verjetnost nastanka,
- BP: popravljena vrednost prometa,
- D: promet,
- $\beta_2$ : koeficient, ki izraža verjetnost neplačila,
- OL: odprte postavke,
- DCI: zagotovljeni promet,
- $\beta_3$ : koeficient, ki izraža verjetnost, da se bo ustvaril pričakovani promet in
- UCI: pričakovani ustvarjeni promet.

Toda težava te metode je predvsem v tem, da je rezultat odvisen od parametrov  $\beta_1$ ,  $\beta_2$ , in  $\beta_3$ . Običajno, so te vrednosti, predvsem  $\beta_1$  in  $\beta_3$ , prepuščene analitiku, ki jih mora na podlagi svojih izkušenj pravilno določiti.

Konovalikhin, Kulik, Sergienko in Balaeva so leta 2008 v svojem raziskovalnem delu pokazali, kako bi lahko tudi ta dva parametra ocenili s pomočjo tehnike stopnjevanja. O tem, kako oceniti verjetnosti neplačil ( $\beta_2$ ), je bilo doslej narejenih že veliko raziskovalnih del<sup>3</sup>.

Vendar ima ta metoda še eno pomanjkljivost, in sicer da temelji le na verjetnosti neplačila in verjetnosti realizacije določenega prometa, ne upošteva pa možnosti, ali je kupec sposoben generirati dovolj denarnega toka, da bo lahko pravočasno poplačal terjatev.

### 3.3.1.3 Metoda pričakovanega dobička

Abtey (1993) je predlagal pravilo odločanja, po katerem mora biti količina kredita, v našem primeru vrednost kreditnega limita, manjša ali enaka dobičku, ki se ga ob tem skuša doseči. Zato je v določenem obdobju optimalna vrednost kreditnega limita tista, ki omogoča realizacijo takega prometa, kjer so pričakovane izgube manjše od pričakovanega dobička.

Za samo odločitev je Abtey (1993) predlagal, da potrebujemo tri parametre: realizirana marža pri kupcu ( $t_m$ ), verjetnost neplačila (PD) in predvidevan realiziran promet ( $CA_p$ ). Torej se lahko za določeno obdobje pričakovani dobiček izrazi kot  $CA_p * t_m$ , potencialna izguba pa kot  $E * PD * (1 - t_m)$ , kjer  $E$  pomeni kreditno izpostavljenost oz. maksimalno višino določenega kreditnega limita.

Če velja, da je pričakovani dobiček večji od potencialne izgube, lahko to zapišemo kot  $CA_p * t_m > E * PD * (1 - t_m)$ . Ko iz enačbe izpostavimo  $E$ , dobimo pravilo odločanja za dodelovanje kreditnih limitov:

---

<sup>3</sup> Več v poglavju o oceni kreditnega tveganja.

$$E \leq \frac{(CA_p * t_m)}{PD * (1 - t_m)} \quad (18)$$

Toda kot smo izpostavili,  $CA_p * t_m$  predstavlja pričakovani dobiček, ki se ga predvideva na podlagi napovedi oz. pričakovanja realiziranega prometa. Skladno s to enačbo je pričakovani promet definiran kot negotov parameter in odločitev bo pravilna le, če bo dosežen vsaj minimalni predvideni realizirani promet. Ob tem se predpostavlja, da kupec ne bo postal insolventen.

Sam avtor je poudaril, da uporaba te enačbe (18) nosi svoje tveganje. Zato je predvsem priporočljiva za kupce, ki so stalni tako z vidika prometa kot plačilnih navad, saj v nasprotnem primeru obstaja veliko tveganje za napačno odločitev.

Abtey (1993) je tudi izpostavil, da pravilo odločanja pri zelo nizkih verjetnostih neplačila – pri skoraj nič, ne poda pravega rezultata, ker gre lahko dobljena vrednost v neskončno. Zato je predlagal, da v teh primerih dobljeno vrednost omejimo s kakšnim parametrom. Omeji pa se jo lahko s pričakovanim realiziranim prometom ali pa vrednostjo, ki jo določi analitik na podlagi svojih izkušenj.

$$E^* < CA_p \text{ ali } E^* < Max \quad (19)$$

Vendar tudi ta metoda temelji predvsem na verjetnosti neplačila in pričakovanih realiziranih donosih, kar ponovno pomeni, da ne upošteva drugih dejavnikov, ki vplivajo na poplačila.

#### 3.3.1.4 Metoda kazalnikov donosnosti

Metoda temelji na oceni pričakovanih realiziranih donosov. Dionne, Artis in Guilln (1996) so predlagali, da se je treba pri določevanju vrednosti kreditnih limitov vprašati, koliko dobička lahko podjetje pričakuje, če odobri določenemu kupcu prodajo na kredit. Odgovor na to vprašanje so določili z enačbo, iz katere je določitev potencialnega dobička odvisna od verjetnosti neplačila. Predlagana enačba je sledeča:

$$E(\text{profit}) = D(r - u) - PD E_1(c_1) - (1 - PD) E_0(c_0) - PD L(1 + r)LGD \quad (20)$$

Kjer velja, da je:

- L: kreditni limit,
- r: obrestna mera,
- $\mu$ : alternativna obrestna mera investiranih sredstev,
- $c_0$ : administrativni stroški, povezani z neplačilom kupcev, ki so insolventni,
- $c_1$ : administrativni stroški, povezani z neplačilom kupcev, ki niso insolventni,

- LGD: pričakovana izguba ob neplačilu in
- PD: verjetnost neplačila.

Leta 2005 je Altman izpostavil, da je lahko maksimalna vrednost dodeljenega kreditnega limita določenemu kupcu ( $L_i^*$ ) enostavna linearna rešitev zgornje enačbe. To pomeni, da se z linearno rešitvijo za posameznega kupca določi kreditni limit, ki bo omogočal pričakovani dobiček.

$$L_i^* \in \arg \max_L (r - \mu)L_i - PD_i L_i (1 + r) LGD_i ; L_i \geq 0 \quad (21)$$

$$\left\{ \begin{array}{l} L_i * LGD * N \left( \frac{N^{-1}(PD_i) - \sqrt{\rho} * N^{-1}(0,99)}{\sqrt{1-\rho}} \right) \leq VAR_i \\ L_i > 0 \end{array} \right\} \quad (22)$$

Kjer velja, da je:

- $L_i$ : kreditni limit,
- $N^{-1}$ : inverzna normalna kumulativna porazdelitev,
- $VAR_i$ : tvegana vrednost, ki predstavlja ob dani tveganosti največjo izgubo, ki se jo lahko utrpi pri odobritvi prodaje na kredit.

Vendar pa ima tudi ta model svoje omejitve. Največja je ta, da izračun optimalnega kreditnega limita temelji le na verjetnosti neplačila (PD). Dejansko pa obstajajo še drugi kvantitativni in kvalitativni dejavniki, ki vplivajo na kreditni limit in ti niso upoštevani pri izračunu verjetnosti neplačila (Bazzi & Hasna, 2015, str. 205).

### 3.3.1.5 Metoda točk tveganj

Metoda predpostavlja, da je profil tveganja ključnega pomena za določitev višine kreditnih limitov. Zato je pomembno, da se pri ocenjevanju tveganja pridobi celotno sliko o podjetju, kateremu se bo odobrilo prodajo na kredit in v ta namen uporabiti vse možne razpoložljive kvantitativne in kvalitativne podatke (Bazzi & Hasna, 2015, str. 206).

Pri uporabi metode točk tveganj je ključnega pomena, da imamo dovolj informacij za izvedbo tako kvalitativne kot tudi kvantitativne analize. Obstaja več različnih postopkov za dodeljevanje točk tveganja in najbolj znan je tisti od Thomasa, Edelmana in Crooka (2000) v delu *Kreditno točkovanje in njegova uporaba oz. v angl. Credit Scoring and its Application*.

Za potrebe določevanja kreditnega limita je treba na dobljeno lestvico točkovanja napraviti prelome, ki so podlaga za določitev višine kreditnega limita. Toda tudi ta način ne poda odgovora, koliko je kupec v določenem obdobju sposoben pravočasno poravnati.

### 3.3.2 Modelirni pristop

Strokovni pristopi določevanja kreditnih limitov najbolj pogosto temeljijo na konceptu pričakovanih realiziranih donosov. To pomeni, da je določena višina kreditnega limita po strokovnih pristopih odvisna predvsem od tega, koliko dobička lahko podjetje pričakuje, če določenemu kupcu odobri prodajo na kredit. Od tega, kako se ga na koncu določi, pa je odvisno, kako se izrazijo pričakovani donosi, ki lahko nastanejo zaradi odobritve prodaje na kredit. Pričakovani donos torej na koncu predstavlja maksimalni odobreni kreditni limit.

To pomeni, da kreditni limiti, izračunani na podlagi strokovnega pristopa, ne podajo odgovora na vprašanje, kolikšen je znesek, ki ga je posamezni kupec v določenem obdobju sposoben pravočasno poravnati, temveč le, koliko lahko znaša pričakovana vrednost donosa v primeru nastopa neplačila.

Ob tem pa strokovni pristopi poleg pričakovanih donosov večinoma temeljijo še na verjetnosti neplačila, kar pa ni najboljše v primeru določevanja kreditnih limitov za namene prodaje na kredit. Carboni (1997) je v svoji študiji dokazal, da je ocena verjetnosti neplačila boljši pokazatelj nerednih plačil, torej plačilne nediscipline, kot pokazatelj sposobnosti plačila.

Zato so se razvili pristopi, ki so poskusili odgovoriti predvsem na vprašanje. Kolikšen je tisti znesek, ki ga je posamezni kupec v določenem obdobju sposoben pravočasno poravnati. Za ta namen se uporabi različne metode iz *data mining* področja, predvsem pa tiste, ki so primerne za napovedovanje. Z modelirnim pristopom poskušamo napovedati, koliko denarnega toka v določenem obdobju je posamezni kupec sposoben ustvariti. To pomeni, da ta pristop temelji predvsem na konceptu ugotavljanja kupčeve plačilne sposobnosti (Dun & Bradstreet, 2011, str. 24).

Za potrebe napovedovanja višine kreditnega limita lahko uporabimo metode, ki napovedujejo pravilno uvrstitev ali pa vrednost. Za prvi način se uporablja predvsem različne klasifikacijske metode, medtem ko za drugega različne regresijske metode (Li & Zhong, 2012, str. 182).

Kateri način bomo izbrali, je vezano na tip uporabljene odvisne spremenljivke. Če je ta v obliki kategorične spremenljivke, se odločimo za metode za klasificiranje, v primeru zvezne spremenljivke pa za regresijo (Lavrač, 2011, str. 37).

Metode klasificiranja oz. razvrščanja poskusijo izdelati tak model, ki na podlagi ugotovljene sposobnosti plačila kupca te razvrsti v naprej dodeljene skupine oz. razrede. Vsaka skupina pa določa intervalno vrednost višine kreditnega limita. Metode regresije pa poskusijo izdelati tak model, ki poda točno vrednost, ki jo je kupec sposoben poplačati. Ta vrednost predstavlja maksimalno višino odobrenega kreditnega limita (Kirkos, Spathis & Manolopoulos, 2010; Yeh & Lien, 2009; Zurada & Lonial, 2005).

### 3.3.2.1 Metode klasificiranja oz. razvrščanja

Metode klasificiranja oz. razvrščanja uporabimo takrat, ko operiramo s kategorično spremenljivko. To pomeni, da imamo v naprej dano n-število razredov, v katere želimo pravilno uvrstiti posamezne enote. V našem primeru nam ti razredi predstavljajo intervalne vrednosti možnih odobrenih višin kreditnega limita.

Cilj razvrščanja je torej, da na podlagi razpoložljivih podatkov razvrstimo kupca v pravi interval, ki bo izražal tako vrednost, ki jo je kupec v določenem obdobju sposoben pravočasno poravnati. Za potrebe kreditnega limita lahko uporabimo sledeče metode:

- linearna diskriminantna funkcija,
- odločitveno drevo,
- Bayesian klasifikatorji,
- k-najbližjih sosedov (k-NN),
- metoda podpornih vektorjev (SVM),
- umetne nevronske mreže (ANN),
- genetski algoritem (GA),
- hibridni algoritem,
- ensemble algoritem, npr. *Random Forest* klasifikator.

**Linearna diskriminantna funkcija:** prvi, ki jo je uporabil za namene razvrščanja, je bil Fisher (1936). Z diskriminantno analizo poiščemo takšno linearno kombinacijo merjenih spremenljivk, ki bo maksimalno ločila vnaprej določene skupine in da bo napaka pri uvrščanju enot v skupine najmanjša.

Diskriminantna analiza temelji na gradnji ene ali več linearnih funkcij, ki vključujejo različne pojasnjevalne spremenljivke. Splošni model se lahko zapiše kot:

$$Z = \alpha + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_p X_p \quad (23)$$

Kjer  $Z$  predstavlja rezultat diskriminacije,  $\alpha$  je konstanta in  $\beta_i$  pa predstavlja koeficient, ki beleži informacijo za linearni prispevek posamezne pojasnjevalne spremenljivke  $X_i$ , kjer velja za  $i=1, 2, \dots, p$ .

Toda njen problem leži v zahtevi, da obstaja linearna povezava med odvisno in neodvisnimi spremenljivkami. Ob tem pa zahteva še, da se vse uporabljene spremenljivke v modelu normalno porazdelijo.

**Odločitveno drevo:** znano tudi kot rekurzivna delitev, ker je zgrajena s pomočjo procesa tako imenovane binarne rekurzivne delitve. Odločitveno drevo je metoda klasificiranja, ki so jo predstavili Breiman, Friedman, Olshen in Stone (1984), in sicer kot metodo klasificiranja, ki uporablja zgodovinske podatke za gradnjo t.i. pravil odločanja, organiziranih v drevesno strukturo.

Odločitveno drevo je sestavljen iz listov, ki ustrezajo razredu oz. vozlišč, ki ustrezajo posameznim atributom, in vej, ki ustrezajo podmnožicam vrednosti različnih atributov. Ena pot od korena do lista predstavlja eno odločitveno pravilo. Na podlagi več takih pravil lahko klasificiramo nove enote (Witten & Frank, 2005, str. 62–64).

V odločitveni teoriji je odločitveno drevo graf, ki določi tako imenovane logične pogoje, ki omogočijo napoved ali razvrstitev enot v prave razrede. Največja prednost je v tem, da je to transparentna metoda, ki poda točno strukturo odločanja, ki jo je lahko razumeti in razložiti. Vendar je njena omejitev v tem, da je ni mogoče posplošiti (Bastos 2008; Lee, 2006; Matuszyk, Mues, & Thomas, 2010).

Poznamo tri splošne algoritme za drevo odločanja: hi-kvadrat avtomatski detektor interakcije (CHAID), klasifikacijsko in regresijsko drevo (CART) in C5<sup>4</sup>. Ti algoritmi se razlikujejo z vidika kriterija, kako ta zgradi drevesno strukturo. CHAID izdela drevo na podlagi hi-kvadrat testa, CART uporabi delitveni kriterij, C5 uporabi entropijo (Yap, Ong & Husain, 2011, str. 13275).

**Bayesian klasifikator** je preprost verjetnostni klasifikator, ki omogoča napovedovanje verjetnosti, da enota pripada določeni skupini. Ta temelji na Bayesianovem teoremu, naloga klasifikatorja pa je, da na podlagi razvojnega nabora vzorcev  $D = \{\mu_1, \dots, \mu_N\}$ , napravi funkcijo preslikave  $f: (x_1, \dots, x_n) \rightarrow C$ , ki poda oznako neznanemu vzorcu  $x = (x_1, \dots, x_n)$ .

Bayesian klasifikator izbere tisti razred uvrstitve, katerega oznaka ima največjo posteriorirno verjetnost  $P(c_j | x_1, \dots, x_n)$  in to na podlagi kriterija najmanjše verjetnostne napake oz. največje posteriorne verjetnosti. To pomeni, če velja, da je  $P(c_i | x) = \max_{j=1, \dots, i} P(c_j | x)$ , potem se lahko določi, da  $x$  pripada k  $c_j$  (Friedman, Geinger & Goldszmidt, 1997, str. 134–315).

---

<sup>4</sup> Lahko uporabimo tudi C4.5 in J4.8.

Najbolj uporabljeni metodi sta Naive Bayesian klasifikator in Bayesian belief networks. Naive Bayesian klasifikator predpostavlja, da so atributi oz. neodvisne spremenljivke med seboj neodvisne. Bayesian belief network pa je grafični model – usmerjeni aciklični graf (DAG), ki dopušča pogojno neodvisnost.

**K-najbližjih sosedov (k-NN)** je neparametrični klasifikator, ki temelji na učenju podobnosti, kar pomeni, da v prostoru atributov klasificira enote na podlagi najbližjih sosedov. Klasifikator je določen z razvojno populacijo, na podlagi katere se med pojasnjevalnimi spremenljivkami izdelajo funkcijske razdalje.

Ta deluje tako, da za vsako novo opazovalno enoto raziskuje prostor z namenom, da ugotovi, kateri k-sosed je najbližji. Klasifikator uvrsti enoto v tisto skupino, pri kateri zabeleži najmanjšo razdaljo med pojasnjevalnimi spremenljivkami. Razdalja  $T$  pa je opredeljena v smislu evklidske razdalje:  $d(X, Y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}$ .

Čeprav je omenjena tehnika zelo enostavna, je njena največja slabost v tem, da pri klasifikaciji prevladujejo razredi z največ enotami (Hand & Vinciotti 2003; Paredes & Vidal 2000).

**Metoda podpornih vektorjev (SVM)** je klasifikacijska tehnika, ki jo je predstavil Vapnik leta 1995. V osnovi so SVM klasifikatorji namenjeni razločevanju dveh razredov. Pri več razredih ponovimo postopek za vsak razred, ki ga želimo ločevati od ostalih. Nov primer klasificiramo v razred z najvišjo vrednostjo odločitvene funkcije.

Osnovna ideja je, da ob dani razvojni populaciji  $\{(x_i, y_i)\}$ ,  $z\ i = \{1, \dots, n\}$ , kjer je  $x_i$  vektor neodvisnih spremenljivk,  $y_i$  predstavlja binarno kategorijo, ki nas zanima,  $n$  pa pomeni število dimenzij vhodnih vektorjev, SVM poskuša najti optimalno hiper-ravnino. Zato je SVM v osnovi neverjetnostmi linearni binarni klasifikator (Li & Zhong, 2012, str. 184).

Optimalno hiper-ravnino lahko izrazimo na način:  $\sum_{i=1}^n w_i x_i + b = 0$ , kjer je  $w = w_1 w_1, \dots, w_n$  običajna hiper-ravnina in  $b$  mejna skalarna vrednost. Če pa upoštevamo hiper-ravnino, za katero velja  $y_i \in \{-1, 1\}$ , in geometrično razdaljo  $\frac{2}{\|w\|^2}$ , se lahko postopek maksimizacije izrazi s sledečo enačbo  $y_i (\sum_{i=1}^n w_i x_i + b) \geq 1$ . Običajno se to reši s pomočjo Lagrangovih multiplikatorjev in uporabo linearnih, polinomskih, Gausovih ali sig-modalnih porazdelitev.

Iz tega sledi, da metoda vključuje tri elemente: enačbo točkovanja, ki je linearna kombinacija pojasnjevalnih spremenljivk, ki so bile uporabljene za razvrščanje; objektivno funkcijo, ki upošteva tako vzorce za učenje kot za testiranje za namene optimizacije razvrstitve novih enot; in optimizacijski algoritem za določanje optimalnih parametrov.

Prednost SVM je v tem, da ne zahteva vnaprej določene strukture podatkov in njihove porazdelitve, torej je neparametrična metoda. Pomanjkljivost pa jev njegovi interpretaciji (Bellotti & Crook, 2009; Huang, Chen & Wang, 2007).

**Umetne nevronske mreže (ANN)** predstavljajo poskus posnemanja vrste nelinearnega učenja, ki je značilna za nevronske mreže, ki jih ustvarja narava. Da se lahko nevronska mreža uči, moramo priskrbeti skupek zgodovinskih vhodnih podatkov in ustrezne poznane vrednosti izhodov. Nevronska mreža se uči tako, da skuša postopno razumeti povezavo med vhodnimi in izhodnimi podatki. Mreža iterativno uravnava uteži za vsak testni primer, dokler se povprečna napaka na kvadrat med ocenjeno in dejansko vrednostjo ne nahaja na predhodno določenem zadovoljivem nivoju (De Barcelos-Tronto, Simíes da Silva & Sant'Anna, 2008, str. 358–360).

Mreže so zelo dobro orodje za neznano podatkovno modeliranje, saj so sposobne prepoznati zelo zapletene vzorce med vhodnimi in izhodnimi podatki, na podlagi katerih lahko napovejo pravilno klasifikacijo. Največja prednost teh modelov je predvsem v tem, da se zelo hitro učijo in ne beležijo predpostavk, ki narekujejo razmerja med vhodnimi podatki (Li & Zhong, 2012, str. 183).

**Genetski algoritem (GA)** je računalniški algoritem, ki ga je predstavil Holland (1975), ki posnema naravno selekcijo Darwinove evolucijske teorije z namenom, da poda optimalno rešitev. Genetski algoritem temelji na matematičnem splošnem konceptu optimizacije, in sicer na prilagodljivem hevrističnem iskalnem algoritmu, ki temelji na mehanizmu naravne selekcije in genetike. Glavni cilj genetskega algoritma je, da na podlagi procesa evolucije ustvari populacijo možnih rešitev. To pomeni, da v procesu izdelave uporabi genetske operacije, kot so mutacije in razmnoževanja (Koza, 1992, str. 687).

**Hibridni algoritem** združuje dve ali več predhodno predstavljenih metod z namenom, da združi njihove prednosti za izboljšavo njihovega prvotnega delovanja (Hsieh, 2005; Lee & Chen, 2005). Običajno iz ene metode uporabi klasifikator, ki ga kombinira z izbirno funkcijo oz. parametrom za klasificiranje iz druge metode. Vendar za enkrat še ni skupne rešitve za razvrščanje hibridnih modelov (Li & Zhong, 2012, str. 185).

Če povzamemo Tsaija in Chena (2010), se lahko hibridni modeli ločijo v 4 skupine: združevanje + razvrščanje, razvrščanje + združevanje, združevanje + razvrščanje in razvrščanje + združevanje. Li in Zhong (2012) pa jih ločita na *Simple Hybrid Models* in *Class-Wise Classifier*.

**Ensemble algoritem** je nova tehnika in zato na vprašanje, kaj je pravzaprav ensemble<sup>5</sup> učenje, še ni jasne opredelitve. Na splošno velja prepričanje, da je ena izmed najbolj

---

<sup>5</sup> Beseda izhaja iz francoščine in pomeni skupaj.

pomembnih značilnosti v tem, da se lahko vedno znova uči iz istega problema, kar je drugače od načina pridobivanja celotne rešitve iz individualnih rešitev, temelječih na reševanju različnih zaporednih podproblemov (Li & Zhong, 2012, str. 186).

Pomembna razlika med hibridnimi in ensemble klasifikatorji je v tem, da hibridni modeli uporabijo samo en klasifikator, medtem ko za izbirno funkcijo in klasifikacijo uporabijo različne načine iz različnih metod (npr: uporaba ANN za klasifikatorja in MARS ali LR ali GA itd. za izbirno funkcijo). Medtem ko ensemble učenje uporablja različne klasifikatorje različnih metod in večkrat trenira različne vzorce, npr. uporabo SVM klasifikatorja z različnimi parametri (Li & Zhong, 2012, str. 186).

To pomeni, da so ensemble klasifikatorji kombinacija različnih klasifikatorjev, kjer je njihov namen povečati učinkovitost primarnih klasifikatorjev. V samem procesu se lahko uporabi več tehnik, *bagging*, *boosting* in *stacking*. Nekateri avtorji tudi menijo, da hibridne algoritme je moč obravnavati kot posamezen primer *stackinga* (Li & Zhong, 2012, str. 186).

### 3.3.2.2 Regresijske metode

Metode razvrščanja omogočajo določitev višine kreditnih limitov na podlagi verjetnosti pripadnosti določeni skupini, ki določa intervalno vrednost višine kreditnega limita. Regresijske metode medtem omogočajo točno dodelitev višine kreditnega limita. Cilj regresije je torej v tem, da za izbrano časovno obdobje in na podlagi razpoložljivih podatkov napove vrednost, ki jo bo kupec lahko pravočasno poravnal.

Za potrebe kreditnega limita se lahko v primerih, ko se razpolaga z zvezno odvisno spremenljivko, uporabi nekatere od zgoraj že opisanih metod, le da so te prilagojene za zvezne tipe, npr: regresijska drevesa, SVM za regresijo, ANN za regresijo in k-NN za regresijo. Poleg zgoraj omenjenih načinov za potrebe kreditnega limita lahko uporabimo še:

- linearno regresijo,
- multivariatno prilagodljivo regresijo *splines* (MARS),
- genetske, hibridne in ensemble algoritme.

**Linearna regresija** je bila prva med regresijskimi analizami, ki je bila močno zastopana v praksi. Razlog za to je, da je modele, ki so linearno odvisni od svojih neznanih parametrov, lažje izračunati kot tiste, ki so nelinearno odvisni. Toda problem linearne regresije leži prev v predpostavki o linearnosti, kise pogosto izkaže, da jev praksi težko dosežena. In v primeru, dani dosežena, lahko dobimo pristranske rezultate, ki nas bodo vodili v napačne odločitve (Košmelj, 2007a, str. 152).

**Multivariatna prilagodljiva regresija splines (v nadaljevanju MARS):** prvi, ki je predstavil to metodo, je bil Friedman (1991). MARS je nelinearna in neparametrična metoda, ki zelo dobro obravnava večdimenzionalne podatkovne strukture in omogoča posploševanje. Funkcija MARS se običajno izrazi s sledečo funkcijo:

$$\hat{f}(x) = a_0 + \sum_{m=1}^M a_m \prod_{i=1}^{K_m} [s_{km}(x_{v(k,m)}) - t_{km}] \quad (24)$$

V kateri  $a_i$  predstavlja parametre,  $M$  število baznih funkcij in  $K_m$  število vozlov,  $s_{km}$  lahko zajema vrednosti od  $-1$  do  $1$  in predstavlja levo ali desno povezano funkcijo,  $x_{v(k,m)}$  pa predstavlja oznako neodvisne spremenljivke in  $t_{km}$  lokacijo vozla.

MARS se izvaja v dveh fazah. V prvi sestavi veliko število baznih funkcij na način, da se preveč prilagajajo podatkom. V drugi fazi pa tiste funkcije, ki najmanj prispevajo, izbriše s pomočjo generaliziranega navzkrižnega validacijskega merila (GCV).

## 4 MODELIRANJE

Namen izdelave modela za določevanje kreditnih limitov je napovedati tisti znesek, ki ga bo podjetje v določenem obdobju sposobno poravnati. V ta namen lahko uporabimo različne metode iz *data mining* področja, predvsem pa tiste, ki so primerne za napovedovanje. V primerih, ko želimo napovedati vrednost, uporabimo eno izmed regresijskih metod, medtem ko se v primerih, ko imamo razrede in želimo napovedati pravilno uvrstitev, uporabimo eno izmed klasifikacijskih metod.

To pomeni, da postopek za izdelavo modela za določevanje kreditnih limitov ni nič drugega kot navaden postopek, ki ga uporabimo pri izdelavi običajnih modelov za napovedovanje. Najprej je treba pridobiti podatke, ki opisujejo tisto, kar želimo napovedati. Nato je treba spoznati in očistiti podatke in podati končno definicijo, za koga in kaj se bo napovedovalo ter kakšno metodo za napovedovanje se bo uporabilo.

Na podlagi predhodnega preučevanja, kaj vse lahko vpliva na iskani pojav, napravimo nabor dejavnikov oz. kazalnikov, s pomočjo katerih ga bomo poskusilo napovedovati. Tudi dejavnike je treba spoznati in po potrebi transformirati; in to skladno s potrebami posamezne izbrane metode, ki jo bomo uporabili.

Ko končamo postopek priprave podatkov, se lahko začnemo fazo iskanja pravega modela. Na koncu ga lahko, če dobimo tak model, ki zadosti pričakovanjem, še testiramo na različne načine in z različnih vidikov, z namenom, da ugotovimo njegovo robustnost v spremenjenih okoliščinah. V primerih, ko model ne zadovolji pričakovanj, poskušamo

ugotoviti razloge za tak izid, povzeti ugotovitve in podati morebitne predloge za izboljšave ter z njimi ponoviti postopek.

## 4.1 Podatki

Podatke za izdelavo modela smo pridobili pri bonitetni hiši Bisnode, ki od leta 2006 naprej na mesečni ravni s pomočjo slovenskih podjetij zbira plačila računov. Za zbiranje podatkov je oblikovan partnerski program, v katerega se lahko vključi vsako podjetje in na ta način prispeva k večji transparentnosti plačilnih navad v slovenskem gospodarskem prostoru. V desetih letih se je število računov povzpelo na preko 48 milijonov, s katerimi se pokriva do 50% aktivnih delujočih gospodarskih subjektov<sup>6</sup>. Pokrite so vse panoge in za vsak gospodarski subjekt, za katerega se pridobi račun, se zabeleži datum izdaje računa, datum zapadlosti, datum plačila in vrednost računa, izražene v evrih.

Za potrebe izdelave modela smo se odločili za uporabo zgolj tistih podatkov za gospodarske družbe<sup>7</sup> (v nadaljevanju podjetja), ki so v letih 2013 ali 2014 zadostila pogoju, da je njihova vsota pridobljenih računov vsaj enaka ali višja od 5 odstotkov skupne vrednosti zabeleženih stroškov blaga, materiala in storitev. Pridobili smo podatke za 7.419 podjetij, za katera se je beležilo 692.393 računov, kar pomeni v povprečju 93 računov na posamezno podjetje.

Pridobljeno bazo je bilo treba najprej očistiti. Izločili smo vse račune, ki so beležili manjkajoče vrednosti v datumu plačila. Nato račune, ki so beležili daljši rok plačila od enega leta. Sledila je izločitev računov, ki so beležili kasnejši datum izdaje od datuma zapadlosti ali datuma plačila. Na koncu pa še vse račune, na katere niso bile zabeležene vrednosti ali pa je bila ta negativna. S tem smo izločili 5,7 odstotka pridobljenih računov in 7,5 odstotka podjetij.

Drugo čiščenje se je izvedlo z vidika podjetij. Izločili smo vsa podjetja, ki so že izbrisana iz poslovnega registra; podjetja, ki so začela v letu 2013 ali 2014 enega od insolventnih postopkov; tista, ki so v enakem obdobju zabeležila blokado<sup>8</sup>, in na koncu še tista, ki so bila na seznamu davčnih neplačnikov. Po teh pogojih se je še dodatno izločilo 9,2 odstotka podjetij in 5,5 odstotka računov.

Za potrebe validacije modela je v obeh letih dobro imeti enake enote. S tem namenom smo izločili še vsa podjetja, ki niso zadostila temu pogoju. Kot dodatni pogoj pa smo določili, da mora vsako podjetje v obeh letih beležiti vsaj 10 računov ali več.


---

<sup>6</sup> Gospodarski subjekti so gospodarske družbe, samostojni podjetniki, zadrage, društva, zavodi javnega in zasebnega prava.

<sup>7</sup> Gospodarske družbe so: družba z neomejeno odgovornostjo, družba z omejeno odgovornostjo in delniška.

<sup>8</sup> Blokada podjetja pomeni, da je podjetje beležilo rezervacijo na vseh odprtih transakcijskih računih 4 ali več delovnih dni.

Slika 5: Prikaz čiščenja podatkov




Na koncu, po izvedenem čiščenju, je ostalo 3.346 podjetij in 575.408 računov, v povprečju 172 računov na podjetje. Za potrebe modela je bilo tako izločenih 54,9 odstotka podjetij in 16,9 odstotka računov.

#### 4.1.1 Pregled

Za pravilno definicijo ciljne spremenljivke, v našem primeru vrednost kreditnega limita, je treba najprej spoznati, za kakšna podjetja se je pridobilo račune in kakšni so ti računi z vidika roka plačila, časa zamude in same vrednosti računov.

Podatke smo pridobili za podjetja zasebne lastnine (97,4 odstotka), v katerih prevladuje domači kapital (93,4 odstotka). Kar 84,2 odstotka podjetij je mikro, sledijo jim majhna podjetja z 9,7 odstotka. Največ podjetij prihaja iz dejavnosti trgovine (19,2 odstotka), sledijo jim podjetja iz predelovalne dejavnosti (18,6 odstotka).

Slika 6: Pregled podjetij po dejavnosti (v odstotkih)



Z vidika roka plačila smo ugotovili, da je kar 94,7odstotka vseh računov iz leta 2013 beležilo rok plačila do 60 dni, medtem ko je bilo v letu 2014 takih računov 93,0 odstotka.

Z vidika časa plačila je bilo v letu 2013 44,5 odstotka takih, ki so plačali na valuto ali prej, medtem ko je bilo takih v letu 2014 41,3 odstotka. Takih, ki so plačali do 10 dni po valuti, je bilo v letu 2013 67,0 odstotka, v letu 2014 pa 63,4 odstotka.

*Slika 7: Pregled računov z vidika roka in časa plačila*

| Odstotek računov |              |              | Odstotek računov          |              |              |
|------------------|--------------|--------------|---------------------------|--------------|--------------|
| Rok plačila      | 2013         | 2014         | Čas plačila               | 2013         | 2014         |
| Od 0 do 8 dni    | 17,9         | 15,6         | Pred valuto               | 22,3         | 19,3         |
| Od 9 do 15 dni   | 18,5         | 16,6         | Na valuto                 | 22,2         | 22,0         |
| Od 16 do 30 dni  | 19,5         | 16,6         | Od 1 do 10 dni po valuti  | 22,5         | 22,1         |
| Od 31 do 45 dni  | 20,1         | 17,4         | Od 11 do 29 dni po valuti | 21,9         | 18,7         |
| Od 46 do 60 dni  | 18,7         | 26,7         | Nad 30 dni po valuti      | 11,1         | 18,0         |
| Nad 60 dni       | 5,3          | 7,0          | <b>Skupaj</b>             | <b>100,0</b> | <b>100,0</b> |
| <b>Skupaj</b>    | <b>100,0</b> | <b>100,0</b> |                           |              |              |

Kot zanimivost lahko izpostavimo tudi pojav, opažen v obeh letih. In sicer, da so računi z rokom plačila nad 30 dni ali več na koncu zabeležili večje zamude pri plačilu kot računi s krajšim plačilnim rokom, in to ne glede na vrednost pridobljenega računa. V letu 2013 se je izkazalo, da je bilo med računi, ki so beležili rok plačila 30 dni ali več, kar 49,5 odstotka takih, ki so bili plačani z več kot 10-dnevno zamudo, medtem ko je bilo v letu 2014 takih že 53,6 odstotka.

*Slika 8: Strukturni pregled računov*

| Leto 2013 v %             |                    |                          |                      |        | Leto 2014 v %             |                    |                          |                      |        |
|---------------------------|--------------------|--------------------------|----------------------|--------|---------------------------|--------------------|--------------------------|----------------------|--------|
| Rok Plačila / Čas plačila | Pred ali na valuto | Od 1 do 10 dni po valuti | Nad 10 dni po valuti | Skupaj | Rok Plačila / Čas plačila | Pred ali na valuto | Od 1 do 10 dni po valuti | Nad 10 dni po valuti | Skupaj |
| Do 8 dni                  | 59,7               | 23,8                     | 16,5                 | 100,0  | Do 8 dni                  | 61,6               | 23,5                     | 14,9                 | 100,0  |
| Od 9 do 15 dni            | 52,3               | 25,7                     | 22,0                 | 100,0  | Od 9 do 15 dni            | 51,1               | 27,3                     | 21,6                 | 100,0  |
| Od 16 do 30 dni           | 52,6               | 26,3                     | 21,1                 | 100,0  | Od 16 do 30 dni           | 51,3               | 28,8                     | 19,9                 | 100,0  |
| Nad 30 dni                | 31,5               | 19,1                     | 49,5                 | 100,0  | Nad 30 dni                | 28,7               | 17,7                     | 53,6                 | 100,0  |

Ugotovitve z vidika vrednosti kažejo, da prevladujejo manjše vrednosti računov. V letu 2013 je bilo kar 64 odstotkov takih, ki so beležili vrednost le do 500 evrov (v nadaljevanju EUR), medtem ko je bilo v letu 2014 takih kar 68,6 odstotka. Računov nad 2000 EUR se je v letu 2013 beležilo le 12,9 odstotka, v letu 2014 pa le 9,9 odstotka.

Z vidika posameznega podjetja ugotavljamo, da je bilo v letu 2013 le 30,1 odstotka takih, ki so imela več kot 100 računov, v letu 2014 pa je bilo takih 32 odstotkov.

Pri pregledu, koliko je znašala skupna vrednost vseh računov za posamezno podjetje, ugotavljamo, da je bilo v letu 2013 21,5 odstotka takih, kjer je bila skupna vrednost manjša od 5 tisoč EUR, v letu 2014 je bilo takih 20,2 odstotka.

*Slika 9: Pregled računov in njihove vrednosti po podjetjih*

| Odstotek podjetij        |              |              |
|--------------------------|--------------|--------------|
| Skupna vrednost računov  | Leto 2013    | Leto 2014    |
| Do 5.000 EUR             | 21,5         | 20,2         |
| Od 5.000 do 10.000 EUR   | 15,9         | 16,0         |
| Od 10.000 do 15.000 EUR  | 11,3         | 10,9         |
| Od 15.000 do 25.000 EUR  | 14,2         | 14,9         |
| Od 25.000 do 50.000 EUR  | 15,4         | 16,3         |
| Od 50.000 do 100.000 EUR | 19,9         | 10,9         |
| Nad 100.000 EUR          | 1,8          | 10,7         |
| <b>Skupaj</b>            | <b>100,0</b> | <b>100,0</b> |


| Odstotek podjetij |              |              |
|-------------------|--------------|--------------|
| Št. Računov       | 2013         | 2014         |
| Od 10 do 50       | 32,4         | 30,8         |
| Od 51 do 100      | 37,5         | 37,2         |
| Nad 100           | 30,1         | 32,0         |
| <b>Skupaj</b>     | <b>100,0</b> | <b>100,0</b> |

Med skupno vrednostjo računov od 5 tisoč do 25 tisoč EUR vrednosti se je v obeh letih uvrstilo za okoli 41 odstotkov vseh podjetij. Skupna vrednost računov nad 100 tisoč EUR pa se v letu 2013 beleži le za 1,8 odstotka podjetij, v letu 2014 pa za kar 10,7 odstotka podjetij.

#### 4.1.2 Izbira obdobja

Podatke o zaprtih računih smo pridobili za obdobje 2013 in 2014. Preko pregleda podatkov smo ugotovili, da obstaja v obeh letih bolj ali manj enaka struktura računov, tako z vidika vrednosti kot roka plačila in zamud. Zato smo se odločili, da bomo podatke o računih za leto 2013 uporabili za razvoj modela, podatke za leto 2014 pa za testiranje.

Slika 10: Predstavitev časovnega izbora



V finančnem svetu se običajno skušati napovedovati za eno leto v naprej (Dun & Bradstreet, 2009, str. 18). To pomeni, da se skuša s podatki iz leta  $t-1$  napovedati izid v letu  $t$ . V našem primeru smo se odločili, da se bo za razvoj modela uporabili kreditni limit, ki bo izražen na podlagi računov iz leta 2013. Iz tega sledi, da smo za napovedovanje kreditnega limita uporabili finančne kazalnike iz leta 2012.

## 4.2 Določitev kreditnega limita

S pomočjo modela za določevanje kreditnih limitov skušamo ugotoviti, kolikšen je tisti znesek, ki ga je posamezno podjetje v določenem obdobju sposobno pravočasno poravnati. V praksi se običajno poskuša oceniti ta znesek za obdobje 3 mesecev oz. obdobje enega četrtertletja (Dun & Bradstreet, 2011, str. 31–32).

Čeprav se običajno želi oceniti zmožnost pravočasnega plačila, pa bi bila v našem primeru takšna definicija na pridobljenih podatkih prestroga, saj je takih računov za izbrana leta nekaj nad 40 odstotkov. Če bi se držali te opredelitve, bi izločili skoraj 60 odstotkov vseh računov. Zato smo se odločili za nekoliko mehkejšo definicijo, in sicer: »Kolikšen je tisti znesek, ki ga je posamezno podjetje v določenem obdobju sposobno poravnati z rahlo zamudo?«. Za potrebe izdelave tega modela so prišli v poštev vsi računi, ki so bili plačani z do 8 dni zamude.

Naslednja dilema je bila, kako definirati znesek oz. vrednost kreditnega limita. Ob pregledu podatkov smo opazili, da število računov in njihova vrednost za vsa podjetja nista enakomerno porazdeljena skozi čas. To pomeni, da se lahko za določeno podjetje v enem mesecu beleži samo 1 račun za 100 EUR, nato nekaj mesecev nič, na koncu leta pa npr. 20 računov z različnimi vrednostmi.

Slika 11: Shema za določitev kreditnega limita


|      | JAN   | FEB   | MAR   | APR   | MAJ   | JUN   | JUL   | AVG   | SEP   | OKT    | NOV   | DEC |
|------|-------|-------|-------|-------|-------|-------|-------|-------|-------|--------|-------|-----|
|      |       |       |       |       |       |       |       |       |       |        |       |     |
|      | 1     |       |       |       |       |       |       |       |       |        |       |     |
|      |       | 2     |       |       |       |       |       |       |       |        |       |     |
|      |       |       | 3     |       |       |       |       |       |       |        |       |     |
|      |       |       |       | 4     |       |       |       |       |       |        |       |     |
|      |       |       |       |       | 5     |       |       |       |       |        |       |     |
|      |       |       |       |       |       | 6     |       |       |       |        |       |     |
|      |       |       |       |       |       |       | 7     |       |       |        |       |     |
|      |       |       |       |       |       |       |       | 8     |       |        |       |     |
|      |       |       |       |       |       |       |       |       | 9     |        |       |     |
|      |       |       |       |       |       |       |       |       |       | 10     |       |     |
|      |       |       |       |       |       |       |       |       |       |        |       |     |
| ID   | Sum 1 | Sum 2 | Sum 3 | Sum 4 | Sum 5 | Sum 6 | Sum 7 | Sum 8 | Sum 9 | Sum 10 | MAX W |     |
| ID 1 | 463   | 981   | 2.031 | 2.019 | 3.453 | 3.599 | 4.210 | 2.940 | 2.545 | 2.235  | 4.210 |     |
| ID 2 | 1.734 | 1.209 | 2.590 | 2.048 | 2.575 | 2.186 | 2.200 | 2.202 | 1.209 | 1.580  | 2.590 |     |

Zaradi tega smo se odločili, da bomo za vsako podjetje napravili seštevke vrednosti računov za 3-mesečno premikajoče obdobje. Med vsemi pridobljenimi seštevki smo nato izbrali najvišjo vrednost kot vrednost limita, ki ga je podjetje sposobno poravnati v obdobju 3 mesecev.

Za leto 2013<sup>9</sup> smo tako pridobili 37,8 odstotka podjetij, ki so na tak način beležila najvišjo vrednost pod 3 tisoč EUR, vrednost nad 30 tisoč EUR pa samo 11,0 odstotka podjetij. Med njimi je bilo tudi 19 takih, ki so beležili več kot 1 milijon EUR tako izražene kreditnega limita, in eno podjetje z maksimalno skupno vrednostjo 51,4 milijona EUR.

Tako veliki razponi so posledica različne velikosti obsegov ekonomije podjetij, za katere smo pridobili račune. Čeprav v pridobljeni populaciji prevladujejo mikro in majhna podjetja, so med njimi tudi srednja in velika. Zaradi tega se je dobljeni znesek še relativiziral glede na 3-mesečno prodajo<sup>10</sup>.

*Slika 12: Porazdelitev relativiziranega kreditnega limita*



Rezultat je pokazal, da kar 46,7 odstotka podjetjem izračunani limit predstavlja vrednost pod 5 odstotkov 3-mesečne prodaje, medtem ko le 8,2 odstotka podjetjem več kot četrtino te prodaje. Med njimi je bilo tudi veliko ekstremov, ki jih nismo izločili, temveč smo jim podelili maksimalno vrednost, za katero smo določili, da bo 25 odstotkov.

### 4.3 Kazalniki


Po definiciji ciljne spremenljivke, ki je v našem primeru kreditni limit, nastopi čas, da izberemo dejavnike oz. kazalnike, s katerimi ga bomo poskusili napovedati. Kreditni limit mora izražati plačilno sposobnost posameznega podjetja. Plačilna sposobnost podjetja pa je odvisna od likvidnosti sredstev, od katerih je na koncu odvisno, ali bo podjetje imelo zadostno količino denarnega toka, da bo lahko sproti poravnalo svoje obveznosti.

<sup>9</sup> Ker smo se odločili, da se model izdelava na podlagi podatkov iz leta 2013, bodo v magistrskem delu prikazani rezultati samo za to leto.

<sup>10</sup> Ob tem predpostavljamo, da podjetja ne beležijo sezonske komponente.

Ker želimo pri izdelavi modela kreditnega limita ugotoviti, koliko denarnega toka v določenem obdobju je posamezno podjetje sposobno ustvariti, je pomembno, da izberemo tiste kazalnike, ki izražajo likvidnost posameznega podjetja.

*Slika 13: Prikaz izbora kazalnikov*



To so predvsem kazalniki, ki so sestavljeni iz komponent obratnega kapitala, in kazalniki, ki izražajo denarni tok samega podjetja. Za potrebe modela se je izbralo tudi nekaj kazalnikov uspešnosti, predvsem tiste, ki izražajo donosnost v svojem poslovanju in gospodarnost z vidika stroškov, saj podjetje, ki ni uspešno v svojem osnovnem poslovanju, v končnem smislu ne more biti zares likvidno.

Ob tem pa se je izbralo še nekaj kazalnikov, ki izražajo način financiranja, saj bo v primeru, da je podjetje preveč zadolženo ali da svojega bremena ni sposobno sproti servisirati, njegova likvidnost trpela. Nato pa tudi nekaj kazalnikov, ki podajo informacijo o načinu investiranja, saj bo v primeru, ko ima podjetje preveč svojega kapitala investiranega v sredstvih, ki se zelo počasi obračajo, to imelo negativen učinek na likvidnost.

Na koncu smo kot kazalnik izbrali tudi stopnjo tveganja neplačila v dejavnosti, izraženo preko odstotka blokad podjetij v teh dejavnostih. Ta kazalnik smo izbrali zato, ker smo želeli vključiti tudi likvidnost poslovnega okolja, v katerem posamezno podjetje posluje.

Skupno smo zbrali 50 različnih kazalnikov z vseh opisanih področij. Tudi za izračun izbranih kazalnikov je bonitetna hiša Bisnode posredovala finančne izkaze za obdobje 2011–2013. Celoten seznam in definicije izbranih kazalnikov se nahajajo v Prilogi 2.

#### **4.3.1 Transformacija**

Izbrani kazalniki so številčne spremenljivke, zato je zelo pomembno, preden začnemo izdelavo modela, pregledati porazdelitve vsakega izbranega kazalnika. Po pričakovanjih smo ugotovili, da so njihove porazdelitve zelo asimetrične, večina jih je desno, nekateri

med njimi pa so tudi v levo. Asimetrija je predvsem posledica ekstremnih vrednosti, ki se pojavijo pri posameznemu kazalniku. V ekonomskem svetu velja pravilo, da imajo tudi ekstremi svojo informacijo (Dun & Bradstreet, 2009, str. 28). Zato smo se odločili, da bomo v takih primerih naredili primerno transformacijo.

V primerih, ko smo beležili veliko število manjkajočih vrednosti, smo jih spremenili v diskretno oz. kategorično ali celo v *dummy* obliko. Več podrobnosti o transformaciji se nahaja v Prilogi 2.

Po izvedeni transformaciji so postale porazdelitve razmeroma lepše, razen za nekatere od kazalnikov, ki so povezani s financiranjem. Porazdelitve transformiranih kazalnikov in njihovo osnovno statistiko si lahko pogledate v Prilogi 3.

#### **4.3.2 Metoda glavnih komponent**

Metoda glavnih komponent (v nadaljevanju PCA) je geometrijska metoda razvrščanja, katere osnovna zamisel je opisati razpršenost  $n$  enot v  $m$  razsežnem prostoru (Košmelj, 2007b, str. 159).

Metoda je namenjena pojasnitvi variančno-kovariančne strukture množice preučevanih spremenljivk, s pomočjo oblikovanja nekaj novih spremenljivk, ki predstavljajo linearne kombinacije prvotnih spremenljivk in i jih imenujemo glavne komponente. Temeljni namen metode sta skrčenje količine podatkov in razlaga vsebine preučevanega pojava (Rovan, 2002, str. 1).

PCA je pomembna, ker odkrije do tedaj neznane povezave med spremenljivkami in prispeva k boljši razlagi preučevanega pojava. In prav s tem namenom smo jo uporabili v našem primeru.


Vsaka dobljena komponenta predstavlja medsebojno močno korelirane spremenljivke, za katere ni smiselno, da so istočasno v modelih, saj vsebujejo enako informacijo. S takim spoznanjem se lahko izognemo problemu multikolinearnosti pri metodah, ki so na to občutljive (Pahor, 2004; Rován, 2002).

PCA je zelo občutljiva na višinsko skalo med vhodnimi podatki (Kotu, 2015, str. 357). Izbrani kazalniki kljub izvedeni transformaciji ne beležijo enakih skal, med njimi sta posebna dva, ki še posebej izstopata. Iz tega razloga smo napravili standardizacijo na vseh izbranih kazalnikih, z namenom, da uničimo ta efekt. Ko se napravi standardizacija, se PCA izvede na korelacijski matriki in ne več na kovariančni (Košmelj, 2007b; Pahor, 2004; Rován, 2002).

S pomočjo programa SPSS smo nato izvedli PCA pri kateri smo uporabili tudi pravokotno rotacijo z namenom, da bi dobili bolj enostavno sliko pojava<sup>11</sup> (Pahor, 2004; Rovin 2002). Kot rezultat smo dobili 10 komponent, katerih lastna vrednost je višja od 1 in skupaj pojasnijo 74,2 odstotka celotne variance izbranih kazalnikov.

*Slika 14: Celotna varianca razložena po komponentah – PCA*

| Pojasnjena Varianca |                          |                   |                |
|---------------------|--------------------------|-------------------|----------------|
| Komponente          | Začetne lastne vrednosti |                   |                |
|                     | Skupaj                   | Odstotek variance | Kumulativa (%) |
| 1                   | 9,54                     | 21,69             | 21,69          |
| 2                   | 6,01                     | 13,66             | 35,35          |
| 3                   | 3,77                     | 8,57              | 43,93          |
| 4                   | 2,90                     | 6,59              | 50,51          |
| 5                   | 2,46                     | 5,59              | 56,11          |
| 6                   | 2,12                     | 4,82              | 60,93          |
| 7                   | 1,75                     | 3,99              | 64,92          |
| 8                   | 1,57                     | 3,56              | 68,48          |
| 9                   | 1,29                     | 2,94              | 71,41          |
| 10                  | 1,23                     | 2,78              | 74,20          |



Opazili smo tudi, da se uvrstitev kazalnikov znotraj pridobljenih komponent brez rotacije in z njo ni spremenila. Spremenila se je zgolj utež teh kazalnikov – tisti, ki so prevladovali v komponenti brez rotacije, so v rotaciji pridobili še večjo utež.

Iz prve komponente smo ugotovili, da imajo kazalniki, sestavljeni iz dobička pred obrestmi in davki (v nadaljevanju EBIT) ali poslovnega denarnega toka, glede na prodajo ali prihodke podobno informacijo in pozitivno vplivajo na prvo komponento. Podobno informacijo beleži tudi kazalnik, izražen kot razmerje poslovnih odhodkov minus amortizacija glede na prodajo, le da ima negativen vpliv.

Iz druge komponente smo ugotovili, da so kazalniki, ki izražajo komponente obratnega kapitala, medsebojno močno korelirane spremenljivke. Medtem ko smo iz tretje komponente ugotovili, da kazalnik, kot EBIT na sredstva ali pa kot denarni tok iz poslovanja na sredstva, nosi enako informacijo.

Iz četrte komponente smo ugotovili, da je kazalnik vrednosti sredstev medsebojno močno koreliran s kazalnikom stopnje dolžniškosti financiranja, vendar ima prvi pozitiven vpliv, drugi pa negativnega. Iz pete komponente smo ugotovili, da kazalnika CAPEX na sredstva in prosti denarni tok v razmerju z denarnim tokom iz poslovanja izražata podobno informacijo, le da ima prvi negativen vpliv, drugi pa pozitivnega. Iz šeste komponente smo razbrali, da sta koeficient obračanja osnovnih sredstev in kazalnik odstotek terjatev in zalog v sredstvih medsebojno močno korelirana.

<sup>11</sup> Z zavedanjem, da zanemari obstoj specifičnih komponent, ki vplivajo na faktor.

Slika 15: Predstavniki posameznih komponent – PCA

| Ekstrakcija | Komponenta 1  |                                                                                          |
|-------------|---------------|------------------------------------------------------------------------------------------|
| 0,848       | EBIT_PRO      | EBIT / Prodaja                                                                           |
| 0,872       | OCF_PRI       | (EBITDA - Davki) / Prihodki                                                              |
| 0,850       | OCF_PRO       | (EBITDA - Davki) / Prodaja                                                               |
| -0,808      | PO_AMOR_PROD  | Poslovni odhodki - amortizacija / Prodaja                                                |
| Ekstrakcija | Komponenta 2  |                                                                                          |
| 0,948       | KPT_Z_KPO     | (Poslovne terjatve + zaloge) / Poslovne obveznosti                                       |
| 0,938       | WC_PO         | Obratni kapital / Poslovne obveznosti                                                    |
| 0,838       | WC_SRED       | Obratni kapital / Sredstva                                                               |
| 0,837       | KT_KPO        | Kratkoročne poslovne terjatve / Kratkoročne poslovne obveznosti                          |
| Ekstrakcija | Komponenta 3  |                                                                                          |
| 0,838       | EBIT_SRED     | EBIT / Povprečna sredstva                                                                |
| 0,825       | OCF_SRED      | (EBITDA - Davki) / Povprečna sredstva                                                    |
| Ekstrakcija | Komponenta 4  |                                                                                          |
| 0,902       | NW            | (Sredstva - Finančne obveznosti (K+D)) / Sredstva                                        |
| -0,892      | FO_SRED       | Finančne obveznosti (K+D) / Sredstva                                                     |
| Ekstrakcija | Komponenta 5  |                                                                                          |
| -0,913      | CAPEX_SRED    | CAPEX / Sredstva                                                                         |
| 0,743       | FCF_OCF       | (EBITDA - CAPEX - davki) / (EBITDA - davki)                                              |
| Ekstrakcija | Komponenta 6  |                                                                                          |
| 0,853       | OOS           | Prodaja / povprečna opremljena sredstva                                                  |
| 0,678       | Z_T_SRED      | Zaloge in poslovne terjatve / Sredstva                                                   |
| Ekstrakcija | Komponenta 7  |                                                                                          |
| 0,828       | BM            | (Prodaja - nabavna vrednost prodanega blaga in materiala) / Prodaja                      |
| 0,819       | SS_SNMSD      | Stroški storitev / Nabavna vrednost blaga + stroški materiala, storitev in dela          |
| Ekstrakcija | Komponenta 8  |                                                                                          |
| 0,744       | FO_EBITDA     | Finančne obveznosti (K+D) / EBITDA                                                       |
| 0,676       | FO_KAP        | Finančne obveznosti (K+D) / Kapital                                                      |
| Ekstrakcija | Komponenta 9  |                                                                                          |
| -0,728      | KT_PRO        | Kratkoročne poslovne terjatve / Prodaja                                                  |
| 0,643       | PRO_SNM_KPO   | Prodaja - nabavna vrednost blaga in stroškov materiala / Kratkoročne poslovne obveznosti |
| Ekstrakcija | Komponenta 10 |                                                                                          |
| 0,915       | KPO_EBIT      | Kratkoročne poslovne obveznosti / EBIT                                                   |
| 0,914       | OCF_EBIT      | EBITDA - davki / EBIT                                                                    |

S sedmo komponento smo ugotovili, da bruto marža in kazalnik, ki izraža odstotek stroškov storitev med vsemi stroški, potrebnimi za poslovanje, podata podobno informacijo. Medtem ko se je v osmi ugotovilo, da sta med seboj močno korelirana kazalnika finančne obveznosti na poslovni denarni tok in koeficient dolgovno-kapitalskega razmerja.

Pri deveti komponenti smo opazili, da imata največji vpliv kazalnik, izražen s terjatvami na prodajo, in kazalnik, izražen kot bruto dobiček na kratkoročne poslovne obveznosti, vendar prvi vpliva pozitivno, drugi pa negativno. Iz zadnje komponente pa smo ugotovili, da nosita najbolj podobno informacijo kazalnika kratkoročne obveznosti na EBIT in kazalnik poslovni denarni tok na EBIT.

Čeprav smo predstavili le predstavnike iz posameznih komponent, bomo za potrebe modeliranja uporabili vse tiste kazalnike, ki so znotraj posamezne komponente beležili ekstrakcijo, višjo od 0,6. Za te kazalnike se je za potrebe modeliranja definiralo, da so med seboj substituti. Kako se je slednje uporabilo v procesu modeliranja, je podrobneje razloženo v naslednjem poglavju. V Prilogi 4 so podani celotni rezultati PCA.

## 4.4 Izdelava modela

Pred izdelavo modela je treba izbrati metodo, s katero se bo poskusilo sestaviti model. Metoda se običajno izbere na podlagi podane spremenljivke, ki jo želimo napovedati. V našem primeru je kreditni limit številčna spremenljivka, za katero so primerne regresijske metode in klasifikatorji, ki so prilagojeni takim tipom spremenljivk.

Za potrebe magistrskega dela smo se odločili, da bomo uporabili navadno linearno regresijo in Naive Bayesian klasifikator, ki sprejme tako diskretne kot številčne tipe spremenljivk.

Ker je bil cilj magistrskega dela izdelava splošnega modela za določevanje kreditnih limitov, smo najprej poskusili izdelati model na vseh podatkih, torej na vseh dejavnostih skupaj. Vendar smo kmalu ugotovili, da je ne glede na uporabljeno metodo znotraj izbrane populacije preveč različnih vzorcev, pripadajočih različnim podskupinam in da na splošno nobena metoda ne more podati na taki populaciji uporabnih rezultatov.

Zato smo se odločilo za štiri osrednje dejavnosti po številu podjetij, te pa so bile trgovina, predelovalne dejavnosti, gostinstvo in strokovne, znanstvene in tehnične dejavnosti; in tako skušali ugotoviti, za katero dejavnost lahko izdelamo najboljši model za napovedovanje kreditnih limitov.

Pred samim začetkom modeliranja smo za vsako dejavnost na slučajen način s pomočjo operatorja Shuffle razdelili populacijo. In sicer na tisto, na kateri se je model razvijal, in na tisto, na kateri bomo testirali rezultate dobljenih modelov. Pri tem smo uporabili kriterij 70 : 30.

Pri izdelavi modelov smo se držali koncepta, da morajo biti enostavni, razumljivi in skladni z ekonomskimi pričakovanji. Za izdelavo vseh modelov smo uporabili program RapidMiner.

#### **4.4.1 Linearna regresija**

Koncept regresije se je razvil že v obdobju viktorijanskega časa, ko je leta 1888 Galton prvi prišel na plan s konceptom regresija v smislu povprečja in tako postavil osnovni temelj, na podlagi katerega so se razvile vse nadaljnje regresijske metode (Kotu, 2015, str. 165).

Linearna regresija spada v tako imenovane regresijske metode, ki so med najpogostejše uporabljenimi metodami za napovedovanje. Njihova značilnost je v tem, da na podlagi podatkov izdelajo funkcijo, in sicer, da napovejo vrednost odvisne spremenljivke  $y$  z združevanjem spremenljivk za napovedovanje  $X$  v funkciji,  $y = f(X)$ .

##### **4.4.1.1 Kratka teoretska predstavitev**

Linearna regresija ni le ena najstarejših napovednih metod, ampak je tudi tista, ki se jo najlažje razume in da enostavno razložiti. Osnovni cilj metode je, da najde tako funkcijo, ki najboljšje pojasni linearni trend.

Model linearne regresije predpostavlja, da je povezava med odvisno spremenljivko  $Y$  in  $X = \{X_1, \dots, X_p\}$  linearna, zato lahko izrazimo  $Y$  kot::

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_p X_p + \varepsilon \quad (26)$$

Kjer velja, da je:

- $\beta_i$  = regresijski koeficjent spremenljivke  $i$ ,
- $\varepsilon$  predstavlja naključno napako in je neodvisna od  $X$ .

Običajno se  $\beta_i$  oceni s pristopom minimiziranja vsote kvadratov napake, lahko pa se uporabijo tudi drugi pristopi. Čeprav je izbrana metoda relativno enostavna za razumevanje in uporabo, je njena slabost v tem, da morajo veljati naslednje predpostavke, če ne pa dobimo pristranske rezultate (Košmelj, 2007a; Pahor, 2004; Rován, 2002):

- neodvisne spremenljivke niso linearne funkcije ostalih neodvisnih spremenljivk,
- $Y$  je slučajna spremenljivka, ki se porazdeljuje normalno:  $Y_i \approx N(y_i, \sigma)$ ,
- $\varepsilon$  je slučajna spremenljivka, ki se porazdeljuje normalno:  $\varepsilon \approx N(0, \sigma)$ ,
- ostanki so neodvisni med seboj:  $Cov(\varepsilon_i, \varepsilon_j) = 0$ ,
- število enot je večje od števila spremenljivk  $n > k$ .

Pri izdelavi linearnega regresijskega modela je zelo pomembno, da ta ne vsebuje multikolinearnosti in da so vsi dobljeni koeficienti statistično značilni. Ob tem pa je cilj, da je ocena napake regresije čim manjša in da je z izbranimi spremenljivkami možno pojasniti čim večji delež odvisne spremenljivke ( $Y$ ). To se ocenjuje s tako imenovanim popravljenim R kvadratom. Na koncu je treba še zagotoviti, da ostanki regresije niso odvisni od  $Y$  in da so ti bolj ali manj normalno porazdeljeni.

#### 4.4.1.2 Opis postopka

Ker smo razpolagali s kar 50 različnimi kazalniki, se je postopek modeliranja začel tako, da smo za vsako izbrano dejavnost na vseh kazalnikih napravili *backward* selekcijo po kriteriju AIC. *Backward* selekcija začne z modelom, ki vsebuje vse spremenljivke in jih odstranjuje iz modela glede na izbrani kriterij. V našem primeru smo izbrali AIC<sup>12</sup> kriterij, ki na podlagi informacijske entropije omogoča kompromis med povečanjem števila parametrov modela in zmanjšanjem napake.

RapidMiner nam pri *backward* selekciji omogoča več načinov uporabe AIC kriterija. Za potrebe modela smo uporabili opcijo *M5 primer*. Ta ob v vsaki iteraciji odstrani tisti atribut oz. spremenljivko, v našem primeru kazalnik, ki ima najmanjši standardizirani koeficjent, in ponovno napravi regresijo brez tega kazalnika, in če se AIC poveča, potem izloči kazalnik iz regresije (Deshpande, 2012).

<sup>12</sup> Kratica za angleški izraz *Akaike Information Criterion*. V primeru linearne regresije je izražena kot  $AIC = n \cdot \ln(RSSn) + 2 \cdot K$ .

S pomočjo *backward* selekcije smo za vsako dejavnost dobili ožji nabor kazalnikov, ki so se izkazali po posameznih dejavnosti za najbolj pomembne za napovedovanje kreditnega limita. Za vsaki ožji nabor pa smo pogledali še, ali med njimi obstajajo substituti, ki so bili definirani po rezultatih PCA. Za te smo pazili, da v model niso vstopali istočasno, saj so med seboj močno korelirani.

Ker velja pravilo, da bolj kot je t-test visok, bolj je spremenljivka pomembna za regresijo (Kotu, 2015, str. 174), smo se odločili, da za vsako dejavnost začnemo postopek modeliranja tako, da iz rezultata *backward* selekcije izberemo po enega predstavnika iz različnih segmentov, in sicer tistega, ki ima največji t-test, in tako naredimo prve modele.

Na podlagi pridobljenih rezultatov smo nato odstranila neznčilne kazalnike in dodajali nove v iskanju tistega, ki bi doprinesel novo informacijo v model. Pri tem smo uporabljali tudi spoznanja, pridobljena na podlagi PCA.

Tako smo poskušali model sestaviti z različnimi kombinacijami kazalnikov, od prvotnih do *dummy* oblik, vse z namenom, da bi nova kombinacija ali oblika kazalnika pripomogla k izboljšanju rezultatov modelov. Rezultati najboljših dobljenih modelov so za vsako dejavnost prikazani v nadaljevanju.

Tako smo postopoma izdelovali model na način, da smo dodajali in odstranjevali kazalnike n-krat, z namenom dobiti takšnega, ki ima najvišji možen R kvadrat in hkrati najnižjo možno napako. Pri socialnih in vedenjskih modelih se običajno sprejme nižje vrednosti R kvadrat, ob tem pa je pomembno, da ta ni pod 0,2, saj to pomeni, da izbrane spremenljivke v modelu nezadostno pojasnjujejo vrednost, ki jo želimo napovedati (Kotu, 2015, str. 180).

#### 4.4.1.3 Rezultati

Na podlagi rezultatov *backward* selekcije smo kmalu ugotovili, da za dejavnost trgovina ne bomo mogli izdelati modela. Ugotovili smo, da imata na teh podatkih statistično značilen vpliv na kreditni limit le kazalnik bruto dobiček v razmerju s seštevkom stroškov storitev in dela ter kazalnik finančne obveznosti na EBITD-o.

Ob tem pa skupaj lahko razložita le 10 odstotkov variabilnosti iskanega limita. Zaradi tega smo se odločili, da bomo v nadaljevanju prikazali le rezultate za predelovalne dejavnosti, gostinstvo in strokovne, znanstvene in tehnične dejavnosti.


##### 4.4.1.3.1 Predelovalna dejavnost

S pomočjo *backward* selekcije smo ugotovili, da je v predelovalni dejavnosti med vsemi nabranimi kazalniki 12 takih, ki bi bili lahko pomembni za napovedovanje vrednosti

kreditnega limita. Kot prvi najbolj pomemben kazalnik bi bil s pozitivnim vplivom odstotek stroškov storitev med vsemi poslovnimi stroški (SS\_SNMSD).

Slika 16: Rezultati backward selekcije za predelovalno dejavnost

| Kazalniki     | Koeficient | S.E.  | Stand. Koef. | t-test | p-vrednost |
|---------------|------------|-------|--------------|--------|------------|
| SS_SNMSD      | 9,555      | 2,309 | 0,268        | 4,138  | 0,000      |
| BM            | -8,874     | 2,930 | -0,232       | -3,028 | 0,003      |
| FN_NN_OP_SRED | 1,638      | 0,590 | 0,114        | 2,778  | 0,006      |
| Z_T_SRED      | -8,123     | 3,022 | -0,284       | -2,688 | 0,007      |
| OOS           | 0,176      | 0,089 | 0,166        | 1,984  | 0,048      |
| PRO_SNM_SS_SD | -3,748     | 1,164 | -0,242       | -3,220 | 0,001      |
| PO_AMOR_PROD  | -9,320     | 4,556 | -0,202       | -2,046 | 0,041      |
| PD            | 15,528     | 7,572 | 0,086        | 2,051  | 0,041      |
| FO_KAP        | -0,474     | 0,215 | -0,103       | -2,203 | 0,028      |
| FO_EBITDA     | -0,283     | 0,159 | -0,103       | -1,778 | 0,076      |
| KT_KPO        | -1,804     | 1,053 | -0,225       | -1,713 | 0,087      |
| DOZ           | -0,558     | 0,328 | -0,111       | -1,699 | 0,090      |



Kot drugi in tretji pomemben kazalnik bi lahko bila kazalnika bruto dobiček v razmerju s seštevkom stroškov storitev in dela (PRO\_SNM\_SS\_SD) in bruto marža (BM), toda z negativnim vplivom.

Na podlagi informacij, ki smo jih pridobili s pomočjo *backward* selekcije, smo začelo izdelovati različne modele. Po preizkušanju različnih kombinacij smo dobili nekaj modelov, ki so z različnimi nabori kazalnikov napovedali od 30 do 36 odstotkov gibanja kreditnega limita.

Vendar so bili med njimi tudi taki, ki so imeli več kot 10 kazalnikov, ali pa celo neznačilne. A problem vseh teh modelov je bil, da je ostajal zelo velik interval napake ocene ne glede na to, kakšnega smo izdelali. Razlog za to je verjetno ta, da ostaja z narejenimi modeli na testni populaciji več kot 65 odstotkov nepojasnjene variance vrednosti kreditnega limita.

Na koncu smo kot najboljšega izbrali model, prikazan v Sliki 17, ki uspe s 7 kazalniki razložiti 36,3 odstotka variance kreditnega limita. Med vsemi kazalniki v modelu ima največji pomen koeficient dolgoročne pokritosti dolgoročnih sredstev (KAP\_DOOF\_OP\_SRED\_NN\_Z), sledi mu kazalnik dnevi vezave poslovnih obveznosti (DVPO) in odstotek naložbe na opredmetena sredstva (FN\_NN\_OP\_SRED).

Koeficient dolgoročne pokritosti dolgoročnih sredstev in naložbe na opredmetena sredstva imata pozitiven vpliv, medtem ko imajo dnevi vezave poslovnih obveznosti negativnega. Vsi trije vplivi so skladni z ekonomskimi pričakovanji. Kot zanimivost lahko izpostavimo, da model samo s temi tremi kazalniki napove 27,4 odstotka variance kreditnega limita, kar predstavlja 76 odstotkov celotne variance, ki se jo uspe razložiti z izbranim modelom.

Slika 17: Izbrani regresijski model za predelovalno dejavnost

| Kazalnik             | Koef.  | S.E.  | Stand. Koef. | t-test | p-vrednost | Testiranje                        |
|----------------------|--------|-------|--------------|--------|------------|-----------------------------------|
| FN_NN_OP_SRED        | 2,127  | 0,633 | 0,145        | 3,361  | 0,001      | <b>2013</b>                       |
| KAP_DOF_OP_SRED_NN_Z | 1,468  | 0,258 | 0,259        | 5,694  | 0,000      | squared_error: 33,225 +/- 62,020  |
| DVPO                 | -0,956 | 0,219 | -0,206       | -4,362 | 0,000      | <b>squared_correlation: 0,363</b> |
| KT_KPO               | -0,826 | 0,392 | -0,102       | -2,107 | 0,036      |                                   |
| SS_SNMSD             | 3,784  | 1,554 | 0,106        | 2,435  | 0,015      | <b>2014</b>                       |
| KPO_EBIT_1 (1: <-5)  | -2,374 | 0,989 | -0,104       | -2,400 | 0,017      | squared_error: 60,285 +/- 68,409  |
| RPROD_1 (1: <0,5)    | -2,707 | 0,988 | -0,119       | -2,741 | 0,006      | <b>squared_correlation: 0,015</b> |
| (Intercept)          | 8,773  | 1,513 |              | 5,800  | 0,000      |                                   |

Kot pomemben kazalnik, toda z negativnim vplivom, sta se izkazala tudi koeficient kratkoročnega terjatveno-obveznostnega razmerja (KT\_KPO) in odstotek stroškov storitev med vsemi poslovnimi stroški (SS\_SNMSD), vendar s pozitivnim vplivom.

Kot rezultat se je dobilo tudi, da je rast prodaje (RPROD\_1) pomembna, ko je ta manjša od 50 odstotkov, in takrat negativno vpliva na kreditni limit. Kot zadnje pa se je izkazalo, da je za kreditni limit pomembno tudi razmerje med kratkoročnimi poslovnimi obveznostmi na EBIT-o (KPO\_EBIT\_1), in sicer takrat, ko je ta negativen in je razmerje večje od 5.

Dobljeni model smo poskusili uporabiti tudi na podatkih iz leta 2014, vendar se je izkazalo, da se rezultati zelo poslabšajo, napaka ocene se je skoraj podvojila in R kvadrat je padel celo na 0,015. Pri ostalih modelih je bil rezultat še slabši.

#### 4.4.1.2.2 Gostinstvo

V dejavnosti gostinstva smo na podlagi *backward* selekcije ugotovili, da je kar 20 kazalnikov takih, ki bi lahko bili pomembni za napovedovaje kreditnega limita. Med njimi je bilo kar nekaj substitutov, za katere je bila potrebna pazljivost, da niso bili v modelu istočasno.

Po *backward* selekciji so se v gostinski dejavnosti kot možni najbolj pomembni kazalniki izkazali koeficient kratkoročnega terjatveno-obveznostnega razmerja (KT\_KPO), odstotek stroškov storitev med vsemi poslovnimi stroški (SS\_SNMSD) in donosnost sredstev (ROA).

Tudi tokrat se je izkazalo, da ima odstotek stroškov storitev med poslovnimi stroški pozitiven vpliv. Za koeficient kratkoročnega terjatveno-obveznostnega razmerja in donosnosti sredstev pa, da imata negativen vpliv. Vsi trije vplivi so skladni z ekonomskimi pričakovanji.

Slika 18: Rezultati backward selekcije za dejavnost gostinstva

| Kazalniki            | Koeficient | S.E.  | Stand. Koef. | t-test  | p-vrednost |
|----------------------|------------|-------|--------------|---------|------------|
| FO_SRED              | -3,549     | 0,860 | -0,184       | -4,125  | 0,000      |
| NW                   | -2,974     | 0,792 | -0,168       | -3,755  | 0,000      |
| KAP_SRED             | -2,319     | 0,724 | -0,144       | -3,203  | 0,001      |
| KAP_DOF_OP_SRED_NN_Z | 0,554      | 0,181 | 0,135        | 3,060   | 0,002      |
| DVPO                 | -1,100     | 0,211 | -0,230       | -5,214  | 0,000      |
| KK                   | 1,355      | 0,328 | 0,182        | 4,135   | 0,000      |
| KT_KPO               | -5,321     | 0,514 | -0,461       | -10,352 | 0,000      |
| KPT_Z_KPO            | 2,365      | 0,483 | 0,216        | 4,897   | 0,000      |
| WC_PO                | 1,011      | 0,437 | 0,102        | 2,313   | 0,021      |
| WC_PRO               | -0,891     | 0,455 | -0,086       | -1,955  | 0,051      |
| SS_SNMSD             | 17,125     | 1,831 | 0,433        | 9,356   | 0,000      |
| ROA                  | -12,052    | 1,873 | -0,283       | -6,433  | 0,000      |
| EBIT_SRED            | 8,027      | 1,420 | 0,253        | 5,652   | 0,000      |
| OCF_SRED             | -2,527     | 1,414 | -0,079       | -1,786  | 0,075      |
| OCF_FO               | 0,750      | 0,419 | 0,079        | 1,790   | 0,074      |
| FCF_OBV              | 3,900      | 1,261 | 0,136        | 3,093   | 0,002      |
| KFO_FO               | 0,696      | 0,215 | 0,142        | 3,242   | 0,001      |
| EBIT_PRO             | -10,803    | 2,191 | -0,225       | -4,931  | 0,000      |
| KI_PRI               | 7,752      | 2,275 | 0,152        | 3,408   | 0,001      |
| FO_KAP               | 0,274      | 0,137 | 0,089        | 1,993   | 0,047      |

Na koncu smo kot najboljšega izbrali model, ki je prikazan na Sliki 19, ki uspe s 7 kazalniki razložiti 32,3 odstotka variance kreditnega limita. Tudi v izbranem modelu se je za najbolj pomemben kazalnik s pozitivnim vplivom izkazal odstotek stroškov storitev med vsemi poslovnimi stroški (SS\_SNMSD). Sledita mu kazalnik bruto dobiček v razmerju s seštevkom stroškov storitev in dela (PRO\_SNM\_SS\_SD) in koeficient kratkoročnega terjatveno-obveznostnega razmerja (KT\_KPO), toda z negativnima vplivoma.

Slika 19: Izbrani regresijski model za dejavnost gostinstva

| Kazalnik      | Koef.  | S.E.  | Stand. Koef. | t-test | p-vrednost | Testiranje                        |
|---------------|--------|-------|--------------|--------|------------|-----------------------------------|
| FO_SRED       | 1,108  | 0,996 | 0,058        | 1,111  | 0,267      | <b>2013</b>                       |
| DOZ           | 0,880  | 0,420 | 0,101        | 2,097  | 0,037      | squared_error: 34,959 +/- 44,867  |
| DVPO          | -0,873 | 0,240 | -0,185       | -3,637 | 0,000      | <b>squared_correlation: 0,323</b> |
| KK            | 1,123  | 0,458 | 0,144        | 2,455  | 0,015      |                                   |
| KT_KPO        | -2,674 | 0,693 | -0,208       | -3,857 | 0,000      | <b>2014</b>                       |
| PRO_SNM_SS_SD | -5,515 | 0,853 | -0,316       | -6,462 | 0,000      | squared_error: 37,751 +/- 59,690  |
| SS_SNMSD      | 18,758 | 1,902 | 0,482        | 9,862  | 0,000      | <b>squared_correlation: 0,202</b> |
| (Intercept)   | 8,803  | 1,748 |              | 5,035  | 0,000      |                                   |

V modelu se nahaja tudi kazalnik kratkoročnega koeficienta (KK) s pozitivnim vplivom, ki je po PCA potencialni substitut za kazalnik koeficienta kratkoročnega terjatveno-obveznostnega razmerja. Vendar se je v primeru izključitve enega ali drugega iz modela rezultat zelo poslabšal. Ker med njima obstaja le srednja korelacija, smo upoštevali tak model.

V izbranem modelu so se kot pomembni kazalniki izkazali tudi dnevi obračanja zalog (DOZ) in dnevi vezave poslovnih obveznosti (DVPO), le da imajo prvi pozitiven vpliv, drugi pa negativnega. Kot zadnji pomemben kazalnik se je v modelu izkazal kazalnik stopnje dolžniškosti financiranja (FO\_SRED) in to s pozitivnim vplivom.

Dobljeni model smo poskusili uporabiti tudi na podatkih iz leta 2014, in tokrat dobili nekoliko boljše rezultate kot pri modelu za predelovalne dejavnosti. Tudi tokrat so se rezultati sicer poslabšali, vendar je R kvadrat kljub temu ostal nad 0,2.

#### 4.4.1.2.3 Strokovne, znanstvene in tehnične dejavnosti

Na podlagi *backward* selekcije smo v primeru strokovne, znanstvene in tehnične dejavnosti ugotovili, da je 12 takih kazalnikov, ki bi lahko bili pomembni za napovedovanje kreditnega limita, vendar je med njimi kar nekaj substitutov, ki nosijo podobne informacije.

*Slika 20: Rezultati backward selekcije za strokovne, znanstvene in tehnične dejavnosti*

| Kazalniki            | Koeficient | S.E.   | Stand. Koef. | t-test | p-vrednost |
|----------------------|------------|--------|--------------|--------|------------|
| DVPO                 | -1,451     | 0,404  | -0,280       | -3,595 | 0,000      |
| OCF_PRO              | 12,901     | 4,439  | 0,338        | 2,906  | 0,004      |
| FO_SRED              | -28,754    | 13,592 | -1,020       | -2,116 | 0,035      |
| KAP_DOF_OP_SRED_NN_Z | -0,627     | 0,261  | -0,186       | -2,406 | 0,017      |
| NW                   | -27,509    | 12,146 | -1,027       | -2,265 | 0,024      |
| SS_SNMSD             | 5,556      | 1,874  | 0,186        | 2,964  | 0,003      |
| FO_OP_SRED_NN        | 0,657      | 0,291  | 0,166        | 2,254  | 0,025      |
| PRO_SRED             | -1,054     | 0,512  | -0,187       | -2,059 | 0,040      |
| OCF_PO               | -3,991     | 2,100  | -0,268       | -1,900 | 0,058      |
| KT_KPO               | 3,040      | 1,386  | 0,373        | 2,193  | 0,029      |
| WC_PRO               | -1,134     | 0,639  | -0,107       | -1,775 | 0,077      |
| WC_PO                | -2,328     | 1,218  | -0,340       | -1,912 | 0,057      |

Po *backward* selekciji bi bili lahko najbolj pomembni kazalniki dnevi vezave poslovnih obveznosti (DVPO) z negativnim vplivom, odstotek realiziranega poslovnega toka v prodaji (OCF\_PRO) in kazalnik odstotek stroškov storitev med vsemi poslovnimi stroški (SS\_SNMSD), toda oba s pozitivnim vplivom. Vendar se je pri tej dejavnosti izkazalo, da ne glede na uporabljeno kombinacijo kazalnikov nismo mogli napraviti modela, ki bi omogočal razlago variance kreditnega limita za več kot 18 odstotkov.

Kot zanimivost lahko izpostavimo, da s temi tremi kazalniki, ki so se izkazali po *backward* selekciji za potencialne kazalnike za napovedovanje kreditnega limita, skupaj uspemo pojasniti 15,9 odstotka gibanja iskanega limita.

#### 4.4.2 Naive Bayesian klasifikator

Naive Bayesian spada v tako imenovano skupino Bayesian klasifikatorjev. Na splošno velja, da so Bayesian klasifikatorji preprosti verjetnostni klasifikatorji, ki omogočajo napovedovanje verjetnosti, da enota pripada določeni skupini. Ti temeljijo na Bayesianovem teoremu<sup>13</sup> in njihova naloga je, da na podlagi razvojnega nabora vzorcev  $D = \{\mu_1, \dots, \mu_N\}$ , napravijo funkcijo preslikave  $f: (x_1, \dots, x_n) \rightarrow C$ , katera poda oznako neznanemu vzorcu  $x = (x_1, \dots, x_n)$  (Friedman et al., 1997, str. 132–133).

##### 4.4.2.1 Kratka teoretska predstavitev

Naive Bayesian klasifikator se intenzivno preučuje od leta 1950 naprej in spada v družino tako imenovanih enostavnih verjetnostnih klasifikatorjev, ki temeljijo na pogojni verjetnosti, ker predpostavljajo pogojno neodvisnost vrednosti različnih atributov oz. spremenljivk v danem razredu (Kononenko, 2001, str. 89–90).

Klasifikator je preprost, ker za vsak nabor atributov za posamezen razred izračuna verjetnostno porazdelitev. Neznani vzorec razvrsti tako, da najprej izračuna verjetnosti, da posamezen vzorec pripada razredu glede na porazdelitveno funkcijo posameznih atributov in te verjetnosti združi. Končno razvrstitev poda po kombinaciji posameznih verjetnosti – odloči se za tisto, pri kateri je kombinirana verjetnost največja (Meža, 2013, str. 1).

Pri Naive Bayesian se lahko verjetnost razreda za posamezno vrednost atributov zapiše kot:

$$p(c_j | v_1 \dots v_n) = p(c_j) * \frac{p(v_1 \dots v_n | c_j)}{p(v_1 \dots v_n)} \quad (27)$$

Ker predpostavljamo, da obstaja pogojna neodvisnost med atributi, lahko predhodno enačbo zapišemo kot:

$$p(c_j | v_1 \dots v_n) \approx \prod_i \frac{p(c_j | v_j)}{p(c_j)} \quad (28)$$

Na podlagi teh posameznih verjetnosti klasifikator napravi kombinacijo, ki predstavlja največjo verjetnost nastanka. To pa naredi na podlagi t.i. pravila maksimalne a posteriori verjetnostne ocene oz. MAP, ki se zapiše kot:

---

<sup>13</sup>Ta je poimenovan po Thomasu Bayesu. Osnovni koncept teorema je opisal Richard Price leta 1763 v eseju *Essay Towards Solving a Problem in the Doctrine of Chances*.

$$C_{max} = \arg \max_{c_j} p(c_j | v_1 \dots v_n) \quad (29)$$

Največja prednost tega klasifikatorja je v tem, da je enostaven in zaradi tega robusten. Ob tem razen pogojne neodvisnosti ne zahteva nobene predpostavke in zna operirati tudi z manjkajočimi podatki (Kotu, 2015 str. 117).

Čeprav je bil klasifikator prvotno izdelan za kategorične spremenljivke, ga lahko uporabimo tudi za številčne, saj vzame vsako številsko vrednost kot svoj razred (Kotu, 2015 str. 118).

#### 4.4.2.2 Opis postopka

Pri linearni regresiji se je že pokazala potreba, da se model naredi za posamezne dejavnosti, zato smo se odločili, da bomo Naive Bayesian klasifikator izvedli samo za predelovalne dejavnosti in za dejavnost gostinstva ker se pri ostalih dveh dejavnostih na podlagi regresijske metode ni dobilo pričakovanih rezultatov.

Čeprav Naive Bayesian klasifikator sprejme za ciljno spremenljivko tudi številčno spremenljivko, ker jo interpretira kot polinomsko oz. večkategorično, smo kmalu ugotovili, da na tak način ne bomo dobili zelenega kriterija.

Iz tega razloga smo se odločili, da našo ciljno spremenljivko – kreditni limit razdelimo v razrede. Ker se ni vedelo, katero število razredov je za izbrane dejavnosti ustrezno, smo preverili, katero bolj ustreza. Za predelovalne dejavnosti se je izkazalo, da je najbolj primeren kreditni limit, razdeljen v štiri razrede, v dejavnosti gostinstva pa v tri.

Tudi za potrebe Naive Bayesian klasifikatorja se je na začetku uporabilo vseh 50 kazalnikov. Z vidika kazalnikov ta klasifikator ni najbolj hvaležen, ker nima metode, s katero bi nepomembne kazalnike sam izločil iz modela. Zato je na posamezniku, da sam ugotovi, kateri kazalnik doprinese k modelu največ in kateri izmed njih rezultate popači, in to preko opazovanja odstotka pravilne napovedi.

Zaradi tega smo se odločili, da najprej za vsako dejavnost znotraj posameznega segmenta kazalnikov pogledamo, kateri bi uspelo na individualnem nivoju s pomočjo Naive Bayesian klasifikatorja doseči čim višji odstotek pravilne uvrstitve.

V zavedanju, da imajo klasifikatorji radi diskretne oblike in da so finančni kazalniki večinoma izraženi v številčni obliki, smo ta postopek ponovili za vsak kazalnik tudi še v diskretni obliki, izraženi preko 4, 3 in 2 razredov.

S pomočjo postopka smo ugotovili, kateri kazalniki uspejo enakomerno porazdeliti podjetja v vse izbrane razrede in kateri oz. katera njihova oblika uspe razvrstiti podjetja le v določene razrede.

Nato smo iz vsakega segmenta izbrali le tiste, ki so uspeli enakomerno porazdeliti podjetja v vse izbrane razrede, in pogledali, kakšen odstotek pravilne uvrstitve smo dobili in katere razrede model slabo napoveduje.

Nato smo v model dodali kazalnike oz. njegove oblike, ki so se na individualnem nivoju dobro izkazali za napovedovanje teh razredov, in pogledali, kaj se zgodi. V primeru, da se je rezultat napovedi izboljšal, smo ga pustili v modelu, v nasprotnem pa smo kazalnik odstranili. Ko smo v modelu pridobili že veliko število kazalnikov, smo se lotili njihovega odstranjevanja iz modela in tako poskušali ugotoviti, kateri kazalnik ne doprinaša v model nič ali mu celo še škodi.

Opisan postopek smo tako n-krat ponovil z vsemi možnimi kombinacijami in s ciljem, da bi dosegli čim večji odstotek pravilne uvrstitve.

#### 4.4.2.3 Rezultati

V nadaljevanju bosta za vsako izbrano dejavnost prikazana le modela, ki sta se med vsemi izkazala kot najboljša. Vodilo pri izbiri modela je bilo, da se s čim nižjim številom kazalnikov v modelu doseže čim večji skupni odstotek pravilne uvrstitve, ob tem pa še čim bolj enakomerno porazdelitev pravilne uvrstitve po razredih.

V primeru predelovalne dejavnosti se je kreditni limit razdelil v štiri razrede, kar pomeni, da smo iskali približno 50-odstotne pravilne uvrstitve, vendar nam tega ni uspelo doseči, ne glede na to, kakšno kombinacijo kazalnikov smo uporabila. Kljub temu pa je bil ta kriterij skoraj dosežen v dveh razredih.

V primeru dejavnosti gostinstva se je kreditni limit razdelil v tri razrede, kar pomeni, da smo iskali približno 60-odstotne pravilne uvrstitve. Tudi v tem primeru nam ni uspelo doseči prav tega cilja, nam je pa uspelo pridobiti enakomerne natančne napovedi znotraj posameznih razredov.

Ker pri nobeni izbrani dejavnosti s postopkom modeliranja nismo dobili želenega odstotka pravilne uvrstitve, smo se odločili, da dobljenih modelov ne bomo preverili s podatki iz leta 2014.

##### 4.4.2.3.1 Predelovalna dejavnost

Za potrebe predelovalne dejavnosti smo kreditni limit razdelili v štiri enake razrede, v vsakem je bilo po 25 odstotkov podjetij. V prvi razred so se uvrstila podjetja, ki so beležila

kreditni limit do 2,9 odstotka 3-mesečne prodaje, v drugi razred podjetja, ki so beležila limit v višini med 2,9 in 5,0 odstotka te prodaje, v tretji tista, ki so beležila med 5,0 do 8,4 odstotka in v četrtega tista podjetja s kreditnim limitom, višjim od 8,4 odstotka 3-mesečne prodaje.

Na tako spremenjenem kreditnem limitu smo s pomočjo Naive Bayesian klasifikatorja poskusili izdelati tak model, ki bi podal za vse štiri razrede čim večji odstotek pravilne uvrstitve. Nastalo je več različnih modelov, na katerih smo preizkusili zelo veliko različnih kombinacij. Med vsemi smo za najboljšega izbrali tega, ki ga prikazuje Slika 21.

*Slika 21: Izbrani klasifikacijski model za predelovalno dejavnost*

| % Pravilne uvrstitve: 45,04 |           |                   |                   |            |                    |                  |              |
|-----------------------------|-----------|-------------------|-------------------|------------|--------------------|------------------|--------------|
|                             | Do 2,85 % | Od 2,85 do 5,05 % | Od 5,05 do 8,35 % | Nad 8,35 % | Natančnost razreda | Kazalniki modela | Št. razredov |
| Do 2,85 %                   | 18        | 4                 | 9                 | 6          | 48,7%              | DOZ              | 5            |
| Od 2,85 do 5,05 %           | 8         | 16                | 3                 | 5          | 50,0%              | KAP_SRED         | 3            |
| Od 5,05 do 8,35 %           | 4         | 7                 | 13                | 9          | 39,4%              | OOS              | 2            |
| Nad 8,35 %                  | 5         | 6                 | 6                 | 12         | 41,4%              | PRO_SNMSD_KFOFO  | 2            |
| Uporaba razreda             | 51,4%     | 48,5%             | 41,9%             | 37,5%      |                    | Z_T_SRED         | 4            |

Izbrani model vsebuje 5 kazalnikov, s katerimi se skupno pravilno uvrsti 45,4 odstotka podjetij. Po izbranem modelu se je izkazalo, da so dnevi obračanja zalog (DOZ), stopnja lastniškega financiranja (KAP\_SRED), koeficient obračanja osnovnih sredstev (OOS), odstotek zalog ter terjatev v sredstvih (Z\_T\_SRED) in kazalnik za pokrivanje finančnega dolga (PRO\_SNMSD\_KFOFO) za predelovalno dejavnost pomembni kazalniki za napovedovanje kreditnega limita.

V primeru, ko smo tej kombinaciji dodali dodatni kazalnik – ne glede na obliko, se je rezultat pravilne uvrstitve poslabšal. Enako je veljalo v primeru, ko je bil kak obstoječi kazalnik odstranjen ali vključen v drugačni obliki. Kot zanimivost lahko izpostavimo tudi, da s kazalniki dneva obračanja zalog (DOZ), stopnjo lastniškega financiranja (KAP\_SRED) in pokrivanjem finančnega dolga (PRO\_SNMSD\_KFOFO) lahko dosežemo 36,7 odstotka pravilne uvrstitve.

Čeprav izbrani model kot celota ne doseže 50-odstotne pravilne uvrstitve, lahko opazimo, da zelo dobro razvršča podjetja v drugi razred, v katerem doseže zeleni cilj pravilne uvrstitve. Model dobro razvrsti podjetja tudi v prvi razred, saj jih pravilno uvrsti 48,7 odstotka, medtem ko pade ta odstotek v tretjem in v četrtem razredu na okoli 40 odstotkov. Odstotki uvrstitve niso bili tako slabi, če jih primerjamo z ostalimi modeli, ki niso bili izbrani. Na splošno lahko povzamemo, da so imeli vsi modeli največje težave pri razvrščanju podjetij v tretji in četrti razred.

Celotna tabela Naive Bayes porazdelitve za izbrane kazalnike modela se nahaja v Prilogi 5.

#### 4.4.1.2.2 Gostinstvo

Za potrebe dejavnosti gostinstva se je kreditni limit razdelil v tri enake razrede, kar pomeni približno 33 odstotkov podjetij na razred. V prvi razred so se uvrstila podjetja, ki so beležila kreditni limit v višini do 4 odstotkov 3-mesečne prodaje, v drugi razred podjetja, ki so beležila med 4 in 9 odstotkov, medtem ko so se v tretji razred uvrstila podjetja, katerih kreditni limit je bil višji od 9 odstotkov 3-mesečne prodaje.

Na tako spremenjenem kreditnem limitu smo poskusili izdelati model, ki bi podal za vse 3 razrede čim večji odstotek pravilne uvrstitve. Tudi tokrat smo napravili več različnih modelov, na katerih smo preizkusili veliko različnih kombinacij. Kot rezultat smo dobili model, ki je predstavljen na Sliki 22 in ki poda med vsemi izdelani modeli najboljše rezultate.

Vendar ima izbrani model kar 15 kazalnikov, da lahko doseže 53-odstotno pravilno uvrstitev. Ostali izdelani modeli so potrebovali še več kazalnikov za enako ali celo slabšo uvrstitev. V primeru, ko je bil obstoječi kazalnik odstranjen ali vključen v kakšni drugi obliki, so se rezultati modela poslabšali.

Slika 22: Izbrani klasifikacijski model za dejavnost gostinstva

| % Pravilne uvrstitve: 53,04% |  |           |  |                   |  |            |  |
|------------------------------|--|-----------|--|-------------------|--|------------|--|
|                              |  | Do 4,05 % |  | Od 4,05 do 8,95 % |  | Nad 8,95 % |  |
| Do 4,05 %                    |  | 26        |  | 21                |  | 5          |  |
| Dd 4,05 do 8,95 %            |  | 2         |  | 11                |  | 6          |  |
| Nad 8,95 %                   |  | 10        |  | 10                |  | 24         |  |
| Uporaba razreda              |  | 68,4%     |  | 26,2%             |  | 68,6%      |  |

| Kazalniki modela | Št. Raz. | Kazalniki modela | Št. Raz. | Kazalniki modela | Št. Raz. | Kazalniki modela | Št. Raz. |
|------------------|----------|------------------|----------|------------------|----------|------------------|----------|
| BM               | 2        | EBIT_PO          | 2        | FO_EBITDA        | 2        | PRO_SNMSD_KFOFO  | /        |
| CAPEX_SRED       | 4        | EBIT_PRO         | /        | FO_KAP           | /        | PRO_SRED         | 4        |
| DOZ              | 2        | EBIT_SRED        | 4        | FO_OP_SRED_NN    | 2        | RPROD            | 3        |
| DVPO             | 5        | FN_NN_OP_SRED    | 4        | NW               | 2        |                  |          |

Iz modela razberemo, da za gostinsko dejavnost potrebujemo bruto maržo (BM), kazalnik CAPEX (CAPEX\_SRED), oba kazalnika obračanja zalog (DOZ) in poslovnih obveznosti (DVPO), EBIT-o izraženo na različne načine (EBIT\_PO, EBIT\_PRO in EBIT\_SRED), odstotek naložb na opredmetena sredstva (FN\_NN\_OP\_SRED), nato kar štiri kazalnike, ki opisujejo strukturo financiranja (FO\_EBITDA, FO\_KAP, FO\_OP\_SRED\_NN in NW), ob tem še kazalnik za pokrivanje finančnega dolga (PRO\_SNMSD\_KFOFO), prodajo na sredstva (PRO\_SRED) in na koncu še rast v prodaji, da napovemo oz. določimo vrednost kreditnega limita.

Če pogledamo, kako uspešno model razvrsti podjetja po izbranih razredih, opazimo, da ima največje težave s prvim razredom. Z enakim problemom so se soočali tudi vsi ostali

neizbrani modeli, le da je bila uvrstitev še slabša. Na drugi strani pa model zelo natančno uvrsti podjetja v drugi razred, kjer se odstotek pravilne uvrstitve povzpne skoraj na 58.

Celotna tabela Naive Bayes porazdelitve za izbrane kazalnike modela se nahaja v Prilogi 5.

## 5 UGOTOVITVE

Najprej smo ugotovili, da je za izdelavo splošnega modela za določanje kreditnega limita za celotno slovensko gospodarstvo treba obvezno delati na nivoju dejavnosti ali celo na nivoju poddejavnosti. To pa iz razloga, ker obstaja preveč različnih vzorcev obnašanja, da bi lahko povzeli neko splošno rešitev za vse – ne glede na to, kakšno metodo bi uporabili.

Ugotovili smo tudi, da so se v regresijskem modelu za obe dejavnosti kot najbolj pomembni kazalniki za napovedovanje kreditnega limita izkazali dnevi vezave poslovnih obveznosti (DVPO), koeficient kratkoročnega terjatveno-obveznostnega razmerja (KT\_KPO) in odstotek stroškov storitev med vsemi poslovnimi stroški (SS\_SNMSD).

In sicer, koeficient kratkoročnega terjatveno-obveznostnega razmerja (KT\_KPO) in kazalnik dnevi vezave poslovnih obveznosti (DVPO) imajo pri obeh dejavnostih negativen vpliv na kreditni limit, medtem ko ima odstotek stroškov storitev med vsemi poslovnimi stroški (SS\_SNMSD) pozitivnega.

Vsi trije vplivi so skladni z ekonomskimi pričakovanji. To pomeni, da je podjetje, ki beleži dolge dneve vezave poslovnih obveznosti, slab plačnik, ker potrebuje veliko časa, da poravnava svoje obveznosti. Enako sporočilo poda koeficient kratkoročnega terjatveno-obveznostnega razmerja. Če ima podjetje veliko obveznosti in malo terjatev, to pomeni, da nima dovolj prostih denarnih sredstev, da bi lahko financiralo svoje kupce.

Odstotek stroškov storitev med vsemi poslovnimi stroški pa pomeni, da storitveni stroški prevladujejo. To pa lahko pomeni, da podjetje za večino svojih potrebnih poslovnih prvin najema zunanje vire – tako za delovno silo kot za različne poslovne komponente. Iz tega sledi, da tak način poslovanja podjetjem lahko omogoča bolj prosta denarna sredstva in se zato beleži pozitiven vpliv.

Medtem ko s pomočjo Naive Bayesian klasifikatorja smo ugotovili, da sta se edino kazalnik obračanja zalog (DOZ) in kazalnik pokritost finančnega dolga (PRO\_SNMSD\_KFOFO) izkazala v obeh dejavnostih kot pomembna za določevanje kreditnega limita.

Kot tretje smo ugotovili, da se je z naborom kazalnikov, ki smo jih uporabili za izdelavo modelov, naredili največ, kar se je dalo. Izkazalo se je, da večina izbranih kazalnikov doprinašajo v model podobne informacije. Če bi želeli izboljšati rezultat, bi morali dodati

nove kazalnike, ki bi doprinesli modelom nove informacije. V ta namen bi se priporočalo dodati še kazalnike, ki opisujejo plačilne navade.

Druge izboljšave bi lahko naredili tudi na segmentu izbire populacije in same definicije ciljne spremenljivke. Z namenom, da se ne bi izgubili preveč enot, ni bilo nobenega začetnega pogoja, ki bi določal, koliko najmanj mora znašati kreditni limit, da se ga lahko uporabi za modeliranje. Na tej točki bi lahko postavili mejo, da mora ta znašati npr. 5 tisoč EUR.

Enako je potem veljalo tudi ob spremembi v odstotkovno obliko, ko se ni zahtevalo nobenega pogoja, kolikšen sme biti ta minimalni odstotek, da se uporabi za potrebe modela. Lahko bi se določila meja nad 1 odstotek. Za ekstremne vrednosti kreditnega limita smo določili, da se jih spremeni v 25 odstotkov, lahko pa bi jih tudi izključili iz analize.

Na ta način bi za linearno regresijo zagotovili lepšo porazdelitev odvisne spremenljivke. Medtem ko bi se pri metodi klasificiranja lahko nekoliko bolj poigrali z različnimi mejami razredov. Morda odločitev, da je v vseh razredih enako število podjetij, ni bila najbolj prava. Morda bi se dalo dobiti kakšno delitev razredov, ki bi bolje ločevala podjetja z vidika kreditnega limita in na podlagi katere bi lahko klasifikator podal še boljše rezultate.

Vendar je največji problem, zakaj nismo dobili rezultatov, kot smo jih želeli, v tem, da nismo razpolagali s pravo vrednostjo za določitev odvisne spremenljivke. Prvi razlog leži v naravi uporabljenih podatkov, saj zajeti računi ne zagotavljajo prave likvidnosti podjetij.

V praksi to pomeni, da lahko obravnavamo dve podjetji s podobno finančno strukturo, ki sta bili v realnosti sposobni pravočasno poravnati, npr. 10 odstotkov vrednosti prodaje ustvarjene v obdobju enega četrtertja, vendar smo imeli za prvega podatke o teh 10 odstotkih, za drugega pa npr. le za 1 odstotek. To pa posledično pomeni, da bo model tako težko razločeval med tema dvema podjetjema in bo iskal take rešitve, ki se na koncu izkažejo kot nerobustne ali pa preveč prilagojene na razvojno populacijo.

Drugi razlog pa leži v dejstvu, da se v slovenskem gospodarstvu vrednosti kreditnega limita ne dodeljuje objektivno, kar pomeni na podlagi njegove plačilne sposobnosti, temveč so te bolj ali manj subjektivne odločitve posameznikov. Te pa je težko zajeti s pomočjo modelov za napovedovanje, sestavljenih s pomočjo finančnih kazalnikov, če ti prvotno niso bili uporabljeni za odločitve o določevanju kreditnih limitov.

## **SKLEP**

V literaturi ni skupne razlage, zakaj so podjetja pripravljena ponuditi prodajo na kredit, se pa večina nastalih teorij združi v prepričanju, da odlog plačila pomaga rešiti nepopolnost

oz. neučinkovitost finančnega trga. To pa zato, ker prodajalec s prodajo na kredit prevzame finančno posredno vlogo. Ta pa pride še bolj do izraza v gospodarskih panogah, v katerih se vodi restriktivna monetarna politika, in v tistih, v katerih finančni sistem temelji na bankah.

In prav tak sistem ima slovensko gospodarstvo, zato je prodaja na kredit za slovenska podjetja nekaj običajnega, vsakodnevnega. To potrjuje tudi podatek, da slovenska podjetja beležijo v povprečju od 11 do 12 odstotkov vseh sredstev v terjatvah do kupcev, na drugi strani pa obveznosti do dobaviteljev predstavljajo v povprečju od 10 do 11 odstotkov vseh obveznosti. Oba odstotka sta konstantna skozi čas, in to ne glede na zadnjo nastalo krizo (Bisnode, 2016a, str. 45–48).

Obseg nujenja prodaje na kredit pri posameznem podjetju je predvsem odvisen od povpraševanja kupcev po takih nakupih, in od dobaviteljev – koliko so ti pripravljeni financirati. Toda na koncu je prodaja na kredit predvsem odvisna od značilnosti individualnega podjetja, predvsem pa sposobnosti ustvariti dovolj prostih denarnih sredstev, ki lahko financirajo tak način prodaje in dovolj visoko maržo, da lahko pokriva morebitne izgube.

Podjetje, ki omogoča prodajo na kredit, bi se moralo zavedati, da za celotni odobreni čas odloga plačila financira kupca in da ima do poplačila vezana sredstva v terjatvah. Oboje pa nosi tveganje. Prvo je povezano z negotovostjo poplačila terjatev, to je kreditno tveganje, drugo je povezano z negotovostjo pravočasnega preoblikovanja terjatev v denarna sredstva, kar pa je likvidnostno tveganje.

V primeru prodaje na kredit je likvidnostno tveganje pogojeno s kreditnim tveganjem, zato je ključnega pomena, da podjetje dela prav na slednjem. Tudi v primeru prodaje na kredit je kreditno tveganje sestavljeno iz verjetnosti neplačila, kreditne izpostavljenosti in potencialne izgube. Na temo, kako oceniti verjetnost neplačila, je bilo napisanih že veliko del. Potencialna izguba pa ni nič drugega kot kreditna izpostavljenost minus zavarovanje. In ker v večini primerov prodaje na kredit ni zavarovanj, ostane samo kreditna izpostavljenost tista, ki nas lahko ščiti pred nezaželenimi izgubami zaradi neplačil. In to na način, da se za vsakega kupca določi najvišjo vrednost kreditne izpostavljenosti, kar pomeni, da se mu določi kreditni limit.

Obstaja veliko strokovnih metod, kako določiti višino kreditnega limita. Bazzi in Hasna (2015) sta izpostavila, da obstaja toliko različnih strokovnih metod, kolikor je različnih analitikov. Po pregledavanju literature lahko povzamemo, da večina temelji na konceptu donosov, ki pa so pogojeni z verjetnostjo neplačila.

Če želimo uporabiti kreditni limit kot sredstvo, ki nas lahko zaščiti pred kreditnim tveganjem, potemtakem donosni vidik ni dovolj. S tega vidika določevanje kreditnih

limitov ni samo vprašanje, koliko donosa nam bo prodaja na kredit omogočila. Temveč vprašanje, ali je kupec v odobrenem roku plačila sploh sposoben to vrednost poplačati. Vendar sposobnost plačila se ne vedno izraža v oceni verjetnosti neplačila, če se sklicujemo na Carbonijevo (1997) študijo. Ta pravi, da je ocena verjetnosti neplačila bolj pokazatelj plačilne nediscipline kot pokazatelj sposobnosti plačila.

V primeru, če želimo uporabiti kreditni limit kot sredstvo za zaščito pred nezaželenimi izgubami, mora ta temeljiti na plačilni sposobnosti posameznega kupca. V ta namen so se razvili pristopi, ki so poskusili odgovoriti predvsem na vprašanje: »Kolikšen je tisti znesek, ki ga je posamezno podjetje v določenem obdobju sposobno pravočasno poravnati?« Za ta namen uporabimo različne metode iz data mining področja, predvsem pa tiste, ki so primerne za napovedovanje (Dun & Bradstreet, 2011, str. 22).

Cilj magistrskega dela je bil izdelati model, ki bi napovedoval ta znesek. Napovedani znesek, pa bi ga lahko uporabili za določevanje kreditnih limitov. Čeprav nismo dobili želenih rezultatov, se je kljub temu pokazal postopek, kako se lahko izdelata model za določevanje kreditnih limitov.

V našem primeru se je izkazalo, da na podatkih, ki smo jih uporabili za izdelavo modela, obstaja preveč različnih vzorcev obnašanja. Za boljše rezultate bi morali izdelati modele vsaj na nivoju oddelkov dejavnosti. Uporabljen postopek na portfelju kupcev nekega podjetja, ki posluje B2B, daje dobre rezultate, ker se na njem izraža bolj homogeni vzorec obnašanja (Dun & Bradstreet, 2011, str. 78).

Vsako podjetje bi za svoje potrebe lahko izdelalo model za določevanje kreditnih limitov. Čas je, da podatke, ki jih beležijo v svojih podatkovnih arhiv, začnejo tudi aplikativno uporabljati, in to ne samo za komercialne namene, kdo bo kaj kupil, temveč tudi za finančne, da se ugotovi, kdo je sploh sposoben poplačati svoje nakupe. In temu služijo modeli za določevanje kreditnega limita.

Delo pa bomo končali s mislijo, da je določitev prave višine kreditnega limita tisto pravo zavarovanje pred nezaželeno izgubo, ki lahko nastopi zaradi nudenja prodaje na kredit.

## LITERATURA IN VIRI

1. Abtey, B. H. (1993). *Comment evaluer les risques lies aux investissements*. Malakoff: Dunod.
2. Ademovič, A. (2008). *Učinkovita izterjava terjatev: Uspešen finančni menedžer*. Maribor: Založba Forum Media.
3. Alphonse, P., Ducret, J., & Eric, S. (2004). When trade credit facilitates access to bank finance: evidence from US small business data. *EFMA 2004 Basel*. Najdeno 30. oktobra 2015 na spletnem naslovu [http://papers.ssrn.com/sol3/papers.cfm?abstract\\_id=462660](http://papers.ssrn.com/sol3/papers.cfm?abstract_id=462660)
4. Altman, E. I. (1968). Financial Ratios, Discriminant Analysis And The Prediction Of Corporate Bankruptcy. *The Journal of Finance*, 23(4), 589–609.
5. Altman, E., Resti, A., & Sironi, A. (2005). *Recovery Risk The next Challenge in Credit Risk Management*. London: Risk Books.
6. Arora, N., Bohn, J. R., & Zhu, F. (2005). Reduced Form vs. Structural Models of Credit Risk: A Case Study of Three Models. *Moody's KMV*. Najdeno 3. marca 2015 na spletnem naslovu [http://www.planchet.net/EXT/ISFA/1226.nsf/d512ad5b22d73cc1c1257052003f1aed/bed8a147e3c08a41c125757a004f67ba/\\$FILE/Arora\\_Bohn\\_Zhu\\_reduced\\_structural\\_20050217.pdf](http://www.planchet.net/EXT/ISFA/1226.nsf/d512ad5b22d73cc1c1257052003f1aed/bed8a147e3c08a41c125757a004f67ba/$FILE/Arora_Bohn_Zhu_reduced_structural_20050217.pdf)
7. Barry, A. M. (1997). *Credit Management, the Key to Profitable Trading*. New York: John Wiley & Sons.
8. Basel Committee on Banking Supervision - Basel II. (2006). *International Convergence of Capital Measurement and Capital Standards*. Basel: Bank for International Settlements.
9. Bastos, J. A. (2008). Credit scoring with boosted decision trees. *MPRA*. Najdeno 18. aprila 2015 na spletnem naslovu [https://mpra.ub.uni-muenchen.de/8156/1/MPRA\\_paper\\_8156.pdf](https://mpra.ub.uni-muenchen.de/8156/1/MPRA_paper_8156.pdf)
10. Bastos, R., & Pindado, J. (2008). An agency model to explain trade credit policy and empirical evidence. *Applied Economics*, 39(20), 2631–2642.
11. Bazzi, M., & Hasna, C. (2015). Rating models and its Applications: Setting Credit Limits. *Journal of Applied Finance & Banking*, 5(5), 201–216.
12. Beaver, W. (1967). Financial Ratios as Predictors of Failure. *EFN*. Najdeno 15. decembra 2014 na spletnem naslovu <http://down.cenet.org.cn/upfile/36/200612612338179.pdf>
13. Bellotti, T., & Crook, J. N. (2009). Support vector machines for credit scoring and discovery measures and their application to thinning. *Expert Systems with Applications*, 36(2), 3302–3308.
14. Berk, A., Lončarski, I., Zajc, P., Krajnović, E., Deželan, S., Valentinčič, A., & Groznik, P. (2006). *Poslovne finance*. Ljubljana: Ekonomska fakulteta.
15. Biais, B., & Gollier, C. (1997). Trade credit and credit rationing. *The Review of Financial Studies*, 10(4), 903–937.

16. Bierman, H., & Hausman, W. H. (1970). The Credit Granting Decision. *Management Science*, 16, 519–532.
17. Bisnode. (2016a). *Gospodarski pregled skozi čas* (interno gradivo). Ljubljana: Bisnode.
18. Bisnode. (2016b). *Salda Konti za leto 2013 in 2014*. Ljubljana: Bisnode.
19. Bisnode. (2016c). *Finančni izkazi za obdobje 2011–2013*. Ljubljana: Bisnode.
20. Bisnode. (2016d). *Negativni dokogdi za obdobje 2011–2014*. Ljubljana: Bisnode.
21. Bisnode. (2016e). *Poslovni register*. Ljubljana: Bisnode.
22. Blazenko, G. W., & Vandezande, K. (2003). The Product Differentiation Hypothesis for Corporate Trade Credit. *Managerial and Decision Economics*, 24, 457–469.
23. Bougheas, S. Mateut, S., & Mizen, P. (2009). Corporate trade credit and inventories: new evidence of a trade-off from accounts payable and receivable. *Journal of Banking and Finance*, 33(2), 300–307.
24. Brealey, R., & Myers, S. (2011). *Principles of Corporate Finance*, 10<sup>th</sup> edition. New York: McGraw-Hill.
25. Breiman, L., Friedman, J. H., Olshen, R. A., & Stone, C.I. (1984). *Classification and regression trees*. Belmont: Wadsworth.
26. Brennan, M. J., Miksimovic, V., & Zechner, J. (1988). Vendor financing. *The Journal of Finance*, 43(5), 1127–1141.
27. Brick, I. E., & Fung, W. K. H. (1984). Taxes and the Theory of Trade Debt. *Journal of Finance*, 39(4), 1169–1176.
28. Brigham, E. F., & Daves, P. R. (2013). *Intermediate Financial Management*, 11<sup>th</sup> edition. Mason: South-Western, Cengage Learning.
29. Brigham, E. F., & Ehrhardt, M. C. (2011). *Financial management: theory and practice*, 13<sup>th</sup> edition. Mason: South-Western Cengage Learning.
30. Brigham, E. F., & Houston, J. F. (2009). *Fundamentals of Financial Management*, 12<sup>th</sup> edition. Mason: South-Western Cengage Learning.
31. Burkart, M., & Ellingsen, T. (2004). In-kind finance: a theory of trade credit. *American Economic Review*, 94, 569–590.
32. Carboni, A. (2007). *Analyse de la prise en compte de la capacite payer dans la cotede risque pour les dfauts des particuliers*. Montral: M.Sc. finance, HEC.
33. Cespedes, J. C. G. (2002). Credit Risk Modelling and Basel II. *Algo Research Quarterly*, 5(1), 57–66.
34. Chacko, G., Sjoman, A., Motohashi, H., & Dessain, V. (2006). *Credit Derivatives a Primer on Credit Risk, Modeling, and Instruments*. New Jerse: Pearson Education.
35. Cheng, N. S., & Pike, R. (2003). The trade credit decision: evidence of UK firms. *Managerial and Decision Economics*, 24(6/7), 419–438.
36. Cunat, V. (2007). Trade credit: suppliers as debt collectors and insurance providers. *The Review of Financial Studies*, 20(2), 491–527.
37. Danielson, M. G., & Scott, J. A. (2004). Bank loan availability and trade credit demand. *Financial Review*, 39(4), 579–600.

38. De Barcelos-Tronto, I. F., Simies da Silva, J. D., & Sant'Anna, N. (2008). An investigation of artificial neural networks based prediction systems in software project management. *Journal of Systems and Software*, 81(3), 356–367.
39. Deloof, M., & Jegers, M. (1996). Trade credit, product quality, and intragroup trade: some European evidence. *Financial Management*, 25(3), 33–43.
40. Deloof, M., & Jegers, M. (1999). Trade credit, corporate groups, and the financing of Belgian firms. *Journal of Business Finance & Accounting*, 26(7/8), 945–967.
41. Demirguc-Kunt, A., & Maksimovic, V. (2001). *Firms as financial intermediaries: evidence from trade credit data*, (delovno gradivo). Washington: World Bank Policy Research.
42. Deshpande, B. (2012). How to apply feature selection in linear regression with RapidMiner. *SIMAFORÉ*. Najdeno 14. maja 2016 na spletnem naslovu <http://www.simafore.com/blog/bid/111764/How-to-apply-feature-selection-in-linear-regression-with-RapidMiner>
43. Dionne, G., Artis, M., & Guilln, M. (1996). Count data models for a credit scoring system. *Journal of Finance, journal of Empirical Finance*, 3, 303–325.
44. Dolenc, P., & Stubelj, I. (2011). *Poslovne finance s praktičnimi primeri*. Ljubljana: Samozaložba P. Dolenc.
45. Dun & Bradstreet. (2009). *How to Build a Failure Model* (interno gradivo). Duesseldorf: Dun & Bradstreet.
46. Dun & Bradstreet. (2011). *How to Modelling a Customize Trade Credit Line Model* (interno gradivo). Duesseldorf: Dun & Bradstreet.
47. Durand, D. (1941). *Risk elements in consumer instalment financing*. New York: National Bureau of Economics.
48. Edwards, B. (1993). *Improving Cash Flow and Profits*. Hertfordshire: Director Books.
49. Emery, G. W. (1984). A pure financial explanation for trade credit. *The Journal of Financial and Quantitative Analysis*, 19(3), 271–285.
50. Ferris, J. S. (1981). A Transactions Theory of Trade Credit Use. *Quarterly Journal of Economics*, 86(2), 243–270.
51. Fisher, R. A. (1936). The Use of Multiple Measurements in Taxonomic Problems. *Annals of Eugenics*, 7(2), 179–188.
52. Fisman, R., & Love, I. (2003). Trade credit, financial intermediary development and industry growth. *The Journal of Finance*, 58(1), 353–374.
53. Frank, M. Z., & Maksimovic, V. (2004). *Trade credit, collateral, and adverse selection* (delovno gradivo). USA: University of British Columbia.
54. Friedman, J. H. (1991). Multivariate Adaptive Regression Splines. *Annals of Statistics*, 19(1), 1–141.
55. Friedman, N., Geinger, D., & Goldszmidt, M. (1997). Bayesian Network Classifiers. *Machine Learning*, 29, 131–163.
56. Galitz, L. (1995). *Financial Engineerng: Tools and Techniques to Manage Financial Risk*. New York: McGraw-Hill Trade.

57. Garcia-Teruel, P. J., & Martinez-Solano, P. (2007). Short-term debt in Spanish SMEs. *International Small Business Journal*, 25(6), 579–602.
58. Garcia-Teruel, P. J., & Martinez-Solano, P. (2010a). Determinants of trade credit: a comparative study of European SMEs. *International Small Business Journal*, 28(3), 215–233.
59. Garcia-Teruel, P. J., & Martinez-Solano, P. (2010b). A dynamic perspective on the determinants of accounts payable. *Review of Quantitative Finance and Accounting*, 34(4), 439–457.
60. Giudici, P. (2003). *Applied Data Mining: Statistical Methods for Business and Industry*. West Sussex: John Wiley & Sons.
61. Hand, D. J., & Henley, W. E. (2007). Statistical Classification Methods in Consumer Credit Scoring: a Review. *Journal of the Royal Statistical Society: Series A*, 160(3), 523–541.
62. Hand, D. J., & Vinciotti, V. (2003). Choosing k for two-class nearest neighbour classifiers with unbalanced classes. *Pattern Recognition Letters*, 24, 1555–1562.
63. Hastie, T., Tibshirani, R., & Friedman, J. (2008). *The Elements of Statistical Learning, Data Mining, Inference, and Prediction*, 2<sup>nd</sup> edition. California: Stanford.
64. Holland, H. J. (1975). *Adaptation in Natural and Artificial Systems, an Introductory Analysis with Applications to Biology, Control, and Artificial Intelligence*. Cambridge: The MIT Press.
65. Holliwell, J. (1998). *The Financial Risk Manual*. Harlow: Financial Times.
66. Hsieh, N. C. (2005). Hybrid Mining Approach in the Design of Credit Scoring Models. *Expert Systems with Applications*, 28(4), 655–665.
67. Huang, C. L., Chen, M. C., & Wang, C. J. (2007). Credit scoring with a data mining approach based on support vector machines. *Expert Systems with Applications*, 33(4), 847–856.
68. Huyghebaert, N. (2006). On the determinants and dynamics of trade credit use: empirical evidence from business start-ups. *Journal of Business Finance and Accounting*, 33(1/2), 305–328.
69. Igličar, A., & Hočevár, M. (2011). *Računovodstvo za managerje*. Ljubljana: GV Založba.
70. Jain, N. (2001). Monitoring Costs and Trade Credit. *Quarterly Review of Economics and Finance*, 41(1), 89–110.
71. Jarrow, R. A., & Turnbull, S. M. (1995). Pricing Derivatives on Financial Securities Subject to Credit Risk. *Journal of Finance*, 50(1), 53–85.
72. Jorion, P. (2006). *Value at Risk*, 3<sup>rd</sup> edition, New York: McGraw-Hill.
73. Kendall, R. (1998). *Risk Management for Executives*. London: Pitman Publishing.
74. Keramati, A., & Yousefi, N. (2011). A Proposed Classification of Data Mining Techniques in Credit Scoring. *IEOM*. Najdeno 10. decembra 2014 na spletnem naslovu <http://www.iieom.org/ieom2011/pdfs/IEOM061.pdf>
75. Kester, G. W., Hoover, S. A., & Pirkle, K. M. (2004). How much debt can a borrower afford?. *The RMA Journal*, 87(3), 46–51.

76. Kirkos, E., Spathis, C., & Manolopoulos, Y. (2010). Audit-firm group appointment: an artificial intelligence approach. *Journal of Intelligent Systems in Accounting Finance and Management*, 17(1), 1–17.
77. Kohler, M., Britton, E., & Yates, T. (2000). *Trade credit and the monetary transmission mechanism* (delovno gradivo). London: Bank of England.
78. Kolay, M. K. (1991). Managing Working Capital Crises: A System Dynamics Approach. *Management Decision*, 29(5), 46–52.
79. Kononenko, I. (2001). Machine learning for medical diagnosis: history, state of the art and perspective. *Artificial Intelligence in Medicine*, 23, 89–109.
80. Konovalikhin, M. J., Kulik, V. V., Sergienko, D. O., & Balaeva, O. V. (2008). The Scaling Model for Credit Limit Management. WCE. Najdeno 23. maja 2014 na spletnem naslovu [http://www.iaeng.org/publication/WCE2008/WCE2008\\_pp1786-1790.pdf](http://www.iaeng.org/publication/WCE2008/WCE2008_pp1786-1790.pdf)
81. Košmelj, K. (2007a). *Uporabna statistika, 2. dopolnjena izd.* Ljubljana: Biotehniška fakulteta.
82. Košmelj, K. (2007b). Metoda glavnih komponent: osnove in primer. *Acta agriculturae Slovenica*, 89(1), 159–175.
83. Kotu, V. (2015). *Predictive Analytics and Data Mining, Concepts and Practice with RapidMiner*. Waltham: Morgan Kaufmann.
84. Koza, J. R. (1992). *Genetic Programming on the Programming of Computers by Means of Natural Selection*. Cambridge: The MIT Press.
85. Kristanc, R. (2009). *Ocenjevanje in spremljanje kreditnega tveganja* (interno gradivo Hypo Alpe-Adria-Bank, d.d.). Ljubljana: Hypo Alpe-Adria-Bank, d.d.
86. Kristanc, R. (2010). *Debt capacity* (interno gradivo Hypo Alpe-Adria-Bank, d.d.). Ljubljana: Hypo Alpe-Adria-Bank, d.d.
87. Lamberg, S., & Vålming, S. (2009). *Impact of Liquidity Management on Profitability: a study of the adaptation of liquidity strategies in a financial crisis* (Master thesis). Sweden: Umeå School of Business.
88. Lando, D. (1998). On Cox Processes and Credit Risky Securities. *The Review of Derivatives Research*, 2, 99–120.
89. Lavrač, N. (2011). *Data Mining and Knowledge Discovery* (študijsko gradivo). Ljubljana: Jožef Stefan Institute.
90. Lee, W.C. (2006). Genetic Programming Decision Tree for Bankruptcy Prediction. WC Lee. Najdeno 17. aprila 2015 na spletnem naslovu WC Lee - JCIS, 2006 - atlantispress.com
91. Lee, T. S., & Chen, I. F. (2005). A Two-Stage Hybrid Credit Scoring Model Using Artificial Neural Networks and Multivariate Adaptive Regression Splines. *Expert Systems with Application*, 28(4), 743–752.
92. Lee, Y., & Stowe, J. (1993). Product Risk, Asymmetric Information and Trade Credit, *Journal of Financial and Quantitative Analysis*, 28(2), 285–300.

93. Leippold, M., Vanini, P., & Ebnoether, S. (2003). Optimal Credit Limit Management. *FINRISK*. Najdeno 22. junija 2014 na spletnem naslovu [http://www.econbiz.de/archiv1/2008/50447\\_credit\\_limit\\_management.pdf](http://www.econbiz.de/archiv1/2008/50447_credit_limit_management.pdf)
94. Lessmann, S., Seow, H. V., Baesens, B., & Thomas, L. (2013). Benchmarking state-of-the-art classification algorithms for credit scoring: A ten-year update. *The University of Edinburgh Business School*. Najdeno 2. avgusta 2015 na spletnem naslovu [http://www.business-school.ed.ac.uk/waf/crc\\_archive/2013/42.pdf](http://www.business-school.ed.ac.uk/waf/crc_archive/2013/42.pdf)
95. Lewellen, W., McConnell J., & Scott, J. (1980). Capital market influences on trade credit policies. *Journal of Financial Research*, 3(2), 105–113.
96. Li, X. (2011). *Determinants of trade credit: a study of listed firms in the Netherlands* (Master Thesis), Enschede: University of Twente.
97. Li, X. L., & Zhong, Y. (2012). An Overview of Personal Credit Scoring: Techniques and Future Work. *International Journal of Intelligence Science*, 2(4), 181–189.
98. Long, M. S., Malitz, I. B., & Ravid, S. A. (1993). Trade credit, quality guarantees, and product marketability. *Financial Management*, 22(4), 117–127.
99. Madan, D., & Unal, H. (1998). Pricing the risks of default. *Review of Derivatives Research*, 2, 121–160.
100. Maness, T. S., & Zietlow, J. T. (2002). *Short – Term Financial Management*, 2<sup>nd</sup> edition. USA: Thomson Learning.
101. Marotta, G. (2005). When do trade credit discounts matter? Evidence from Italian firm-level data. *Applied Economics*, 37(4), 403–416.
102. Matuszyk, A., Mues, C., & Thomas, L. C. (2010). Modelling LGD for unsecured personal loans: decision tree approach. *Journal of the Operational Research Society*, 10(61), 393–398.
103. Mayr, B. (2003). *Kako gospodariti, da bomo potrebovali čim manj virov financiranja*. Ljubljana: Gospodarska zbornica Slovenije.
104. Merton, R. C. (1974). On the pricing of corporate debt: the risk structure of interest rates. *J. Finance*, 29, 449–470.
105. Meža, M. (2013). IS–Vaja 4: Klasifikacija Naive Bayes v orodju RapidMiner. *LdOS*. Najdeno 20. maja 2016 na spletnem naslovu [http://www.ldos.si/slo/03\\_Lectures/24\\_IS/Vaje/1314/IS%20-%20Vaja4.pdf](http://www.ldos.si/slo/03_Lectures/24_IS/Vaje/1314/IS%20-%20Vaja4.pdf)
106. Michalski, G. (2007). Portfolio management approach in trade credit decision making. *Romanian Journal of Economic Forecasting*, 3, 42–53.
107. Morgan, J. P. (1997). CreditMetrics™–Technical Document. *Heriot Watt University*. Najdeno 12. oktobra 2015 na spletnem naslovu <http://www.macs.hw.ac.uk/~mcneil/F79CR/CMTD1.pdf>
108. Ng, C. K., Kiholm-Smith, J., & Smith, R. L. (1999). Evidence on the determinants of credit terms used in interfirm trade. *Journal of Finance*, 54, 1109–1130.
109. Nilsen, J. H. (2002). Trade credit and the bank lending channel. *Journal of Money, Credit and Banking*, 34(1), 226–253.

110. Niskanen, J., & Niskanen, M. (2006). The determinants of corporate trade credit policies in a bank dominated financial environment: The case of Finnish small firms. *European Financial Management*, 12(1), 81–102.
111. Pahor, M. (2004). *Zapiski predavanj Statistika 3*. Ljubljana: Ekonomska fakulteta.
112. Paredes, R., & Vidal, E. (2000). A Class-Dependent Weighted Dissimilarity Measure for Nearest Neighbor Classification Problems. *Pattern Recogn. Lett.*, 21(12), 1027–1036.
113. Pass, R., & Pike, C. (1987). Management of Working Capital: A Neglected Subject. *Management Decision*, 25(1), 18–24.
114. Petersen, M. A., & Rajan, R. G. (1994). The benefits of lending relationships: evidence from small business data. *The Journal of Finance*, 49(1), 3–37.
115. Petersen, M. A., & Rajan, R. G. (1995). The effect of credit market competition on lending relations. *The Quarterly Journal of Economics*, 60, 407–44.
116. Petersen, M. A., & Rajan, R. G. (1997). Trade credit: theories and evidence. *The Review of Financial Studies*, 10(3), 661–691.
117. Pike, R., Cheng, N. S., Cravens, K., & Lamminmaki, D. (2005). Trade credit terms: asymmetric information and price discrimination evidence from three continents, *Journal of Business Finance & Accounting*, 32, 1197–1236.
118. Planinšič, D. (2008). *Organiziranje izterjave zapadlih terjatev* (diplomsko delo). Maribor: Ekonomsko-poslovna fakulteta.
119. Price, R. (1763). Essay Towards Solving a Problem in the Doctrine of Chances. UCLA. Najdeno 20. maja 2016 na spletnem naslovu <http://www.stat.ucla.edu/history/essay.pdf>
120. Rebernik, M., & Repovž, L. (2000). *Od ideje do denarja: podjetniški proces*. Ljubljana: Gospodarski vestnik.
121. Repovž, L. (1994). *Problemi likvidnostnega managementa s poudarkom na oblikovanju terjatev do kupcev*. Maribor: ZFRD Slovenije.
122. Rodriguez-Rodriguez, O. M. (2006). Trade credit in small and medium size firms: an application of the system estimator with panel data. *Small Business Economics*, 27(2/3), 103–126.
123. Rován, J. (2002). *Metoda glavnih komponent* (študijsko gradivo). Ljubljana: Ekonomska fakulteta.
124. Saunders, A. (1999). *Credit Risk Measurement: New Approaches to Value-at-Risk and Other Paradigms*. New York: John Wiley and Sons.
125. Sanchez, A. (2003). *Bear faced credit*. London: Credit Management – Journal of the Institute of Credit Management.
126. Scherr, F. C. (1996). Optimal Trade Credit Limits. *Financial Management*, 25(1), 71–85.
127. Schwartz, R. A. (1974). An economic model of trade credit. *The Journal of Financial and Quantitative Analysis*, 9(4), 643–657.
128. Selan, T. (2002). *Ocena kreditne sposobnosti podjetja* (strokovno gradivo). Ljubljana: Delavnica ocena kreditne sposobnosti podjetja.

129. Selan, T. (2004). *Ocena kreditne sposobnosti kupca in uspešna izterjava* (strokovno gradivo). Ljubljana: GV izobraževanje za dvig vrednosti.
130. Shin, H. H., & Soenen, L. (1998). Efficiency of Working Capital Management and Corporate Profitability. *Financial Practice and Education*, 8(2), 37–45.
131. *Slovenski računovodski standardi 2016*. (2016). Ljubljana: Slovenski inštitut za revizijo.
132. Smith, J. K. (1987). Trade credit and informational asymmetry. *The Journal of Finance*, 42(4), 863–872.
133. Srinivasan, V., & Kim, Y. H. (1987). The Credit Granting Decision: A Note. *Management Science*, 33(10), 1361–1362.
134. Šeligo, R. (1997). Obvladovanje danih blagovnih kreditov s poudarkom na politiki kreditiranja kupcev. *Revizor*, 4-5, 109–131.
135. Thomas, L. C., Edelman, D. B., & Crook, J. N. (2000). *Credit Scoring and its Applications*. Philadelphia: SIAM.
136. Tsai, C. F., & Chen, M. L. (2010). Credit Rating by Hybrid Machine Learning Techniques. *Applied Soft Computing*, 10(2), 374–380.
137. Van Horne, C. J. (1993). *Financijsko upravljanje i politika*. Zagreb: Mate.
138. Van der Wijst, N., & Hol, S. (2002). Trade Credit in Europe. *31<sup>st</sup> Meeting of the European Working Group on Financial Modelling*. Agia Napa: European Working Group on Financial Modelling.
139. Vapnik, V. N. (1995). *The Nature of Statistical Learning Theory*. New York: Springer Verlag.
140. Vernimmen, P., Quiry, P., Dallochio, M., Le Fur, Y., & Salvi, A. (2005). *Corporate Finance, Theory and Practice*. West Susse: John Wiley & Sons Ltd.
141. Weston, J. F., & Copeland, E. T. (2000). *Managerial Finance*, 11<sup>th</sup> edition. London: The Dryden Press.
142. Wei, P., & Zee, S. M. L. (1997). Trade credit as quality signal: an international comparison. *Managerial Finance*, 23(4), 63–72.
143. Wilson, N., & Summers, B. (2002). Trade credit terms offered by small firms: survey evidence and empirical analysis. *Journal of Business Finance & Accounting*, 29(3/4), 317–351.
144. Witten, I. H., & Frank, E. (2005). *Data Mining Practical Machine Learning Tools and Techniques*, 2<sup>nd</sup> edition. Amsterdam: Morgan Kaufmann publishers.
145. Yap, B. W., Ong, S. H., & Husain, H. M. (2011). Using data mining to improve assessment of credit worthiness via credit scoring models. *Expert Systems with Applications*, 38, 13274–13283.
146. Yeh, I. C., & Lien, C. H. (2009). The comparisons of data mining techniques for the predictive accuracy of probability of default of credit card clients. *Expert Systems with Applications*, 36(2), 2473–2480.
147. Ziane, Y. (2011). An investigation into the determinants of trade credit use by French small and medium enterprises. *M.O.D.E.M.* Najdeno 29. novembra 2015 na spletnem naslovu <https://www.researchgate.net/>

148. Zurada, J., & Lonial, S. (2005). Comparison of the Performance of Several Data Mining Methods for Bad Debt Recovery in the Healthcare Industry. *The Journal of Applied Business Research*, 2(2), 37–53.

## **PRILOGE**



## KAZALO PRILOG

|                                                              |    |
|--------------------------------------------------------------|----|
| Priloga 1: Slovarček slovenskih prevodov tujih izrazov ..... | 1  |
| Priloga 2: Seznam kazalnikov in njihova transformacija ..... | 3  |
| Priloga 3: Pregled transformiranih kazalnikov .....          | 6  |
| Priloga 4: Analiza glavne komponente.....                    | 20 |
| Priloga 5: Naive Bayesian klasifikator .....                 | 23 |



## Priloga 1: Slovarček slovenskih prevodov tujih izrazov

**Adaptive heuristic search algorithms** - hevristični iskalni algoritem.  
**Adjusted working capital** - popravljeni obratni kapital.  
**Artificial neural networks** - umetne nevronske mreže.  
**Attribute** - neodvisna spremenljivka.  
**Bank-based financial systems** - finančnih sistemih, kjer banke prevladujejo.  
**Cash conversion cycle** - proces kroženja denarja.  
**Cash crunch situation** - likvidnostnih težavah.  
**Chi-square automatic interaction detector** - hi-kvadrat avtomatski detektor interakcije.  
**Classification and regression trees** - klasifikacijsko in regresijsko drevo.  
**Classification** – razvrščanje.  
**Clustering** – združevanje.  
**Credit granting** – odobritev kreditov.  
**Credit line** – kreditni limit.  
**Credit score** - »indeks« kreditne sposobnosti.  
**Credit spreads** – kreditni razpon.  
**Decison rule** – pravilo odločanja.  
**Decision trees** – odločitveno drevo.  
**Default intensity** - neplačilne intenzivnosti.  
**Directed acyclic graph** - usmerjeni aciklični graf.  
**Expected profit method** - metoda pričakovanega dobička.  
**Exposure at default** - kreditna izpostavljenost ob trenutku neplačila.  
**Fat cat** - sproščena politika.  
**Financial intermediary role** - finančna posredna vloga.  
**Firm value** – vrednost podjetja.  
**Generalized cross validation criterion** - navzkrižnega validacijskega merila.  
**Generalization ability** – posplošiti.  
**Genetic algoritem** - genetski algoritem.  
**Gross profit margin** – marža.  
**Label** – oznaka.  
**Lean-and-mean** - omejevalna politika.  
**Loss given at default** - potencialna izguba on nastanku neplačila.  
**Machine learning** – strojno učenje.  
**Mapping funkcion** - funkcijo preslikave.  
**Market imperfection** – neučinkovitost trga.  
**Mathematical global optimization** – optimizacija.  
**Maximal threshold** – maksimalna vrednost.  
**Multiperiod concept** – več-obdobni koncept.  
**Multivariate adaptive regression splines** - multivariatna prilagodljiva regresija Splines.  
**Nearest neighbor classifiers** - k-najbližjih sosedov.  
**Net present value** - neto sedanja vrednost.  
**Net worth** - neto vrednost podjetja.  
**Open account** - prodaja na odprto.  
**Overfit** – preprileganje.  
**Principal component analysis** - metoda glavnih komponent.

**Recovery** – izsterjava.

**Posterior probability** – posteriorirna verjetnost.

**Repayment capacity** – sposobnost plačila.

**Risk points method** - metoda točk tveganj.

**Risk profile** - profil tveganja.

**Profitability indicators method** - metoda kazalnikov donosnosti.

**Probability of default** - verjetnost neplačila.

**Regressing toward the mean** - regresija v smislu povprečja.

**Scalar threshold** - skalarna vrednost.

**Scaling methodology** - tehnike stopnjevanja.

**Scaling model** – stopnjevalna metoda.

**Single period formulation** - eno obdobjna formulacija.

**Support vector machine** - metoda podpornih vektorjev.

**Target variable** - odvisna spremenljivka.

**Test set** – testna populacija.

**Tractable** – obvladljivost.

**Trade credit** – prodaja na kredit.

**Trade credit line** – kreditni limit za potrebe prodaje na kredit.

**Training set** - razvojna populacija.

**Threshold** – mejna vrednost.

## Priloga 2: Seznam kazalnikov in njihova transformacija

| ID | Segment      | Kratice              | Ime                                                                              | Izračun                                                                                                       | Transformacija [min,max]                                                       |
|----|--------------|----------------------|----------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------------------------|--------------------------------------------------------------------------------|
| 1  | Financiranje | KAP_SRED             | Stopnja lastniškosti financiranja                                                | Kapital / Sredstva                                                                                            | [-1;1]                                                                         |
| 2  | Financiranje | FO_SRED              | Stopnja dolžniškosti financiranja                                                | Finančne obveznosti (K+D) / Sredstva                                                                          | [0;1,5]                                                                        |
| 3  | Financiranje | KFO_FO               | Zapadlost finančnih obveznosti                                                   | Kratkoročne finančne obveznosti / Finančne obveznosti (K+ D)                                                  | Diskretna: 1 is null, 2 = 0, 3: ≤ 0,25, 4: ≥0,25 and ≤0,75, 5: >0,75           |
| 4  | Financiranje | FO_KAP               | Koeficient dolgovno-kapitalskega razmerja                                        | Finančne obveznosti (K+D) / Kapital                                                                           | [-5;5]                                                                         |
| 5  | Financiranje | FO_EBITDA            | Finančne obveznosti na EBITDA                                                    | Finančne obveznosti (K+D) / EBITDA                                                                            | [-2;6]                                                                         |
| 6  | Financiranje | FO_FCF               | Finančne obveznosti na prosti denarni tok                                        | Finančne obveznosti (K+D) / (EBITDA-CAPEX-davek)                                                              | [-2;6]                                                                         |
| 7  | Financiranje | OBV_KSRED            | Obveznosti na kratkoročna sredstva                                               | (Poslovne (K+D) + finančne obveznosti (K+D) / Kratkoročna sredstva                                            | [0;5]                                                                          |
| 8  | Financiranje | NW                   | Neto sredstva                                                                    | Sredstva - Finančne obveznosti (K+D) / Sredstva                                                               | [-1;1]                                                                         |
| 9  | Investiranje | FO_OP_SRED_NN        | Finančne obveznosti na opredmetena osnovna sredstva z naložbenimi nepremičninami | Finančne obveznosti (K+D) / (Opredmetena osnovna sredstva + naložbene nepremičnine)                           | [0;5]                                                                          |
| 10 | Investiranje | FN_NN_OP_SRED        | Odstotek naložb na opredmetena sredstva                                          | (Finančne naložbe (K+D) + naložbene nepremičnine) / Opredmetena osnovna sredstva                              | Dummy: 1 ima naložbe, 0 nima naložb                                            |
| 11 | Investiranje | KAP_DOF_OP_SRED_NN_Z | Koeficient dolgoročne pokritosti dolgoročnih sredstev                            | (Kapital + dolgoročne finančne obveznosti) / (Opredmetena osnovna sredstva + naložbene nepremičnine + zaloge) | [-5;5]                                                                         |
| 12 | Investiranje | CAPEX_SRED           | CAPEX na sredstva                                                                | CAPEX / Sredstva                                                                                              | [-1,1]                                                                         |
| 13 | Likvidnost   | WC_SRED              | Obratni kapital na sredstva                                                      | Obratni kapital / Sredstva                                                                                    | [-1;1]                                                                         |
| 14 | Likvidnost   | Z_T_SRED             | Odstotek zalog ter terjatev v sredstvih                                          | Zaloge in poslovne terjatve / Sredstva                                                                        | /                                                                              |
| 15 | Likvidnost   | DOZ                  | Dnevi obračanja zalog                                                            | (365 / (Stroški blaga in materiala / Zaloge))                                                                 | Diskretna: 1 is null, 2: ≤30, 3; >30 and ≤90, 4: >90 and ≤180, 5: >180         |
| 16 | Likvidnost   | DVT                  | Dnevi vezave terjatev                                                            | (Poslovne terjatve (K + D) / Prodaja / 365)                                                                   | /                                                                              |
| 17 | Likvidnost   | OOS                  | Koeficient obračanja osnovnih sredstev                                           | Prodaja/ Povprečna opredmetena sredstva                                                                       | [0;20]                                                                         |
| 18 | Likvidnost   | PRO_SRED             | Prodajo na sredstva                                                              | Prodaja / Povprečna sredstva                                                                                  | [0;10]                                                                         |
| 19 | Likvidnost   | WC_PRO               | Obratni kapital na prodajo                                                       | ((Zaloge + kratk. posl. terjatve - poslovne obveznosti) / Prodaja)                                            | [-5;5]                                                                         |
| 20 | Likvidnost   | DVPO                 | Dnevi vezave poslovnih obveznosti                                                | (Posl. obveznosti (K + D) / Stroški blaga, materiala in storitev) * 365                                       | Diskretna: 1: ≤60, 2: >60 and ≤90, 3; >90 and ≤120, 4: >1200 and ≤180, 5: >180 |
| 21 | Likvidnost   | KK                   | Kratkoročni koeficient                                                           | Kratkoročna sredstva / Kratkoročne obveznosti                                                                 | [0;4]                                                                          |
| 22 | Likvidnost   | PK                   | Pospešeni koeficient                                                             | (Kratkoročna sredstva - zaloge / Kratkoročne obveznosti)                                                      | [0;3]                                                                          |

| ID | Segment     | Kratice         | Ime                                                            | Izračun                                                                                                                 | Transformacija [min,max] |
|----|-------------|-----------------|----------------------------------------------------------------|-------------------------------------------------------------------------------------------------------------------------|--------------------------|
| 23 | Likvidnost  | KT_KPO          | Koeficient kratkoročnega terjatveno-obveznostnega razmerja     | Kratkoročne poslovne terjatve/ Kratkoročne poslovne obveznosti                                                          | [0;3]                    |
| 24 | Likvidnost  | KT_PRO          | Odstotek terjatev v prodaji                                    | Kratkoročne poslovne terjatve/ Prodaja                                                                                  | [0;3]                    |
| 25 | Likvidnost  | WC_PO           | Obratni kapital na poslovne obveznosti                         | Obratni kapital / Poslovne obveznosti                                                                                   | [-1;3]                   |
| 26 | Likvidnost  | KPT_Z_KPO       | Seštevek terjatev in zalog na kratkoročne poslovne obveznosti  | Poslovne terjatve + zaloge / Poslovne obveznosti                                                                        | [0;3]                    |
| 27 | Denarni tok | FCF_OBV         | Prosti denarni tok na obveznosti                               | (EBITDA-CAPEX-davki) / (Poslovne (K+D) in finančne obveznosti (K+D))                                                    | [-0,5;0,5]               |
| 28 | Denarni tok | KPO_EBIT        | Kratkoročne poslovne obveznosti na EBIT                        | Kratkoročne poslovne obveznosti / EBIT                                                                                  | [-15;15]                 |
| 29 | Denarni tok | EBIT_PO         | EBIT na poslovne obveznosti                                    | EBIT / Kratkoročne Poslovne obveznosti                                                                                  | [-0,5;0,5]               |
| 30 | Denarni tok | OCF_PRI         | Denarni tok iz poslovanja na prihodke                          | (EBITDA - davki) / Prihodki                                                                                             | [-1;1]                   |
| 31 | Denarni tok | OCF_PO          | Kazalnik tekoče pokritosti obveznosti                          | (EBITDA - davki) / Kratkoročne Poslovne obveznosti                                                                      | [-1;1]                   |
| 32 | Denarni tok | OCF_PRO         | Denarni tok iz poslovanja na prodajo                           | (EBITDA - davki) / Prodaja                                                                                              | [-1;1]                   |
| 33 | Denarni tok | OCF_SRED        | Denarni tok iz poslovanja na sredstva                          | (EBITDA - davki) / Povprečna sredstva                                                                                   | [-1;1]                   |
| 34 | Denarni tok | FCF_OCF         | Prosti denarni tok na denarni tok iz poslovanja                | (EBITDA-CAPEX-davki) / (EBITDA - davki)                                                                                 | [-2;2]                   |
| 35 | Denarni tok | OCF_EBIT        | Denarni tok iz poslovanja na EBIT                              | (EBITDA - davki) / EBIT                                                                                                 | [-5;5]                   |
| 36 | Denarni tok | OCF_FO          | Denarni tok iz poslovanja na finančne obveznosti               | (EBITDA - davki) / Finančne obveznosti (K+D)                                                                            | [-1,5;1,5]               |
| 37 | Denarni tok | OCF_CII_CFI     | Denarni tok iz poslovanja na celoten ustvarjen denarni tok     | (EBITDA - davki)/ (EBITDA - davki)+sprememba v obratnem kapitalu + sprememba investiranja + sprememba v financiranju    | [-2;2]                   |
| 38 | Uspešnost   | PRO_SNMSD_KFOFO | Pokritost finančnega dolga                                     | (Prodaja - stroški nabave, materiala in storitev - stroški dela) / (Kratkoročne finančne obveznosti + finančni odhodki) | [-1;1]                   |
| 39 | Uspešnost   | PO_AMOR_PROD    | Poslovni odhodki brez amortizacije na prodajo                  | (Poslovni odhodki - amortizacija) / Prodaja                                                                             | [0;2]                    |
| 40 | Uspešnost   | PRO_SNM_SS_SD   | Bruto dobiček v razmerju s seštevkom stroškov storitev in dela | (Prodaja - nabava vrednost + materiala) / storitve + delo                                                               | [-3;3]                   |
| 41 | Uspešnost   | PRO_SNM_KPO     | Bruto dobiček na kratkoročne poslovne obveznosti               | (Prodaja - nabavna vrednost blaga in stroškov materiala) / Kratkoročne poslovne obveznosti                              | [-2;10]                  |
| 42 | Uspešnost   | SS_SNMSD        | Odstotek stroškov storitev med vsemi poslovnimi stroški        | Stroški storitev / (Nabavna vrednost blaga + stroški materiala, storitev in dela)                                       | [0;1]                    |
| 43 | Uspešnost   | ROA             | Donosnost sredstev                                             | Poslovni izid / Povprečna sredstva                                                                                      | [-1;1]                   |
| 44 | Uspešnost   | BM              | Bruto marža                                                    | Prodaja - nabavna vrednost prodanega blaga in materiala/ Prodaja                                                        | [-1;1]                   |



| ID | Segment   | Kratice   | Ime                                              | Izračun                                                           | Transformacija<br>[min,max] |
|----|-----------|-----------|--------------------------------------------------|-------------------------------------------------------------------|-----------------------------|
| 45 | Uspešnost | EBIT_PRO  | EBIT na prodajo                                  | EBIT / Prodaja                                                    | [-1;1]                      |
| 46 | Uspešnost | EBIT_SRED | EBIT na sredstva                                 | EBIT / Povprečna sredstva                                         | [-1;1]                      |
| 47 | Uspešnost | KI_PRI    | Poslovni izid na prihodke                        | Poslovni izid / prihodke                                          | [-1;1]                      |
| 48 | Uspešnost | RPROD     | Rast prodaje                                     | $(\text{Prodaja } t - \text{Prodaja } t-1) / \text{Prodaja } t-1$ | [-1;1]                      |
| 49 | Ostalo    | SKD       | Standardna klasifikacija dejavnosti              | /                                                                 | /                           |
| 50 | Ostalo    | PD        | Odstotek blokad po dejavnosti – raven na oddelek | Št. Podjetij z blokado / Št. Podjetij v oddelku dejavnosti        | /                           |


### Priloga 3: Pregled transformiranih kazalnikov

#### Financiranje:

|                        | KAP_SRED | FO_SRED | FO_KAP | FO_EBITDA | FO_FCF | OBV_KSRED | NW    |
|------------------------|----------|---------|--------|-----------|--------|-----------|-------|
| Mean                   | 0,37     | 0,26    | 0,75   | 1,89      | 1,37   | 1,58      | 0,74  |
| Median                 | 0,38     | 0,18    | 0,26   | 1,04      | 0,00   | 1,01      | 0,82  |
| Mode                   | -1,00    | 0,00    | 0,00   | 0,00      | 0,00   | 5,00      | 1,00  |
| Std. Deviation         | 0,35     | 0,29    | 1,74   | 2,50      | 2,80   | 1,46      | 0,31  |
| Skewness               | -1,19    | 1,51    | 0,24   | 0,50      | 0,59   | 1,35      | -2,05 |
| Std. Error of Skewness | 0,04     | 0,04    | 0,04   | 0,04      | 0,04   | 0,04      | 0,04  |
| Kurtosis               | 3,10     | 2,78    | 2,84   | -0,98     | -1,04  | 0,63      | 6,79  |
| Std. Error of Kurtosis | 0,09     | 0,09    | 0,09   | 0,09      | 0,09   | 0,09      | 0,09  |
| Minimum                | -1,00    | 0,00    | -5,00  | -2,00     | -2,00  | 0,00      | -1,00 |
| Maximum                | 1,00     | 1,50    | 5,00   | 6,00      | 6,00   | 5,00      | 1,00  |
| Percentiles            |          |         |        |           |        |           |       |
| 25                     | 0,18     | 0,00    | 0,00   | 0,00      | -0,13  | 0,60      | 0,59  |
| 50                     | 0,38     | 0,18    | 0,26   | 1,04      | 0,00   | 1,01      | 0,82  |
| 75                     | 0,61     | 0,41    | 1,15   | 3,89      | 3,68   | 1,97      | 1,00  |

| KFO_FO                         | Percent | Cumulative Percent |
|--------------------------------|---------|--------------------|
| Valid                          |         |                    |
| Brez fin obv.                  | 24,1    | 24,1               |
| Samo dol. fin obv.             | 12,0    | 36,1               |
| do 25% kratk. fin. obv.        | 14,2    | 50,3               |
| od 25 do 75 % kratk. fin. obv. | 19,3    | 69,6               |
| nad 75 kratk. fin. obv.        | 30,4    | 100,0              |
| Total                          | 100,0   |                    |








## Investiranje:

|                               |    | FO_OP_SRED_NN | CAPEX_SRED | KAP_DOF_OP_SRED_NN_Z |
|-------------------------------|----|---------------|------------|----------------------|
| <b>Mean</b>                   |    | 1,19          | 0,07       | 1,60                 |
| <b>Median</b>                 |    | 0,54          | 0,02       | 1,07                 |
| <b>Mode</b>                   |    | 0,00          | 0,00       | 5,00                 |
| <b>Std. Deviation</b>         |    | 1,62          | 0,14       | 1,74                 |
| <b>Skewness</b>               |    | 1,57          | 1,38       | 0,24                 |
| <b>Std. Error of Skewness</b> |    | 0,04          | 0,04       | 0,04                 |
| <b>Kurtosis</b>               |    | 1,03          | 13,06      | 1,74                 |
| <b>Std. Error of Kurtosis</b> |    | 0,09          | 0,09       | 0,09                 |
| <b>Minimum</b>                |    | 0,00          | -1,00      | -5,00                |
| <b>Maximum</b>                |    | 5,00          | 1,00       | 5,00                 |
| <b>Percentiles</b>            | 25 | 0,05          | 0,00       | 0,71                 |
|                               | 50 | 0,54          | 0,02       | 1,07                 |
|                               | 75 | 1,29          | 0,08       | 2,13                 |

| FN_NN_OP_SRED       | Percent | Cumulative Percent |
|---------------------|---------|--------------------|
| Brez fin. Inves.    | 34,2    | 34,2               |
| Valid Z fin. Inves. | 65,8    | 100,0              |
| Total               | 100,0   |                    |







### Likvidnost:








|                        | WC_SRED | Z_T_SRED | DVT   | OOS   | PRO_SRED | WC_PRO |
|------------------------|---------|----------|-------|-------|----------|--------|
| Mean                   | 0,07    | 0,40     | 0,00  | 8,57  | 1,74     | 0,09   |
| Median                 | 0,07    | 0,37     | 0,00  | 4,99  | 1,32     | 0,05   |
| Mode                   | -1,00   | 0,00     | 0,00  | 20,00 | 10,00    | 5,00   |
| Std. Deviation         | 0,29    | 0,26     | 0,01  | 7,71  | 1,55     | 0,62   |
| Skewness               | -0,64   | 0,38     | 1,25  | 0,55  | 2,27     | 0,93   |
| Std. Error of Skewness | 0,04    | 0,04     | 0,04  | 0,04  | 0,04     | 0,04   |
| Kurtosis               | 2,05    | -0,85    | 30,60 | -1,40 | 7,10     | 40,10  |
| Std. Error of Kurtosis | 0,09    | 0,09     | 0,09  | 0,09  | 0,09     | 0,09   |
| Minimum                | -1,00   | 0,00     | 0,00  | 0,00  | 0,00     | -5,00  |
| Maximum                | 0,91    | 1,00     | 0,65  | 20,00 | 10,00    | 5,00   |
| Percentiles            |         |          |       |       |          |        |
| 25                     | -0,06   | 0,19     | 0,05  | 1,86  | 0,76     | -0,04  |
| 50                     | 0,07    | 0,37     | 0,25  | 4,99  | 1,32     | 0,05   |
| 75                     | 0,24    | 0,59     | 0,40  | 19,70 | 2,22     | 0,19   |

|                               | KK    | PK    | KT_KPO | KT_PRO | WC_PO | KPT_Z_KPO |
|-------------------------------|-------|-------|--------|--------|-------|-----------|
| <b>Mean</b>                   | 1,66  | 1,27  | 1,12   | 0,27   | 0,56  | 1,48      |
| <b>Median</b>                 | 1,31  | 1,04  | 0,93   | 0,18   | 0,27  | 1,30      |
| <b>Mode</b>                   | 4,00  | 3,00  | 3,00   | 3,00   | 3,00  | 3,00      |
| <b>Std. Deviation</b>         | 1,16  | 0,93  | 0,85   | 0,39   | 1,07  | 0,90      |
| <b>Skewness</b>               | 0,85  | 0,69  | 0,84   | 4,68   | 0,94  | 0,39      |
| <b>Std. Error of Skewness</b> | 0,04  | 0,04  | 0,04   | 0,04   | 0,04  | 0,04      |
| <b>Kurtosis</b>               | -0,37 | -0,73 | -0,20  | 27,09  | 0,06  | -1,01     |
| <b>Std. Error of Kurtosis</b> | 0,09  | 0,09  | 0,09   | 0,09   | 0,09  | 0,09      |
| <b>Minimum</b>                | 0,00  | 0,00  | 0,00   | 0,00   | -1,00 | 0,00      |
| <b>Maximum</b>                | 4,00  | 3,00  | 3,00   | 3,00   | 3,00  | 3,00      |
| <b>Percentiles</b>            |       |       |        |        |       |           |
| 25                            | 0,82  | 0,54  | 0,45   | 0,09   | -0,21 | 0,77      |
| 50                            | 1,31  | 1,04  | 0,93   | 0,18   | 0,27  | 1,30      |
| 75                            | 2,22  | 1,86  | 1,57   | 0,30   | 1,07  | 2,14      |

|                  | Percent | Cumulative Percent |
|------------------|---------|--------------------|
| brez zalog       | 29,2    | 29,2               |
| do 30 dni        | 24,7    | 53,9               |
| od 30 do 90 dni  | 20,9    | 74,8               |
| od 90 do 180 dni | 11,2    | 86,0               |
| nad 180 dni      | 14,0    | 100,0              |
| Total            | 100,0   |                    |

|                   | Percent | Cumulative Percent |
|-------------------|---------|--------------------|
| do 60 dni         | 19,3    | 19,3               |
| od 60 do 90 dni   | 19,0    | 38,3               |
| od 90 do 120 dni  | 15,2    | 53,5               |
| od 120 do 180 dni | 18,0    | 71,5               |
| nad 180           | 28,5    | 100,0              |
| Total             | 100,0   |                    |
















## Denarni tok:

|                               |           | FCF_OBV | KPO_EBIT | EBIT_PO | OCF_PRI | OCF_PO |
|-------------------------------|-----------|---------|----------|---------|---------|--------|
| <b>Mean</b>                   |           | 0,07    | 3,73     | 0,11    | 0,07    | 0,36   |
| <b>Median</b>                 |           | 0,06    | 3,05     | 0,09    | 0,06    | 0,30   |
| <b>Mode</b>                   |           | 0,50    | 15,00    | 0,50    | -1,00   | 1,00   |
| <b>Std. Deviation</b>         |           | 0,25    | 8,14     | 0,28    | 0,15    | 0,44   |
| <b>Skewness</b>               |           | -0,25   | -0,45    | -0,46   | -1,80   | -0,41  |
| <b>Std. Error of Skewness</b> |           | 0,04    | 0,04     | 0,04    | 0,04    | 0,04   |
| <b>Kurtosis</b>               |           | 0,08    | -0,07    | -0,15   | 18,48   | 0,50   |
| <b>Std. Error of Kurtosis</b> |           | 0,09    | 0,09     | 0,09    | 0,09    | 0,09   |
| <b>Minimum</b>                |           | -0,50   | -15,00   | -0,50   | -1,00   | -1,00  |
| <b>Maximum</b>                |           | 0,50    | 15,00    | 0,50    | 1,00    | 1,00   |
| <b>Percentiles</b>            | <b>25</b> | -0,04   | 0,12     | 0,00    | 0,02    | 0,10   |
|                               | <b>50</b> | 0,06    | 3,05     | 0,09    | 0,06    | 0,30   |
|                               | <b>75</b> | 0,20    | 10,22    | 0,30    | 0,12    | 0,70   |

|                               |           | OCF_PRO | OCF_SRED | FCF_OCF | OCF_CII_CFI | OCF_EBIT | OCF_FO |
|-------------------------------|-----------|---------|----------|---------|-------------|----------|--------|
| <b>Mean</b>                   |           | 0,08    | 0,08     | 0,46    | 0,39        | 1,70     | 0,59   |
| <b>Median</b>                 |           | 0,06    | 0,08     | 0,76    | 0,69        | 1,46     | 0,44   |
| <b>Mode</b>                   |           | -1,00   | -1,00    | 1,00    | 1,00        | 5,00     | 1,50   |
| <b>Std. Deviation</b>         |           | 0,17    | 0,16     | 0,93    | 0,81        | 2,20     | 0,78   |
| <b>Skewness</b>               |           | -0,91   | -1,84    | -1,22   | -1,68       | -0,80    | -0,57  |
| <b>Std. Error of Skewness</b> |           | 0,04    | 0,04     | 0,04    | 0,04        | 0,04     | 0,04   |
| <b>Kurtosis</b>               |           | 16,08   | 15,14    | 1,31    | 2,17        | 1,65     | 0,21   |
| <b>Std. Error of Kurtosis</b> |           | 0,09    | 0,09     | 0,09    | 0,09        | 0,09     | 0,09   |
| <b>Minimum</b>                |           | -1,00   | -1,00    | -2,00   | -2,00       | -5,00    | -1,50  |
| <b>Maximum</b>                |           | 1,00    | 0,94     | 2,00    | 2,00        | 5,00     | 1,50   |
| <b>Percentiles</b>            | <b>25</b> | 0,02    | 0,03     | 0,18    | 0,13        | 0,89     | 0,11   |
|                               | <b>50</b> | 0,06    | 0,08     | 0,76    | 0,69        | 1,46     | 0,44   |
|                               | <b>75</b> | 0,13    | 0,14     | 1,00    | 1,00        | 2,99     | 1,50   |

















### Uspešnost:

|                               | PRO_SNMSD_KFOFO | PO_AMOR_PROD | PRO_SNM_SS_SD | PRO_SNM_KPO | SS_SNMSD |
|-------------------------------|-----------------|--------------|---------------|-------------|----------|
| <b>Mean</b>                   | 0,30            | 0,95         | 1,21          | 4,17        | 0,35     |
| <b>Median</b>                 | 0,24            | 0,94         | 1,14          | 3,39        | 0,30     |
| <b>Mode</b>                   | 1,00            | 2,00         | 3,00          | 10,00       | 1,00     |
| <b>Std. Deviation</b>         | 0,42            | 0,18         | 0,43          | 2,98        | 0,23     |
| <b>Skewness</b>               | -0,19           | 2,50         | 1,32          | 0,66        | 1,02     |
| <b>Std. Error of Skewness</b> | 0,04            | 0,04         | 0,04          | 0,04        | 0,04     |
| <b>Kurtosis</b>               | 0,64            | 14,54        | 11,63         | -0,70       | 0,52     |
| <b>Std. Error of Kurtosis</b> | 0,09            | 0,09         | 0,09          | 0,09        | 0,09     |
| <b>Minimum</b>                | -1,00           | 0,11         | -3,00         | -2,00       | 0,00     |
| <b>Maximum</b>                | 1,00            | 2,00         | 3,00          | 10,00       | 1,00     |
| <b>Percentiles</b> 25         | 0,06            | 0,88         | 1,04          | 1,76        | 0,18     |
| 50                            | 0,24            | 0,94         | 1,14          | 3,39        | 0,30     |
| 75                            | 0,54            | 0,99         | 1,29          | 6,19        | 0,46     |

|                               | ROA   | BM    | EBIT_PRO | EBIT_SRED | KI_PRI | RPROD |
|-------------------------------|-------|-------|----------|-----------|--------|-------|
| <b>Mean</b>                   | 0,01  | 0,65  | 0,01     | 0,03      | 0,01   | 0,06  |
| <b>Median</b>                 | 0,01  | 0,64  | 0,02     | 0,03      | 0,01   | -0,01 |
| <b>Mode</b>                   | -1,00 | 1,00  | -1,00    | -1,00     | -1,00  | 1,00  |
| <b>Std. Deviation</b>         | 0,11  | 0,25  | 0,16     | 0,16      | 0,14   | 0,33  |
| <b>Skewness</b>               | -2,89 | -0,63 | -2,67    | -1,86     | -3,63  | 1,18  |
| <b>Std. Error of Skewness</b> | 0,04  | 0,04  | 0,04     | 0,04      | 0,04   | 0,04  |
| <b>Kurtosis</b>               | 29,43 | 1,50  | 18,57    | 15,45     | 25,45  | 2,32  |
| <b>Std. Error of Kurtosis</b> | 0,09  | 0,09  | 0,09     | 0,09      | 0,09   | 0,09  |
| <b>Minimum</b>                | -1,00 | -1,00 | -1,00    | -1,00     | -1,00  | -1,00 |
| <b>Maximum</b>                | 0,86  | 1,00  | 1,00     | 1,00      | 0,81   | 1,00  |
| <b>Percentiles</b> 25         | 0,00  | 0,49  | 0,00     | 0,00      | 0,00   | -0,11 |
| 50                            | 0,01  | 0,64  | 0,02     | 0,03      | 0,01   | -0,01 |
| 75                            | 0,04  | 0,88  | 0,06     | 0,07      | 0,04   | 0,13  |





## Priloga 4: Analiza glavne komponente

| Total Variance Explained |                     |               |              |                                     |               |              |                                   |               |              |
|--------------------------|---------------------|---------------|--------------|-------------------------------------|---------------|--------------|-----------------------------------|---------------|--------------|
| Component                | Initial Eigenvalues |               |              | Extraction Sums of Squared Loadings |               |              | Rotation Sums of Squared Loadings |               |              |
|                          | Total               | % of Variance | Cumulative % | Total                               | % of Variance | Cumulative % | Total                             | % of Variance | Cumulative % |
| 1                        | 9,543               | 21,689        | 21,689       | 9,543                               | 21,689        | 21,689       | 5,511                             | 12,525        | 12,525       |
| 2                        | 6,012               | 13,665        | 35,354       | 6,012                               | 13,665        | 35,354       | 5,300                             | 12,045        | 24,570       |
| 3                        | 3,771               | 8,571         | 43,925       | 3,771                               | 8,571         | 43,925       | 4,233                             | 9,621         | 34,191       |
| 4                        | 2,898               | 6,587         | 50,512       | 2,898                               | 6,587         | 50,512       | 4,000                             | 9,092         | 43,283       |
| 5                        | 2,461               | 5,593         | 56,105       | 2,461                               | 5,593         | 56,105       | 3,004                             | 6,826         | 50,109       |
| 6                        | 2,122               | 4,823         | 60,928       | 2,122                               | 4,823         | 60,928       | 2,550                             | 5,795         | 55,904       |
| 7                        | 1,754               | 3,987         | 64,915       | 1,754                               | 3,987         | 64,915       | 2,266                             | 5,151         | 61,054       |
| 8                        | 1,568               | 3,563         | 68,478       | 1,568                               | 3,563         | 68,478       | 2,060                             | 4,682         | 65,736       |
| 9                        | 1,292               | 2,936         | 71,414       | 1,292                               | 2,936         | 71,414       | 1,864                             | 4,236         | 69,973       |
| 10                       | 1,225               | 2,785         | 74,199       | 1,225                               | 2,785         | 74,199       | 1,860                             | 4,226         | 74,199       |
| 11                       | ,983                | 2,234         | 76,433       |                                     |               |              |                                   |               |              |
| 12                       | ,908                | 2,064         | 78,498       |                                     |               |              |                                   |               |              |
| 13                       | ,853                | 1,938         | 80,436       |                                     |               |              |                                   |               |              |
| 14                       | ,830                | 1,887         | 82,323       |                                     |               |              |                                   |               |              |
| 15                       | ,738                | 1,677         | 84,000       |                                     |               |              |                                   |               |              |
| 16                       | ,704                | 1,600         | 85,600       |                                     |               |              |                                   |               |              |
| 17                       | ,681                | 1,548         | 87,148       |                                     |               |              |                                   |               |              |
| 18                       | ,634                | 1,441         | 88,589       |                                     |               |              |                                   |               |              |
| 19                       | ,548                | 1,246         | 89,835       |                                     |               |              |                                   |               |              |
| 20                       | ,508                | 1,154         | 90,988       |                                     |               |              |                                   |               |              |
| 21                       | ,457                | 1,038         | 92,026       |                                     |               |              |                                   |               |              |
| 22                       | ,372                | ,846          | 92,872       |                                     |               |              |                                   |               |              |
| 23                       | ,353                | ,802          | 93,674       |                                     |               |              |                                   |               |              |
| 24                       | ,324                | ,736          | 94,410       |                                     |               |              |                                   |               |              |
| 25                       | ,276                | ,626          | 95,037       |                                     |               |              |                                   |               |              |
| 26                       | ,264                | ,599          | 95,636       |                                     |               |              |                                   |               |              |
| 27                       | ,234                | ,532          | 96,167       |                                     |               |              |                                   |               |              |
| 28                       | ,224                | ,509          | 96,676       |                                     |               |              |                                   |               |              |
| 29                       | ,201                | ,456          | 97,132       |                                     |               |              |                                   |               |              |
| 30                       | ,184                | ,417          | 97,549       |                                     |               |              |                                   |               |              |
| 31                       | ,171                | ,388          | 97,937       |                                     |               |              |                                   |               |              |
| 32                       | ,157                | ,358          | 98,295       |                                     |               |              |                                   |               |              |
| 33                       | ,131                | ,297          | 98,592       |                                     |               |              |                                   |               |              |
| 34                       | ,126                | ,286          | 98,878       |                                     |               |              |                                   |               |              |
| 35                       | ,105                | ,238          | 99,116       |                                     |               |              |                                   |               |              |
| 36                       | ,091                | ,208          | 99,324       |                                     |               |              |                                   |               |              |
| 37                       | ,088                | ,200          | 99,524       |                                     |               |              |                                   |               |              |
| 38                       | ,055                | ,125          | 99,649       |                                     |               |              |                                   |               |              |
| 39                       | ,052                | ,118          | 99,767       |                                     |               |              |                                   |               |              |

| Total Variance Explained |               |              |                                     |               |              |                                   |               |              |
|--------------------------|---------------|--------------|-------------------------------------|---------------|--------------|-----------------------------------|---------------|--------------|
| Initial Eigenvalues      |               |              | Extraction Sums of Squared Loadings |               |              | Rotation Sums of Squared Loadings |               |              |
| Total                    | % of Variance | Cumulative % | Total                               | % of Variance | Cumulative % | Total                             | % of Variance | Cumulative % |
| 40                       | ,037          | ,084         | 99,851                              |               |              |                                   |               |              |
| 41                       | 0,031         | 0,072        | 99,922                              |               |              |                                   |               |              |
| 42                       | 0,025         | 0,056        | 99,979                              |               |              |                                   |               |              |
| 43                       | 0,009         | 0,021        | 100                                 |               |              |                                   |               |              |
| 44                       | 0             | 0            | 100                                 |               |              |                                   |               |              |

| Component Matrixa            |           |       |       |       |       |       |       |       |       |       |
|------------------------------|-----------|-------|-------|-------|-------|-------|-------|-------|-------|-------|
|                              | Component |       |       |       |       |       |       |       |       |       |
|                              | 1         | 2     | 3     | 4     | 5     | 6     | 7     | 8     | 9     | 10    |
| Zscore(KAP_SRED)             | ,604      | ,417  | -,145 | ,207  | -,213 | -,355 | -,033 | ,039  | ,036  | -,236 |
| Zscore(FO_SRED)              | -,389     | -,434 | ,640  | ,044  | ,029  | ,288  | -,084 | ,129  | ,136  | ,154  |
| Zscore(FO_KAP)               | ,004      | -,250 | ,380  | ,081  | ,100  | -,053 | ,143  | ,002  | ,221  | -,445 |
| Zscore(DVT)                  | -,260     | ,088  | ,389  | -,257 | ,283  | ,495  | ,156  | -,109 | ,098  | -,057 |
| Zscore(FO_EBITDA)            | ,005      | -,421 | ,610  | ,009  | ,131  | -,114 | ,116  | -,058 | ,102  | -,378 |
| Zscore(FO_FCF)               | ,115      | -,230 | ,492  | -,364 | -,072 | -,105 | ,128  | ,085  | ,106  | -,258 |
| Zscore(KAP_DOE_OP_SRED_NN_Z) | ,369      | ,462  | -,127 | ,024  | -,166 | ,158  | ,275  | -,135 | ,236  | -,297 |
| Zscore(OBV_KSRED)            | -,377     | -,711 | ,243  | ,087  | -,195 | ,044  | -,035 | ,059  | ,061  | ,061  |
| Zscore(NW)                   | ,404      | ,417  | -,624 | -,041 | -,019 | -,302 | ,075  | -,125 | -,121 | -,199 |
| Zscore(WC_SRED)              | ,384      | ,561  | ,490  | ,080  | ,294  | -,048 | -,040 | ,019  | ,013  | -,059 |
| Zscore(Z_T_SRED)             | -,020     | ,528  | ,080  | -,294 | ,597  | ,157  | ,083  | -,133 | -,152 | ,101  |
| Zscore(OOS)                  | -,018     | ,360  | -,311 | -,344 | ,415  | ,494  | ,138  | -,009 | -,049 | -,176 |
| Zscore(PRO_SRED)             | -,093     | ,005  | -,455 | -,256 | ,379  | ,395  | -,158 | ,296  | -,157 | -,066 |
| Zscore(WC_PRO)               | ,124      | ,365  | ,411  | ,079  | ,099  | ,016  | ,142  | -,149 | -,188 | ,271  |
| Zscore(KK)                   | ,473      | ,684  | ,044  | ,181  | -,108 | ,009  | -,084 | ,102  | ,020  | -,075 |
| Zscore(PK)                   | ,511      | ,613  | -,083 | ,218  | -,210 | ,069  | ,011  | ,077  | ,079  | -,075 |
| Zscore(KT_KPO)               | ,466      | ,566  | ,372  | ,269  | -,005 | ,088  | ,009  | ,081  | -,031 | ,061  |
| Zscore(KT_PRO)               | -,080     | ,348  | ,203  | ,109  | -,104 | -,046 | ,418  | -,474 | ,160  | ,345  |
| Zscore(FCF_OBV)              | ,650      | ,055  | ,028  | -,540 | -,211 | ,010  | -,120 | ,117  | ,169  | ,209  |
| Zscore(KPO_EBIT)             | ,126      | -,101 | -,045 | -,178 | ,337  | -,361 | ,659  | ,389  | -,049 | ,040  |
| Zscore(WC_PO)                | ,363      | ,611  | ,541  | ,177  | ,156  | ,008  | -,132 | ,104  | -,091 | ,060  |
| Zscore(KPT_Z_KPO)            | ,386      | ,617  | ,536  | ,175  | ,173  | -,008 | -,129 | ,102  | -,097 | ,050  |
| Zscore(EBIT_PO)              | ,771      | -,287 | ,035  | -,076 | ,096  | ,062  | -,008 | ,112  | ,152  | ,075  |
| Zscore(OCF_PRI)              | ,729      | -,453 | ,146  | -,005 | -,018 | -,029 | ,023  | -,192 | -,267 | ,004  |
| Zscore(OCF_PO)               | ,789      | -,320 | ,175  | ,078  | -,075 | ,006  | -,136 | ,158  | ,097  | ,112  |
| Zscore(OCF_PRO)              | ,631      | -,402 | ,188  | ,007  | -,075 | -,028 | ,098  | -,263 | -,349 | ,138  |
| Zscore(OCF_SRED)             | ,759      | -,282 | -,087 | -,054 | ,191  | -,014 | -,072 | -,079 | ,343  | ,148  |
| Zscore(OCF_CII_CFI)          | ,161      | -,015 | ,084  | -,170 | -,087 | ,040  | -,044 | ,241  | ,002  | ,128  |
| Zscore(FCF_OCF)              | -,028     | ,248  | ,110  | -,591 | -,352 | ,104  | -,057 | ,126  | ,080  | ,162  |
| Zscore(OCF_EBIT)             | ,150      | -,168 | ,034  | -,066 | ,172  | -,357 | ,574  | ,545  | -,054 | ,132  |
| Zscore(OCF_FO)               | ,640      | ,019  | -,406 | -,063 | ,101  | -,083 | ,028  | ,025  | ,081  | ,287  |

| Component Matrixa       |           |        |        |        |        |        |        |        |        |        |
|-------------------------|-----------|--------|--------|--------|--------|--------|--------|--------|--------|--------|
|                         | Component |        |        |        |        |        |        |        |        |        |
|                         | 1         | 2      | 3      | 4      | 5      | 6      | 7      | 8      | 9      | 10     |
| Zscore(PRO_SNMSD_KFOFO) | 0,736     | -0,201 | -0,036 | 0,064  | -0,15  | 0,138  | -0,114 | 0,211  | 0,007  | 0,087  |
| Zscore(PO_AMOR_PROD)    | -0,667    | 0,414  | -0,072 | 0,034  | 0,002  | -0,033 | 0,064  | 0,044  | 0,309  | 0,117  |
| Zscore(PRO_SNM_SS_SD)   | 0,52      | -0,355 | 0,108  | 0,037  | -0,143 | 0,143  | 0,044  | -0,048 | -0,266 | -0,058 |
| Zscore(PRO_SNM_KPO)     | 0,457     | 0,103  | 0,011  | 0,238  | -0,287 | 0,427  | -0,072 | 0,475  | -0,036 | -0,145 |
| Zscore(SS_SNMSD)        | 0,089     | -0,034 | -0,138 | 0,185  | -0,304 | 0,539  | 0,498  | -0,037 | 0,047  | 0,043  |
| Zscore(ROA)             | 0,732     | -0,141 | -0,125 | -0,063 | 0,231  | -0,006 | -0,025 | -0,201 | 0,39   | -0,026 |
| Zscore(BM)              | 0,284     | -0,058 | -0,111 | 0,215  | -0,472 | 0,435  | 0,45   | -0,069 | -0,049 | 0      |
| Zscore(EBIT_PRO)        | 0,73      | -0,359 | 0,025  | -0,145 | 0,134  | 0,053  | 0,014  | -0,151 | -0,309 | -0,086 |
| Zscore(EBIT_SRED)       | 0,786     | -0,211 | -0,084 | -0,108 | 0,224  | 0,008  | -0,027 | -0,155 | 0,376  | 0,048  |
| Zscore(KI_PRI)          | 0,688     | -0,249 | -0,064 | -0,108 | 0,173  | 0,059  | 0,005  | -0,168 | -0,141 | -0,155 |
| Zscore(RPROD)           | 0,099     | -0,208 | -0,215 | 0,019  | 0,303  | 0,284  | -0,07  | 0,068  | 0,042  | 0,001  |
| Zscore(CAPEX_SRED)      | -0,04     | -0,296 | -0,189 | 0,778  | 0,373  | 0,067  | 0,004  | 0,057  | 0,064  | 0,078  |

| Rotated Component Matrixa – Varimax |           |       |       |       |       |       |       |       |       |       |
|-------------------------------------|-----------|-------|-------|-------|-------|-------|-------|-------|-------|-------|
|                                     | Component |       |       |       |       |       |       |       |       |       |
|                                     | 1         | 2     | 3     | 4     | 5     | 6     | 7     | 8     | 9     | 10    |
| Zscore(KAP_SRED)                    | ,128      | ,393  | ,194  | ,713  | ,021  | -,308 | ,039  | ,018  | ,139  | ,014  |
| Zscore(FO_SRED)                     | -,077     | -,016 | -,084 | -,892 | -,026 | -,086 | ,009  | ,279  | ,046  | -,064 |
| Zscore(FO_KAP)                      | ,041      | ,004  | ,042  | -,116 | -,113 | -,060 | ,007  | ,676  | ,026  | ,051  |
| Zscore(DVT)                         | -,147     | ,146  | -,073 | -,432 | ,147  | ,521  | ,133  | ,281  | -,187 | -,088 |
| Zscore(FO_EBITDA)                   | ,226      | ,011  | -,011 | -,321 | -,058 | -,122 | -,119 | ,744  | -,058 | ,077  |
| Zscore(FO_FCF)                      | ,181      | ,014  | ,060  | -,199 | ,385  | -,078 | -,065 | ,543  | ,023  | ,166  |
| Zscore(KAP_DOV_OP_SRED_NN_Z)        | -,076     | ,270  | ,192  | ,521  | ,126  | ,117  | ,446  | ,172  | -,065 | -,086 |
| Zscore(OBV_KSRED)                   | ,055      | -,465 | -,118 | -,611 | -,105 | -,317 | ,024  | ,203  | ,074  | -,023 |
| Zscore(NW)                          | ,087      | ,016  | ,095  | ,902  | ,017  | ,081  | -,025 | -,231 | -,028 | ,060  |
| Zscore(WC_SRED)                     | ,035      | ,838  | ,115  | ,102  | ,042  | ,115  | -,137 | ,185  | -,075 | ,029  |
| Zscore(Z_T_SRED)                    | -,100     | ,412  | -,043 | ,047  | ,092  | ,678  | -,221 | -,111 | -,302 | ,088  |
| Zscore(OOS)                         | -,128     | ,037  | ,012  | ,194  | ,094  | ,853  | ,129  | -,067 | ,020  | -,015 |
| Zscore(PRO_SRED)                    | -,054     | -,215 | -,001 | ,020  | -,041 | ,665  | -,084 | -,260 | ,392  | ,034  |
| Zscore(WC_PRO)                      | ,094      | ,566  | -,109 | -,121 | ,054  | ,016  | ,031  | -,095 | -,337 | ,062  |
| Zscore(KK)                          | -,041     | ,685  | ,117  | ,452  | ,088  | -,043 | ,146  | -,103 | ,147  | -,093 |
| Zscore(PK)                          | -,030     | ,565  | ,177  | ,504  | ,063  | -,075 | ,313  | -,128 | ,145  | -,092 |
| Zscore(KT_KPO)                      | ,073      | ,837  | ,092  | ,128  | ,009  | -,061 | ,174  | -,019 | ,028  | -,019 |
| Zscore(KT_PRO)                      | -,190     | ,261  | ,001  | -,009 | ,045  | -,128 | ,284  | -,072 | -,728 | ,001  |
| Zscore(FCF_OBV)                     | ,285      | ,140  | ,554  | ,092  | ,633  | -,031 | ,015  | -,149 | ,139  | ,056  |
| Zscore(KPO_EBIT)                    | ,051      | -,052 | ,067  | ,106  | -,013 | ,113  | -,035 | ,122  | -,085 | ,915  |
| Zscore(WC_PO)                       | ,040      | ,938  | ,015  | ,015  | ,054  | ,003  | -,085 | ,033  | ,020  | -,025 |
| Zscore(KPT_Z_KPO)                   | ,055      | ,948  | ,024  | ,038  | ,048  | ,010  | -,098 | ,038  | ,018  | -,014 |
| Zscore(EBIT_PO)                     | ,505      | ,108  | ,638  | ,008  | ,033  | -,017 | ,073  | ,044  | ,187  | ,146  |
| Zscore(OCF_PRI)                     | ,872      | ,030  | ,281  | ,006  | -,019 | -,135 | ,033  | ,080  | -,019 | ,035  |

| Rotated Component Matrixa – Varimax |           |        |        |        |        |        |        |        |        |        |
|-------------------------------------|-----------|--------|--------|--------|--------|--------|--------|--------|--------|--------|
|                                     | Component |        |        |        |        |        |        |        |        |        |
|                                     | 1         | 2      | 3      | 4      | 5      | 6      | 7      | 8      | 9      | 10     |
| Zscore(OCF_PO)                      | 0,556     | 0,204  | 0,566  | -0,071 | 0,011  | -0,265 | 0,067  | 0,028  | 0,276  | 0,064  |
| Zscore(OCF_PRO)                     | 0,85      | 0,054  | 0,166  | -0,058 | 0,008  | -0,172 | 0,081  | -0,02  | -0,159 | 0,05   |
| Zscore(OCF_SRED)                    | 0,402     | 0,03   | 0,825  | 0,074  | -0,055 | -0,018 | -0,018 | 0,004  | 0,019  | 0,041  |
| Zscore(OCF_CII_CFI)                 | 0,071     | 0,083  | 0,117  | -0,108 | 0,228  | -0,033 | 0,014  | -0,087 | 0,185  | 0,123  |
| Zscore(FCF_OCF)                     | -0,154    | 0,043  | 0,022  | -0,077 | 0,743  | 0,032  | 0,063  | -0,133 | 0,048  | -0,027 |
| Zscore(OCF_EBIT)                    | 0,065     | -0,005 | 0,061  | -0,014 | -0,013 | -0,091 | 0,018  | 0,054  | 0,074  | 0,914  |
| Zscore(OCF_FO)                      | 0,278     | 0,034  | 0,562  | 0,331  | -0,007 | 0,035  | 0,032  | -0,382 | 0,02   | 0,184  |
| Zscore(PRO_SNMSD_KFOFO)             | 0,495     | 0,151  | 0,459  | 0,054  | 0,035  | -0,148 | 0,198  | -0,122 | 0,366  | 0,032  |
| Zscore(PO_AMOR_PROD)                | -0,808    | -0,007 | -0,204 | -0,046 | 0,009  | 0,041  | -0,004 | -0,085 | -0,18  | -0,019 |
| Zscore(PRO_SNM_SS_SD)               | 0,67      | 0,011  | 0,106  | -0,037 | 0,004  | -0,09  | 0,199  | 0,059  | 0,126  | -0,006 |
| Zscore(PRO_SNM_KPO)                 | 0,173     | 0,328  | 0,111  | 0,055  | 0,005  | -0,037 | 0,473  | -0,047 | 0,643  | -0,042 |
| Zscore(SS_SNMSD)                    | 0,05      | -0,075 | 0,001  | -0,038 | -0,062 | 0,093  | 0,819  | -0,058 | -0,049 | 0,024  |
| Zscore(ROA)                         | 0,326     | 0,057  | 0,79   | 0,239  | -0,062 | 0,084  | 0,005  | 0,126  | -0,061 | -0,037 |
| Zscore(BM)                          | 0,246     | -0,027 | 0,001  | 0,079  | -0,001 | -0,088 | 0,828  | -0,056 | -0,007 | -0,014 |
| Zscore(EBIT_PRO)                    | 0,848     | 0,017  | 0,278  | 0,103  | 0,022  | 0,121  | -0,017 | 0,065  | 0,042  | 0,056  |
| Zscore(EBIT_SRED)                   | 0,393     | 0,055  | 0,838  | 0,157  | -0,018 | 0,067  | 0,003  | 0,094  | -0,037 | 0,01   |
| Zscore(KI_PRI)                      | 0,667     | 0,019  | 0,356  | 0,207  | -0,026 | 0,165  | 0      | 0,106  | 0,038  | 0,002  |
| Zscore(RPROD)                       | 0,1       | -0,146 | 0,22   | -0,093 | -0,229 | 0,329  | 0,018  | -0,069 | 0,169  | -0,019 |
| Zscore(CAPEX_SRED)                  | -0,014    | -0,043 | 0,108  | -0,127 | -0,915 | -0,056 | 0,055  | -0,075 | 0,086  | 0,042  |

## Priloga 5: Naive Bayesian klasifikator

### Predelovalna dejavnost:

| Attribute       | Parameters                        | pred.<br>range1 [-<br>$\infty$ - 2.850] | pred.<br>range2 [2.850 -<br>5.050] | pred.<br>range3 [5.050 -<br>8.350] | pred.<br>range4 [8.350 -<br>$\infty$ ] |
|-----------------|-----------------------------------|-----------------------------------------|------------------------------------|------------------------------------|----------------------------------------|
| OOS             | value=range1 [- $\infty$ - 2,850] | 0,434                                   | 0,623                              | 0,533                              | 0,455                                  |
| OOS             | value=range2 [2,850 - $\infty$ ]  | 0,566                                   | 0,377                              | 0,467                              | 0,545                                  |
| OOS             | value=unknown                     | 0,000                                   | 0,000                              | 0,000                              | 0,000                                  |
| PRO_SNMSD_KFOFO | value=range1 [- $\infty$ - 0,325] | 0,513                                   | 0,519                              | 0,413                              | 0,481                                  |
| PRO_SNMSD_KFOFO | value=range2 [0,325 - $\infty$ ]  | 0,487                                   | 0,481                              | 0,587                              | 0,519                                  |
| PRO_SNMSD_KFOFO | value=unknown                     | 0,000                                   | 0,000                              | 0,000                              | 0,000                                  |
| KAP_SRED        | value=range1 [- $\infty$ - 0,295] | 0,368                                   | 0,312                              | 0,267                              | 0,312                                  |
| KAP_SRED        | value=range2 [0,295 - 0,595]      | 0,382                                   | 0,351                              | 0,267                              | 0,312                                  |
| KAP_SRED        | value=range3 [0,595 - $\infty$ ]  | 0,250                                   | 0,338                              | 0,467                              | 0,377                                  |
| KAP_SRED        | value=unknown                     | 0,000                                   | 0,000                              | 0,000                              | 0,000                                  |
| Z_T_SRED        | value=range1 [- $\infty$ - 0,205] | 0,184                                   | 0,260                              | 0,240                              | 0,351                                  |
| Z_T_SRED        | value=range2 [0,205 - 0,355]      | 0,237                                   | 0,260                              | 0,320                              | 0,273                                  |
| Z_T_SRED        | value=range3 [0,355 - 0,555]      | 0,263                                   | 0,260                              | 0,307                              | 0,143                                  |
| Z_T_SRED        | value=range4 [0,555 - $\infty$ ]  | 0,316                                   | 0,221                              | 0,133                              | 0,234                                  |
| Z_T_SRED        | value=unknown                     | 0,000                                   | 0,000                              | 0,000                              | 0,000                                  |
| DOZ             | mean                              | 3,237                                   | 3,169                              | 2,720                              | 2,558                                  |
| DOZ             | standard deviation                | 1,242                                   | 1,371                              | 1,214                              | 1,343                                  |

accuracy: 45.04%

|                                | true range1 [- $\infty$ - 2.... | true range2 [2.850 ... | true range3 [5.050 ... | true range4 [8.350 ... | class precision |
|--------------------------------|---------------------------------|------------------------|------------------------|------------------------|-----------------|
| pred. range1 [- $\infty$ - ... | 18                              | 4                      | 9                      | 6                      | 48.65%          |
| pred. range2 [2.85...          | 8                               | 16                     | 3                      | 5                      | 50.00%          |
| pred. range3 [5.05...          | 4                               | 7                      | 13                     | 9                      | 39.39%          |
| pred. range4 [8.35...          | 5                               | 6                      | 6                      | 12                     | 41.38%          |
| class recall                   | 51.43%                          | 48.48%                 | 41.94%                 | 37.50%                 |                 |

**Gostinstvo:**

| Attribute     | Parameters                         | pred.<br>range1 [- $\infty$<br>- 4.050] | pred.<br>range2<br>[4.050 -<br>8.950] | pred.<br>range3<br>[8.950 - $\infty$ ] |
|---------------|------------------------------------|-----------------------------------------|---------------------------------------|----------------------------------------|
| RPROD         | value=range1 [- $\infty$ - -0,035] | 0,352                                   | 0,410                                 | 0,344                                  |
| RPROD         | value=range2 [-0,035 - 0,075]      | 0,275                                   | 0,325                                 | 0,376                                  |
| RPROD         | value=range3 [0,075 - $\infty$ ]   | 0,374                                   | 0,265                                 | 0,280                                  |
| RPROD         | value=unknown                      | 0,000                                   | 0,000                                 | 0,000                                  |
| FO_EBITDA     | value=range1 [- $\infty$ - 1,825]  | 0,396                                   | 0,506                                 | 0,581                                  |
| FO_EBITDA     | value=range2 [1,825 - $\infty$ ]   | 0,604                                   | 0,494                                 | 0,419                                  |
| FO_EBITDA     | value=unknown                      | 0,000                                   | 0,000                                 | 0,000                                  |
| NW            | value=range1 [- $\infty$ - 0,655]  | 0,462                                   | 0,542                                 | 0,484                                  |
| NW            | value=range2 [0,655 - $\infty$ ]   | 0,538                                   | 0,458                                 | 0,516                                  |
| NW            | value=unknown                      | 0,000                                   | 0,000                                 | 0,000                                  |
| DOZ           | value=range1 [- $\infty$ - 2,500]  | 0,747                                   | 0,639                                 | 0,548                                  |
| DOZ           | value=range2 [2,500 - $\infty$ ]   | 0,253                                   | 0,361                                 | 0,452                                  |
| DOZ           | value=unknown                      | 0,000                                   | 0,000                                 | 0,000                                  |
| EBIT_PO       | value=range1 [- $\infty$ - 0,085]  | 0,451                                   | 0,482                                 | 0,591                                  |
| EBIT_PO       | value=range2 [0,085 - $\infty$ ]   | 0,549                                   | 0,518                                 | 0,409                                  |
| EBIT_PO       | value=unknown                      | 0,000                                   | 0,000                                 | 0,000                                  |
| BM            | value=range1 [- $\infty$ - 0,585]  | 0,560                                   | 0,494                                 | 0,527                                  |
| BM            | value=range2 [0,585 - $\infty$ ]   | 0,440                                   | 0,506                                 | 0,473                                  |
| BM            | value=unknown                      | 0,000                                   | 0,000                                 | 0,000                                  |
| FN_NN_OP_SRED | value=range2 [0,500 - 0]           | 0,297                                   | 0,301                                 | 0,215                                  |
| FN_NN_OP_SRED | value=range1 [- $\infty$ - 0,500]  | 0,000                                   | 0,000                                 | 0,000                                  |
| FN_NN_OP_SRED | value=range4 [0 - $\infty$ ]       | 0,703                                   | 0,699                                 | 0,785                                  |
| FN_NN_OP_SRED | value=unknown                      | 0,000                                   | 0,000                                 | 0,000                                  |
| PRO_SRED      | value=range1 [- $\infty$ - 0,765]  | 0,319                                   | 0,205                                 | 0,129                                  |
| PRO_SRED      | value=range2 [0,765 - 1,865]       | 0,264                                   | 0,289                                 | 0,269                                  |
| PRO_SRED      | value=range3 [1,865 - 3,810]       | 0,176                                   | 0,289                                 | 0,280                                  |
| PRO_SRED      | value=range4 [3,810 - $\infty$ ]   | 0,242                                   | 0,217                                 | 0,323                                  |
| PRO_SRED      | value=unknown                      | 0,000                                   | 0,000                                 | 0,000                                  |
| EBIT_SRED     | value=range1 [- $\infty$ - -0,005] | 0,198                                   | 0,265                                 | 0,290                                  |
| EBIT_SRED     | value=range2 [-0,005 - 0,025]      | 0,264                                   | 0,277                                 | 0,247                                  |
| EBIT_SRED     | value=range3 [0,025 - 0,075]       | 0,341                                   | 0,193                                 | 0,247                                  |
| EBIT_SRED     | value=range4 [0,075 - $\infty$ ]   | 0,198                                   | 0,265                                 | 0,215                                  |
| EBIT_SRED     | value=unknown                      | 0,000                                   | 0,000                                 | 0,000                                  |
| CAPEX_SRED    | value=range1 [- $\infty$ - 0,005]  | 0,286                                   | 0,205                                 | 0,301                                  |
| CAPEX_SRED    | value=range2 [0,005 - 0,035]       | 0,286                                   | 0,337                                 | 0,247                                  |
| CAPEX_SRED    | value=range3 [0,035 - 0,115]       | 0,220                                   | 0,205                                 | 0,194                                  |
| CAPEX_SRED    | value=range4 [0,115 - $\infty$ ]   | 0,209                                   | 0,253                                 | 0,258                                  |

| Attribute       | Parameters         | pred.<br>range1 $[-\infty - 4.050]$ | pred.<br>range2<br>[4.050 - 8.950] | pred.<br>range3<br>[8.950 - $\infty$ ] |
|-----------------|--------------------|-------------------------------------|------------------------------------|----------------------------------------|
| CAPEX_SRED      | value=unknown      | 0                                   | 0                                  | 0                                      |
| FO_KAP          | mean               | 1,016                               | 1,074                              | 0,634                                  |
| FO_KAP          | standard deviation | 2,422                               | 2,279                              | 2,325                                  |
| FO_OP_SRED_NN   | mean               | 1,033                               | 1,319                              | 1,444                                  |
| FO_OP_SRED_NN   | standard deviation | 1,406                               | 1,642                              | 1,631                                  |
| DVPO            | mean               | 2,857                               | 2,542                              | 2,204                                  |
| DVPO            | standard deviation | 1,472                               | 1,484                              | 1,471                                  |
| PRO_SNMSD_KFOFO | mean               | 0,272                               | 0,303                              | 0,201                                  |
| PRO_SNMSD_KFOFO | standard deviation | 0,348                               | 0,409                              | 0,442                                  |
| EBIT_PRO        | mean               | 0,013                               | -0,004                             | -0,014                                 |
| EBIT_PRO        | standard deviation | 0,091                               | 0,108                              | 0,109                                  |

accuracy: 53.04%

|                                  | true range1 $[-\infty - 4.050]$ | true range2 [4.050 - 8.9... | true range3 [8.950 - $\infty$ ] | class precision |
|----------------------------------|---------------------------------|-----------------------------|---------------------------------|-----------------|
| pred. range1 $[-\infty - 4.050]$ | 26                              | 21                          | 5                               | 50.00%          |
| pred. range2 [4.050 - 8....      | 2                               | 11                          | 6                               | 57.89%          |
| pred. range3 [8.950 - $\infty$ ] | 10                              | 10                          | 24                              | 54.55%          |
| class recall                     | 68.42%                          | 26.19%                      | 68.57%                          |                 |