

UNIVERZA V LJUBLJANI
EKONOMSKA FAKULTETA

MAGISTERSKO DELO

**KREDITNO TVEGANJE PRI NOVO IZDANIH
PLAČILNIH KARTICAH – PRIMER SLOVENSKEGA
IZDAJATELJA PLAČILNIH KARTIC**

Ljubljana, maj 2011

BOŠTJAN KRALJ

IZJAVA

Študent Boštjan Kralj izjavljam, da sem avtor tega magistrskega dela, ki sem ga napisal pod mentorstvom doc. dr. Aljošo Valentinčičem, in dovolim objavo diplomskega dela na fakultetnih spletnih straneh.

V Ljubljani, maj 2011

Podpis: _____

STVARNO KAZALO

UVOD	1
1 TEORIJA PLAČILNIH KARTIC IN TVEGANJA POVEZANA S PLAČILNIMI KARTICAMI	3
1.1 Nastanek plačilnih kartic	4
1.2 Motivi za izvedbo transakcij s plačilnimi karticami	6
1.2.1 Ravnotežni položaj kartičnega sistema	8
1.3 Tveganja plačilnih kartic	12
2 OBVLADOVANJE KREDITNEGA TVEGANJA	13
2.1 Finančna tveganja	14
2.2 Eksterno ocenjevanje kreditnega tveganja	17
2.2.1 Kreditni biroji v Evropi	18
2.3 Odpravljanje kreditnega tveganja	22
2.3.1 Zmanjševanje kreditne izpostavljenosti	24
2.3.2 Razpršitev (diverzifikacija) kreditne izpostavljenosti	26
2.4 Potrošniška posojila, njihov razvoj in kreditno tveganje	29
2.4.1 Potrošniška posojila v Združenih državah Amerike	29
2.4.2 Posojila fizičnim osebam v Evropski uniji	32
2.4.3 Posojila fizičnim osebam v Sloveniji	34
3 SISTEMI KREDITNEGA TOČKOVANJA	35
3.1 Kako delujejo sistemi kreditnega točkovanja	36
3.2 Razvoj sistemov kreditnega točkovanja	37
3.3 Vrste sistemov kreditnega točkovanja	38
3.4 Ocenjevanje profitabilnosti	40
4 NAPOVEDOVALNA STATISTIKA	41
4.1 Linearna regresija	42
4.2 Diskriminantna analiza	45
4.3 Logistična regresija	46
5 UPORABA LOGISTIČNE REGRESIJE ZA ZMANJŠANJE KREDITNEGA TVEGANJA PRI IZDAJI PLAČILNIH KARTIC	48
5.1 Pregled uporabe napovedovalnih statistik za zmanjševanje kreditnega tveganja	49
5.2 Opredelitev problema in načrt dela	50
5.3 Razvoj modela za obvladovanje kreditnega tveganja novo izdanih plačilnih kartic	51
5.3.1 FICO sistem točkovanja	52
5.4 Podatki za pripravo statističnega modela	54
5.4.1 Opredelitev odvisne spremenljivke	55
5.4.2 Opredelitev neodvisnih spremenljivk	57
5.5 Uporaba logistične regresije za izdelavo modela za ugotavljanje bonitete fizične osebe	67

5.5.1	Regresijski model na celotnem vzorcu.....	67
5.6	Regresijski model na podskupini v vzorcu	71
5.6.1	Definiranje podskupine ujemajočih se parov	72
5.6.2	Regresijski model podskupini ujemajočih se parov.....	74
5.6.3	Vpliv spremembe cut-off vrednosti	79
	SKLEP	81
	VIRI IN LITERATURA	84
	PRILOGE.....	1

KAZALO SLIK

Slika 1:	Udeleženci kartičnega sistema.....	6
Slika 2:	Storitve, ki jih opravljajo kreditni biroji v Evropi	18
Slika 3:	Podatki s katerimi razpolagajo kreditni biroji o posameznikih	19
Slika 4:	Podatki o kreditih s katerimi razpolagajo kreditni biroji o posameznikih	20
Slika 5:	Uporabniki storitev kreditnih birojev	21
Slika 6:	Pričakovani donosi in standardni odkloni različnih možnih portfeljev	28
Slika 7:	Rast potrošniških posojil po drugi svetovni vojni v ZDA glede na vrsto posojilodajalcev ...	29
Slika 8:	Odstotek zapadlih terjatev iz naslova plačilnih kartic starih od 30 do 89 dni v ZDA	31
Slika 9:	Delež neodplačanih posojil fizičnih oseb v BDP v državah EU v letu 2009	32
Slika 10:	Rast posojil posameznikom v starih državah EU in novih državah EU v letih 2004-2010	33
Slika 11:	Rast posojil fizičnim osebam v Sloveniji od leta 2004 naprej	34
Slika 12:	Homoskedastičnost	44
Slika 13:	Grafična predstavitev linearne diskriminantne analize	45
Slika 14:	Logistična funkcija	48
Slika 15:	Proces razvoja modela	50
Slika 16:	Porazdelitev kreditnih točk med dobre in slabe plačnike	52
Slika 17:	Porazdelitev FICO točk v letu 2008	53
Slika 18:	Proces plačevanja obveznosti iz naslova plačilne kartice	56
Slika 19:	Frekvenčna porazdelitev fizičnih oseb glede na verjetnost prejema opomina	71
Slika 20:	Frekvenčna porazdelitev fizičnih oseb glede na verjetnost prejema opomina	79
Slika 21:	ROC krivulja	81

KAZALO TABEL

Tabela 1:	Verjetnostna porazdelitev ustvarjenega donosov podjetja X in Y	26
Tabela 2:	podatki o imetnikih plačilne kartice.....	54
Tabela 3:	Korelacija med številom prejetih opominov in številom prejetih blokad	56
Tabela 4:	Klasifikacija imetnikov kartic glede na prejeti opomin	57
Tabela 5:	Prejeti opomini glede na spol imetnika plačilne kartice.....	58
Tabela 6:	Prejeti opomini glede na zakonski stan.....	59
Tabela 7:	Stanovanjske razmere imetnikov plačilnih kartic	60
Tabela 8:	Starost imetnikov plačilnih kartic	60
Tabela 9:	Število članov v gospodinjstvu	61
Tabela 10:	Stopnja izobrazbe.....	62
Tabela 11:	DM imetnikov plačilnih kartic.....	63
Tabela 12:	Delovna doba imetnikov plačilnih kartic	63

Tabela 13: Območje bivanja.....	64
Tabela 14: Razporeditev imetnikov plačilnih kartic glede na dejavnost podjetja v katerem so zaposleni	64
Tabela 15: Krediti imetnikov plačilnih kartic	65
Tabela 16: Način poravnave obveznosti imetnikov plačilnih kartic	66
Tabela 17: plača imetnikov plačilne kartice.....	66
Tabela 18: Klasifikacija oseb, ki so vključene v regresijski model	68
Tabela 19: Spremenljivke, ki so vključene v enačbo.....	68
Tabela 20: Omnibus test	69
Tabela 21: Rezultat vključitve neodvisnih spremenljivk v regresijski model	69
Tabela 22: Skupine imetnikov plačilnih kartic, ki so identični pri vseh 13ih neodvisnih spremenljivkah.....	73
Tabela 23: Razlike glede na odvisne spremenljivke znotraj posameznega para	73
Tabela 24: Klasifikacija imetnikov plačilnih kartic.....	75
Tabela 25: Spremenljivke, ki so vključene v enačbo.....	75
Tabela 26: Omnibus test	75
Tabela 27: Povzetek regresijskega modela	76
Tabela 28: Rezultat vključitve neodvisnih spremenljivk v regresijski	76
Tabela 29: Neodvisne spremenljivke vključene v model	77

UVOD

Ekonomist Peter Bernstein je v eni izmed svojih knjig napisal, da je meja med sodobnim časom in preteklostjo presežena takrat, kot poznamo skrivnosti tveganj. Ko so ljudje spoznali, da prihodnost ni odvisna od »muhavosti« bogov in našli način, kako uporabiti prihodnost za današnjo korist, so prestopila to navidezno mejo. Tudi podjetja vsakodnevno sprejemajo tveganja pri poslovanju, vendar samo z razumevanjem, merjenjem in ugotavljanja negativnega učinka tveganja lahko sprejemajo tveganje v njihovo koristi. Sposobnost ugotavljanja, kaj se bo zgodilo v prihodnosti in tako izbrati pravilno alternativno, je ključni člen za uspešnost sodobnih podjetij (Bernstein, 1998, str.1).

Tveganje in negotovost igrata pomembno vlogo v današnjem času. Vsak dan sprejemajo odločitve na podlagi nepopolnih informacij. Preprosto opravilo, kot je prečkanje ceste, zahteva kompleksno in hitro oceno verjetnosti in tveganja na podzavestni ravni. Ker sprejemamo takšne odločitve vsak dan, nas lahko hitro zavede, da je sprejemanje odločitve v svetu negotovosti, nekaj kar je dobro razumljeno. Seveda to ni res. Frank Knight je v knjigi »Risk, Uncertainty and Profit« razložil, da sta tveganje in negotovost dva različna koncepta. Tveganje je namreč nekaj kar lahko ovrednotimo z verjetnostjo, negotovosti pa ne moremo kvantificirati na enostaven način. Cilj sodobnega podjetja mora biti, da na strokoven način predvidi prihodnost, da bo lahko danes sprejel najboljšo odločitev, na podlagi katere bo zmanjšal tveganja, ki vplivajo na njegovo poslovanje. Odločitev mora temeljiti na ustrezni analizi, na podlagi katere identificiramo vplive različnih faktorjev, ki vplivajo na izid (Knight, 2002, str. 16).

V preteklosti je veljalo, da so poslovne banke ene izmed najbolj konservativnih podjetij, saj so na eni strani zaradi zakonskih predpisov in na drugi strani velike stopnje tveganosti njihovega poslovanja, veljale kot komitentom »neprijazno« podjetje. Vpeljava tržnega pristopa v poslovanje se je v zadnjih tridesetih letih dotaknil tudi poslovnih bank. Če želi neka poslovna banka danes aktivno konkurirati na področju poslovanja s prebivalstvom, mora imeti dobro razvito strategijo diverzifikacije storitev in hkrati zagotoviti ustrezne vire in kompetence za konkuriranje na ciljnih tržnih segmentih. S ciljem vzpostavitve ustreznega upravljanja odnosov s strankami (ang. customer relationship management) morajo tako svojim komitentom nuditi različne vrste storitve (plačilni promet, potrošniško kreditiranje, varčevanje, itd.). Predvsem z razvojem računalniške tehnologije je izdaja plačilnih kartic postala glavno orodje za izvajanje tržne strategije (Kara et. al, 1996, str. 210).

V zadnjih petnajstih letih so plačilne kartice postale testni primer za raziskovanje kako lahko prenesemo osnovne finančne teorije (analiza tveganja in donosa) na področje, kjer ni mogoče najti običajnih akterjev na finančnih in gospodarskih trgih (dobro poučeni investitorji). Plačilne kartice so kompleksen finančni instrument, saj njihovo uporabnost zaznamujejo številne karakteristike, kot tudi različni motivi za uporabo (nedenarne transakcije, kreditiranje, lojalnost, ugodnosti, itd.). Prvi izdajatelji plačilnih kartic so bile poslovne banke, zadnjih dvajset let pa se odločajo za izdajo plačilnih kartic tudi druga podjetja (trgovci, letalski prevozniki, itd.). Za izdajatelje plačilnih kartic le-te predstavljajo uporabno marketinško orodje, vendar nosijo tudi določeno tveganje. Eno izmed največjih tveganj, povezanih s plačilnimi karticami je t.i. kreditno tveganje, ki predstavlja možnost, da terjatve do imetnikov kartic, ki so nastale zaradi odloženega plačila, poplačane delno oziroma sploh ne bodo poplačane (Scholnick et. al, 2007, str. 1469).

Namen, cilj in temeljna raziskovalna hipoteza magistrskega dela

Na temo obravnavanja kreditnega tveganja je v Sloveniji že bilo napisanih kar nekaj diplomskih, magistrskih in doktorskih nalog, vendar so se večinoma le-te nanašale na kreditno tveganje pri pravnih osebah. Samo nekaj nalog in znanstvenih člankov je bilo napisanih na področju potrošniških posojil medtem, ko naloge oziroma znanstvenega članka na temo kreditnega tveganja plačilnih kartic še ni bilo. Namen magistrskega dela je s pomočjo tuje strokovne literature preučiti različne možnosti, kako naj izdajatelji plačilnih kartic obvladujejo kreditno tveganje. V magistrskem delu se bom predvsem osredotočil na to, kako naj se izdajatelj plačilnih kartic sploh odloči ali bo posamezniku odobril izdajo plačilne kartice na podlagi podatkov, ki jih izdajatelj pridobi na podlagi prejete pristopnice.

Za potrebe magistrske naloge bom tudi uporabil bazo podatkov o izdanih plačilnih karticah enega izmed slovenskih izdajateljev plačilnih kartic. V podjetju se dnevno srečujejo z vprašanjem ali neki (fizični) osebi, ki zaprosi za izdajo plačilne kartice, odobriti izdajo le-te. V veliki večini primerov osebo, ki zaprosi za izdajo kartice, v podjetju ne poznajo oziroma razpolagajo z manjšim naborom podatkov o tej osebi (gre za demografske podatke, podatke o zaposlitvi, izobrazbi, plači,...). Seveda je v podjetju cilj, da se izda čim več plačilnih kartic, vendar na drugi strani nastaja tudi tveganje neplačila s strani imetnikov plačilne kartice, ki lahko povzročajo veliko škodo podjetju. Problem, ki ga podjetje ima je, kako identificirati, na podlagi ozkega nabora podatkov o prosilcu za izdajo plačilne kartice, zaupanja vredne osebe in jih ločiti od tistih, ki svojih obveznosti ne bodo poravnali.

Cilj magistrskega dela je s pomočjo logistične regresije potrditi ali ovreči postavljeno hipotezo, da lahko podjetje zmanjša kreditno tveganje novo-izdanih

plačilnih karticah z ustreznim obravnavanjem podatkov prejetih na podlagi pristopnice za izdajo plačilne kartice. Natančneje bo ugotavljal ali lahko na podlagi določenih demografskih/socioloških podatkov, ki jih izdajatelj plačilne kartice pridobi iz pristopnice napravimo model, ki bo v največji možni meri pravilno izračunaval verjetnost neplačila vsakega posameznika, ki je zaprosil za izdajo plačilne kartice.

Magistrsko delo je sestavljeno iz dveh vsebinskih področij. V prvem delu je predstavljen poglobljen teoretično-analitičen pregled strokovne literature, znanstvenih razprav in raziskav ter člankov tujih strokovnjakov s področja obvladovanja kreditnega tveganja plačilnih kartic. Prvi del magistrskega dela je sestavljen s pomočjo metode kompilacije, s katero sem združil spoznanja različnih avtorjev s področja obvladovanja kreditnega tveganja plačilnih kartic. V drugem, empiričnem delu magistrskega dela, je predstavljena statistična analiza podatkov slovenskega izdajatelja plačilnih kartic ter dokaz, da je možno zmanjšati kreditno tveganje novo-izdanih plačilnih kartic z uvedbo logistične regresije.

Magistrsko delo je sestavljeno iz petih zaokroženih poglavij. V prvem poglavju je predstavljena teorija plačilnih kartic in tveganja povezana s plačilnimi karticami. V tem poglavju je predstavljeno kako so nastale plačilne kartice in njihov razvoj, motive za obstoj plačilnih kartic ter tveganja, ki so povezana s plačilnimi karticami. V drugem poglavju so predstavljene metode obvladovanja kreditnega tveganja pri čemer sem se osredotočil na to kako ocenjevati kreditno tveganje ter kako ga odpravljati. V tretjem poglavju so predstavljeni bonitetni sistemi, ki jih danes uporabljajo izdajatelji plačilnih kartic, kako delujejo takšni bonitetni sistemi, njihov razvoj ter kakšne vrste bonitetnih sistemov poznamo. V četrtem poglavju so predstavljene različne vrste statističnih metod, ki jih lahko uporabimo za izdelavo modela s katerimi lahko zmanjšujemo kreditno tveganje. V petem poglavju je prikazana uporabo logistične regresije na dejanskem primeru slovenskega izdajatelja plačilnih kartic, skupaj z dokazati, da je možno zmanjšati kreditno tveganje novo izdanih plačilnih kartic z ustreznim obravnavanje podatkov pridobljenih na pristopnici za izdajo plačilne kartice. Magistrsko delo je zaključeno s sklepnimi ugotovitvami.

1 TEORIJA PLAČILNIH KARTIC IN TVEGANJA POVEZANA S PLAČILNIMI KARTICAMI

V današnjem svetu so postal plačilne kartice nepogrešljivi finančni instrument v vseh razvitih državah. Po podatkih Banke Slovenije, je bilo v letu 2009 v Sloveniji

izdanih več kot 1.460.000 plačilnih kartic, ki so skupaj ustvarile promet, ki presega 2,3 milijarde EUR. Priljubljenost plačilnih kartic se povečuje še naprej, saj je odstotek trgovcev, ki sprejema plačilne kartice večji od odstotka imetnikov plačilnih kartic. Imetniki plačilnih kartic vidijo njihovo uporabno vrednost predvsem v enostavnem načinu plačevanja blaga in storitev, kjer pridobijo »brezplačno« kreditno linijo in svoje obveznosti poravnajo enkrat na mesec oziroma če jim izdajatelj kartice omogoči, je lahko doba odplačila celo daljša od enega meseca (Banka Slovenije, 2010, str. II.-40).

Poleg brezplačen kreditne linije imajo imetniki kartic pri uporabi kartic določene ugodnosti (popusti, zavarovanja, posebne ponudbe, itd.). Tudi trgovci imajo koristi od sprejemanja plačilnih kartic, saj povečujejo prodajo na račun kupcev, ki v času nakupa nimajo dovolj lastnih sredstev za nakup, plačilna kartica pa jim takšen nakup omogoči. Enostavnost in priročnost plačilnih kartic ima seveda tudi svojo ceno. Po podatkih Evropske komisije (2007), so plačilne kartice najdražji način plačevanja za trgovca, saj v Evropski Uniji (EU) trgovci v povprečju plačujejo provizijo za sprejemanje plačilnih kartic v višini med 0,77% in 3,10% (Evropska komisija, 2007, str. 103).

1.1 Nastanek plačilnih kartic

Košček plastike, ki jo ima danes v svoji denarnici skoraj vsakdo, je prve zametke dobil v začetku 20. stoletja v ZDA. V tistem času so podjetja iskala načine, kako bi lahko hkrati svojim kupcem ponudila določeno storitev s tem, da bi jim omogočili odloženo plačilo. Podjetje Western Union je že leta 1914 kupcem, za katere so menili, da so zaupanja vredne stranke, ponudila t.i. kupčevo kartic (ang. shopper-plate). S časoma so tudi drugi trgovci pričeli uporabljati kovinske kartice na katerih je bilo natisnjeno ime lastnika kartice in njegova identifikacijska številka. Ob nakupu je stranka priložila kartico, trgovec pa je odtisnil sprednjo stran kartice na papir. Trgovec je dnevno zbiral potrdila o nakupih in enkrat mesečno poslal račun imetniku kartice. Značilnost teh kartic je bil, da so jih lahko stranke uporabljale samo v trgovinah izdajatelja te kartice (Worthington, 2001, str. 486).

Leta 1950 je Newyorški poslovnež, Frank McNamara, izdelal prvo plačilno kartico, ki je imetnikom omogočala plačevanje računov v različnih Newyorških restavracijah. V tistih časih restavracije niso sprejemale v plačilo čekov, izdanih s strani bank izven New Yorka. Koncept te kartice je temeljil na tem, da je izdajatelj kartice prejel provizijo v višini med 5% in 10% za vsak nakup. Na začetku je bilo kar nekaj težav z uveljavitvijo prve plačilne kartice, vendar je naposled na

sprejemanje pristalo 27 restavracij v New Yorku. Kartica se je imenovala Diners Club, ki se uporablja še danes (Worthington, 2001, str. 486).

Kasneje so pričeli izdajati kartice tudi druga podjetja, kot so American Express, Barclaycard, Visa, Mastercard, itd. Z večanjem števila izdanih kartic, sta se pojavila dva osnovna tipa kartic (Federal Trade Commission, 2003, str. 2):

- t.i.
kreditna kartica (ang. credit card), ki omogočajo imetnikom, da plačujejo nakupe s kartico, vendar lahko svojo mesečno obveznost prenesejo na kasnejše obdobje, vendar morajo zato plačati obresti (pravilno slovensko: kreditna kartica);
- t.i.
kartica s plačilom na odlog (ang. charge card), ki omogoča imetnikom, da plačajo nakupe s kartico, vendar morajo svojo obveznost plačati enkrat mesečno in se jih ne sme prenesti na kasnejše obdobje (pravilno slovensko: kartica z odloženim plačilom).


V večini držav velikokrat prihaja do napačne interpretacije med »charge card« in »credit card«. Tudi v Sloveniji se najpogosteje uporablja izraz *kreditna kartica*, čeprav so te kartice po svojih lastnostih *kartice z odloženim plačilom* in ne *kreditne kartice*. V magistrskem delu sem, zaradi poenostavitve, uporabljal izraz **plačilna kartica**, ki zajema tako kartice z odloženim plačilom, kot tudi kreditne kartice.

Navidezno enostaven kartični sistem, pa v realnosti ni tako enostaven, saj gre za kompleksen informacijski sistem v katerem so običajno sodelujejo štirje udeleženci (Wang, 2010, str. 88-89):

- im
etnika kreditne kartice (ang. cardholder); to je fizična oseba, ki je zaprosila izdajatelja kartice, da mu izda kreditno kartico z določenim limitom in za ta namen plačuje letno naročnino oziroma članarino;
- tr
govec (ang. merchant); je pravna oseba, katera je podpisala pogodbo s posrednikom, da bo na prodajnih mestih sprejemal v plačilo kreditno kartico, ki jo bo ob nakupu predložil imetnik kreditne kartice in za ta namen plačuje določeno provizijo od zneska posameznega nakupa (ang. merchant service charge);

- **dajatelj plačilne kartice** (ang. issuer); je pravna oseba, ki se ukvarja z izdajanjem kartic, običajno so to poslovne banke oziroma specializirane finančne institucije, vendar se vse pogosteje za izdajo kartic odločajo druge pravne osebe (trgovci, letalski prevozniki, itd.) in nekateri tudi sami sprejemajo kreditno tveganje;
- **posrednik** (ang. acquirer); je pravna oseba, s katerim trgovec sklene pogodbo o sprejemanju kartic in ima pooblastilo s strani izdajatelja kartic, da lahko izvaja poravnavo transakcij s karticami, posrednik mora za ta namen plačati določeno provizijo izdajatelju kartice (ang. interchange fee); običajno so posredniki poslovne banke.

Slika 1: Udeleženci kartičnega sistema



1.2 Motivi za izvedbo transakcij s plačilnimi karticami

Če bolj natančno pogledamo zgornji model kartičnega poslovanja, nas zanima kakšni so motivi, da takšen model obstaja v praksi, kjer je:

- **trgovec** pripravljen plačati posredniku (oz. izdajatelju) določeno provizijo, da lahko kupec kupi blago in storitve in
- **izdajatelj kartice** pripravljen prevzemati kreditna tveganja, ki izhajajo iz kartičnega poslovanja.

Ekonomista Sujit Chakravorti in Ted To (2003, str. 585) sta oblikovala model s kateri sta iskala razloge, zakaj udeleženci sodelujejo pri takšnem sistemu kartičnega poslovanja. V modelu sta se osredotočila predvsem na stroške in koristi, ki jih ima posamezna transakcija (nakup na odlog) na vsakega izmed udeležencev kartičnega sistema.

Model temelji na osnovah popolne konkurence med imetniki kartice in trgovci, vendar predvideva samo enega izdajatelja kartic in en proizvod s katerim se trguje. Ker med imetniki kartic in trgovci obstaja popolna konkurenca kjer nobena stran ne more vplivati na ceno (p), blago je homogeno, vsi imajo popolne informacije. Pomembna komponenta modela je, da predpostavlja dve obdobji (npr. dva zaporedna meseca), vendar ne dopušča, da se provizije za transakcije spreminjajo (tukaj mislimo na »interchange fee« in »merchant service charge«). Ker model predvideva samo dve obdobji, ima imetnik kartice možnost nakupa na odlog samo v prvem obdobju, svoje obveznosti pa mora poravnati v začetku drugega obdobja, imetniku kartice pa ni potrebno plačati obresti (razen v primeru, če bi imetnik kartice poravnal svoje obveznosti z zamudo) (Chakravorti, To, 2003, str. 585).

Razloge za delovanje takšnega sistema kartičnega poslovanja lahko tako razdelimo v tri skupine (Chakravorti, To, 2003, str. 585-587):

a)

R

azlog na strani kupca (imetnika plačilne kartice)

Vsak kupec ima mesečni dohodek (w_t), ki ga porabi za nakup izdelka trgovca. Kupec ima možnost plačati izdelek od trgovca z denarjem ali plačilno kartico. Pogoji, da bo lahko kupec izdelek plačal s plačilno kartico je, da ima limit $L(w)$, ki presega ceno izdelka, sicer mu plačilna kartica ne zadovoljuje njegovih potreb. Če se kupec odloči, da bo plačal izdelek s plačilno kartico, lahko privarčuje prosta denarna sredstva, ki mu bo prinesel določen donos (R).

b)

R

azlog na strani trgovca

Trgovec se na drugi strani sooča z odločitvijo ali sprejemati plačilne kartice in za njih plačevati izdajatelju določeno provizijo v višini $\rho > 0$. Razloga, zakaj je trgovec pripravljen sprejemati plačilne kartice sta:

- kupci s plačilnimi karticami bodo trgovcu povečali prihodki in na
- imetnik kartice bo kupil blago pri njemu in ne pri konkurenci. ku

c) *azlogi na strani izdajatelja kartice* **R**

Izdajatelju kartic je v interesu, da kupci kupujejo čim več s plačilnimi karticami, saj je njegov dohodek odvisen od vrednosti (oz. števila) transakcij s karticami. Izdajatelju se pojavi dilema, katerim kupcem ponuditi kartico in kakšen limit na kartic $L(w)$ mu odobriti. Ker pri kupcih z nizkim dohodkom obstaja tveganje za neplačilo obveznosti, zato izdajatelje takim kupcem kartice ne bo izdal. Konservativni izdajatelj tako pri izdaji kartice upošteva naslednji pogoj:

$$\begin{aligned} L(w) &= 0 ; \text{ če } w_1 < p \\ L(w) &= p ; \text{ če } w_1 \geq p \end{aligned} \quad (1)$$

Iz zgornjega zapisa izhaja, da bi izdajatelj kartice odobril kartico z limitom p samo tistim kupcem, katerih mesečni dohodek presega ceno tega izdelka. Kot bomo videli v nadaljevanju, so izdajatelji kartic pripravljeni izdati kartico tudi tistim kupcem, ki imajo mesečni dohodek nižji od vrednosti blaga p .

1.2.1 Ravnotežni položaj kartičnega sistema

Preden nastane transakcija s plačilno kartico, mora vsak udeleženec v kartičnem sistemu sprejeti določene odločitve (Chakravorti, To, 2003, str. 587-591):

- izdajatelj kartice:
 - ka
teri je tisti dohodek, na podlagi katerega bo odobril kupcu limit na kartici
→ mora določiti kateri je tisti minimalni dohodek, katerega mora imeti kupec, da mu bo odobril izdajo kartice (w);
 - ka
kšno provizijo naj zaračuna trgovcu;

- trg
ovec:
 - se
mora odločiti ali bo sprejemal plačilne kartice ali ne pri proviziji, ki mu jo bo zaračunal izdajatelj kartice;
- ku
pec:
 - se
mora odločiti ali bo izdelek kupil ali ne;
 - če
se odloči, da bo izdelek kupil, kako bo ta izdelek plačal (z gotovino ali s plačilno kartico)

a) K
upčevo ravnotežje

Kupec bo vedno kupil izdelek, ki ga potrebuje, če imajo dovolj sredstev, da si lahko privošči takšen nakup. Če je kupec kupil blago v prvem obdobju, si bo lahko privoščil nakup tudi v drugem obdobju¹, če je izpolnjen naslednji pogoj:

$$Rw_1 + w_2 \geq 2p \quad (2)$$

Kupec, ki se je odločil, da bo v prvem obdobju plačal blago s plačilno kartico in denarna sredstva privarčeval, bo dosegel določen donos (R). Izdajatelj kartice bo seveda zahteval od kupca, da v drugem obdobju odplača dolg, ki je nastal v prvem obdobju, prav tako model tudi predvideva, da bo kupec konec drugega obdobja poravnal tudi nakup v drugem obdobju.

Prednost kartičnega sistema za kupca je tudi v možnosti, da si lahko kupec privošči nakup blaga v obeh obdobjih, če seštevek njegovih mesečnih dohodkov ne dosega vrednosti dvakratnika cene blaga. Pogoj, da si bo lahko privoščil takšen nakup je:

$$R \geq (2p - w_2) / w_1 \quad (3)$$

Če je donos (R), ki ga kupec ustvari zaradi privarčevanih denarnih sredstev, dovolj velik, si lahko v drugem obdobju privošči nakup blaga, čeprav njegov dohodek

¹ Model predvideva, da nakup s plačilno kartico v drugem obdobju ni več mogoč, zato bo kupec v drugem obdobju blago plačal z gotovino.

manjši o vrednosti blaga. Če kupec potrebuje blago tudi v drugem obdobju, njegov privarčevani dohodek iz prvega obdobja (Rw_1) in tekoči dohodek (w_2), ne zadošča za poravnavo nakupa iz prvega obdobja in nakupa blaga v drugem obdobju. Kupec bo tako lahko sprejel odločitev, da v drugem obdobju plača blago z gotovino, blago, ki ga je kupil v prvem obdobju, s plačilno kartico pa ne bo plačal izdajatelju kartice.

Iz ravnovesnega položaja kupca izhaja, če bo kupec imel priložnost, da kupi blago s plačilno kartico, bo takšen nakup zanj vedno bolj ugoden, kot pri plačilu z gotovino, saj kupec ne plača nobenih dodatnih stroškov pri plačilu s plačilno kartico, poleg tega pa lahko na privarčevana sredstva zasluži določen donos. Iz tega namreč izhaja, da se bo kupec vedno odločil za nakup s plačilno kartico, če mu bo izdajatelj kartice odobril izdajo le-te. Tveganje, ki pa izhaja iz takšne odločitve pa lahko pripelje do tega, da kupec svojih obveznosti ne bo poravnal do izdajatelja kartic, ko obveznost zapade v plačilo.

b)

Tr

govčevo ravnotežje

Med trgovcem in kupcem obstaja popolna konkurenca, kar pomeni, da je trgovec nima vpliva na ceno (p). Iz tega dejstva tudi izhaja, da sprejemanje plačilnih kartic povzroča dodatne stroške trgovcu, ki jih ne sme zaračunati kupcu. Ključnega pomena za trgovca je, da bo lahko s sprejemanjem kartic povečal prihodke, saj bi v nasprotnem primeru ohranil enake prihodke, pri čemer bi moral plačati še stroške sprejemanja plačilnih kartic.

Dobiček trgovca, ki ne sprejema kartic lahko izračunamo po naslednji formuli:

$$\pi^{nk} = (p * q^{nk}) - (c * q^{nk}) \quad (4)$$

Dobiček trgovca, ki sprejema kartice lahko izračunamo po naslednji formuli:

$$\pi^k = (p * q^k) - ((c + \rho) * q^k) \quad (5)$$

Kot je navedeno zgoraj, bo trgovec zainteresiran za sprejemanje kartic takrat, kot velja:

$$\begin{aligned} \pi^k &> \pi^{nk} \\ q^k * (p - c - \rho) &> q^{nk} * (p - c) \end{aligned} \quad (6)$$

Dokler je provizija (ρ) dovolj majhna in $q^k > q^{nk}$ bo trgovec imel večje koristi od kartičnega poslovanja, kot bi jih imel, če kartic ne bi sprejemal. Odločitev trgovca o sprejemanju kartic tako temelji na podlagi ocene tekočega in prihodnjega povpraševanja po blagu (q^k in q^{nk}). Povpraševanje v prvem obdobju je odvisno od višine dohodka kupcev (w) in limita, ki ga izdajatelj odobri kupcem ($L(w)$). Povpraševanje v drugem obdobju je odvisno od sredstev, ki jih imajo kupci (odvisno ali so kupili v prvem obdobju s plačilno kartico ali ne).

c)

Iz

dajateljevo ravnotežje

Izdajatelj kartice maksimira dobiček na podlagi izbire provizije, ki jo bo zaračunal trgovcu (ρ) in optimalnega dohodka, ki ga mora imeti imetnik kartice (w), da mu odobri kartico z določenim limitom. Ker je izdajatelj monopolist lahko oblikuje višino provizije (ρ) višje, kot bi bila v popolni konkurenci, vendar mora pri tem upoštevati dejstvo, da bo trgovec pripravljen plačati takšno provizijo, dokler bo njegov dobiček pri sprejemanju kartic večji ali vsaj enaka dobičku, kot če kartic ne bi sprejemal. Na drugi strani mora izdajatelj kartice nositi tveganje, da imetnik kartice svojih obveznosti ne bo plačal. Če bi bili najnižji dohodki kupcev ($w_{\min}$) večji od cene blaga (p), potem ne bi prišlo do neplačil s strani imetnikov kartic.

$$w_{\min} < p < w_{\max} \quad (7)$$

Če bi izdajatelj izdal kartico samo takšnemu kupcu, ki ima dohodek višji od cene izdelka, potem tveganja neplačila ne bi bilo. Na tem mestu se postavi vprašanje zakaj bi bil izdajatelj pripravljen izdati kartico tudi tistim kupcem, ki imajo nižji dohodek, kot znaša cena tega izdelka? Razlogi za to so:

- ke
r velja formula 3, si bo lahko kupec privoščil nakup blaga v obeh obdobjih tudi, če bo seštevek njegovih mesečnih dohodkov manjši od vrednosti blaga kupljenega v obeh obdobjih;
- ob
staja možnost, da kupec blaga v drugem obdobju ne bo potreboval in bi v tem primeru kupec vrnil denar izdajatelju kartice, ki bi se pokrila iz kupčevega dohodka v prvem in drugem obdobju;
- ku
pec bi kupil blago v prvem obdobju (če kartice ne bi imel, blaga ne bi kupil),

s tem bi se povečali prihodki trgovca, ki bi plačal provizijo izdajatelju kartice; prihodki izdajatelja kartice se bodo povečali.

Naloga izdajatelja kartice je določitev optimalnega dohodka kupca (w), da mu lahko izda kartico z limitom $L(w)$, pri čemer mora biti w takšen, da bo minimiziral tveganje neplačila s strani imetnika kartice.

1.3 Tveganja plačilnih kartic

Upravljanje s tveganji je en izmed ključnih nalog, s katerimi se morajo soočiti izdajatelji plačilnih kartic. Izdajatelj plačilnih kartic mora tako zagotoviti ustrezno politiko upravljanja s tveganji, ki izhajajo iz kartičnega poslovanja. V praksi imajo izdajatelji organizirane posebne organizacijske enote, ki se ukvarjajo samo z obvladovanjem tveganj. Z marketinškega vidika je cilj izdajatelja plačilnih kartic, da pridobi čim več novih imetnikov kartic, vendar cilj upravljanja s tveganji je iskanje optimalnega razmerja med donosom in tveganjem oziroma iskanje načina kako zmanjšati posamezna tveganja. Izdajatelji kartic se srečujejo z različnimi vrstami tveganj (Slawsky, Zafar, 2005, str. 23):

- **Kreditno tveganje**; kreditno tveganje predstavlja tveganje, da imetnik kartice ne bo poravnal svojih obveznosti ob zapadlosti; to je eno izmed ključnih tveganj s katerimi se soočajo izdajatelji plačilnih kartic, saj njihova vloga kartičnem sistemu ni samo prenos denarja od imetnika kartice do trgovca, ampak se izdajatelj zaveže do trgovca, da mu bo nakazal denar za nakup imetnika kartice ne glede na to, ali bo imetnik izdajatelju dejansko nakazal denar ali ne; več o samem kreditnem tveganju je napisano v nadaljevanju magistrske naloge.
- **Tveganje zlorab kartic**; v osnovi ločimo dve vrsti tveganja zlorab, in sicer (Bhattacharyya, 2010, str. 2):
 - **Applikativne zlorabe** (ang. application fraud), kjer prevarant uporabi nepravne podatke oziroma zlorabi podatke drugih oseb z namenom pridobitve plačilne kartice;
 - **Verbalne zlorabe** (ang. behavioural fraud), ki se delijo na štiri podvrste:

- Kr
aja novih kartic se zgodi takrat, ko prevarant ukrade pošto z novo izdano plačilno kartico (ang. mail theft),
 - Kr
aja/izguba obstoječih kartic se zgodi, ko prevarant ukrade plačilno kartico, ko je ta že bila uporabljena s strani pravega imetnika kartice,
 - P
onarejanje kartic, ki se zgodi, da prevarant prebere magnetni zapis oz. čip na plačilni kartici in napravi kopijo prave kartice,
 - »V
irtualne zlorabe« ki se pojavljajo pri spletnem nakupovanju, kjer prevarant pridobi številko kartice ter izvede nakup(e) na internetu;
- Te
tehnološka tveganja; uspeh plačilnih kartic je v veliki meri odvisen od tehnološke platforme, ki omogoča izvajanje plačil s karticami; če tehnološka platforma ne deluje, to pomeni, da transakcije ne morejo biti izvedene, kar lahko povzroči škodo:
 - tr
govcu, saj blaga oziroma storitve ne bo mogel prodati,
 - iz
dajatelju kartice, ki ne bo mogel zaračunati provizije za prodano blago oziroma storitve) ter
 - ku
pcu, ki ne bo mogel kupiti blaga oziroma storitve.

2 OBVLADOVANJE KREDITNEGA TVEGANJA

Kreditno tveganje predstavlja verjetnost izgube do katere bi lahko prišlo zaradi sprememb v dejavnostih, ki vplivajo na poslovanje podjetja. Tveganje ima pri ljudeh običajno negativen prizvok, vendar na drugi strani predstavlja tudi priložnost za dobiček. Dostikrat se tveganje uporablja v povezavi z besedo izpostavljenost (ang. exposure), vendar med njima obstaja razlika, saj se tveganje nanaša na verjetnost (ang. probability) izgube medtem, ko se izpostavljenost nanaša na možnost (ang.

possibility) izgube. Možnost izgube tako predstavlja predpogoj, za nastanek verjetnosti izgube (Condamin et. Al, 2006, 33-34).

Nedavni pretresi na finančnih trgih so povzročili, da se vsa podjetja soočajo z večjimi tveganji pri svojem poslovanju. Ključni element pri tem je način obvladovanja podjetniških tveganj (ang. enterprise risk management). Finančna podjetja, kot so banke, zavarovalnice so tako še bolj motivirana, da izpolnjujejo številne zakonske zahteve pri obvladovanju tveganj in doseganju kapitalske ustreznosti. Obvladovanje tveganj sicer ni novost, ki se je pojavila ob zadnji finančni krizi, ampak se podjetja že dobrih dvajset letu ukvarjajo kako obvladovati tveganja. Obvladovanje tveganj tako predstavlja integriran način doseganja strateških ciljev vsakega podjetja z določanjem nivoja sprejemljivih tveganj (Olson, Wu, 2008, str. 25).

V osnovi podjetja delijo tveganja v dve skupini, in sicer finančna tveganja in operativna tveganja. Karen A. Horcher (2005, str. 2) opredeljuje finančna tveganja, kot tista tveganja, ki nastanejo pri denarnih (finančnih) transakcijah in zajemajo nakup oziroma prodajo, naložbe, posojila in druge vrste dejavnosti podjetja. Finančna tveganja tako nastanejo kot posledica pravnih poslov, prevzemov ali združitvev, posojilnega financiranja ali drugih aktivnosti posloводства, lastnikov, konkurence ali državnih organov. Posledica takšnih aktivnosti ima povečanje stroškov, zmanjšanje prihodkov oziroma kakorkoli drugače vpliva na donosnost poslovanja.

Za operativna tveganja pa tako enoznačne definicije ni, saj za vsako panogo ali celo podjetje obstajajo drugačna operativna tveganja. Ena izmed definicij operativnih tveganj, ki se je uveljavila v finančnem sektorju opredeljuje, da operativno tveganje je tveganje, pri katerem lahko nastane posredna ali neposredna škoda za podjetje, kot posledica neustreznih oziroma pomanjkljivih notranjih procesov, dejanj zaposlenih in sistema oziroma negativnih zunanjih posledic (Operating Risk 2001, str. 2).

2.1 Finančna tveganja

Finančno tveganje izhaja tako na strani fizičnih oseb, kot tudi na strani podjetij, ker uporabljajo finančne instrumente. Tveganja, ki izhajajo iz teh instrumentov so lahko zelo različni in lahko povzročijo spremembo njihove vrednosti zaradi nihanj obrestnih mer, spremembe deviznih tečajev, nihanj cen vrednostnih papirjev na borzah in uporaba izvedenih finančnih instrumentov.

Upravljanje s finančnimi tveganji je proces s katerim zmanjšujemo negativne vplive, ki izvirajo iz finančnega poslovanja. Upravljanje s tveganji se začne z oceno finančnih tveganj, katerim je izpostavljeno podjetje in pripravo ukrepov s katerimi lahko zmanjšamo negativne vplive finančnih tveganj. Podjetje, ki dobro upravlja s finančnimi tveganji lahko doseže pomembne konkurenčne prednosti. Za doseg tega je potrebno razviti strategijo upravljanja s finančnimi tveganji, ki angažira zaposlene skozi interna pravila, proceduro, da obvladujejo finančnih tveganj (Horcher, 2005, str.3).

Finančna tveganja lahko delimo v več skupin, odvisno od vrste podjetja. H. D. Skipper in W.J. Kwon (2007, str. 21) delita finančna tveganja v tri skupine:

- **tržno tveganje** (ang. market risk) je tveganje spremembe vrednosti finančnega sredstva, ki izvira iz dogajanj na finančnih trgih in gospodarstvu. Podjetja so največkrat izpostavljena obrestnemu tveganju, valutnemu tveganju in inflacijskemu tveganju. Iz finančnih sredstev pa običajno izhaja tudi likvidnostno tveganj, t.j. tveganja, da zaradi majhne likvidnosti trga ne bomo uspeli prodati določenega finančnega sredstva. Za tržna tveganja izhaja, da so močno odvisna od dogajanj v gospodarstvu (večinoma to velja za globalno ekonomijo, lahko pa tudi za posamezne države) in jih za to običajno imenujemo tudi sistematična tveganja;
- **cenovno tveganje** (ang. price risk) je tveganje izgube prihodkov, ki izhaja iz napačne opredelitve cene blaga in storitev, ki pa je odvisno od vrste izdelka (npr. za zdravila je cenovno tveganje bistveno manjše, kot za izdelke vsakodnevnne rabe);
- **kreditno tveganje** (ang. credit risk) oziroma tudi tveganja poslovnega partnerja (ang. counterparty risk); predstavlja možnost, da bo podjetje utrpelo škodo s strani poslovnega partnerja, ker ta ni izpolnil svojih pogodbenih obveznosti; običajno se kreditno tveganje izraža skozi dana posojila, izdane garancije, ki jih nudijo svojim poslovnim partnerjem, saj za njih obstaja tveganje, da ne bodo povrnila izposojenih sredstev, ko le-te zapadejo v plačilo.

Običajno kreditno tveganje nastaja skozi posojilno dejavnost, investicije in kreditiranje kupcev, ki vključuje prodajo blaga in kasnejše plačilo kupljenega blaga. Kreditno tveganje pa nastaja tudi preko izpolnjevanja pogodbenih zavez (npr. pri

izvedenih finančnih instrumentih). Ko terjatev ni plačana v celotni na pogodbeno dogovorjen rok zaradi dejstva, da podjetje noče plačati bodisi ne more plačati svojih obveznosti, takrat nastane škoda za podjetje, ki je odobrilo kredit (Horchner, 2005, str. 103).

Horchner (2005, str. 104) je opredelila, da kreditno tveganje vsebuje naslednje vrste tveganj:

- **tv**
eganje neplačila obveznosti (ang. default risk); tveganje pomeni, da prejemnik kredita ne bo poravnal svojih obveznosti ob zapadlosti;
- **tv**
eganja neplačila pred zapadlostjo (ang. counterparty pre-settlement risk); je tveganje, da nasprotna stran ne izpolni določenih pogodbenih obveznosti pred zapadlostjo obveznosti – podjetje, ki ima likvidnostne težave se npr. odloči, da bo poravnala le obveznosti do države in bank medtem, ko ne bo plačevala obveznosti do dobaviteljev, gre za t.i. začetne signale (ang. early warning signals), da obstaja verjetnost, da ob nadaljevanju plačilnih težav podjetje ne bo poravnalo vseh svojih obveznosti;
- **tv**
eganja pri poravnavi obveznosti (ang. counterparty settlement risk); je tveganje, ki nastane, ko se dve podjetji med seboj izmenjujeta plačilo in dobavo blaga in eno podjetje izpolni svojo obveznost, drugo ne; takšnemu tveganju rečemo tudi Herstatt tveganje (ang. Herstatt risk) imenovano po nemški banki Herstatt, ki je šlo v likvidacijo 26. junija 1974; Herstatt banka je bila zelo aktivna na valutnih trgih in na ta dan, ko je šla banka v likvidacijo, bi se morale zgoditi vnaprej dogovorjene valutne zamenjav z ameriškimi bankami. Tako se je zgodilo, da so ameriške banke do 10:30 po newyorškem čas (16:30 po evropskem času) plačale svoje obveznosti do Herstatt banke in pričakovale, da bo banka Herstatt plačala svoje obveznosti, vendar se to ni zgodilo, saj so nemški regulatorji sprožili postopek likvidacije Herstatt banke po koncu delovnega dne (16:30 po evropskem času oz. 10:30 po ameriškem času). Tako so ameriške banke nakazale svoje obveznosti do banke Herstatt, vendar proti plačila niso prejele (Questa, 1999, str. 111).
- **pr**
avno tveganje (ang. legal risk) pravna tveganja sama po sebi običajno niso

obravnavana kot finančna tveganja, vendar ima lahko neizpolnjevanje določenih pravnih zahtev negativne finančne posledice za podjetje (npr. podjetje ni imelo dovoljenja, da sklene določen posel oziroma oseba s katero se je sklenil kredit ni bilo pooblaščen za sklenitev takšnega posla);

- **de**
želno in politično tveganje (ang. sovereign and country risk); je pomembno predvsem pri mednarodnih transakcijah, saj se lahko zgodi, da določena država sprejme določene ukrepe, ki prepovedujejo prenos denarja iz države in navkljub dejstvu, da bi podjetje plačalo svoje obveznosti, le-te zaradi ukrepov države ne morem izpolniti;
- **tv**
eganje koncentracije (ang. concentration risk); to tveganje nastane takrat, ko je določeno podjetje izpostavljeno do enega samega podjetja oziroma manjše skupine podjetij; če ima podjetje, ki smo mu odobrili kredit plačilne težave, to avtomatsko pomeni, da bo tudi to podjetje lahko imelo velike težave zaradi neplačila s strani kreditojemalca.

2.2 Eksterno ocenjevanje kreditnega tveganja

Podjetja, ki se soočajo s kreditnim tveganjem vlagajo izjemno veliko resursov oziroma uporabljajo napredne programe za analiziranje in upravljanje kreditnega tveganja. Podjetja lahko uporabljajo rešitve specializiranih podjetja, ki se ukvarjajo z ocenjevanje kreditnega tveganja podjetij, kot na primer rating agencije Standard&Poor, Moody's, Fitch za pravne osebe oziroma v primeru fizičnih oseb obstajajo v nekaterih državah t.i. kreditni biroji. Vse več podjetij pa ima organizirane posebne oddelke ali skupine zaposlenih, katerih naloga je ocenjevanje plačilna sposobnosti njihovih kupcev (Langohr, Langohr, 2008, x).

Pri ocenjevanju kreditnega tveganja so banke bolj napredne, kot pa običajna podjetja. Večina bank namreč razvije svoje lastni model, ki ocenjuje tveganje njihovih posojilojemalcev. Način za ocenjevanje kreditnega tveganja oziroma izdelava t.i. bonitetnih sistemov je ključno orodje s katerim banke oziroma podjetja poskušajo oceniti kakšno je tveganje nasprotne strani ter oceniti verjetnost neplačila obveznosti. Ena izmed rešitev, ki jo lahko uporabi podjetje oziroma tudi banka, za ocenjevanje kreditnega tveganja, je uporaba podatkov, ki jih pripravijo kreditni biroji (Silver Lake Editors , 2005, str. 101-105).


2.2.1 Kreditni biroji v Evropi

V Evropi so kreditni biroji organizirani v okviru posamezne države, za meddržavno sodelovanje pa skrbi organizacija Združenje ponudnikov informacij o potrošniških kreditih (Association of Consumer Credit Information Suppliers), v katero je vključenih 37 članic. Nekateri kreditni biroji imajo že dolgo zgodovino delovanja, saj je kar enajst kreditnih birojev v Evropi nastalo že pred letom 1990. Na drugi strani so v nekaterih državah kreditni biroji nastali šele po letu 2001 in med temi državami je tudi Slovenija, ki je pred nekaj leti ustanovila kreditni biro Slovenski informacijski sistem bonitet (SISBON). Razlog za pozen razvoj kreditnega biroja v Sloveniji, leži v zakonodaji, saj je bila šele v letu 2008 v Sloveniji spremenjena zakonodaja, na podlagi katere se je ustanovil SISBON, ki je namenjen elektronski sistem izmenjave informacij o boniteti fizičnih oseb (Združenje bank Slovenije, 2010).

V sistemu SISBON se zbirajo in obdelujejo podatki, ki se nanašajo na zadolženost in izpolnjevanja pogodbenih obveznosti fizičnih oseb posameznikov, vendar bo sistem dodobra zaživel šele v letu 2011. V skladu z novim Zakonom o potrošniških kreditih (ZPotK-1) bodo banke namreč dolžne preverjati vsakega novega posojilojemalca – fizično osebo. V Sloveniji smo tako s spremembo zakonodaje »prisilili« posojilodajalce, da posredujejo podatke v SISBON in tudi pri odobravanju posojil morajo le-ti obvezno preveriti vsakega posameznika v sistemu SISBON.

Rothemund in Gerhardt (2011, str. 1) sta na podlagi ankete tridesetih kreditnih birojev v Evropi ugotovila, da kreditni biroji sicer opravljajo različne naloge, vendar je ključna naloga vseh kreditnih birojev v Evropi priprava posebnih kreditnih poročil o fizičnih osebah oziroma omogočanje dostopa do kreditne zgodovine posameznika.

Slika 2: Storitve, ki jih opravljajo kreditni biroji v Evropi



Vir: Rothemund, Gerhardt, 2011, str. 5

Kot je razvidno iz zgornje slike, vsi kreditni biroji v Evropi pripravljajo bodisi kreditna poročila bodisi podatke o zgodovini posojil posameznika. Kar 23 kreditnih birojev v Evropi imajo tudi razvit bonitetni sistem in uporabnikom sistema ponujajo izdelano bonitetno oceno o posamezniku. Poleg teh dveh storitev, pa večina kreditnih birojev ponuja svetovanje in pomoč pri razvoju bonitetnih sistemov, medtem, ko kreditni biroji v Evropi običajno ne nudijo pomoči pri izterjavi dolgov (Rothemund, Gerhardt, 2011, str. 5).


a)

o

sebni podatki, ki jih zbirajo kreditni biroji

Vsi kreditni biroji v Evropi hranijo podatke o posameznikih, ki svojih obveznosti niso plačevali medtem, ko tri četrtine kreditnih birojev ponuja tudi podatke o tem, da je nek posameznik vse svoje obveznosti plačeval v rokih. Poleg teh podatkov, pa kreditni biroji hranijo tudi druge vrste podatkov, kot so podatki o socialno-ekonomskem stanju posameznika in celo podatkov o odprtih oziroma zaprtih tožbah in postopkih na sodiščih (Rothemund, Gerhardt, 2011, str. 12).

Slika 3: Podatki s katerimi razpolagajo kreditni biroji o posameznikih



Vir: Rothemund, Gerhardt, 2011, str. 12

Iz zgornje slike izhaja, da večina kreditnih birojev razpolaga s podatkom o imenu in priimku, naslovu, datumu rojstva in spolu. Zanimivo je, da večina kreditnih birojev nima podatka o plači posameznika oziroma o njegovem premoženju. Iz zgornjega tako izhaja, da imajo kreditni biroji dostop le do podatkov, ki jih so prejeli le od posojilodajalcev, sodišč in ostalih državnih organov, ne vsebujejo pa podatkov, na katere bi imel posameznik možnost, da jih spreminja.


b)

P

Podatki o kreditni sposobnosti posameznika

Zgoraj so bili predstavljeni samo osebni podatki o posameznikih, ki jih imajo kreditni biroji. Kreditni biroji pa pridobivajo tudi podatke o kreditih direktno s strani posojilodajalcev. Podatki, ki jih pridobivajo so predstavljeni v spodnji sliki.

Slika 4: Podatki o kreditih s katerimi razpolagajo kreditni biroji o posameznikih



Vir: Rothemund, Gerhardt, 2011, str. 13

Večina kreditnih birojev zbira podatke o dolgu na plačilnih karticah, nepremičninskih kreditih, znesek odobrenega kredita, itd. Zanimivo je dejstvo, da nekateri kreditni biroji pridobivajo podatke tudi od ponudnikov telekomunikacijskih podjetij in podjetji, ki dobavljajo elektriko, vodovod, itd. Zanimivo je tudi to, da imajo trije kreditni biroji tudi podatek o obrestni meri posojila.


c)

U

porabniki storitev kreditnih birojev

Rothemund in Gerhardt (2011, str. 15) sta ugotovila, da so uporabniki storitev kreditnih birojev različna podjetja, prav tako pa kreditni biroji ponujajo različne vrste podatkov. Nekateri kreditni biroji omogočajo samo t.i. negativne podatke, kot na primer, da nek posameznik ne plačuje svojih obveznosti, nekaterim izbranim uporabnikom pa ponujajo tudi t.i. pozitivne podatke, kot na primer, da nek posameznik vse svoje obveznosti plačuje pravočasno in brez zamud. Pri tem sta Rothemund in Gerhardt poudarila, da je pri posredovanju podatkov ključna zakonodaja v posamezni državi, saj le-ta onemogoča, da bi lahko kar vsakdo dobil vse možne podatke o kreditni sposobnosti posameznika.

Slika 5: Uporabniki storitev kreditnih birojev



Vir: Rothemund, Gerhardt, 2011, str. 15

Iz zgornje slike izhaja, da kar v 22 državah so uporabniki storitev banke, pri čemer samo v štirih državah banke lahko dostopajo tudi do t.i. pozitivnih podatkov o posameznikih. Drugi najpomembnejši uporabnik storitev kreditnih birojev so leasing hiše, takoj za njim pa so izdajatelji plačilnih kartic. Kar v 18 državah namreč izdajatelji plačilnih kartic lahko dostopajo do informacij o kreditni sposobnosti posameznikov – v petih državah lahko izdajatelji plačilnih kartic dostopajo tudi do t.i. pozitivnih podatkov.

2.3 Odpravljanje kreditnega tveganja

Vsako podjetje se mora samo odločiti na kakšen način bo upravljalo s kreditnim tveganjem. Eno izmed ključnih vprašanj, na katero mora odgovoriti vsako podjetje je, kakšno tveganje je pripravljeno nositi oziroma kje je meja med sprejemljivim in nesprejemljivim kreditnim tveganjem. Obstaja več različnih načinov odpravljanja kreditnega tveganja:

- **Prilaganje cene tveganju** (ang. risk-based pricing); banke običajno prilagodijo obrestno mero za posojilo glede na tveganost posojilojemalca. Pri tem se običajno upoštevajo različni dejavniki, ki določajo ceno oziroma tveganje (namen posojila, ročnost, zavarovanje posojila,...) (Mays, 1998, str 6-8);
- **Zaveze posojilojemalca** (ang. covenants); podjetja se morajo pri posojilih zavezati, da bodo izpolnjevala določene zaveze pri svojem poslovanju sicer lahko banka predčasno odpokliče posojilo; primeri takšnih klavzul so: prepoved izplačila dividend v času posojila, prepoved novega zadolževanja, izpolnjevanje določenih finančnih kazalnikov (npr. *neto dolg/EBITDA* ne sme presegati vrednosti 4); pri fizičnih osebah so običajno zaveze, da bo prejemal plačo na račun pri banki posojilodajalki, bo imel zavarovane nepremičnine najmanj v vrednosti nadomestitvene vrednosti nepremičnine, obvezna sklenitev življenjskega zavarovanja in vinkulacija zavarovalne police na banko itd. (Ciby, 2006, str 315-317).
- **Zavarovanje kredita** (ang. credit insurance) oziroma uporaba **kreditnih izvedenih finančnih instrumentov** (ang. credit derivatives); posojilodajalec sklene s zavarovalnico ali neko drugo zaupanja vrednim podjetjem zavarovanje za primer neplačila obveznosti s strani posojilojemalca; čedalje bolj pa se uporabljajo tudi t.i. kreditne zamenjave (ang. credit default swaps) (Ammann, 2001, str. 175-177);
- **Zmanjševanje kreditne izpostavljenosti** (ang. tightening); posojilodajalci lahko zmanjšajo kreditno tveganje z zmanjšanje izpostavljenosti pri posameznih posojilojemalcih;
- **Razpršitev kreditne izpostavljenosti** (ang. diversification); z večanjem števila posojilojemalcev se zmanjšuje kreditno tveganje (Ciby, 2006, str. 264);
- **Zavarovanje posojila s strani posojilojemalca** (ang. collateral); banke pri

posojilojemalcih s slabšo boniteto zahtevajo, da se posojilo zavaruje s hipotekami na nepremičninah (Gregory, 2010, str. 65).

2.3.1 Zmanjševanje kreditne izpostavljenosti

Ključno vprašanje pri obvladovanju kreditne izpostavljenosti je, kakšen je maksimalni znesek »kredita«, ki ga lahko podjetje odobri stranki in hkrati pričakuje, da bo to podjetje plačalo svoje obveznosti? V zadnjih desetletjih so podjetja dajala zelo velik poudarek na rasti poslovanja. Predvsem finančne institucije so pričele uvajati vedno nove in nove finančne produkte in storitve, ki so na eni strani povečevale dobiček družb, vendar na drugi strani tudi povečevale kreditno tveganje.

Povečano kreditno tveganje se po navadi odraža predvsem v povečanju slabih terjatev oz. terjatev, ki jih je težko izterjati (ang. bad debt). Še posebej banke in podjetja, ki izdajajo plačilne kartice so prisiljena, da v največji možni meri zmanjšujejo slabe terjatve. Ena izmed možnih rešitev kako zmanjšati slabe terjatve, je pridobivanje natančnih ocen o kakovosti posamezne terjatve, saj dobra ocena kvalitete terjatve prinaša dve pomembni prednosti:

- UV
ede se neodvisna informacija, ki optimizira postopek odobritve kredita in
- Z
manjša stroške povezane z izterjavo neplačanih terjatev (Sung, 2010, str. 3704).

Načini merjenja in obvladovanja kreditnega tveganja so se pričeli razvijati že v 70ih letih 20. stoletja. Podjetja so predvsem iskala načine, kako meriti in obvladovati kreditno izpostavljenost. Zanimivo je predvsem to, da so ključno vlogo pri povečevanju pomena kreditne izpostavljenosti prinesle spremembe v zunanjem okolju in ne na podlagi notranjih dejavnikov podjetja (Altman, Saunders, 1998, str. 1721):

- po
večevanje števila stečajev podjetij,
- ko
nkurence med posojilodajalci (zniževanje marž za posojila),

- zmanjšanja vrednost nepremičnin (in s tem zavarovanja) na mnogih trgih,
- rasti števila izvedenih finančnih instrumentov, ki so jih pričela uporabljati podjetja itd.

V praksi so se pri obvladovanju kreditne izpostavljenosti poslužujejo predvsem ukrepov za zmanjšanje kreditne izpostavljenosti. Seveda so sistem zmanjšanja kreditne izpostavljenosti odvisni od vrste organizacije (npr. za banke velja, da so pri zmanjševanju kreditne izpostavljenosti bistveno bolj aktivne kot ostala podjetja). Tehnike, ki se jih podjetja običajno poslužujejo pri upravljanju kreditne izpostavljenosti so (Horcher, 2005, str. 110):

- formalizacija kreditne funkcije v podjetju,
- razpršitev oziroma diverzifikacija kreditne izpostavljenosti,
- uporaba medsebojnih poravnjav (kompensacij), ki zmanjšujejo tveganja,
- redotočanje na zanesljive poslovne partnerje,
- uporaba zavarovanj plačil, kjer je to možnost,
- spremljanje tržne vrednosti pogodb.

Marsikatero podjetje zgolj spremlja gibanje slabih terjatev, kar je pravzaprav pasivni pristop k obvladovanju tveganja. Ljudje, ki so v podjetjih odgovorni za obvladovanje kreditnega tveganja, so zelo velikokrat pod pritiskom, da mora podjetje širiti poslovanje, zato je aktivno obvladovanje kreditnega tveganja v takih primerih zapostavljeno. V takšnih primerih se podjetja po navadi lotijo le spremljanja kreditnega tveganja tako, da zbirajo nekatere informacije o terjatvah, jih obdelajo ter izračunajo nekatere kazalnike. Seveda je spremljanje obsega slabih terjatev pomemben element pri obvladovanju kreditnega tveganja, vendar

kadar pride do pomembnega povečanja slabih terjatev, je škoda že narejena (Ciby, 2006, str. 147).

2.3.2 Razpršitev (diverzifikacija) kreditne izpostavljenosti

Vsako podjetje želi pri svojem poslovanju doseči določen dobiček oz. donos. Vsa podjetja so tudi pri svojem poslovanju soočena s tveganji, ki vplivajo na njihov donos, ki je lahko pozitiven ali negativen. Postavi se nam vprašanje ali lahko zmanjšamo tveganje, če razpršimo našo kreditno izpostavljenost na več strank? Da bi lahko odgovorili na to vprašanje je potrebno najprej opredeliti kakšna je povezava med pričakovanim (zahtevanim) donosom in verjetnostjo, da bomo dosegli takšen donos (Ciby, 2006, str. 264).

Najlažje si to predstavljamo, če vzamemo enostaven primer iz bančnega poslovanja. Predpostavimo, da se banka odloča ali odobriti posojilo podjetju X, če vemo, da obstaja določena verjetnost, da to podjetje svojih obveznosti ne bo vrnilo. Predpostavljamo tudi, da bo banka dosegla različen donos pri različnih možnih izidih (podjetje X vrne posojilo ob zapadlosti ali z zamudo in delnim odpisom obresti ali z nevrnjenim delom glavnice).

Če želimo še izračunati kakšno je tveganje, moramo poiskati mero za tveganje. V finančni teoriji se uporablja standardni odklon pričakovane stopnje donosa, kot mera tveganja. Standardni odklon je definiran kot varianca, ki je mera statistične razpršenosti določene spremenljivke glede na pričakovani donos. Večja, kot je spremenljivost (volatilnost) pričakovanih rezultatov, večji bo standardni odklon, kar pomeni, da varianca in standardni odklon merita negotovost pričakovanega izida. Varianco tako definiramo z naslednjo formulo (Bodie, 2001, str. 137):

$$\sigma^2 = \sum_i p(s) [(r(s) - E(r))^2] \quad (8)$$

Nadaljnje nas zanima kaj se zgodi s kreditnim tveganjem banke, če bi poleg podjetju X, banka odobrila še finančni leasing nepremičnin podjetju Y. Predpostavimo naslednjo verjetnostna porazdelitev ustvarjenega donosa na posojilo podjetja X in leasinga podjetja Y.

Tabela 1: Verjetnostna porazdelitev ustvarjenega donosov podjetja X in Y²

² Predpostavljamo, da je posojilo podjetju X dano na nezavarovani osnovi, finančni leasing podjetju Y pa je sklenjen na podlagi prenosa lastninske pravice na banko ob sklenitvi pogodbe; pri leasingu še predpostavljamo, da bi banka lahko v primeru, da podjetje Y ne bi plačalo svojih obveznosti banki, nepremičnino prodalo na trgu po bistveno višji ceni, kot je le-ta znašala ob podpisu pogodbe.

	Verjetnost	Donos podjetja X	Donos podjetja Y
Podjetje bo vrnil posojilo na dan zapadlosti	60%	15%	8%
Podjetje ne bo vrnil posojilo na dan zapadlosti in banka bo pristala na odpis dela obresti	30%	10%	5%
Kreditojemalec ne bo vrnil posojila	10%	-15%	20%
Pričakovani donos, $E(r)$		10,5%	8,3%
Standardni odklon, σ		8,79%	4,12%

Vir: lasten primer

Iz zgornjih dveh možnosti vidimo, da je pri podjetju X pričakovani donos večji, kot pri podjetju Y, vendar pa je tveganje (standardni odklon) podjetja Y manjši, kot pri podjetju X. Če bi se morala banka odločiti, da bi financiralo samo eno podjetje, bi se tako bilo pred dilemo ali sprejeti večje tveganje, da bi ustvarilo večji donos.

Če želi banka izvedeti kakšen je potencial diverzifikacije, je potrebno ugotoviti kakšna je korelacija in kovarianca teh dveh posojil. Kovarianca je namreč merilo koliko dve spremenljivki variirata skupaj (za razliko od variance, ki meri koliko variira ena sama spremenljivka). Pozitivna kovarianca pomeni, da pričakovani donosi gibljejo v enaki smeri medtem, ko negativna kovarianca pomeni, da se pričakovani donosi gibljejo v nasprotni smeri.

Kovarianco lahko zapišemo kot:

$$Cov(r_x, r_y) = \sum_s Pr(s) [r_x(s) - E(r_x)] [r_y(s) - E(r_y)] \quad (9)$$

Na podlagi podatkov iz zgornje tabele lahko izračunamo kovarianco:

$$\begin{aligned} Cov(r_x, r_y) &= 0,6[15 - 10,5][8 - 8,3] + 0,3[10 - 10,5][5 - 8,3] + \\ &= +0,1[-15 - 10,5][-20 - 8,3] = -30,15 \end{aligned} \quad (10)$$

Na podlagi izračunane kovariance lahko izračunamo kakšna je korelacija med kreditoma podjetju X in Y:

$$\rho(X, Y) = \frac{Cov[r_x, r_y]}{\sigma_x \sigma_y} = \frac{-30,15}{10,5 * 4,12} = -0,83 \quad (11)$$

Kot vidimo iz tega primera je korelacija med kreditom podjetja X in Y negativna, in sicer -0,83, kar nam pove, da se bo v primeru povečanja možnost neplačila s strani podjetja X, povečal donos kredita Y.

Ko imam banka na izbiro dva posojilojemalca z varianco σ_X^2 in σ_Y^2 in jih združimo v portfelj, pri čemer je potrebno upoštevati relativno velikost posameznega posojila (relativno velikost lahko določimo kot w_X in w_Y). Varianco portfelja posojil izračunamo z naslednjo formulo:


$$\sigma_P^2 = w_X^2 \sigma_X^2 + w_Y^2 \sigma_Y^2 + 2w_X w_Y \text{Cov}(r_1, r_2) \quad (12)$$

V našem primeru predpostavljajmo, da sta posojilo podjetju X in leasing podjetju Y enaki vrednosti, in sicer $w_X = w_Y = 0,5$. Na podlagi tega lahko izračunamo varianco portfelja:

$$\sigma_P^2 = [(0,5)^2 * 8,79] + [(0,5)^2 * 4,12^2] + (2 * 0,5 * 0,5 * (-30,15)) = 8,49 \quad (13)$$

Iz variance tako izhaja, da je standardni odklon portfelja $\sigma_P = \sqrt{8,49} = 2,91\%$. Iz tega primera vidimo, da lahko banka zaradi diverzifikacije posojil/leasinga zmanjša tveganje njenega portfelja naložb.

Slika 6: Pričakovani donosi in standardni odkloni različnih možnih portfeljev



Vir: lastni prikaz


Zgornji primer tako kaže, da v primerih, ko je ima banka na razpolago dva možni naložbe (npr. posojilo in leasing), ki sta med seboj negativno korelirani, lahko z diverzifikacijo (razpršitvijo) zmanjša tveganje. Iz zgornjega primera izhaja, da bi banka s takšnim portfeljem posojila in leasinga imela manjše tveganje, kot če bi se samo odločilo za leasing podjetju Y.

2.4 Potrošniška posojila, njihov razvoj in kreditno tveganje

2.4.1 Potrošniška posojila v Združenih državah Amerike

Potrošniško financiranje se je pričelo razvijati v ZDA po drugi svetovni vojni, vendar največjo rast je doseglo v zadnjih dvajsetih letih. Predvsem po drugi svetovni vojni (v obdobju 1948-1965) je bila inflacija v ZDA izjemno nizka (povprečna letna inflacija je znašala 1,7%), ZDA pa so dosegale pozitivno gospodarsko rast. Poleg tega se ljudje v času druge svetovne vojne niso množično odločali za nakup trajnih dobrin. K razvoju potrošniških posojil so tako prispevali različni socialno-ekonomski dejavniki. Zaradi stabilnega gospodarskega položaja in rasti prebivalstva, se je povpraševanje po trajnih dobrinah močno povečevalo, kar je bila tudi osnova za razvoj potrošniškega financiranja, ki je omogočalo nadaljnjo rast ameriškega gospodarstva. Če je še v prvih letih po drugi svetovni vojni veljalo, da so določeni izdelki namenjeni samo premožnim (npr. avtomobili), je uvedba potrošniškega financiranja omogočila, da si je nakup lahko privoščil večji del prebivalstva ZDA. Za ZDA tako že zadnjih petdeset let velja, da je potrebno dobro živeti že danes če tudi na kreditih. Ravno zaradi tega se je v ZDA pojavil tudi izraz »potrošniška družba« (Gelpi, Labruière, 2000, str. 105).

Slika 7: Rast potrošniških posojil po drugi svetovni vojni v ZDA glede na vrsto posojilodajalcev



Vir: Federal reserves, marec 2011

Iz zgornje slike izhaja, da je bila rast potrošniških posojil predvsem v zadnjih 20ih letih izjemna. Večino potrošniških posojil še vedno odobrijo poslovne banke, vendar na drugi strani je delež sekuritiziranih posojil (ang. securitised loans) v močnem vzponu. V ZDA je sekuritizacija pomembna za izdajatelje plačilnih kartic in za avtomobilska posojila, saj se lahko osnovni posojilodajalec odloči, da bo finančne vire za odobreno posojilo poiskal pri drugih posojilodajalcih, v zavarovanje pa bo zastavil terjatve iz odobrenih potrošniških posojil. Prvi sekuretizacija potrošniških posojil se je zgodila leta 1986, ko je družba Salomon Brothers »odkupila« terjatve od plačilnih kartic od Banc One v obliki posebnega vrednostnega papirja imenovanega Certificates for Amortising Revolving Debts – CARDS. Razvoj sektoretizacije je šel od tega trenutka naprej z nesluteno hitrostjo naprej (Kothari, 2006, str. 387-388).


Ker se je številno potrošnikov, ki so si bili pripravljeni sposoditi denar, da so ga lahko porabili za takojšen nakup blaga in storitev, vse večje, so bili posojilodajalci primorani razviti sistem za odobravanje posojil različnih vrst, od potrošniških posojil, hipotekarnih posojil ter odobrite kreditnih kartic. Z povečevanjem zadolževanja potrošnikov se je tudi večal njihov absolutni dolg. Pojavljati so se začele plačilne zamude, ko so posojilojemalci vračali posojila z zamudo oziroma svojega dolga sploh niso bili sposobni odplačati. Razvoj t.i. potrošniške družbe je tudi pripeljal do tega, da ljudje, ki niso bili več sposobni plačevati svojih dolgov,

hkrati pa za poplačilo teh dolgov niso imeli dovolj premoženja (npr. nepremičnin, avtomobilov, itd.) so morali razglasiti t.i. osebni stečaji (Caouette et.al, 2008, str. 203).

Že vrsto let različne institucije v razvitih državah zbirajo podatke o neplačevanju obveznosti iz naslova plačilnih kartic, ki predstavljajo en del potrošniških posojil. Ameriško bančno združenje (ABA) vsak kvartal objavlja podatke o t.i. zamudah pri plačilih potrošniških posojil (ang. consumer credit delinquency rate) medtem, ko Federal Deposit Insurance Corporate v ZDA natančneje spremlja tudi gibanje neplačil iz naslova plačilnih kartic. Zgodovinsko gledano so neplačila posojil obstajala od nekdaj in tudi cilj posojilodajalcev ni, da zmanjšajo odstotek zamujenih plačil na nič. Ključno za posojilodajalca je, da lahko odobri posojilo čim večjemu številu fizičnih oseb, pri čemer mora ohraniti delež neplačil na sprejemljivi ravni (Frumkin, 2005, str. 46-47).

Szilank (2008, str. 14) je ob začetku finančno-ekonomske krize, ki se je zgodila v drugi polovici leta 2007 ugotavljal, da so se v preteklosti neplačila s strani imetnikov plačilnih kartic gibala znotraj ozkega koridorja. Szilank je tudi napovedoval, da se bo v času krize delež neplačil povečeval, vendar le-ta ne bo dosegel tako visokih odstotkov, kot jih bodo dosegala neplačila s strani pravnih oseb.

Slika 8: Odstotek zapadlih terjatev iz naslova plačilnih kartic starih od 30 do 89 dni v ZDA




Vir: Federal Deposit Insurance Corporate, 2010

Iz zgornjega grafa lahko razberemo, da so bila pričakovanja Szilank pravilna, saj se je z začetkom finančne krize res povečal delež neplačil imetnikov plačilnih kartic, vendar je z izboljševanjem ekonomske situacije, delež neplačil zopet padel na raven pred finančno krizo. Če gledamo odstotek neplačil skozi daljše obdobje vidimo, da je delež neplačanih zapadlih terjatev iz naslova plačilnih kartic starih od 30 do 89 dni v ZDA v zadnjih dvajsetih letih v povprečju gibal med 2% in 3%. Z drugimi besedami to pomeni, da lahko povprečni izdajatelj plačilnih kartic v ZDA pričakuje, da bo v povprečju od 2% do 3% njegovih terjatev iz naslova plačilnih kartic ne bo plačano v roku 30 dni po zapadlosti.

2.4.2 Posojila fizičnim osebam v Evropski uniji

Tudi v državah Evropske Unije (EU) je pomen posojil iz dneva v dan večji, vendar pa obstajajo velike razlike med državami v EU glede uporabe in dostopnosti do posojil. Po podatkih ECB je delež neodplačanih posojil fizičnih oseb v primerjavi z BDP najvišji na Danskem, kjer ta odstotek dosega kar 139% BDP. V spodnji sliki lahko vidimo, da na zgornjem delu grafa, kjer je odstotek posojil v primerjavi z BDP visok, lahko najdemo večinoma »stare« članice EU medtem, ko države, ki so se EU pridružile šele po letu 2004, najdemo večinoma v spodnjem delu grafa. V večini novih članic EU delež neodplačanih posojil fizičnim osebam ne dosega 40% BDPja. Slovenija tukaj ni izjema, saj znaša delež neodplačanih posojil fizičnih oseb samo 24% (Evropska centralna banka, marec 2011).


Slika 9: Delež neodplačanih posojil fizičnih oseb v BDP v državah EU v letu 2009



Vir: Evropska centralna banka, marec 2011

V zadnjem desetletju so tudi v Evropski uniji (EU) posojila fizičnim osebam dosegala rekordne rasti, pri čemer so glavnino rasti prinesle nove članice v EU, ki še v 90ih letih 20. stoletja niso imel močno razvitega financiranja, kot so ga imele stare članice EU. Tudi v najrazvitejših državah EU, kot so Velika Britanija, in Španija, ki so že prej imele velik odstotek posojil v primerjavi z bruto domačim proizvodom (BDP), še vedno dosega pozitivne rasti v obsegu potrošniškega financiranja, kar kaže na to, kako velik pomen imajo posojila na BDP (Vandone, 2009, str. 4).

Slika 10: Rast posojil posameznikom v starih državah EU in novih državah EU v letih 2004-2010




Vir: Evropska centralna banka, marec 2011

Iz zgornjega grafa lahko vidimo, da se je vrednost neodplačanih posojil fizičnim osebam v novih državah EU od leta 2004 do začetka leta 2011 povišala kar za 6x, medtem, ko se je višina neodplačanih posojil povečala zgolj za 41%.

2.4.3 Posojila fizičnim osebam v Sloveniji

Tudi v Sloveniji smo v zadnjih letih zabeležili hitro rast posojil fizičnim osebam, vendar pa je posebnost Slovenije v tem, da je rast prihajala večinoma iz stanovanjskih posojil in ne toliko od potrošniških posojil. Kot je razvidno iz spodnjega grafa se je neodplačana vrednost posojil fizičnih oseb v Sloveniji od januarja 2004 do januarja 2011 povečala za 218%, vendar je bila največja rast dosežena na segmentu stanovanjskih posojil. Neodplačana vrednost stanovanjskih posojil se je od januarja 2004 do januarja 2011 povečala kar za 549% medtem, ko se je neodplačana vrednost potrošniških posojil povečala le za 87%. Zaradi hitre rasti stanovanjskih posojil, se je njihov delež v celotnih posojilih fizičnim osebam povečal iz 25,2% na 52,2%, delež potrošniških posojil pa zmanjšal iz 51,2% na 30,5% (ECB, 2011).

Slika 11: Rast posojil fizičnim osebam v Sloveniji od leta 2004 naprej



Vir: ECB, 2011

3 SISTEMI KREDITNEGA TOČKOVANJA

Finančne institucije so v začetku 60ih leti 20. stoletja pričela uporabljati t.i. sistem kreditnega točkovanja (ang. credit scoring). Postavi se vprašanje kaj pravzaprav je sistem kreditnega točkovanja? Da lahko odgovorimo na to vprašanje, je potrebno to besedno zvez razdeliti na dva pojma *kredit* in *točkovanje*. Besedo *kredit* danes preprosto pomeni »kupi sedaj, plačaj kasneje« ne glede na to ali gre za vsakodnevno potrošnjo, nakup trajnega blaga ali celo finančnih instrumentov. Beseda kredit izhaja iz latinske besede *kredo*, kar pomeni zaupanje. Če se nekdo odloči, da bo komu nekaj posodil, mora imeti zaupanje, da mu bo ta oseba izpolnila svoj del dogovora. Veliko ljudi smatra dostop do kredita kot pravico, vendar ta pravica prinaša tudi obveznosti. Posojilojemalci morajo tako plačati ceno s katero si ustvarijo zaupanje, vrnejo kredit v skladu z dogovorjenimi roku in plačajo premijo, ki jo zaračuna posojilodajalec, če mu posojilojemalec ne bi vrnil denarja nazaj (Anderson, 2007, str. 3-4).

Točkovanje se nanaša na matematično operacijo s katero določamo rang posamezni situaciji na podlagi realne ali pričakovane kakovosti z namenom razlikovanja med posameznimi situacijami. Z razpoložljivimi podatki tako tvorimo numerično oceno (npr. podjetje ocenimo s 45 točkami), ki izraža določeno

kakovost medtem, ko s posamičnimi črkami identificiramo razrede, ki predstavljajo posamezno kakovostno raven (npr. podjetje, ki ima več kot 50 točke je v razredu A, podjetje, ki manj kot 50 točk se nahaja v razredu B) (Anderson, 2007, str. 5).

Sistem kreditnega točkovanja tako predstavlja odločitveni model na podlagi katerega posojilodajalec oceni ali bo nekomu odobril kredit ali ne. Ti modeli tako določajo kdo bo dobil kredit, v kakšni višini in s kakšno strategijo bo posojilojemalec maksimalno koristil od posojilodajalca. Sistemi kreditnega točkovanja tako posredno ocenjujejo kreditno sposobnost za vsakega posojilojemalca posebej. Posojilodajalec s sistemom kreditnega točkovanja napravi dve odločitvi. Prva odločitev je ali bo odobril kredit novemu kupcu in druga odločitev je kakšen limit bo odobril temu kupcu (Thomas et. al, 2002, str.9).

3.1 Kako delujejo sistemi kreditnega točkovanja

Večina ljudi razume sistem točkovanja na način, kot to poznamo iz športnih tekmovanj. Sodniki ocenjujejo nastop tekmovalca in vsak napravi oceno, ocene sodnikov se seštejejo in dobimo končni rezultat. Na tekmovanjih tako sodniki določijo zmagovalca, vendar pa pri sistemih kreditnega točkovanja odločimo ali bo nekdo dobil kredit ali ne. Vsa podjetja pa seveda ne uporabljajo enakih sistemov kreditnega točkovanja. Vsako podjetje lahko razvije svoj sistem kreditnega točkovanja tako, da se lahko celo zgodi, da nekdo v banki A ne bi dobil posojila, v banki B pa bi ga dobil (Anderson, 2007, str. xxxi).

Sistemi kreditnega točkovanja imajo največjo dodano vrednost takrat, ko podjetje usmerja oziroma jim služi kot podpora pri odločitvah, ki vplivajo na njihove kupce. V postopku odločitve posojilodajalci definirajo različne scenarije, ki jim ga omogoča sistem kreditnega točkovanja, ter izberejo ustrezne naslednje korake, kot na primer odobritev/zavrnitev, najvišja vrednost posojila, obrestna mera, doba odplačevanja, itd. Dostikrat pa se podjetja ne odločajo samo na podlagi rezultata sistema kreditnega točkovanja, ampak jim to služi kot eden izmed podatkov, ki vplivajo na končno odločitev – podjetja si dostikrat pustijo svobodo, da na koncu na podlagi nekih drugih podatkov ali subjektivne ocene odločijo, ali bodo odobrile posojilo ali ne (Burrell, 2007 , 81-82).

Dobri sistemi kreditnega točkovanja uporabljajo modele predvidevanja (algoritme), na podlagi katerih rangirajo posameznike na podlagi verjetnosti, da bodo »dobri« ali »slabi« v prihodnosti. Sistemi tako temeljijo na preteklih izkušnjah in njihovo sporočilo je zelo jasno. Če sistem odloči, da je nekdo »dober«, potem ga je potrebno sprejeti z odprtimi rokami (model predvideva nizko tveganje) oziroma je

nekdo »slab«, katerega je potrebno zavrniti (model za te osebe predvideva večje tveganje). Algoritmi na podlagi katerih se napravi sistem kreditnega točkovanja so lahko zelo različni, vendar se najpogosteje pojavljajo v obliki regresijske enačbe (Gujarati, 2004, str. 52):

$$y = b_0 + b_1x_1 + b_2x_2 + \dots + b_nx_n + e \quad (14)$$

Regresijska enačba ima tako naslednje elemente:

- x ...neodvisna spremenljivka
- b ...regresijski koeficient je faktor, ki pojasnjuje moč neodvisne spremenljivke – določa relativno pomembnost neodvisne spremenljivke
- y ... odvisna spremenljivka, ki na pove rezultat regresijske enačbe
- e ...rezidual, ki predstavlja delež v regresijski enačbi, katerega ni možno razložiti

3.2 Razvoj sistemov kreditnega točkovanja

Obstajajo različni načini, kako razviti sistem kreditnega točkovanja. Kot je že bilo omenjeno, so se prvi sistemi kreditnega točkovanja pojavili v 60ih leti 20. stoletja in od takrat so ti sistemi doživeli pravi razcvet. Eden izmed razlogov za uspeh sistemov kreditnega točkovanja, je komercializacija računalnikov. Marsikdo je bili skeptičen, da lahko računalnik napravi ustrezno odločitev, vendar so kmalu ugotovili, da avtomatizirani sistemi kreditnega točkovanja prinašajo številne prednosti. V osnovi lahko delimo razvoj sistemov kreditnega točkovanja na tri obdobja, in sicer:

Pionirji razvoja kreditnega točkovanja – 1935-1959

Začetki razvoja sistema kreditnega točkovanja so za današnje razmere nenavadne. Leta 1936 je angleški statistik Ronald Aylmer Fisher objavil znanstveni članek o linearni diskriminantni analizi, na podlagi katere je razvrstil različne vrste očesnih šarenic. Fisherjeve raziskave niso bile koristne samo za medicino, ampak so predstavljale osnovo za razvoj napovedovalne statistike (ang. predictive statistics). Leta 1941 je David Durand dokazal, da se podobna statistična analiza lahko uporabi tudi za razlikovanje med dobrimi in slabimi poslovnimi odločitvami. David Durand je analiziral 7.200 anuitetnih posojil, ki jih odobrilo 27 različnih podjetij svojim komitentom. Durand je razpolagal s podatki o starosti, spolu, zaposlitvi, poklicu, podjetju v katerem so zaposleni in premoženju posameznika. Zanimivo je predvsem to, da je le majhen delež vseh posojil takih, ki

so jih vzele ženske, analiza pa je pokazala, da so le-te manj tveganje, kot moški (Thomas et.al, 2004, str. 5-6).

Začetki avtomatizacije sistemov kreditnega točkovanja – 1960-1979

V 60ih letih 20. stoletja je večina trgovcev v Združenih državah Amerike svojim strankam nudila nakupe na obroke. Obvladovanje takšnega načina financiranja za kupce je trgovcem povzročalo veliko težav, saj je zaradi decentraliziranega odločanja o odobritvi nakupa na obroke nastalo veliko prevar in slabih terjatev. Leta 1963 je blagovnica Montgomery Ward v sodelovanju s svetovalnim podjetjem Fair Isaac, razvila prvo t.i. vedenjsko točkovanje (angl. behavioural scoring) in tako centralizirala odločitve o odobritvi nakupa na obroke na enem mestu. Kmalu so tudi drugi trgovci, izdajatelji plačilnih kartic ugotovili, da jim takšen način obvladovanja kreditnega tveganja prinaša veliko koristi. Na podlagi sistema kreditnega točkovanja, so v zelo kratkem času znižali delež neplačil (ang. default rate) za več kot 50% (Anderson, 2007, str. 40).

Ekspanzija sistemov kreditnega točkovanja – po letu 1980

Do leta 1980 so se z razvojem sistemov kreditnega točkovanja ukvarjali predvsem v ZDA medtem, ko v Evropi in drugod po svetu takšnih sistemov niso uporabljali. Po letu 1980 so začele predvsem angleške banke uporabljati sisteme kreditnega točkovanja predvsem zaradi širitve ponudbe bančnih produktov nekomitentom, razširitev uporabe plačilnih kartic in širitve potrošniškega financiranja. Pred letom 1980 sta se uporabljala predvsem diskriminantna analiza in linearni verjetnostni modeli (ang. linear probability model), z razvojem osebnih računalnikov in njihovo uporabo v komercialne namene, so omogočali analize in izdelave sistemov kreditnega točkovanja s pomočjo drugih statističnih orodij. Danes se najpogosteje uporablja logistična regresija, sledita pa ji ekspertni sistemi (ang. expert systems) in nevronske mreže (ang. neural networks). V 80ih letih 20. stoletja se je tudi povečalo število t.i. kreditnih birojev, ki so se specializirali za izdelovanje bonitetnih ocen za fizične osebe (Anderson, 2007, str. 42-43).

3.3 Vrste sistemov kreditnega točkovanja

Kot smo videli zgoraj, je smisel sistema kreditnega točkovanja ocenitev ali je posameznik zaupanja vredna oseba, kar v praksi pomeni, da je posameznik sposoben vrniti dolg in ali je pripravljen vrniti dolg. V teoriji se pojavljajo različni sistemi kreditnega točkovanja, kjer vsaki sistem ocenjuje določen segment

tveganja. Različne vrste kreditnega točkovanja so predstavljene v nadaljevanju (Paleologo, 2009, str. 490):

Ocenjevanje novih strank (ang. application scoring)

Ocenjevanje novih strank se nanaša na ocenjevanje kreditne sposobnosti novih strank, ko le-te zaprosijo za posojilo ali izdajo plačilne kartice. Z ocenjevanjem novih strank ocenjujemo tveganje nove stranke na podlagi ocenjevanje socialnih, demografskih, finančnih in drugih podatkov, ki jih običajno pridobimo na podlagi izpolnjenega obrazca oziroma pristopnice.

Vedenjsko ocenjevanje (ang. behavioral scoring)

Vedensko ocenjevanje je podobno ocenjevanju novih strank s tem, da pri tem ocenjujemo obstoječe stranke. Posledica tega je, da ima posojilodajalec oziroma izdajatelj kartic že določene podatke o obnašanju stranke do posojilodajalca (npr. za vsakega posojilojemalca ima banka podatek ali je le-ta plačal svoje obveznosti ob zapadlosti oziroma ali je le-ta plačeval svoje obveznosti z zamudo).

Ocenjevanje izterjave (ang. collection scoring)

Ocenjevanje izterjave je vrsta ocenjevanja, ko posamezne stranke razdelimo v različne segmente glede na intenzivnost izterjave. Na različnih segmentih izvajajo podjetja različne ukrepe za izterjavo. Običajno podjetja uporabljajo tri različne stopnje glede na zamudo pri plačilu:

- **Zgodnja faza izterjave** (običajno 10-20 dni zamude); stranka zamuja nekaj dni, posojilodajalec običajno pošlje prijazno pismo, v katerem pozove stranko, da poravnava svoje obveznosti;
- **Srednja faza izterjave** (običajno 20-60 dni zamude), stranka je že bila opozorjena s strani posojilodajalca, posojilojemalec je omejil nadaljna črpanja posojila oziroma omejil uporabo plačilne kartice;
- **Pozna faza izterjave** (običajno nad 60 dni); posojilodajalci običajni predajo takšne stranke v eksterno izterjavo oziroma pričnejo izvajati ustrezne pravne postopke za izterjavo (npr. unovčitev zavarovanj, kjer le-to obstaja, začetek postopka na sodišču,...).

Zaznavanje goljufij (ang. fraud detection)

Pri zaznavanju goljufij gre za posebne sistem ocenjevanja verjetnosti, da bo prišlo do zlorab oziroma goljufij. Zlorabe ali goljufije se lahko zgodijo že pri posredovanju pristopnice (npr. napačni podatki o dejanskem pošiljatelju) oziroma bo prišlo do zlorab v kasnejši fazi (npr. zloraba plačilne kartice).

3.4 Ocenjevanje profitabilnosti

Posebna vrsta sistema točkovanja je ocenjevanje profitabilnosti (ang. profit scoring). V zadnjih nekaj leti so posojilojemalci pričeli razmišljati, kako bi spremenili koncept »zmanjševanja tveganja« v koncept »maksimiziranja profita« posamezne stranke. Če bi želeli poenostaviti stvari bi rekli, da je potrebno samo spremeniti definicijo kaj je »dobra« stranka v obstoječih sistemih točkovanja in smo s tem rešili tudi to vprašanje. Vendar, zadeva ni tako enostavna, saj na kreditno tveganje oziroma bolj natančno višino slabega dolga vplivajo odločitve, ki so bile sprejete ob dodelitvi posojila (izdaji plačilne kartice). Prav tako pa na samo donosnost posamezne stranke vplivajo tudi drugi dejavniki kot na primer stroški marketinga, zagotavljanja dodatnih storitev, cenovna politike, itd. Zelo hitro vidimo, da vzpostavitev ocenjevanja profitabilnosti ni tako enostavna, saj v praksi določeni problemi (Thomas, 2000, str. 165-167), in sicer:

- težave pri pridobivanju in obdelovanju podatkov; če bi želeli preverjati profitabilnost vsakega posamezne stranke, bi potrebovali podatke o vsakem prihodku in strošku, ki ga ustvari posamezna stranka, kar bi pomenilo, da mora imeti banka ali izdajatelj plačilnih kartic izjemno dobro razvit informacijski sistem, ki omogoča takšno zbiranje podatkov;
- na kakšnem nivoju meriti profitabilnost stranke; ali bi morale podjetje gledati profitabilnost na vsakem posameznem produktu ali na celotnem poslovanju s stranko; če bi gledali profitabilnost po posameznem produktu se lahko zgodi, da bi stranko zavrnilo (npr. stranka ima pri poslovni banki posojilo, ki ga redno odplačuje, stranka pa je zaprosila še za izdajo plačilne kartice, ki pa bi jo uporabila samo nekajkrat letno – ali je smiselno, da takšno stranko zavrnemo pri izdaji plačilne kartice, kar bi lahko povzročilo, da stranka prenese posojilo na drugo banko); če pa gledamo profitabilnost na nivoju celotnega poslovanja s stranko, predpostavljamo, da je odločitev o izbiri produkta s strani stranke njena samostojna odločitev in lahko izgubimo možnost vplivanja na višji profit.

4 NAPOVEDOVALNA STATISTIKA

Statistika v sodobnem gospodarstvu igra pomembno vlogo, čeprav so ljudje velikokrat skeptični do njene uporabne vrednosti. Že v prejšnjem poglavju je bilo omenjeno, da so sodobni bonitetni sistemi nastali na podlagi statističnih raziskav. Predvsem v 20. stoletju se je pojavilo kar nekaj novih statističnih orodij, na podlagi katerih lahko napovedujemo rezultate v določenem kontroliranem okolju z dovolj veliko verjetnostjo, da lahko na podlagi tega napravimo ustrezno odločitev. Za sodobne bonitetne modele se tako že vrsto let uporabljajo različna statistična orodja, vendar ima vsako orodje svoje prednosti in slabosti. Preden začnemo sestavljati statistični model, moramo opredeliti naslednje dejavnike, ki ključno vplivajo na končni rezultat. Odločitve, potrebne pri izdelavi statističnega modela so (Anderson, 2007, str. 164):

- **primernosti**; ali je uporabljeno statistično orodje prava izbira za naš bonitetni sistem;
- **hitrost uvajanja**; kako hitro se lahko ljudje naučijo uporabljati statistično orodje in ali model omogoča hitro reagiranje na spremenjene razmere v gospodarstvu;
- **prilagodljivost**; ali lahko model uporabimo za točno specifičen problem s katerim se soočamo;
- **kakovost izhodni podatkov**; ali razumemo izhodne podatke in jih je možno interpretirati na enostaven način;
- **interakcije**; ali lahko z modelom ugotovimo interakcije med spremenljivkami in jih uporabimo v statističnem modelu;
- **neuravnoteženost podatkov**; če imamo zelo majhno število primerov, ki so slabi, so nekatera statistična orodja nezanesljiva;
- **zveznost/nezveznost podatkov**; nekatera statistična orodja se uporabljajo samo z nezveznimi podatki, druga lahko uporabljajo tako zvezne kot tudi nezvezne podatke;
- **izjemni primeri**; posamezni podatki, ki močno odstopajo od povprečja lahko povzročijo napake v statističnem modeliranju oziroma na njihovi podlagi lahko napravimo napačne zaključke.

Danes se pri izdelavi bonitetnega modela največkrat uporablja naslednjih pet statističnih orodij (Anderson et.al, 2009, str. 728):

- Linearna regresija (ang. linear regression),
- Diskriminantna analiza (ang. discriminant analysis),
- Logistična regresija (ang. logistic regression),
- Drevo odločanja (ang. decision tree),
- Nevronske mreže (ang. neural networks),

Zgornjih pet statističnih orodij lahko razdelimo v dve skupini, in sicer v prvo skupino sodijo linearna regresija, diskriminantna analiza in logistična regresija, v drugo skupino pa drevo odločanja in nevronske mreže. Skupna značilnost prve skupine je, da sodijo ta orodja med t.i. parametrične metode (ang. parametric methods), medtem ko druga skupina sodi med t.i. neparametrične metode (ang. non-parametric methods). Razlika med parametričnimi in neparametričnimi metodami je v tem, da neparametrične metode uporabljajo manj (restriktivnih) predpostavk in porazdelitvijo verjetnosti v preučevanem vzorcu. Večina parametričnih metod zahteva, da so spremenljivke zapisane v določenem intervalu, pri čemer je zelo pomembno kakšna je aritmetična sredina preučevanih podatkov, varianca, standardni odklon, itd. V kolikor razpolagamo z nominalnimi ali ordinalnimi podatki, parametrične metode niso več ustrezne in v teh primerih je bolj primerno, da uporabimo neparametrična orodja za analizo izbranega vzorca podatkov (Anderson et.al, 2009, str. 728-729). V nadaljevanju naloge so na kratko predstavljeni parametrični modeli ter kakšne so njihove prednosti oz. slabosti pri izdelavi bonitetnega sistema.

4.1 Linearna regresija

Linearna regresija se uporablja za raziskovanje razmerji med dvema spremenljivkama. Enostavna linearna regresija predpostavlja, da imamo dve spremenljivki, ena spremenljivka je odvisna (y) in druga neodvisna (x). Ti dve spremenljivki predstavljata določeno populacijo in kar nas običajno zanima je, da želimo razložiti »obnašanje« odvisne spremenljivke na podlagi gibanja neodvisne spremenljivke oziroma kako se spreminja odvisna spremenljivka, če se spreminja neodvisna spremenljivka. Če želimo napraviti model, s katerim bomo razložili gibanje odvisne spremenljivke na podlagi neodvisne spremenljivke, moramo odgovoriti na tri vprašanja (Wooldridge, 2000, str. 22):

- kakšen je odnos med odvisno in neodvisno spremenljivko;

- običajno nikoli ne obstaja popolna korelacija med odvisno in neodvisno spremenljivko, zato moramo upoštevati tudi vpliv drugih dejavnikov na odvisno spremenljivko;
- ali smo lahko prepričani, da ob nespremenjenih ostalih pogoji lahko rečemo, da smo pravilno definirali razmerje med odvisno in neodvisno spremenljivko.

Na vsa zgornja vprašanja lahko odgovorimo tako, da napišemo naslednjo enačbo:


$$y = \beta_0 + \beta_1 x_1 + u \quad (15)$$

Zgornji enačbi rečemo tudi linearna regresija z dvema spremenljivkama ali linearni bivariatni regresijski model. Spremenljivka u predstavlja t.i. motnjo (ang. error term) v regresijskem modelu in tako ovira stabilno razmerje med odvisno in neodvisno spremenljivko. Obstaja več razlogov za motnjo, pri čemer je najpreprostejša razlaga, da nikoli ne moremo z neodvisnimi spremenljivkami 100% vplivati na odvisno spremenljivko (Greene, 2002, str. 8). Zaradi tega običajno spremenljivke u ne upoštevamo pri uporabi regresijske enačbe.

Linearna regresija se pri izdelavi bonitetnih modelov zelo redko uporablja, saj ima kar nekaj omejitev oziroma deluje na nekaterih predpostavkah, za katere velja, da v realnosti ne držijo (Anderson, 2007, str. 167):

- linearnost: regresijska enačba predpostavlja, da se neodvisne spremenljivke povečujejo linearno
- neodvisne spremenljivke so fiksne v opazovanem vzorcu;
- povprečna vrednost spremenljivke u je nič (0)
- homoskedastičnost - predpostavka o normalna porazdelitev spremenljivke u (spremenljivka u ima enako varianco pri vseh neodvisnih spremenljivkah)
- obstoj nizke korelacije med spremenljivkami (Gjurati, 2004, str. 66).

Slika 12: Homoskedastičnost



Vir: Gjurati, 2004, str. 67

V povezavi z modeliranjem bonitetnih sistemov se velikokrat uporablja tudi t.i. model linearne verjetnosti (ang. linear probability modelling) na podlagi katerega ocenjujemo verjetnost, da bo posameznik poravnal svoje obveznosti v rokih. Model linearne verjetnosti je zelo podoben, vendar namesto absolutnih števil, uporablja odstotke (Anderson, 2007, str. 167).

$$P(\text{good})_i = \beta_0 + \sum_{j=1}^p \beta_j x_{ij} + u_i \quad (16)$$


Verjetnost vsakega posameznega zapisa i , je vsota konstante in zmnožka uteži (β) in neodvisne spremenljivke, pri čemer zanemarimo u_i . Za uporabo tega modela, je potrebno definirati vse neodvisne spremenljivke binarno, in sicer 0 ali 1. S takšnim preoblikovanjem podatkov pa nastopijo še nekatere druge težave, kar ima za posledico, da »parametersko« enačbe preoblikujemo v »neparametersko« enačbo. To ima za posledico, da (Anderson, 2007, str. 167):

- s preoblikovanjem v binarne podatke rešimo težavo linearnosti in normalne porazdelitve spremenljivk,
- uporabimo točkovanje, na podlagi katerega rangiramo rezultate in odpravimo problem heteroskedastičnosti,
- če operiramo z dovolj velikim vzorcem zmanjšamo vpliv standardne napake (ang. standard error) in avtokorelacije.

4.2 Diskriminantna analiza

Linearna diskriminantna analiza se je pojavila že v 30ih letih 20. stoletja, ko je Ronald Fisher na podlagi določenih spremenljivk preučeval ali lahko razlikujemo med dobrimi in slabimi podjetji. Fisher je pri analizi upošteval določene finančne kazalnike o poslovanju posameznih podjetij in na podlagi te tehnike mu je uspelo določiti mejo, ki ločuje dobra podjetja od slabih podjetij. Takšnemu razlikovanju rečemo tudi diskriminantna funkcija (Sironi, Resti, 2007, str. 287).

Slika 13: Grafična predstavitev linearne diskriminantne analize



Vir: Sironi, Resti, 2007, str. 288

Na sliki 13 je predstavljen poenostavljen Fisherjev model, kjer so v množici A solventna podjetja in v množici B nesolventna podjetja. Vsa podjetja so predstavljena samo z dvema neodvisnima spremenljivkama, x_1 in x_2 . Z linearno diskriminantno analizo smo na podlagi dveh neodvisnih spremenljivk izračunali vrednost »z«, ki razlikuje podjetja v množici A in množici B. Če bi imeli več neodvisnih spremenljivk, bi izračunali vrednost »z« z naslednjo formulo (Sironi, Resti, 2007, str. 288):

$$z_i = \sum_{j=1}^n \gamma_j x_j$$

(17)

$$\gamma = \sum^{-1} (x_1 - x_2)$$

S koeficientom γ_j v linearni enačbi smo tako določili vrednost »z«, na podlagi katere razlikujemo med dvema možnima izidoma (solventna in insolventna). Z drugimi besedami to pomeni, da mora biti vrednost z_i takšna, da je hkrati tudi največja možna razdalja med dvema povprečnima vrednostma (z_A in z_B) dveh skupin podjetij (solventna in insolventna). V praksi to pomeni, da mora biti vrednost »z« za solventna podjetja v največji možni meri podobna med seboj in hkrati kar čim bolj različna od vrednosti »z« za nesolventna podjetja (Sironi, Resti, 2007, str. 289).

Diskriminantno analizo pa lahko uporabimo tudi v procesu odobravanja kredita, saj pridemo do dveh možnih zaključkov, in sicer ali odobrimo kredit ali ga ne odobrimo. Z diskriminantno analizo si pomagamo pri odločitvi tako, da ugotovimo kakšne odločitve bi bile najboljše na podlagi manjšega vzorca preteklih podatkov o odobrenih kreditih. Prednost takšnega sistema je, da dejansko poznamo obnašanje posameznikov, ki smo jim v preteklosti odobrili kredit. Seveda pa tukaj nastane težava, saj se zanašamo na pristranski vzorec, kjer dejansko opazujemo samo tiste posameznike, ki jim je banka odobrila kredit v preteklosti, ne razpolagamo pa s podatki kako bi se obnašali posamezniki, ki jim nismo odobrili kredita. V tem primeru govorimo o pristranskosti vzorca (Thomas et.al, 2002, str.42).

4.3 Logistična regresija

Logistični regresijski model je eno izmed najbolj priljubljenih statističnih orodij za razvrščanje problemov. Logistični regresijski model se za razliko od drugih statističnih orodij (npr. diskriminanta analiza ali navadne linearne regresije) lahko uporabljajo tudi v primerih, ko distribucija spremenljivk ni normalna in je ena izmed najbolj primernih orodij za kreditno točkovanje. Običajno se sicer uporablja t.i. binarna logistična regresija, ki predvideva dva možna izida (npr. da ali ne), čedalje bolj pa se uporabljajo tudi druge vrste logističnih regresij, s katerimi se povečuje natančnost rezultata. Primeri takšnih regresij sta multinominalna regresija, ki predvideva več možnih izidov ter ordinalna logistična regresija (Ong et.al, 2005, str. 42).

Bistvo logistične regresije je napovedovanje verjetnosti nastanka določenega dogodka z vgradnjo podatkov v logistično krivuljo. Najbolj tipični primeri uporabe logistične regresije izvirajo iz medicinskih raziskav (npr. ugotavljanje verjetnosti

srčnega napada osebe glede na starost, spol in indeks telesne mase), uporabljajo pa se tudi za ugotavljanje verjetnosti ali bo neka oseba prenehala plačevati svoje obveznosti (Hosmer, Lemeshow, 2000, str. 1-2).

Če želimo pravilno razumeti rezultat logistične regresije moramo razločevati med dva osnovna pojma, in sicer obeti (ang. odds) in razmerje obetov (ang. odds ratio). Za lažje razumevanje teh dveh pojmov je najbolje, če pogledamo konkretni primeri, in sicer predpostavljamo, da imamo dva vzorca ljudi. V prvem vzorcu je 100 moških, v drugem vzorcu 100 žensk. Z raziskavo smo ugotovili, da 60 moških ima izpit za motor in le 20 žensk ima motor. Obeti (odds), da ima moški izpit za motor je 60:40 oziroma 1,5:1. Na drugi strani so obeti, da ima ženska izpit za motor 20:80 oziroma 0,25:1. Razmerje obetov (odds ratio) je v tem primeru 1,5:0,25 oziroma 6, kar kaže na to, da je verjetnost, da ima moški izpit za avto bistveno večja kot, da ima izpit ženska (Košmelj, 2001, str. 228-229).

Logistična regresija uporablja proces imenovan **ocena največje verjetnosti** (ang. maximum likelihood estimation), ki (Kleinbaum, 2007, str. 604-605):

- transformira odvisne spremenljivke v logistično funkcijo,
- ugotavlja kakšni bi morali biti koeficienti in
- določa vrednost koeficientov na način, da bo maksimiziral logaritemsko funkcijo verjetnosti.

Rezultat ocene največje verjetnosti je tako logistična funkcija, ki jo definiramo kot:

$$\ln\left(\frac{p(\text{good})}{1-p(\text{good})}\right) = b_0 + b_1x_1 + b_2x_2 + \dots + b_kx_k + e \quad (18)$$


Vrednost na levi strani enačbe je naravni logaritem razmerja med verjetnostjo enega in drugega izidom (npr. razmerje med plačnikom in neplačnikom) oziroma naravni logaritem razmerja obetov (odds ratio). Koeficient b_0 je t.i. koeficient prestrežanja (ang. intercept) in nam pove kolikšno bi bila verjetnost za nastanek dogodka, če bi bila vrednost posameznega regresijskega koeficienta ($b_1, b_2, \dots, b_k$) enaka nič. Vsak posamezen regresijski koeficient neodvisnih spremenljivk nam povem velikost oziroma prispevek k oceni verjetnosti. Pozitiven predznak regresijski koeficient pomeni, da posamezna neodvisna spremenljivka povečuje verjetnost nastanka dogodka medtem, ko negativen predznak regresijskega koeficienta pomeni zmanjševanje verjetnosti nastanka dogodka. Pri regresijskih koeficientih je pomembno tudi to, da višja kot je vrednost koeficienta, večji vpliv ima na verjetnost dogodka (Menard, 2009, str. 8).

Ker je logistično funkcijo, zapisana v zgornji formuli težko interpretirati, jo s preoblikovanjem spremenimo v odstotkovno verjetnost z uporabo naslednje formule (Kleinbaum, 2010, str. 6-7):

(19)

Logistično funkcijo pa lahko predstavimo tudi grafično, kjer lahko funkcija zavzame vrednosti med 0 in 1. Na spodnjem grafu je tako predstavljeno na x osi naravni logaritem verjetnosti, na y osi pa odstotkovno verjetnost.

Slika 14: Logistična funkcija



Vir: Anderson, 2007, str. 171

5 UPORABA LOGISTIČNE REGRESIJE ZA ZMANJŠANJE KREDITNEGA TVEGANJA PRI IZDAJI PLAČILNIH KARTIC

5.1 Pregled uporabe napovedovalnih statistik za zmanjševanje kreditnega tveganja

Na temo obravnavanja kreditnega tveganja je bilo v Sloveniji napisanih kar nekaj diplomskih, magistrskih in doktorskih nalog, vendar večina teh nalog obravnava različne teoretične pristope pri obvladovanju kreditnega tveganja. Empiričnih raziskav na področju obvladovanja kreditnega tveganja v Slovenije je manj in v večini primerov se le-te nanašajo na kreditno tveganje pri pravnih osebah. Samo nekaj nalog in znanstvenih člankov je bilo napisanih na področju potrošniških posojil medtem, ko naloge oziroma znanstvenega članka na temo kreditnega tveganja plačilnih kartic v Sloveniji še ni bilo.

Med zanimivejša slovenska dela na področju obvladovanja kreditnega tveganja sodi magistrsko delo Gergete (2005), ki je obravnaval modeliranje bonitetne lestvice plačilne discipline slovenskih podjetij. Gergeta je v nalogi obravnaval dva bonitetna modela s katerimi lahko obvladujemo kreditno tveganje pri prodaji z odlogom plačila za pravne osebe. Modela, ki sta predstavljena v nalogi temeljita na podatkih o finančnih kazalnikih podjetij in na podlagi podatkov o preteklih zamudah. Z uporabo nominalne logistične regresije je Gergeta sestavil modela, pri čemer je natančno prvega modela 62,9%, natančnost drugega modela pa 68,7%.

Javoršek (2007) je v magistrskem delu Napovedovanje zamude pri plačilu obveznosti do dobaviteljev slovenskih podjetij uporabil logistično regresijo za model napovedovanja plačilne discipline, ki upošteva finančne kazalce podjetja, velikost podjetja, tržni delež, dejavnost ter pretekle zamude. Natančnost modela je kar 75,07%, v primeru povečanja tolerance neplačila (iz nič v pet dni) je uspešnost modela še boljša, in sicer 81,23%.

Šenk (2008) pa je s pomočjo nevronske mreže izračunavala boniteto podjetij, pri čemer je sta najpomembnejša podatka za ugotavljanje bonitete podjetja podatek o dodani vrednosti in skupnih prihodkih na zaposlenega. V kolikor se dodana vrednosti in prihodki enakomerno povečujejo skozi leta, je verjetnost neplačila bistveno manjša, kot pa pri podjetjih, katerih dodana vrednost in prihodki bodisi padajo, bodisi se gibljejo v nasprotni smeri.

Na področju kreditnega tveganja potrošniških posojil je bila objavljen znanstveni članek na temo bonitetnega sistema za potrošniška posojila z uporabo nevronske mreže (Šušteršič et.al, 2009). V strokovnem članku so predstavili uporabno statističnega modela nevronske mreže za izdelavo bonitetnega sistema za potrošniška posojila na podlagi nabora več kot 60ih podatkov o odobrenih

potrošniških posojilih. Rezultate, ki so jih dobili z uporabo nevronske mreže so tudi primerjali z rezultati logistične regresije. Raziskava je pokazala, da je natančnost pri napovedovanju plačilne discipline kreditjemalca nevronske mreže znašala 79,3% medtem, ko je natančnost logistične regresije malce nižja, in sicer 76,1%.


5.2 Opredelitev problema in načrt dela

Pri izdelavi magistrskega dela sem se osredotočil na problem, ki ga imajo pri obvladovanju kreditnega tveganja novo izdanih plačilnih kartic izdajatelj plačilnih kartic v Sloveniji. Za potrebe magistrskega dela sem tako uporabil podatke o izdanih plačilnih karticah enega izmed večjih izdajateljev plačilnih kartic v Sloveniji, ki se dnevno srečuje z vprašanjem ali neki fizični osebi, ki zaprosi za izdajo plačilne kartice, odobritev izdaje le-te. V veliki večini primerov osebo, ki zaprosi za izdajo kartice, ne poznajo oziroma razpolaga z manjšim naborom podatkov o tej osebi (večinoma podjetje razpolaga z demografskimi podatki, podatki o zaposlitvi, izobrazbi, plači,...). Seveda je v podjetju cilj, da se izda čim več plačilnih kartic, vendar na drugi strani pa nastaja tudi tveganje neplačila s strani imetnikov plačilne kartice, ki povzročajo škodo podjetju.

Problem, ki ga podjetje ima je, kako identificirati, na podlagi ozkega nabora podatkov o prosilcu za izdajo plačilne kartice, zaupanja vredne osebe in jih ločiti od tistih, ki svojih obveznosti ne bodo poravnali. Anderson (2007, str. 74) predlaga, da se je tovrstne naloge potrebno lotiti strukturirano in preučiti različne možnosti, ki se nam ponujajo. Po Andresenu mora biti ta proces sestavljen iz treh faz, in sicer predpriprave, razvoja modela in uporabe modela.

Slika 15: Proces razvoja modela






Vir: Anderson, 2007, str. 74

V okviru predpriprave so v prejšnjih poglavjih magistrskega dela prikazana teoretična izhodišča na podlagi katerih sem pripravili statistični model in predlog rešitve problema katerega preučujem v magistrski nalogi. V nadaljevanju magistrske naloge je najprej predstavljen razvoj modela, s katerim bo lahko podjetje zmanjšalo kreditno tveganje pri novo izdanih karticah, in sicer so najprej predstavljeni vhodni podatki za model in nato sam statistični model. Pomembno je poudariti, da je model možno narediti samo na podlagi zgodovinskih podatkov. Ko potrdimo, da je na podlagi zgodovinskih podatkov model za podjetje ustrezen lahko le-tega implementiramo in ugotovljamo na podlagi novo izdanih plačilnih karticah ali smo dosegli cilj, ki smo si ga zadali.

5.3 Razvoj modela za obvladovanje kreditnega tveganja novo izdanih plačilnih kartic

Predpostavka pri razvoju modela za obvladovanje kreditnega tveganja pri novo izdanih karticah je, da obstaja nabor podatkov, ki nam omogočajo, da z ustrezno obdelavo in analiziranjem razdelimo osebe v dve skupine, in sicer na tiste, ki bodo svoje obveznosti plačevali v rokih in tiste, ki svojih obveznosti ne bodo plačevali. V praksi se največkrat izdajatelji plačilnih kartic poslužujejo sistemov kreditnega točkovanja, kjer za vsako osebo izračunajo t.i. »kreditne točke« in mu na podlagi tega bodisi odobrijo bodisi zavrnejo izdajo plačilne kartice.

Slika 16: Porazdelitev kreditnih točk med dobre in slabe plačnike



Vir: Caouette, 2008, str. 208

Iz zgornjega grafa je razvidno, da obstajata dve skupini ljudi, vendar bo prišlo med tema dvema skupinama do določenega prekrivanja pri številu doseženih točk. Seveda pa je pri tem pomembno kje postavimo mejo med obema skupinama (ang. cut-off point). Kako postaviti to mejo je seveda odvisno tudi od cilja, ki ga želimo doseči, vendar se največkrat ta meja postavi tam kjer se izenači prihodek ustvarjen s strani ene skupine z izgubo, ki bi jo ustvarila druga skupina. Če to mejo postavimo na takšen način, se zavestno odločimo, da bo del plačilno kartico dobil tudi del populacije, ki svojih obveznosti ne bo poravnal pravočasno (Caouette, 2008, str. 208).

5.3.1 FICO sistem točkovanja


Leta 1958 je podjetje Fair Isaac Corporation izdelalo sistem kreditnega točkovanja, ki se imenuje FICO. FICO je bil zasnovan na način enostavnega zbiranja podatkov o fizičnih osebah in izdelava bonitetne ocene, ki se ga danes v ZDA poslužuje več kot 70% vseh posojilodajalcev. Podatek, ki ga zagotavlja FICO je število kreditnih točk za vsakega posameznika. Minimalno število točk, ki jih lahko posameznik dobi je 350, največje število točk pa 850. Sistem FICO določa konkretno število točk, pri čemer je le-ta sestavljena iz 5 različnih kategorij, in sicer (Rich, 2007, str. 20):

- plačilna disciplina v preteklosti, ki vsebuje podatke o tem ali je oseba plačevala z zamudo ali brez zamude (ta podatek predstavlja 35% končne ocene),

- absolutni znesek, ki ga posameznik dolguje in njegovo gibanje skozi čas (predstavlja 30% končne ocene),
- čas opazovanja plačilne discipline (15% končne ocene),
- število novih posojila v določenem časovnem obdobju (10 % končne ocene),
- vrsta posojil, ki jih uporablja posameznik (10% končne ocene).

Smith (2010, str. 7) je ugotavljal kakšna je distribucija točk oseb, ki jim je FICO izračunal št. kreditnih točk. Cilj analize je bil ugotoviti ali se je zaradi finančne krize spremenilo število točk, ki jih imajo posojilojemalci, ki so sklenili hipotekarno posojilo. Pri analizi je na eni strani primerjal celotno populacijo (vse osebe, ki imajo FICO točke), ter osebe, ki imajo tudi hipotekarno posojilo. V spodnji grafu vidimo porazdelitev FICO točk po razredih in po letih (za leto 2006 in leto 2008) za osebe, ki imajo hipotekarno posojilo (rdeč in zelen stolpec), poleg tega pa je še z modrim stolpcem predstavljena porazdelitev celotne populacije glede na število FICO točk.

Slika 17: Porazdelitev FICO točk v letu 2008



Vir: Smith, 2010, 26

Smith je ugotavljal, da je delež oseb, ki dosega med 650 in 799 točk in imajo hipotekarni kredit večji, kot pa jih ima celotna populacija v tem razredu. Zelo zanimiv pa je tudi preskok med letom 2006 in letom 2008. Vidimo lahko, da je

delež oseb, ki so imele hipotekarno posojilo in hkrati manj kot 699 točk, njihov delež upadel, medtem ko se je delež oseb s hipotekarnim posojilom in so imeli hkrati več kot 700 povečal. Smith je ta trend povezoval s dejstvom, da so zaradi finančne krize posojilodajalci omejili odobravanje hipotekarnih posojil osebam, ki so dosegale manjše število točk (Smith, 2010, str. 7).

Po vzoru sistema FICO sem v magistrski nalogi napravil sistem kreditnega točkovanja, na podlagi katerega bo lahko slovenski izdajatelj plačilnih kartic zmanjševal kreditno tveganje pri novo izdanih plačilnih karticah.

5.4 Podatki za pripravo statističnega modela

Za potrebe magistrskega dela sem uporabil bazo podatkov podjetja o izdanih plačilnih karticah v obdobju od 21.9.2007 do 27.5.2008, ki vsebuje podatke prejete na pristopnici za izdajo plačilne kartice o 8.971 izdanih plačilnih karticah ter določene podatke o njihovi plačilni disciplini, ko so le-ti kartico že prejeli in z njo tudi plačevali. Za vsakega imetnika posebej sem razpolagal s podatki, ki so predstavljeni v spodnji tabeli.

Tabela 2: podatki o imetnikih plačilne kartice

#	Naziv podatka	Vrsta podatka	Tip lestvice
1	Zakonski stan	Opisni podatek	Nominalni
2	Št. članov gospodinjstva	Številčni podatek	Lestvica
3	Stanovanjske razmere	Opisni podatek	Nominalni
4	Podjetje v katerem je zaposlen	Opisni podatek	Nominalni
5	Delovno mesto v podjetju	Opisni podatek	Nominalni
6	Stopnja izobrazbe	Opisni podatek	Nominalni
7	Delovna doba	Številčni podatek	Lestvica
8	Plača	Številčni podatek	Lestvica
9	Višina mesečnega obroka kredita	Številčni podatek	Lestvica
10	Spol	Opisni podatek	Nominalni
11	Starost	Številčni podatek	Lestvica
12	Območje bivanja	Opisni podatek	Nominalni
13	Način poravnave mesečnih obveznosti	Opisni podatek	Nominalni
14	Število prejetih opominov	Številčni podatek	Ordinalni
15	Število blokad kartic ³	Številčni podatek	Ordinalni

Vir: interni podatki slovenskega izdajatelja plačilnih kartic

³ Ko se zgodi blokada kartice ni več možno plačevati s kartico, če tudi je na njej še prosti limit.

Ker so podatki o posameznih imetnikih kartic zaupne narave, kakor tudi podatki o samem kreditnem tveganju podjetja, katero je priskrbelo podatke za izdelavo statičnega modela, konkretnih imen in podatkov za potrebe magistrske naloge niso razkriti. Za predstavitev nabora odvisnih in neodvisnih spremenljivk sem se tako posluževal združevanja posamičnih podatkov v različne skupine, pri čemer je namen takšne predstavitve prikaz obstoja razlik med različnimi podskupinami posameznih podatkov ne glede na to, da dejanski naziv posamezne podskupine oziroma vrednosti neodvisne spremenljivke ni razkrit.

Na podlagi pregleda strokovne literature, upoštevanja prednosti in slabosti posamezne vrste statističnega modeliranja, sem za potrebe magistrske naloge uporabil t.i. **binarno logistično regresijo** na podlagi katere sem oblikoval model kreditnega točkovanja za novo izdane plačilne kartice. Binarna logistična regresija se uporablja takrat, ko želimo predvideti ali se bo nek dogodek zgodil ali ne - odvisna spremenljivka ima dva možna izida. Odvisna spremenljivka mora tako biti definirana kot diskretna spremenljivka, pri čemer lahko le-ta doseže dve možni vrednosti, in sicer 0 in 1. V primeru plačilnih kartic je to lahko:


- imetnik plačilna kartice je plačal vse svoje obveznosti v roku (0) ali
- imetnik plačilne kartice ni plačal vseh svojih obveznosti v roku (1).

Za izdelavo regresijskega modela pa lahko uporabimo različne neodvisne spremenljivke, ki so lahko bodisi diskretne spremenljivke bodisi ali zvezne spremenljivke (Mesa, 2003, str. 229).

5.4.1 Opredelitev odvisne spremenljivke

V zgornji tabeli so predstavljene vse spremenljivke, s katerimi sem razpolagal pri izdelavi magistrske naloge. Med petnajstimi spremenljivkami sta bili tudi dve spremenljivki, ki ju lahko opredelimo kot neodvisni spremenljivki, in sicer *število prejetih opominov* in *število prejetih blokad kartic*. Med tema dvema spremenljivkama pa seveda obstaja močna povezava. Izdajatelj plačilnih kartic namreč v primeru, če imetnik kartice ne plača svojih obveznosti v roku 7 dni po zapadlosti računa, pošlje imetniku opomin, kjer imetnika obvesti, da obveznosti iz naslova plačilne kartice ni poravnal. V kolikor imetnik plačilne kartice tudi po prejemu opomina ne poravnava svojih obveznosti v roku 10 dni, potem izdajatelj plačilne kartice blokira nadaljnjo uporabo le-te. Tako ima izdajatelj plačilnih kartic že danes vpeljan dvostopenjski sistem obvladovanja kreditnega tveganja, pri čemer je prejem opomina predpogoj za blokado plačilne kartice.

Slika 18: Proces plačevanja obveznosti iz naslova plačilne kartice



Vir: izdajatelj plačilnih kartic

Korelacija med podatkom o številu prejetih opominov in številu prejetih blokad je izjemno visoka, kar dokazuje tudi spodnja tabela.

Tabela 3: Korelacija med številom prejetih opominov in številom prejetih blokad

		Št. blokad	Št. opominov
Št. blokad	Pearsonova korelacija	1	0,914
	Sig. (2-tailed)		0,000
	N	8.971	8.971
Št. opominov	Pearsonova korelacija	0,914	1
	Sig. (2-tailed)	0,000	
	N	8.971	8.971

Vir: lastni izračun

Korelacija med številom prejetih opominov in številom prejetih blokad znaša na preučevanem vzorcu imetnikov plačilnih kartic kar 0,914, kar kaže na izjemno močno korelacijo. Na podlagi tega lahko tudi povzamemo, da je prejem opomina zelo dober indikator za izdajatelja plačilnih kartic, da bo imetnik prejel tudi blokado kartice. Za nadaljevanje statistične analize sem tako uporabil podatek o prejetem opominu kot odvisno spremenljivko medtem, ko podatka o prejemu blokade nisem upošteval, saj je le-ta logična posledica prejetega opomina. Lahko bi tudi rekli, da je prejeti opomin za izdajatelja plačilnih kartic zelo dober indikator, da se z imetnikom plačilne kartice dogaja nekaj, kar ima lahko za posledico povečanje kreditnega tveganja.

Za potrebe binarne logistične regresije sem tako preoblikoval podatek o številu prejetih opominov v podatek ali je neka oseba prejela opomin ali ne, pri čemer podatek o dejanskem številu prejetih opominov v nadaljnjo analizo ni bil vključen – tako sem preučeval verjetnost prejema opomina za vsakega posameznega imetnika plačilne kartice.

Tabela 4: Klasifikacija imetnikov kartic glede na prejeti opomin

	Frekvenca	%	Kumulativni %
Ni opomina	4.781	68,8	68,8
Prejeti opomin	2.167	31,2	100,0
Skupaj	6.948	100,0	

Vir: lastni izračun

Kot vidimo iz zgornje tabele, kar 68,8% imetnikov plačilne kartice v opazovanem vzorcu v opazovanem obdobju ni prejelo nobenega opomina, medtem ko je 31,2% imetnikov plačilne kartice prejelo vsaj en opomin.

5.4.2 Opredelitev neodvisnih spremenljivk

Pri opredelitvi neodvisnih spremenljivk sem se soočil s problemom nepopolnih podatkov. Od vzorca 8.971 imetnikov plačilnih kartic je bilo v bazi kar 2.023 imetnikov plačilne kartice, za katere nisem razpolagal z vsemi podatki (problem nepopolne baze podatkov). Problem manjkajočih podatkov se pri statističnih analiza konkretnih primerov dogaja zelo pogosto. Razlogi za manjkajoče podatke so seveda zelo različni (poškodovane baze podatkov, nedoslednosti pri izpolnjevanju baz, itd.), vendar na drugi strani obstajajo različni načini kako statistično obdelovati takšne baze podatkov. Hunt in Jorgensen (2003, str. 433) sta predstavila tri metode na podlagi katerih lahko statistično obdelujemo bazo podatkov z manjkajočimi podatki, in sicer:

- statistično analizo napravimo samo na vzorcu podatkov, kjer imamo vse podatke (ang. complete-case method), pri čemer izločimo vse spremenljivke, za katere nimamo podatkov;
- statistično analizo napravimo na vseh dostopnih primerih, pri čemer manjkajoče podatke nadomestimo s podatki, ki jih imajo primerljivi enote v vzorcu (ang. available-case method), vse ostale pa izločimo iz analize;

- ostali modeli na podlagi katerih lahko vnesemo manjkajoče podatke (npr. analiza z manjkajočimi podatki, vnašanje naključnih podatkov, nadomeščanje manjkajočih podatkov s povprečnim podatkom, itd.).

Vsaka izmed zgoraj naštetih metod ima svoje prednosti in slabosti. Slabost »complete-case« metode je v tem, da je lahko pristranska (t.i. problem »self-selection bias«), ker lahko izločimo podatke, ki so ključnega pomena za uspešnost analize. Na drugi strani McKnight (2007, str. 147) navaja, da nadomeščanje manjkajočih podatkov s podatki o primerljivimi imetnik kartic (available-case method) ni smiselno kadar imamo nam manjka več kot ena spremenljivka pri posameznem podatku.

Za namen magistrske naloge sem uporabil metodo »complete-case«, pri čemer sem zanemaril tiste imetnike plačilnih kartic v vzorcu, katerim so manjkale posamezne neodvisne spremenljivke. Razlog za izbiro »complete-case« metode je bil, da od 2.023 imetnikov plačilnih kartic kar 1.916 takšnih imetnikov plačilnih kartic, ki jim manjka podatek o vsaj dveh spremenljivkah (najbolj pogosto je manjkal podatek o zakonskem stanu, stanovanjskih razmerah in izobrazbi). V večini primerov gre za podatke, ki jih imetnik plačilnih kartic niso izpolnili, saj je bila njihova izpolnitev prostovoljna (npr. zakonski stan, stanovanjske razmere, itd.), ki jih izdajatelj plačilnih kartic do sedaj ni upošteval pri odobritvi izdaje kartice medtem, ko obvezni podatki v bazi niso manjkali (npr. starost, naslov, spol, višina plače, itd.). V nadaljevanju so tako predstavljene vse posamezne neodvisne spremenljivke in njihova povezava z odvisno spremenljivko.

Spol imetnikov plačilnih kartic

V proučevanem vzorcu je bilo 4.224 predstavnikov ženskega spola in 2.724 predstavnikov moškega spola. Marrez in Schmit (2009, str. 3) sta raziskovala ali obstaja razlika med kreditnim tveganjem danih posojil moškim in ženskam v eni izmed severnoafriških bank. V raziskavi sta ugotovila, da obstajajo določene razlike med spoloma, pri čemer je kreditno tveganje pri ženska malenkost večje kot pri moških. Na primeru slovenskega izdajatelja plačilnih kartic po hitrem pregledu do takšne ugotovitve ne moremo priti.

Tabela 5: Prejeti opomini glede na spol imetnika plačilne kartice

			Ženska	Moški	Skupaj
Prejeti opomin	Ni opomina	Skupaj % znotraj spola	2.922 69,2%	1.859 68,2%	4.781 68,8%

	Prejeti opomin	Skupaj % znotraj spola	1.302 30,8%	865 31,8%	2.167 31,2%
Skupaj		Skupaj % znotraj spola	4.224 100,0%	2.724 100,0%	6.948 100,0%

Vir: lastni izračun

Na primeru slovenskega izdajatelja plačilnih kartic namreč ugotavljamo, da je namreč 31,8% moških v preučevanem vzorcu prejelo opomin medtem, ko je 30,8% žensk v preučevanem vzorcu prejelo opomin.

Zakonski stan imetnikov plačilnih kartic

V proučevanem vzorcu sem razpolagal s podatkom o petih različnih vrstah zakonskega stana (vdova/ec, samski, poročen, izven zakonska zveza, ločen). Zaradi varstva podatkov so v tabeli posamezni zakonski stani poimenovani s številko, ki ni povezana z vrstnim redom zakonskih stanov opredeljenih v prejšnjem stavku.

Tabela 6: Prejeti opomini glede na zakonski stan

			Z.stan1	Z.stan2	Z.stan3	Z.stan4	Z.stan5	Skupaj
Prejeti opomin	Ni opomina	Skupaj	913	2.643	476	14	735	4.781
		% Z.stan	64,0%	72,1%	63,1%	60,9%	68,2%	68,8%
	Prejeti opomin	Skupaj	513	1.024	278	9	343	2.167
		% Z.stan	36,0%	27,9%	36,9%	39,1%	31,8%	31,2%
Skupaj		Skupaj	1.426	3.667	754	23	1.078	6.948
		% Z.stan	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%

Vir: lastni izračun

Na primeru zakonskega stana vidimo, da že nastajajo določene razlike pri prejetih opominih. Tako vidimo, da ja kar 39,1% predstavnikov Z.stan4 prejelo opomin medtem, ko je »samo« 27,9% predstavnikov Z.stan1 prejelo opomin. Avery in ostali (2004, str. 837) ugotavljajo, da ima lahko sprememba v zakonskem stanu posameznika pomemben vpliv na spremembo kreditnega tveganja in tako lahko podcenjuje ali precenjuje njegovo kreditno tveganje. Avery in ostali namreč predpostavljajo, da je kreditno tveganje poročenih manjše kot pri samskih (možno zaradi tega, ker imajo tudi partnerji svoj dohodek in takšnim osebam lahko tudi partner pomaga plačati dolg) in v primeru, ko bi se poročeni posameznik ločil, posojilodajalec pa s tem podatkom ne bi razpolagal, bi lahko podcenjeval njegovo

bodoče kreditno tveganje. Prav tako bi lahko za samskega, ki se je poročil, precenjeval njegovo kreditno tveganje.

Stanovanjske razmere imetnikov plačilnih kartic

V preučevanem vzorcu sem razpolagal s podatkom o petih različnih vrstah zakonskih stanov (pri starših, lastnik stanovanja, najemnik, podnajemnik, ne želi razkriti).

Tabela 7: Stanovanjske razmere imetnikov plačilnih kartic

			Razmere1	Razmere2	Razmere3	Razmere4	Razmere5	Skupaj
Prejeti opomin	Ni opomina	Skupaj	2.841	198	284	830	628	4.781
		% Razmere	70,7%	61,1%	61,5%	67,3%	69,2%	68,8%
	Prejeti opomin	Skupaj	1.180	126	178	404	279	2.167
		% Razmere	29,3%	38,9%	38,5%	32,7%	30,8%	31,2%
Skupaj		Skupaj	4.021	324	462	1.234	907	6.948
		% Razmere	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%

Vir: lastni izračun

Tako kot pri zakonskem stanu, tudi na primeru stanovanjskih razmer vidimo, da nastajajo določene razlike glede prejema opominov, in sicer kar 38,9% imetnikov plačilne kartice, ki spadajo v skupino Razmere2, so prejeli opomin medtem, ko je samo 29,3% imetnikov plačilne kartice, ki so spadajo v Razmere1, so prejeli opomin.

Marshall et.al (2010, str. 506) so na primeru večje angleške banke ugotavljali kakšen ima vpliv stanovanjskih razmer na kreditno tveganje fizičnih oseb. Raziskava, ki so jo napravili na fizičnih osebah, ki so najele posojilo v obdobju 1995-2003 je pokazala, da osebe, ki niso lastniki stanovanj oziroma hiš in imajo hkrati neredne dohodke in nadpovprečno število otrok, so v povprečju bistveno bolj tvegani kot ostale fizične osebe. Na drugi strani pa fizične osebe, ki dalj časa živijo na istem naslovu (neodvisno od tega ali so lastniki ali najemniki) in so zaposleni velja, da je verjetnost nevračila posojila bistveno manjša.

Starost imetnikov plačilnih kartic

Za vsakega imetnika plačilne kartice sem razpolagal s podatkom o njegovi starosti na dan izpisa iz baze podatkov izdajatelja plačilne kartice. Izdajatelj plačilnih kartic ima tudi sprejeto politiko, da kartic ne izdaja mladoletnim osebam medtem, ko zgornje meje za izdajo plačilne kartice ni. Za potrebe spodnjega pregleda so podatki o starosti imetnikov plačilnih kartic razdeljeni v 3 starostne skupine.

Tabela 8: Starost imetnikov plačilnih kartic

			Star.A	Star.B	Star.C	Skupaj
Prejeti opomin	Ni opomina	Skupaj % Starost	2.283 71,9%	2.110 64,2%	388 79,8%	4.781 68,8%
	Prejeti opomin	Skupaj % Starost	893 28,1%	1.176 35,8%	98 20,2%	2.167 31,2%
Skupaj		Skupaj % Starost	3.176 100,0%	3.286 100,0%	486 100,0%	6.948 100,0%

Vir: lastni izračun

Iz zgornje tabele je razvidno, da je v starostnem razredu C samo 20,2% imetnikov plačilne kartice prejelo opomin, medtem, ko je kar 35,8% predstavnikov starostnega razred B prejelo opomin. Dionne in ostali (1996, str. 320-323) so ugotavljali na primeru ene izmed španskih bank iz konca 80ih let 20. stoletja, da če iz proučevanega vzorca izberemo skupino posameznikov s podobnimi neodvisnimi spremenljivkami (izobrazba, spol, prihodek, itd.) in je edina razlika med posamezniki v vzorcu starost, obstaja pomembna razlika v kreditnem tveganju pri različnih starostnih skupinah. Dionne in ostali so tako sestavili model obrestnih mer, kjer so izračunali, da bi morali posameznikom, ki so v starostnem razredu 18-24, plačevati za 1,42 odstotne točke višjo obrestno mero, kot bi jo morali plačevati posamezniki, ki so starejši od 40 let, da bi banka dosegla enak pričakovani dobiček, pri različnem tveganju obeh starostnih skupin.

Člani gospodinjstva imetnikov plačilnih kartic

V bazi podatkov izdajatelja plačilnih kartic je tudi razpoložljiv podatek o številu članov gospodinjstva v katerem živi imetnik plačilne kartice. Za potrebe magistrske naloge sem oblikoval 3 različne skupine⁴, pri čemer je v bazi izdajatelja plačilnih kartic zavedeno, da v gospodinjstvu živi med 1 in 10 oseb.

Tabela 9: Število članov v gospodinjstvu

			Gospodin.1	Gospodin.2	Gospodin.3	Skupaj
Prejeti opomin	Ni opomina	Skupaj % Gospodin.	1.157 69,3%	1.825 68,7%	1.799 68,6%	4.781 68,8%
	Prejeti opomin	Skupaj % Gospodin.	512 30,7%	832 31,3%	823 31,4%	2.167 31,2%
Skupaj		Skupaj % Gospodin.	1.669 100,0%	2.657 100,0%	2.622 100,0%	6.948 100,0%

Vir: lastni izračun

⁴Imetniki plačilnih kartic so razdeljeni v skupine z majhnim številom članov v gospodinjstvu (1 ali 2 člana), v skupino s srednjim številom članov v gospodinjstvu (3 ali 4 člane) in v skupino z večjim številom članov v gospodinjstvu (5 ali več).

Kot je razvidno iz zgornje tabele bistvenih razlik med tremi skupinami imetnikov plačilnih kartic ni. Zhang (2010, str. 14) je ugotavljala kakšen vpliv ima število članov gospodinjstva na kreditno tveganje. Zhang je vpliv ugotavljala na primeru ljudi, ki so bili vključeni v državni program »downpayment assistance« v ZDA v obdobju 2005-2009, s katerimi se je fizičnim osebam s podpovprečnim dohodki spodbujalo, da postanejo lastniki stanovanj oziroma hiš. Zhang je ugotovila, da velike družine porabijo bistveno več denarja za nakupe osnovnih življenjskih potrebščin (hrana, obleka, ogrevanje, itd.), kot manjše družine. V kolikor imata majhna in velika družina enak dohodek v absolutni višini, potem je verjetnost neplačila kredita pri veliki družini bistveno velja kot pri manjši družini.

Izobrazba imetnikov plačilnih kartic

Pomemben element razlikovanja med imetniki plačilnih kartic je tudi njihova izobrazba. V bazi podatkov izdajatelja plačilnih kartic je namreč zavedeno za vsakega imetnika kakšno stopnjo izobrazbe⁵ ima.

Tabela 10: Stopnja izobrazbe

			Izobr1	Izobr2	Izobr3	Izobr4	Izobr5	Izobr6	Skupaj
Prejeti opomin	Ni opomina	Skupaj	1.145	233	855	1.323	1.147	78	4.781
		% Izobr	70,3%	68,5%	68,1%	66,8%	70,5%	67,8%	68,8%
	Prejeti opomin	Skupaj	484	107	400	658	481	37	2.167
		% Izobr	29,7%	31,5%	31,9%	33,2%	29,5%	32,2%	31,2%
Skupaj		Skupaj	1.629	340	1.255	1.982	1.629	115	6.948
		% Izobr	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%

Vir: lastni izračun

Iz zgornje tabele izhaja, da bistvenih razlik med stopnjami izobrazbe ni. Malenkostno izstopata Izobr1 in Izobr5, vendar to odstopanje ni statistično značilno. Kočenda in Vojtek (2009, str. 15) na primeru češke banke ugotavljata, da je izmed vseh demografskih podatkov ravno izobrazba tista spremenljivka, ki najbolje opredeljuje kreditno tveganje fizičnih oseb – bolj pomembne spremenljivke so ali je prisotni pri financiranju tudi lastna sredstva fizične osebe ter dolžina časa sodelovanja s posojilodajalcem. Kočenda in Vojtek tudi ugotavljata, da fizične osebe z visoko stopnjo izobrazbe nimajo težav pri odplačevanju dolgov medtem, ko so fizične osebe z nizko stopnjo izobrazbe oziroma brez poklicne izobrazbe težje najdejo dobro plačano službo. Prav tako pa je predvsem pri osebah brez poklicne izobrazbe bistveno bolj izrazito, da imajo sklenjeno zaposlitev samo za določen čas (zaposlitev za nedoločen čas prinaša določeno socialno varnost osebe in tako tudi zagotovilo za redni prejem plače).

⁵ Podatek o izobrazbi je razdeljen v 6 skupin, in sicer: brez izobrazbe, dokončna osnovna šola, poklicna srednja šola, gimnazija oziroma tehnična srednja šola, visokošolska oziroma višješolska izobrazba, končna podiplomska izobrazba (magisterij, doktorat)

Delovno mesto na katerem je zaposlen imetnik plačilne kartice

Podobno kot za izobrazbo imetnikov plačilnih kartic se le-ti razlikujejo glede na delovno mesto (v nadaljevanju DM) na katerem so zaposleni. Delovna mesta so v bazi izdajatelja plačilnih kartic klasificirana kot strokovna DM, administrativna DM, vodstvena DM, operativna DM, DM v izobraževanju, DM v zdravstvu ter podatek za tiste, ki se niso želeli opredeliti glede na DM.

Tabela 11: DM imetnikov plačilnih kartic

			DM1	DM2	DM3	DM4	DM5	DM6	DM7	Skupaj
Prejeti opomin	Ni opomina	Skupaj	657	2.089	774	104	284	182	691	4.781
		% DM	66,6%	68,4%	70,3%	57,5%	70,5%	69,2%	72,1%	68,8%
	Prejeti opomin	Skupaj	329	967	327	77	119	81	267	2.167
		% DM	33,4%	31,6%	29,7%	42,5%	29,5%	30,8%	27,9%	31,2%
Skupaj		Skupaj	986	3.056	1.101	181	403	263	958	6.948
		% DM	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%

Vir: lastni izračun

Iz zgornje tabele vidimo, da so razlike med imetniki plačilnih kartic med različnimi skupinami DM zelo različne. Posebej izstopa DM4, kjer je kar 42,5% imetnikov plačilne kartice v proučevanem obdobju prejelo opomin, medtem kot je »samo« 27,9% imetnikov DM7 prejelo opomin.

Delovna doba imetnikov plačilnih kartic

V povezavi s starostjo imetnikov plačilnih kartic je povezan tudi podatek o delovni dobi imetnika plačilne kartice. V bazi podatkov izdajatelja plačilnih kartic je za vsakega posameznega imetnika plačilne kartice dostopen podatek o tem, koliko let delovne dobe je imel, ko je zaprosil za izdajo plačilne kartice. Za namen spodnjega prikaza sem oblikoval štiri razrede imetnikov plačilnih kartic glede na njihovo delovno dobo (0-10 let, 10-20 let, 20-30 let, nad 30 let).

Tabela 12: Delovna doba imetnikov plačilnih kartic

			DD1	DD2	DD3	DD4	Skupaj
Prejeti opomin	Ni opomina	Skupaj	1.720	731	1.276	1.054	4.781
		% DD	64,9%	78,3%	72,1%	66,0%	68,8%
	Prejeti opomin	Skupaj	929	202	493	543	2.167
		% DD	35,1%	21,7%	27,9%	34,0%	31,2%
Skupaj		Skupaj	2.649	933	1.769	1.597	6.948
		% DD	100,0%	100,0%	100,0%	100,0%	100,0%

Vir: lastni izračun

Iz zgornje tabele je razvidno, da obstajajo velike razlike glede v odstotku prejetih opominov znotraj posamezne skupine imetnikov plačilnih kartic. Tako je na primer samo 21,7% imetnikov plačilne kartice v razredu DD2 prejelo opomin medtem, ko je kar 35,1% imetnikov plačilne kartice v razredu DD1 prejelo opomin.

Območje bivanja imetnikov plačilnih kartic

Imetnike plačilne kartice sem razporedil v osem skupin glede na podatek o njihovi poštni številki.

Tabela 13: Območje bivanja

			Reg1	Reg2	Reg3	Reg4	Reg5	Reg6	Reg7	Reg8	Skupaj
Prejeti opomin	Ni opomina	Skupaj	558	361	413	1.416	890	264	385	494	4.781
		% Reg.	69,1%	68,0%	67,0%	68,7%	67,3%	67,2%	73,5%	71,3%	68,8%
	Prejeti opomin	Skupaj	249	170	203	646	432	129	139	199	2.167
		% Reg.	20,9%	32,0%	33,0%	31,3%	32,7%	32,8%	26,5%	28,7%	31,2%
Skupaj		Skupaj	807	531	616	2.062	1.322	393	524	693	6.948
		% Reg.	100%	100%	100%	100%	100%	100%	100%	100%	100%

Vir: lastni izračun

Iz zgornje tabele izhaja, da so imetniki dve skupini imetnikov plačilne kartice malenkostno odstopata od imetnikov plačilnih kartic iz ostalih skupin, in sicer iz Regije7 in Regije8 je 26,5% oziroma 28,7% prejelo opomin medtem, ko je na drugi strani 33% imetnikov plačilne kartice iz Regije3 prejelo opomin.

Dejavnost podjetja v katerem so zaposleni imetniki plačilnih kartic

Za vsakega imetnika posebej izdajatelj plačilnih kartic razpolaga s podatkom o tem v katerem podjetju je zaposlen. Za potrebe izdelave statističnega modela, sem imetnike razporedil v različne skupine podjetij, in sicer na podlagi Standardna klasifikacija institucionalnih sektorjev (SKIS) kot jih vodi Agencija Republike Slovenije za javnopravne evidence in storitve (Uredba o standardni klasifikaciji institucionalnih sektorjev, 2006). Ti razredi so nefinančne družbe, finančne družbe, javna uprava, samozaposleni, nepridobitne institucije, brezposelni.

Tabela 14: Razporeditev imetnikov plačilnih kartic glede na dejavnost podjetja v katerem so zaposleni

			Dej1	Dej2	Dej3	Dej4	Dej5	Dej6	Skupaj
Prejeti opomin	Ni opomina	Skupaj	208	2.953	189	1.070	332	29	4.781
		% dejavnost	66,7%	69,1%	70,3%	70,4%	62,3%	69,0%	68,8%
	Prejeti opomin	Skupaj	104	1.319	80	450	201	13	2.167
		% dejavnost	33,3%	30,9%	29,7%	29,5%	37,7%	31,0%	31,2%
Skupaj		Skupaj	312	4.272	269	1.520	533	42	6.948
		% dejavnost	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%

Vir: lastni izračun

Iz zgornje tabele izhaja, da izmed vseh skupin najbolj odstopajo imetniki plačilnih kartic iz Dejavnosti5, kjer jih je namreč kar 37,7% prejelo opomin medtem, ko pri ostalih skupinah takšnega odstopanja ni.

Obstoječi krediti imetnikov plačilnih kartic

Z vidika ocenjevanja kreditnega tveganja je za izdajatelja plačilnih kartic pomemben tudi podatek o obstoječih kreditih, ki jih ima prosilec za izdajo plačilne kartice. Podatek, s katerim izdajatelj razpolaga je seveda podatek, ki mu ga je v pristopnici javil sam prosilec za izdajo kartice. Ker gre pri tem podatku za osebno občutljiv podatek se hitro postavi vprašanje pravilnost in točnost podatka, s kateri izdajatelj plačilnih kartic razpolaga. Dokler v Slovenji ne bo zaživel SISBON, kjer bo možno takšen podatek dobiti, se mora izdajatelj odločiti ali bo takšnemu podatku zaupal ali ne.

Tabela 15: Krediti imetnikov plačilnih kartic

			KreditA	KreditB	Skupaj
Prejeti opomin	Ni opomina	Skupaj % Kredit	3.803 70,4%	978 63,4%	4.781 68,8%
	Prejeti opomin	Skupaj % Kredit	1.602 29,6%	565 36,6%	2.167 31,2%
Skupaj		Skupaj % Kredit	5.405 100,0%	1.543 100,0%	6.948 100,0%

Vir: lastni izračun

Za namen zgornjega prikaza sem imetnike plačilnih kartic razdelil v dve skupini, in sicer tiste, ki so sporočili, da imajo kredit (ne glede na njihovo absolutno vrednost oziroma relativno vrednost glede na njegov osebni dohodek). Imetnike plačilnih kartic, ki sem jih razporedil v skupino KreditB, jih je kar 36,6% prejelo opomin, medtem, ko je »samo« 29,6% imetnikov v skupini KreditA prejelo opomin.

Način poravnave obveznosti imetnikov plačilnih kartic

Izdajatelj plačilnih kartic omogoča imetnikom različne načine plačevanja obveznosti, in sicer preko klasičnega plačilnega naloga, trajnikom oz. direktno bremenitvijo ali preko zmanjševanja plače pri delodajalcu.

Tabela 16: Način poravnave obveznosti imetnikov plačilnih kartic

			Plačilo1	Plačilo2	Skupaj
Prejeti opomin	Ni opomina	Skupaj % Plačilo	4.436 67,8%	345 84,8%	4.781 68,8%
	Prejeti opomin	Skupaj % Plačilo	2.105 32,2%	62 15,2%	2.167 31,2%
Skupaj		Skupaj % Plačilo	6.541 100,0%	407 100,0%	6.948 100,0%

Vir: lastni izračun

Iz zgornje tabele je razvidno, da obstaja kar pomembna razlika med dvema skupinama imetnikov. Imetniki, ki so izbrali Plačilo2, jih je samo 15,2% prejelo opomin medtem, ko imetniki, ki so izbrali Plačilo1, jih je 32,2% prejelo opomin.

Plača imetnikov plačilnih kartic

Izdajatelj prav tako razpolaga tudi s podatkom o plači imetnika plačilne kartice. Podatke izdajatelj pridobiva na način, da mora vsak prosilec posredovati prijavnico, na katerem njegov delodajalec potrdi kakšno plačo prejema prosilec. Za namen spodnjega prikaza, so podatki o plači preoblikovani v 3 razrede, in sicer na tiste z nizko plačo, povprečno plačo in visoko plačo.

Tabela 17: plača imetnikov plačilne kartice

			Plača1	Plača2	Plača3	Skupaj
Prejeti opomin	Ni opomina	Skupaj % Plača	483 72,9%	4.192 68,1%	106 80,9%	4.781 68,8%
	Prejeti opomin	Skupaj % Plača	180 27,1%	1.962 31,9%	25 19,1%	2.167 31,2%
Skupaj		Skupaj % Plača	663 100,0%	6.154 100,0%	131 100,0%	6.948 100,0%

Vir: lastni izračun

Iz zgornjih podatkov izhaja, da je 19,1% imetnikov, ki so bili razvrščeni v razred Plača3, prejelo opomin medtem, ko je na drugi strani 31,9% imetnikov, ki so bili opredeljeni v razred Plača2 prejelo opomin. Zuccaro (2010, str. 43) je ugotavljal na primeru 323 fizičnih oseb iz Kanade ugotavljal kateri parametri najbolj vplivajo doseženo bonitetno oceno fizične osebe. Zuccaro je sicer razpolagal z zelo ozkim naborom neodvisnih spremenljiv (starost, plača, vrsta delovnega mesta in ali je oseba imetnika American Express kartice) vendar je z diskriminantno analizo ugotovil, da je podatek o plačil daleč najpomembnejši parameter, ki določa bonitetno oceno fizične osebe. Zuccaro je sicer razpolagal s podatkom ali nekdo

prejema plačo mesečno ali tedensko, pri čemer tedensko plačo običajno prejema ljudje, ki nimajo redne zaposlitve. Z uporabo logistične regresije je tako bil podatek o plači ključnega pomena za doseganje boljše bonitetne ocene, pri čemer se je verjetnost dosega boljše ocene povečala za 68%, če je fizična oseba prejela mesečno plačo v primerjavi z osebo, ki je prejela tedensko plačo.

5.5 Uporaba logistične regresije za izdelavo modela za ugotavljanje bonitete fizične osebe

Na podlagi neodvisnih spremenljivk, ki so predstavljene v prejšnjem podpoglavju sem napravil model za ugotavljanje bonitete fizičnih oseb z uporabo binarne logistične regresije. Regresijski model, ki sem ga uporabil je tako omogočil izračunati verjetnost nastanka dogodka, ki je bil označen kot 1 (ena) oziroma z drugimi besedami je model omogočil izračunati verjetnost za vsako posamezno fizično osebo, kakšna je njegova verjetnost, da bo prejel opomin. Regresijski model je tako ocenjeval naravni logaritem verjetnosti med dvema možnima izidoma – prejem opomina oziroma fizična oseba opomina ne bo prejela.

$$\ln(odds) = \ln\left(\frac{\hat{Y}}{1 - \hat{Y}}\right) = a + bX \quad (20)$$

Spremenljivka $\hat{Y}$ v zgornji enačbi tako določa verjetnost nastanka dogodka, ki smo ga označili z 1 (ena) – prejem opomina, medtem ko $1 - \hat{Y}$ pomeni nastanek dogodka, ki smo ga označili z 0 (nič) – ni prejetega opomina.

Iz vzorca podatkov o izdanih plačilnih karticah slovenskega izdajatelja plačilnih kartic sem napravil dve modela, in sicer prvi model je vključeval celotni vzorec imetnikov plačilnih kartic medtem, ko je drugi model vključeval manjšo podskupino imetnikov plačilnih kartic, ki so se med seboj razlikovali pri samo nekaterih neodvisnih spremenljivkah.

5.5.1 Regresijski model na celotnem vzorcu

Pri prvem regresijskem modelu je upoštevan vzorec 6.948 imetnikov plačilnih kartic. Uspešnost regresijskega modela lahko ugotovimo na način, da najprej preverimo kako uspešni bi bili pri napovedovanju verjetnosti, če neodvisnih spremenljivk ne bi poznali oziroma jih ne bi upoštevali (1. test) in šele potem v

model vključimo tudi neodvisne spremenljivke (2. test). Cilj, ki si ga moramo zadati je, da je rezultat drugega testa bistveno boljši, kot je rezultat prvega testa.

Regresijski model brez upoštevanja neodvisnih spremenljivk

Na podlagi dveh možnih izidov, ki jih izračuna regresijski model in ob odsotnosti drugih informacij oziroma neupoštevanja neodvisnih spremenljivk, bi bila najboljša strategija izdajatelja plačilnih kartic, da izda kartice vsem fizičnim osebam, ki so zaprosile za izdajo plačilne kartice, saj bi s takšno strategijo dosegli, da 68,8% imetnikov kartice ne bo prejelo opomina.

Tabela 18: Klasifikacija oseb, ki so vključene v regresijski model

Opazovani vzorec	Napoved		
	Ni opomina	Prejeti opomin	% pravilnih
Ni opomina	4.781	0	100,%
Prejeti opomin	2.167	0	0,0%
Skupni odstotek			68,8%

Vir: Lastni izračun

Če natančneje pogledamo spremenljivke, ki so bile vključene v regresijsko enačbo vidimo, da naravni logaritem verjetnosti med dvema možnima izidoma $\ln(\text{odds})$ znaša - 0,791 oziroma je predvidena verjetnost prejema opomina $e^B = 0,453$. To pomeni, da je verjetnost, da bo določena oseba prejela opomin 0,453. Seveda smisel regresijskega modela je, da v model vključimo tudi neodvisne spremenljivke, ki so predstavljene v podpoglavju 5.4.2.

Tabela 19: Spremenljivke, ki so vključene v enačbo

	B	S.E	Wald	df	Sig.	Exp(B)
Konstanta	-0,791	0,026	933,699	1	0,000	0,453

Vir: Lastni izračun

Regresijski model z neodvisnimi spremenljivkami

Ko v regresijski model vključimo tudi neodvisne spremenljivke, je pomembno, da tako dosežemo boljši rezultat oziroma dosežemo večjo pravilnost napovedovanja prejema opomina, kot smo jo dosegli pri neupoštevanju neodvisnih spremenljivk. Uspešnost vključitve neodvisnih spremenljivk v model lahko vidimo s t.i. Omnibus testa. Omnibus test je namreč statistični test na podlagi katerega ugotavljamo ali je pojasnjena varianca podatkov bistveno boljša kot nepojasnjena varianca vzorca. Ključna vloga omnibus testa je dobiti odgovor ali obstajajo razlike med dvema

skupinama. Omnibus test nam tako daje odgovor ali je smiselno nadaljevati z iskanjem katere skupine v vzorcu so si med seboj bistveno različne. Če nam omnibus test pokaže statistično značilnost, potem obstaja vsaj en pomemben parameter, s katerim lahko dokažemo, da razliko med dvema skupinama (Maxwell, Delaney, 2004, str. 236).

Tabela 20: Omnibus test

	Hi-kvadrat	df	Sig.
Step	264,613	38	0,000
Block	264,613	38	0,000
Model	264,613	38	0,000

Vir: Lastni izračun

Z Omnibus testom smo ugotovimo, da je hi-kvadrat (ang. Chi-square), ki kaže porazdelitev zveznih verjetnostnih porazdelitev vsot kvadratov k neodvisnih normalno porazdeljenih slučajnih spremenljivk, enak 264,613 pri 38 različnih vrednostih neodvisnih spremenljiv. Z uvedbo neodvisnih spremenljivk v model, smo tako hi-kvadrat zmanjšali iz 8.615,598 na 8.350,985. S tem smo pokazali, da dodajanje neodvisnih spremenljivk k regresijskemu modelu ni bistveno povečalo našo sposobnost za predvidevanje končnega rezultata regresijskega modela. To nam potrjuje tudi rezultat v spodnji tabeli.

Tabela 21: Rezultat vključitve neodvisnih spremenljivk v regresijski model

Opazovani vzorec	Napoved		
	Ni opomina	Prejeti opomin	% pravilnih
Ni opomina	4.708	73	98,5%
Prejeti opomin	2.073	94	4,3%
Skupni odstotek			69,1%


Vir: Lastni izračun

Ko smo vključili v model tudi neodvisne spremenljivke smo dosegli 69,1% uspešnost napovedovanja razdelitve med fizičnimi osebami s prejetim oziroma neprejetim opominom (brez vključitve neodvisnih spremenljivk v regresijski model, je bila uspešnost napovedovanja 68,8%).

Mejo med dobrimi in slabimi plačniki smo postavili pri 0,5, kar pomeni, da smo tudi izenačili statistično napako I vrste in statistično napako II vrste. Iz zgornje tabele lahko tudi vidimo, da je model sicer 98,5% uspešen pri napovedovanju oseb, ki ne bodo prejela opomin, vendar je uspešnost modela pri napovedovanju števila oseb, ki bodo prejela opomin samo 4,3%. Z drugimi besedami bi lahko tudi rekli, da smo

z vključitvijo neodvisnih spremenljivk v model identificirali 94 fizičnih oseb, ki so dejansko prejela opomin (od 2.167), vendar je model na drugi strani napovedal, da bo 73 oseb dobilo opomin, vendar ga dejansko niso prejela. Če bi izdajatelj plačilnih kartic upošteval takšen regresijski model bi dejansko zavrnil izdajo plačilne kartice 73 oseba, čeprav le-te ne bi prejele opomina.

Slika 19: Frekvenčna porazdelitev fizičnih oseb glede na verjetnost prejema opomina



Vir: Lastni izračun

Na podlagi tega rezultata lahko ocenimo, da smo z vključitvijo celotnega vzorca 6.948 oseb v regresijski model sicer dosegli, da lahko identificiramo manjše število oseb, ki dejansko predstavljajo kreditno tveganje za izdajatelja plačilnih kartic, vendar je uspešnost regresijskega modela prenizka, da bi ga bilo smiselno upoštevati tudi v realnosti. S tem namenom sem napravil nov regresijski model na manjši podskupini imetnikov plačilnih kartic.

5.6 Regresijski model na podskupini v vzorcu

Kot je predstavljeno v prejšnjem podpoglavju, na podlagi vzorca 6.948 oseb, katerim je bila izdana kartic, logistična regresija ni omogočala bistvenega izboljšanja rezultata predvidevanja ali bo določena fizična oseba prejela opomin ali ne. V statistiki se tovrstni problemi pojavljajo dokaj pogosto in ena izmed možnih rešitev takšnega problema je določitev podskupine v vzorcu, na podlagi česar bomo lahko identificirali takšno podskupino, kjer bomo lahko izboljšali rezultat regresijske analize.

Največkrat se pri tovrstnih problemih uporablja metoda iskanje ujemajočih se parov (ang. pair matching). Takšna metoda je v statistiki zelo uporabna, kadar

želimo napraviti statistično analizo, kjer potrebujemo določeno stopnjo svobode pri izbiri statističnega vzorca. Pri določanju podskupine tako iz naključnega vzorca blokiramo točno določene enote v vzorcu na podlagi v naprej zastavljenih pravil, kar nam omogoča izboljšanje rezultata statistične analize. Še posebej pogosto se uporablja metoda ujemajočih se parov v primerih, ko se neodvisne spremenljivke močno razlikujejo med seboj. Pomembna zagovornika metode ujemajočih se parov sta bil Rosenbaum in Rubin (1983, str. 41-55). V sredini 80ih let 20. stoletja je kar nekaj statistik dokazovalo, da je metoda ujemajočih se parov pristranska in posledično so rezultati takšne statistične analize neuporabni (LaLonde, 1986, str. 604-620). Konec 90ih let 20. stoletja pa sta Dehejia in Wahba (1999, str. 1062) zavrгла LaLondovo kritiko in dokazala, da je metoda ujemajočih se parov primerna rešitev v kolikor nam statistična analiza na naključnem statističnem vzorcu ne omogoča primerne rešitve.

5.6.1 Definiranje podskupine ujemajočih se parov

Pri določanju podskupine ujemajočih se parov sem tako izhaja iz naključnega vzorca 6.948 imetnikov plačilne kartice. Kot je že omenjeno, sem za vsakega imetnika razpolagal s trinajstimi neodvisnimi spremenljivkami in eno neodvisno spremenljivko. Definiranje podskupine ujemajočih se parov sem izvedel v naslednjih korakih:

1. Korak: ugotavljanje števila različnih skupin imetnikov plačilne kartice v celotnem vzorcu, ki so identični med seboj pri vseh 13ih neodvisnih spremenljivkah.

Iz vzorca 6.948 imetnikov plačilne kartice sem identificiral 110 različnih skupin imetnikov plačilnih kartic, kjer so člani posamezne skupine imetnikov plačilne kartice identični v vseh neodvisnih spremenljivkah, razlikujejo pa se samo pri odvisni spremenljivki (t.j. ali je prejel opomin ali ne). Tako sem identificiral 248 imetnikov plačilne kartice, ki imajo vsaj en par, ki je identičen vseh 13inajstih neodvisnih spremenljivkah⁶.

⁶ Za lažjo interpretacijo je potrebno tabelo 22 prebrati na naslednji način, in sicer:

- obstaja 7 oseb, ki so identični v vseh 13ih neodvisnih spremenljivkah
- imamo 3 različne skupine, ki ima vsaka 5 oseb, ki so identični v 13ih neodvisnih spremenljivkah;
- imamo 2 različni skupini, ki ima vsaka 4 osebe, ki so identični v 13ih neodvisnih spremenljivkah;
- imamo 10 različni skupini, ki ima vsaka 3 osebe, ki so identični v 13ih neodvisnih spremenljivkah;
- imamo 94 različni skupini, ki ima vsaka 2 osebe, ki sta identični v 13ih neodvisnih spremenljivkah.

Tabela 22: Skupine imetnikov plačilnih kartic, ki so identični pri vseh 13ih neodvisnih spremenljivkah

Število imetnikov znotraj posamezne skupine, ki imajo identične vse neodvisnih spremenljivk	Število skupin
7	1
5	3
4	2
3	10
2	94
Skupaj	110

Vir: Lastni izračun

2. Korak: ugotavljanje ali se imetniki plačilnih kartic znotraj posameznega para razlikujejo pri odvisni spremenljivki

Cilj drugega koraka je bil ugotoviti ali obstajajo razlike med tem imetniki plačilnih kartic razlike pri odvisni spremenljivki (t.j. ali so prejele opomin ali ne).

Tabela 23: Razlike glede na odvisne spremenljivke znotraj posameznega para

Število imetnikov znotraj posamezne skupine, ki imajo identične vse neodvisnih spremenljivk	Število skupine	Št. skupin, ki so identične v odvisni spremenljivki
2	94	34
3	10	5
4	2	1
5	3	2
7	1	1
Skupaj	110	82

Vir: Lastni izračun

Na podlagi te analize lahko ugotovimo, da obstajajo takšni primeri, ki so med seboj identični tudi pri odvisni spremenljivki – takšnih skupin je 82 oziroma to predstavlja 98 imetnikov plačilne kartice, ki imajo vsaj en par, ki je identičen vseh trinajstih neodvisnih spremenljivkah in tudi odvisni spremenljivki. Glede na to, da je v podvzorcu ostalo samo še 98 imetnikov plačilne kartice, zaradi premajhnega podvzorca, nadaljnja statistična analiza ni bila smiselna.

3. Korak: ugotavljanje ali se imetniki plačilnih kartic znotraj 110 skupin ujemajo v neodvisni spremenljivki

•

Pri pregledu 110 skupine, ki sem jih identificiral v prvem koraku, sem ugotovil, da od 16ih parov, ki imajo 3, 4, 5 in 7 članov, kar 15 parov ima hkrati skupnih tudi osem neodvisnih spremenljivk, in sicer:

- zakonski stan,
- število članov v gospodinjstvu,
- stanovanjske razmere,
- stopnja izobrazbe,
- delovna doba,
- kredit,
- dejavnost podjetja v katerem so zaposleni,
- plačilo s trajnikom.

Tako sem znotraj 110ih skupin identificiral 57 imetnikov plačilne kartice, ki so med seboj identični v osmih od trinajstih neodvisnih spremenljivk. Teh 57 imetnikov plačilne kartice mi je služilo kot osnova, da sem v osnovnem vzorcu 6.948 imetnikov poiskal še preostale imetnike plačilnih kartic, ki so si identični v zgoraj naštetih neodvisnih spremenljivkah. Takšnih imetnikov plačilne kartice je v osnovnem vzorcu 232, kar predstavlja dovolj veliko podskupino imetnikov plačilnih kartic, na podlagi kateri lahko napravimo statistične analize.

5.6.2 Regresijski model podskupini ujemajočih se parov

Tako kot pri regresijskem modelu na celotnem vzorcu, sem tudi na regresijskem vzorcu podskupine ujemajočih se parov uspešnost regresijskega modela ugotavljal na način, da sem najprej preveril kako uspešni bi bili pri napovedovanju verjetnosti, če neodvisnih spremenljivk ne bi poznali oziroma jih upoštevali (1. test) in šele potem v model vključimo tudi neodvisne spremenljivke (2. test).

Regresijski model brez upoštevanja neodvisnih spremenljivk

Na podlagi dveh možnih izidov, ki jih izračuna regresijski model in ob odsotnosti drugih informacij oziroma neupoštevanja neodvisnih spremenljivk, bi bila najboljša strategija izdajatelja plačilnih kartic, da izda kartice vsem fizičnim osebam, ki so zaprosile za izdajo plačilne kartice, saj bi s takšno strategijo dosegli, da 77,2% imetnikov kartice ne bo prejelo opomina.

Tabela 24: Klasifikacija imetnikov plačilnih kartic

Opazovani vzorec	Napoved		
	Ni opomina	Prejeti opomin	% pravilnih
Ni opomina	179	0	100%
Prejeti opomin	53	0	0%
Skupni odstotek			77,2%

Vir: lastni izračun

Če natančneje pogledamo spremenljivke, ki so bile vključene v regresijsko enačbo vidimo, da naravni logaritem verjetnosti med dvema možnima izidoma $\ln(\text{odds})$ znaša - 1,217 oziroma je predvidena verjetnost prejema opomina $e^B = 0,296$. To pomeni, da je verjetnost, da bo določena oseba prejela opomin 0,296.

Tabela 25: Spremenljivke, ki so vključene v enačbo

	B	S.E	Wald	df	Sig.	Exp(B)
Konstanta	-1,217	0,156	60,574	1	0,000	0,296

Vir: Lastni izračun

Regresijski model z neodvisnimi spremenljivkami

Ko v regresijski model vključimo tudi neodvisne spremenljivke, je pomembno, da tako dosežemo boljši rezultat oziroma dosežemo večjo pravilnost napovedovanja prejema opomina, kot smo jo dosegli pri neupoštevanju neodvisnih spremenljivk.

Tabela 26: Omnibus test

	Hi-kvadrat	df	Sig.
Step	50,622	31	0,015
Block	50,622	31	0,015
Model	50,622	31	0,015

Vir: Lastni izračun

S t.i. Omnibus testom lahko ugotovimo, da je hi-kvadrat (ang. Chi-square), ki kaže porazdelitev zveznih verjetnostnih porazdelitev vsot kvadratov k neodvisnih normalno porazdeljenih slučajnih spremenljivk, enak 50,622 pri 31 različnih vrednostih neodvisnih spremenljiv. Potrebno je tudi preveriti kako dobro model predvideva končni rezultat.

Tabela 27: Povzetek regresijskega modela

Korak	-2 Log likelihood	Cox&Snell R Square	Nagelkerke R Square
1	198,729	0,196	0,298

Vir: lastni izračun

Kot mero uspešnosti predvidevanja končnega rezultata lahko razberemo iz -2 Log likelihood. Z Log likelihood namreč napravimo primerjavo med opazovanim vzorcem in rezultatom modela. Boljši rezultat analize bomo dosegli takrat, ko bo ta številka čim manjša, saj bosta tako dejanski vzorec in napovedani vzorec kar se da med seboj podobna (Mittal, 2007, str. 116). Na primeru regresijske analize na podskupini v vzorcu znaša 198,729 medtem, ko je na primeru celotnega vzorca je namreč -2 Log likelihood znašal kar 8.350,985.

Pri linearni regresijski enačbi poznamo t.i. determinacijski koeficient s katerim ocenjujemo kolikšen del variance ene spremenljivke lahko pojasnimo z variiranjem druge. Pri logistični regresiji enakega koeficienta nimamo, vendar pa se uporablja t.i. Cox & Snell R Square, ki nam nakazuje kolikšen del variance pojasnujemo z logistično regresijo. Cox & Snell R Square tako upošteva velikost vzorca na podlagi Log likelihood in nikoli ne more doseči vrednosti 1, medtem ko determinacijski koeficient lahko doseže tudi vrednost 1. Nagelkerke R Square je modificiran Cox & Snell R Square tako, da le-ta lahko doseže vrednost 1. Zaradi tega je običajno Nagelkerke R Square višji kot je Cox & Snell R Square, kar je tudi dejstvo pri našem primeru (Peat, Barton, 2005, str. 256). Regresijski model, ki smo ga napravili nam pojasnjuje 29,8% variabilnosti odstotkovne verjetnosti našega modela.

Tabela 28: Rezultat vključitve neodvisnih spremenljivk v regresijski

Opazovani vzorec	Napoved		
	Ni opomina	Prejeti opomin	% pravilnih
Ni opomina	176	3	98,3%
Prejeti opomin	34	19	35,8%
Skupni odstotek			84,1%

Vir: lastni izračun

Ko smo vključili v model tudi neodvisne spremenljivke smo dosegli 84,1% uspešnost napovedovanja razdelitve med fizičnimi osebami s prejetim oziroma neprejetim opominom (brez vključitve neodvisnih spremenljivk v regresijski model, je bila uspešnost napovedovanja 77,2%). Tako lahko vidimo, da je model sicer

98,3% uspešen pri napovedovanju oseb, ki ne bodo prejela opomin, hkrati pa je uspešnost modela pri napovedovanju števila oseb, ki bodo prejela opomin 35,8% (na primeru logistične regresije na celotnem vzorcu je bila uspešnost samo 4,3%). Z drugimi besedami bi lahko tudi rekli, da smo z vključitvijo neodvisnih spremenljivk v model identificirali 19 fizičnih oseb, ki so dejansko prejela opomin (od 53), vendar je model na drugi strani napovedal, da bodo 3 osebe dobile opomin, vendar ga dejansko niso prejela. Da lahko sestavimo regresijski model pa je potrebno pogledati tudi katere neodvisne spremenljivke smo vključili v model.

Tabela 29: Neodvisne spremenljivke vključene v model

Spremenljivka	B	S.E.	Wald	Df	Sig.	Exp(B)
DM			3,399	3	0,331	
DM1	-19,069	19.819,662	0,000	1	0,999	0,000
DM2	0,517	0,393	1,734	1	0,188	1,678
DM3	-1,376	1,293	1,132	1	0,287	0,253
DD			0,019	5	1,000	
DD1	20,517	40.192,789	0,000	1	1,000	8,139E8
DD2	20,745	40.192,798	0,000	1	1,000	1,022E9
DD3	43,229	56.841,322	0,000	1	0,999	5,936E18
DD4	1,347	49.223,885	0,000	1	1,000	3,847
DD5	43,029	49.210,39	0,000	1	0,999	4,867E18
Plača			10,684	7	0,153	
Plača1	-25,725	40.191,682	0,000	1	0,999	0,000
Plača2	-25,333	40.191,682	0,000	1	0,999	0,000
Plača3	-24,158	40.191,682	0,000	1	1,000	0,000
Plača4	-25,049	40.191,682	0,000	1	1,000	0,000
Plača5	-21,691	40.191,682	0,000	1	1,000	0,000
Plača6	-23,588	40.191,682	0,000	1	1,000	0,000
Plača7	-42,821	56.840,533	0,000	1	0,999	0,000
Spol	-0,211	0,394	0,287	1	0,592	0,810
Star			7,473	8	0,487	
StarA	20,316	40.191,825	0,000	1	1,000	0,000
StarB	19,035	40.191,825	0,000	1	1,000	0,000
StarC	19,445	40.191,825	0,000	1	1,000	0,000
StarD	18,864	40.191,825	0,000	1	1,000	0,000
StarE	19,139	40.191,825	0,000	1	1,000	0,000
StarF	19,667	40.191,825	0,000	1	1,000	0,000
StarG	18,370	40.191,825	0,000	1	1,000	0,000
StarH	18,449	40.191,825	0,000	1	1,000	0,000
Regija			12,178	7	0,095	
Reg1	0,374	1,026	0,122	1	0,715	1,454

Reg2	0,345	0,977	0,125	1	0,724	1,412
Reg3	-0,041	0,944	0,002	1	0,965	0,959
Reg4	-0,333	0,762	0,191	1	0,662	0,717
Reg5	0,928	0,820	1,282	1	0,257	2,530
Reg6	3,813	1,506	6,411	1	0,011	45,282
Reg7	0,467	0,905	0,220	1	0,639	1,596
Konstanta	-16,055	69.612,931	0,000	1	1,000	0,000

Vir: Lastni izračun

Na podlagi zgornje tabele lahko sedaj sestavimo regresijsko enačbo:

$$\ln(\text{odds}) = -16,055 - 19,069 \text{ DM1} + 0,517 \text{ DM2} + \dots + 0,467 \text{ reg7} \quad (21)$$


Pri logistični regresiji je tako pomembno, da tudi pravilno interpretiramo posamezne koeficiente, ki so navedeni v zgornji enačbi. Konstanta -16,055 nam pove pričakovano vrednost logistične enačbe, ko so vsi vrednosti vseh neodvisnih spremenljivk enaki nič.

V zgornji tabeli vidimo, da imamo neodvisno spremenljivko DM, ki pa je v enačbi ne upoštevamo, ampak upoštevamo samo spremenljivke DM1, DM2 in DM3. Spremenljivka DM na pove ali je le-ta statistično značilna, vendar ji ne dodelimo koeficienta, saj ta spremenljivka ni vključena v model. Namesto DM so v model vključene spremenljivke DM1, DM2 in DM3, kjer ima vsaka spremenljivka svoj koeficient. Vsak posamični koeficient nam tako pove povečanje logaritma razmerja obetov, če se neodvisna spremenljivka poveča za eno enoto. Npr. koeficient -19,069 pri neodvisni spremenljivki DM1 nam pove, da za povečanje vrednosti spremenljivke za eno enoto (iz nič na ena), lahko pričakujemo zmanjšanje za 19,069 vrednosti naravnega logaritma obetov, pri čemer se ostale neodvisne spremenljivke ne spremenijo. Za spremenljivko DM1 pa lahko iz zgornje tabele razberemo, da znaša razmerje obetov 0,000. Za spremenljivko DM2 pa vidimo, da znaša koeficient 0,517 in razmerje obetov 1,678.

Za lažjo interpretacijo lahko model spremenimo v odstotkovno verjetnost z naslednjo enačbo:

$$p(\text{good}) = \frac{1}{1 + e^{-16,055 - 19,069 \text{ DM1} + 0,517 \text{ DM2} + \dots + 0,467 \text{ reg7}}} \quad (22)$$

Slika 20: Frekvenčna porazdelitev fizičnih oseb glede na verjetnost prejema opomina



Vir: Lastni izračun

Z uporabo logistične regresije smo tako lahko za popolnoma vsako fizično osebo v podskupini izračunali verjetnost prejema opomina. V zgornjem grafu je tako prikazana frekvenčna porazdelitev fizičnih oseb glede na verjetnost prejema opomina, ki smo jo izračunali na podlagi logistične regresije in hkrati tudi klasifikacijo oseb glede na to ali so tudi dejansko prejeli opomin ali ne.

5.6.3 Vpliv spremembe cut-off vrednosti

V vseh predstavljenih regresijskih modelih je bila mejna vrednost (cut-off) določena kot 0,5 s čimer smo izenačili napako I vrste z napako II vrste. Vseeno pa se pojavlja vprašanje ali je takšna odločitev pravilna oziroma ali lahko z drugačno cut-off vrednostjo dosežemo boljši rezultat regresijskega modela. Goegebeur (2008, str. 7-8) predlaga tri različne pristope k določitvi cut-off vrednosti, in sicer:

- Cut-off vrednost nastavimo na vrednost 0,5 s čimer bomo izenačili napako I vrste z napako II vrste; Goegebeur poudarja, da je smiselno postaviti takšno cut-off vrednost takrat kot se celotna populacija enakomerno

porazdeli med vrednost nič in ena ter so stroški nepravilne napovedi v primerjavi s stroški pravilne napovedi približno enaki


- Cut-off vrednost nastavimo na principu minimalnega števila napak (ang. minimal error rate); takšen sistem je smiseln takrat, ko se vzorec populacije enakomerno razdeli med vrednosti nič in ena ter so stroški nepravilne napovedi v primerjavi s stroški pravilne napovedi približno enaki
- Cut-off vrednost nastavimo na podlagi minimalnih stroškov napačne napovedi Johnson in Wichern (2007, str. 606-621)

Določitev prave cut-off vrednosti je tako vedno kompromis med pravilno napovedanimi pozitivnimi izidi in pravilno napovedani negativni izidi. Ker se obe vrednosti spremenita z vsako spremembo cut-off vrednosti si je težko predstavljati katera cut-off vrednost je idealna. Rešitev na to vprašanje nam omogoča ROC krivuljo (ang. receiver-operator curve). Danes se ROC krivulja pogosto uporablja pri statističnih raziskavah v medicini in za izdelavo sistemov kreditnega točkovanj, saj nam omogoča analizo pravilno napovedanih možnih izidov regresijske enačbe (rezultata sta lahko bodisi 0 ali 1) in delež napačno napovedanih dogodkov (Resti, Sironi, 2007, str. 309).

ROC krivulja je na prvi pogled podobna Lorentzovi krivulji, vendar je določena razlika med ROC krivuljo in Lorentzovo krivuljo. Lorentzova krivulja se namreč uporablja za univariatno analizo odvisne spremenljivke (npr. dohodka) medtem, ko se ROC krivulja uporablja za bivariatno analizo rezultatov, in sicer ali bo stranka plačala z zamudo ali ne (Anderson, 2007, str. 208).

Teoretično najboljša cut-off vrednost takšna, kjer je hkrati najvišji delež pravilno napovedanih pozitivnih izidov in najvišji delež pravilno napovedanih negativnih izidov in jo tako najdemo kot najvišjo točko na ordinatni osi in najbolj levo točko na abscisni osi. Tako točko je v realnosti težko doseči, zato se običajno izbere takšno točko, ki omogoča višjo občutljivost v zameno za nižjo specifičnost – to je točka, ki je najbolj oddaljena od diagonale v ROC krivulji (Satchell, Xia, 2007 str. 5-6).

Slika 21: ROC krivulja



Zgornji graf tako prikazuje dva modela, in sicer v našem primeru naključni model (diagonalna črta) in regresijski model na podlagi podskupine v vzorcu (krivulja nad diagonalno črto). Tako nam graf kaže kakšna je natančnost regresijskega modela, ki prikazuje površino med krivuljo regresijskega modela in naključnega modela. V primeru regresijskega modela tako znaša koeficient natančnosti 0,764. Boljši rezultat regresijske enačbe bi lahko dosegli, če bi cut-off vrednost prestavili iz 0,5 na 0,49, vendar je razlika v boljšem rezultatu regresijske enačbe ne bi bila bistveno boljša.

SKLEP

Upravljanje s finančnimi tveganji je v sodobnih podjetjih eno izmed pomembnejših področij s katerimi se mora ukvarjati sodobno podjetje. Poleg tržnih in likvidnostnih tveganj je izjemno pomembno tudi obvladovanje kreditnega tveganja. Tudi pri podjetjih, ki izdajajo plačilne kartice, so temu tveganju tudi močno izpostavljena. V magistrski nalogi je bilo prikazano, da se bo posameznik odločil za uporabo plačilne kartice v kolikor mu bo izdajatelj odobril izdajo le-te, saj s tem doseže pozitivne koristi zase. Na drugi strani so tudi trgovci pripravljeni sprejemati v plačilne kartice kot instrument plačevanja, saj si s tem povečujejo prihodke. Na tretji strani pa imamo izdajatelje plačilnih kartic, ki na eni strani povečujejo prihodke z večanjem števila izdanih kartic oziroma večanjem števila transakcij s

karticami, na drugi strani se jim z večanjem števila imetnikov kartic s slabo bonitetno povečuje verjetnost neplačila obveznosti ob zapadlosti.

V magistrskem delu sem se osredotočil na to, kako naj se izdajatelj plačilnih kartic sploh odloči ali bo posamezniku odobril izdajo plačilne kartice na podlagi podatkov, ki jih izdajatelj pridobi na podlagi prejete pristopnice. Natančneje sem poskušal ugotoviti ali lahko na podlagi določenih demografskih/socioloških podatkov, ki jih izdajatelj plačilne kartice pridobi iz pristopnice, napravimo model, ki bo v največji možni meri pravilno izračunaval verjetnost neplačila vsakega posameznika, ki je zaprosil za izdajo plačilne kartice. Raziskava, ki sem jo naredil, je temeljila na dejanskih podatkih enega izmed slovenskih izdajateljev plačilnih kartic, pri čemer sem razpolagal s podatki o 6.948 izdanih plačilnih karticah izdanih v obdobju 21.9.2007 do 27.5.2008.

Pri izdelavi statističnega modela sem uporabil binarno logistično regresijo, ki je ena izmed najbolj priljubljenih statističnih orodij za izdelavo tovrstnih problemov. Model, ki sem ga napravil je tako za vsakega imetnika posebej izračunaval verjetnost, da imetnik plačilne kartice ne bo poravnal svojih obveznosti. Kot dogodek, na podlagi katerega sem ugotavljal ali je imetnik plačilne kartice plačal svoje obveznosti, je bil prejem opomin o neplačilu obveznosti. Z uporabo binarne logistične regresije sem napravil dva modela, in sicer v prvi model sem vključil celotni vzorec 6.948 imetnikov plačilnih kartic, v drugi model pa sem vključil samo podskupino v vzorcu, ki so se med seboj ujemali kar v osmih od trinajstih neodvisnih spremenljivk.

V celotnem vzorcu je bilo 68,8% imetnikov plačilnih kartic, ki so svoje obveznosti plačevali brez zamud oziroma niso prejeli opomina. Z uporabo binarne logistične regresije sem tako napravil model, ki je pravilno napovedoval prejem opomina v 69,1% primerov, kar je pomenilo, da sem z modelom izboljšal rezultat samo za 0,3 odstotne točke. V drugem modelu pa sem napravil binarno logistično regresijo na ujemajočih se parih, pri čemer je model pravilno napovedoval prejem opomina 84,1% primerov, kar je za 6,9 odstotne točke boljši rezultat, kot bi ga dosegli, če na podskupini ne bi uporabili statističnega modela.

V magistrski nalogi sem tako prikazal, da je možno z uporabo binarne logistične regresije napraviti model, na podlagi katerega bo izdajatelj plačilnih kartic lahko ocenjeval na podlagi prejetih podatkov iz pristopnice kakšna je verjetnost, da bo ta oseba prenehala plačevati svoje obveznosti. Tako lahko sedaj to podjetje uporabi to orodje kot pomoč pri zniževanju kreditnega tveganja pri novo izdanih plačilnih karticah. Seveda pa obvladovanje kreditnega tveganja ne konča pri odločitvi za izdajo plačilne kartice, ampak je potrebno imeti tudi vzpostavljen ustrezen sistem

spremljanja plačilne discipline vsakega posameznega imetnika plačilne kartice ter imeti razvit sistem zgodnjega identificiranja sprememb v plačilni disciplini imetnika.

V prihodnosti lahko pričakujemo, da bo šel razvoj kreditnega obvladovanja pri izdajateljih plačilnih kartic v smeri integracije različnih modelov za obvladovanje kreditnega tveganja, pri čemer bo prišlo do povezovanja sistema za odobravanje plačilnih kartic s sistemom t.i. vedenjskega ocenjevanje (ocenjevanje obstoječih imetnikov plačilnih kartic ter predvidevanje njihovega obnašanja) ter segmentacije imetnikov plačilnih kartic na podlagi t.i. profitnega ocenjevanja (profit scoring). Ko bo podjetje imelo integrirane vse te tri sisteme bo celovito obvladovalo kreditno tveganje pri plačilnih karticah.

VIRI IN LITERATURA

1. C. R. Abrahams, M. Zhang: Fair Lending Compliance: Intelligence and Implications for Credit Risk Management, John Wiley and Sons, 2008, 357 str.
2. E. I. Altman, A. Saunders : Credit risk measurement: Developments over the last 20 years, Journal of Banking & Finance, vol. 21, 1998, str. 1721-1742
3. R. Anderson: The Credit Scoring Toolkit Theory and Practice for Retail Credit Risk Management and Decision Automation, New York, 2007, 731 str.
4. R. Anderson: Credit risk assessment: Enterprise-credit frameworks, Standard Bank Group, Johannesburg, 2007, 10 str.
5. R. Anderson, et.al. : Statistics for Business and Economics, second edition, Cengage learning EMEA, Hampshire, 2009, 933 str.
6. M. Ammann: Credit risk valuation: methods, models, and applications, 2. Edition , Springer, 2001, 255 str.
7. R. B. Avery et.al. : Consumer credit scoring: Do situational circumstances matter?, Journal of Banking & Finance 28, 2004, str. 835–856
8. Banka Slovenije: Bilten Januar 2010, Leto 19, št. 1; Ljubljana: Banka Slovenije, 2010, 178 str.
9. Banka Slovenije: Bilten September 2010, Leto 19, št. 9, Ljubljana, 180 str.
10. D. Bunn, G. Wright: 'Interaction of Judgmental and Statistical Forecasting Methods: Issues and Analysis', Management Science 1991, str. 501–518
11. P. L. Bernstein: Against the gods: The remarkable story of risk. New York : John Wiley & Sons, 1998, 383 str.

- 12.S. Bhattacharyya, et.al.: Data mining for credit card fraud: A comparative study, Decision Support Systems, Decision Support Systems, 2010, Elsevier B.V.
- 13.Z. Bodie, A. Kane, A. J. Marcus : Investments», 5th Edition, McGraw-Hill/Irwin, 2001, 1015 str.
- 14.J. Burrell: How to Repair Your Credit Score Now: Simple No Cost Methods You Can Put to Use Today, Atlantic Publishing Company, 2007, 288
- 15.J.B. Caouette, E.I. Altman, P. Narayanan: Managing credit risk, 2nd edition, 2008, New York, John Wiley & Sons, 627 str.
- 16.S. Chakravorti, T. To : A theory of credit cards , International Journal of Industrial Organization, vol. 25, 2007, 583–595
- 17.J. Ciby: Credit risk analysis, McGraw-Hill Publishing, 2006, 339 str.
- 18.L. Condamine, J. Louisot, P. Naïm : Risk quantification: management, diagnosis and hedging, John Wiley and Sons, 2006, 271 str.
- 19.R. H. Dehejia; S. Wahba (1999). "Causal Effects in Nonexperimental Studies: Reevaluating the Evaluation of Training Programs, Journal of the American Statistical Association, Vol. 94, No. 448., 1999), str. 1053-1062
- 20.Dionne et.al : Count data models for a credit scoring system, Journal of Empirical Finance 3, 1996, str. 303-325
- 21.Evropska komisija: Report on the retail banking sector inquiry. Bruselj: European Commission Directorate-General for Competition, 2007, 173 str.
- 22.Federal Trade Commission: Credit and Charge Cards, Washington, 2003, 5 str.
- 23.Federal Reserves: Consumer credit statistical release August 2010, October 2010, 2 str.
- 24.Federal Reserves: Consumer credit statistical release January 2011, March 2011.

- 25.N. Frumkin: Guide to economic indicators, M.E. Sharpe SharpeLtd, 2005, 304 str.
- 26.R. M. Gelpi, F. J. Labruyère: The history of consumer credit: doctrines and practices, Palgrave Macmillan, 2000, 190 str.
- 27.S. Gergeta : Modeliranje bonitetne lestvice plačilne discipline slovenskih podjetij, magistrsko delo, EF, Ljubljana, 2005, 103 str.
- 28.Y. Goegebeur: Logistic regression, Poisson regression and generalized linear models, Department of Statistics, University of Southern Denmark, 2008, 8 str.
- 29.W. H. Greene: Econometric Analysis, fifth edition, Prentice Hall, New Jersey, 2002, 1024 str.
- 30.J. Gregory: Counterparty Credit Risk: The New Challenge for Global Financial Markets, John Wiley and Sons, 2010, 448 str.
- 31.D. N. Gujarati: Basic Econometrics, Fourth Edition, The McGraw-Hill, New York, 2004, 1002 str.
- 32.B. E. Gup : The future of banking, Greenwood Publishing Group, 2003, 366 str.
- 33.L. Hunt, M. Jorgensen: Mixture model clustering for mixed data with missing information, Computational Statistics & Data Analysis 41 (2003), str. 429 – 440
- 34.R. A. Johnson, D. W. Wichern: Applied multivariate statistical analysis, Pearson Prentice Hall, 2007, 773 str.
- 35.A. Kara, E. Kaynak, O. Kucukemiroglu: An Empirical Investigation of US Credit Card Users: Card Choice and Usage Behavior. International Business Review Vol. 5, No. 2, 1996, str. 209-230
- 36.D. G. Kleinbaum, M. Klein, E. R. Pryor : Logistic Regression: A Self-Learning Text, Springer, 2010, 701 str.
- 37.D. G. Kleinbaum, L. L. Kupper, K. E. Muller : Applied regression analysis and other multivariable methods, Cengage Learning, 2007, 906 str.

- 38.F. H. Knight: Risk, Uncertainty and Profit. Washington: Beard Books, 2002, 381
- 39.E. Kočenda, M. Vojtek : Default Predictors and Credit Scoring Models for Retail Banking, Cesifo working paper no. 2862, 2009, 25 str.
- 40.D. Hosmer, S. Lemeshow: Applied Logistic regression, New York, John Wiley & Sons, 1989, 304 str.
- 41.D. Hosmer, S. Lemeshow: Applied Logistic regression 2nd edition, New York, John Wiley & Sons, 2000, 373 str.
- 42.K. A. Horcher: Essentials of Financial Risk Management. New Jersey : John Wiley & Sons, 2005, 257 str.
- 43.M. Javoršek : Napovedovanje zamude pri plačilu obveznosti do dobaviteljev slovenskih podjetij, Ekonomska fakulteta, Univerza v Ljubljani, Ljubljana, 2007
- 44.K. Košmelj : Osnove logistične regresije, Zbornik Biotehniške Fakultete Univerze v Ljubljani 77-2, november 2001, str. 227-238
- 45.V. Kothari: Securitization: the financial instrument of the future, John Wiley and Sons, 2006, 992 str.
- 46.Kweku-Muata Osei-Bryson : Evaluation of decision trees: a multi-criteria approach, Computers & Operations Research, št. 31, 2004, str. 1933–1945
- 47.H. M. Langohr, P. T. Langohr: The rating agencies and their credit ratings: what they are, how they work and why they are relevant, John Wiley and Sons, 2008, 510 str.
- 48.Lee et.al : Credit scoring using the hybrid neural discriminant technique, Expert Systems with Applications 23, 2002, str. 245–254
- 49.R. J. LaLonde : Evaluating the Econometric Evaluations of Training Programs with Experimental Data, The American Economic Review, Vol. 76, No. 4., 1986, str. 604-620

- 50.A. Marshall et.al : Variable reduction, sample selection bias and bank retail credit scoring, Journal of Empirical Finance 17, 2010, str. 501–512
- 51.H. Marrez, M. Schmit: Credit risk analysis in microcredit: How does gender matter?, CEB Working Paper N° 09/053, Université Libre de Bruxelles, April 2009
- 52.S. E. Maxwell, H. D. Delaney : Designing experiments and analyzing data: a model comparison perspective, Volume 1, Routledge, 2004, 1104 str.
- 53.E. Mays : Credit risk modeling: design and application, Lessons Professional Publishing, 1998, 257 str.
- 54.P. E. McKnight: Missing data: a gentle introduction, Guilford Press, 2007, 251 str.
- 55.S. W. Menard : Logistic Regression: From Introductory to Advanced Concepts and Applications, SAGE, 2009, 377 str.
- 56.J.L. Mesa: Understanding data in clinical research: a simple graphical display for plotting data (up to four independent variables) after binary logistic regression analysis, Medical Hypotheses (2004) 62, str. 228–232
- 57.A. Mittal, A. Kassim, Bayesian network technologies: applications and graphical models, Idea Group Inc (IGI), 2007, 356 str.
- 58.D. L. Olson, D. Wu: New Frontiers in Enterprise Risk Management, Heidelberg, Springer-Verlag, 2008, 236 str.
- 59.Ong, et.al : Building credit scoring models using genetic programming, Expert Systems with Applications 29, 2005, str. 41–47
- 60.Operational Risk. Consultative Document. Basel: Basel Committee on Banking Supervision, 2001. 26 str.
- 61.G. Paleologo, A. Elisseeff, G. Antonini: Subagging for credit scoring models, European Journal of Operational Research, 2009, str. 490-499
- 62.M. Rothmund, M. Gerhardt : The European Credit Information Landscape An analysis of a survey of credit bureaus in Europe, European Credit Research Institute, 2011, 23 str.

- 63.G. Questa: Fixed-income analysis for the global financial market: money market, foreign exchange, securities, and derivatives, John Wiley and Sons, 1999, 351 str.
- 64.A. Resti, A. Sironi: Risk management and shareholders' value in banking: from risk measurement models to capital allocation policies, John Wiley and Sons, 2007, 782 str.
- 65.J. Rich: Smart Debt, Entrepreneur Press, 2006, 260 str.
- 66.J. K. Peat, B. Barton: Medical statistics: a guide to data analysis and critical appraisal, Wiley-Blackwell, 2005, 324 str.
- 67.P. R. Rosenbaum; D. B. Rubin : "The central role of the propensity score in observational studies for causal effects, Biometrika, Vol. 70, No. 1., 1983, str. 41-55.
- 68.C. N. Rouse: Bankers' lending techniques, 2nd Edition Lessons Professional Publishing, London, 2002, 300 str.
- 69.S. Satchell, W. Xia : Analytic Models of the ROC Curve: Applications to Credit Rating Model Validation, University of Cambridge, 2007, 33 str.
- 70.B. Scholnick, N. Massoud, A. Saunders, S. Carbo-Valverde, F. Rodriguez-Fernandez: The economics of credit cards, debit cards and ATMs: A survey and some new evidence. Elsevier B.V.: Journal of Banking & Finance 32, 6.5.2007, str. 1468-1483
- 71.Silver Lake Editors : Credit scores, credit cards: how consumer finance works: how to avoid mistakes and how to manage your accounts well, Silver Lake Publishing, 2005, 288 str.
- 72.H. D. Skipper, W.J. Kwon: Risk Management and Insurance: Perspectives in a Global Economy, Blackwell publishing, Malden, 2007, 751 str.
- 73.J.H. Slawsky, S. Zafar: Developing and managing a successful payment cards business, Gower Publishing, Ltd., 2005, 202 str.

- 74.B. C. Smith: Stability in Consumer Credit Scores: Level and Direction of FICO Score Drift as a Precursor to Mortgage Default and Prepayment, Virginia Commonwealth University, 2010, 40 str.
- 75.H. H. Sung : Behavioral assessment of recoverable credit of retailer's customers, Information Sciences, vol 180., 2010, str. 3703 – 3717
- 76.I. Szilank: Credit Trends and Outlook for Consumer ABS, 2008, Standard & Poor's, 32 str.
- 77.B. Šenk : Raziskava kreditnega tveganja s pomočjo nevronske mreže, doktorska dizertacija, 2008, FOV Univerza v Mariboru, Kranj, 126 str.
- 78.M. Šušteršič et.al: Consumer credit scoring models with limited data, Expert Systems with Applications 36, 2009, str. 4736–4744
- 79.L. C. Thomas : A survey of credit and behavioural scoring: forecasting financial risk of lending to consumers, International Journal of Forecasting vol. 16, 2000, str. 149–172
- 80.L.C. Thomas, D.B. Edelman, J.N. Crook: Credit Scoring and its Applications. Society for Industrial and Applied Mathematics, Philadelphia, 2002, 248 str. 300
- 81.L.C. Thomas, D.B. Edelman, J.N. Crook: Readings in credit scoring: foundations, developments, and aims, New York, Oxford University Press, 2004,
- 82.Uredba o standardni klasifikaciji institucionalnih sektorjev, Ur.l. RS, št. 13/2006, 02.02.2006
- 83.A. Valentinčič : Napovedovanje plačilne sposobnosti mikro podjetij v Sloveniji, magistrsko delo, Ekonomska fakulteta v Ljubljani, Ljubljana, 1999, 84 str.
- 84.D. Vandone : Consumer Credit in Europe: Risks and Opportunities of a Dynamic Industry, Springer, 2009, 134 str.
- 85.Z. Wang: Market structure and payment card pricing: What drives the interchange? International Journal of Industrial Organization 28, 2010, str. 86-98

- 86.J. M. Wooldridge: Introductory Econometrics, second edition, Mason, New York, 2002, 805 str.
- 87.S. Worthington : Affinity credit cards : a critical reveiw, International Journal of Retail & Distribution Management, 2001, vol.29, str. 482-512
- 88.Zakon o potrošniških kreditih (ZPotK-1), Ur.l. RS, št. 59/2010
- 89.Y. Zhang : High Default Risk on Down Payment Assistance Program: Adverse Selection Vs. Program Characteristics?, 2010, The Ohio State University, 36 str.
- 90.C. Zuccaro : Classification and prediction in customer scoring, Journal of Modelling in Management, Vol. 5 No. 1, 2010, str. 38-53

PRILOGE

Priloga 1: Statistični izpis regresijskega modela podskupin ujemajočih se parov

```
LOGISTIC REGRESSION VARIABLES Default  
/METHOD=ENTER Vrstadelovnegamesta Spol Območje Starost_razredi  
Plačarazred DelovnaDobarazredi  
/CONTRAST (Plačarazred)=Indicator  
/CONTRAST (Starost_razredi)=Indicator  
/CONTRAST (DelovnaDobarazredi)=Indicator  
/CONTRAST (Vrstadelovnegamesta)=Indicator  
/CONTRAST (Spol)=Indicator  
/CONTRAST (Območje)=Indicator  
/SAVE=PRED PGROUP /CLASSPLOT  
/PRINT=GOODFIT CI(95)  
/CRITERIA=PIN(0.05) POUT(0.10) ITERATE(20) CUT(0.5) .
```

Logistic Regression

Case Processing Summary

Unweighted Cases ^a		N	Percent
Selected Cases	Included in Analysis	232	100,0
	Missing Cases	0	,0
	Total	232	100,0
Unselected Cases		0	,0
Total		232	100,0

a. If weight is in effect, see classification table for the total number of cases.

Dependent Variable Encoding

Original Value	Internal Value
ni opomina	0
prejeti opomin	1

Categorical Variables Codings

			Parameter coding							
			Frequency	(1)	(2)	(3)	(4)	(5)	(6)	(7)
Starost - razredi	StarA	28	1,000	,000	,000	,000	,000	,000	,000	,000
	StarB	60	,000	1,000	,000	,000	,000	,000	,000	,000
	StarC	41	,000	,000	1,000	,000	,000	,000	,000	,000
	StarD	28	,000	,000	,000	1,000	,000	,000	,000	,000
	StarE	25	,000	,000	,000	,000	1,000	,000	,000	,000
	StarF	26	,000	,000	,000	,000	,000	1,000	,000	,000
	StarG	17	,000	,000	,000	,000	,000	,000	1,000	,000
	StarH	6	,000	,000	,000	,000	,000	,000	,000	1,000
	StarI	1	,000	,000	,000	,000	,000	,000	,000	,000
Območje bivanja	Reg1	12	1,000	,000	,000	,000	,000	,000	,000	
	Reg2	16	,000	1,000	,000	,000	,000	,000	,000	
	Reg3	24	,000	,000	1,000	,000	,000	,000	,000	
	Reg4	114	,000	,000	,000	1,000	,000	,000	,000	
	Reg5	29	,000	,000	,000	,000	1,000	,000	,000	
	Reg6	5	,000	,000	,000	,000	,000	1,000	,000	
	Reg7	15	,000	,000	,000	,000	,000	,000	1,000	
	Reg8	17	,000	,000	,000	,000	,000	,000	,000	
Plača-razred	Plača1	75	1,000	,000	,000	,000	,000	,000	,000	
	Plača2	117	,000	1,000	,000	,000	,000	,000	,000	
	Plača3	20	,000	,000	1,000	,000	,000	,000	,000	
	Plača4	10	,000	,000	,000	1,000	,000	,000	,000	
	Plača5	5	,000	,000	,000	,000	1,000	,000	,000	
	Plača6	3	,000	,000	,000	,000	,000	1,000	,000	
	Plača7	1	,000	,000	,000	,000	,000	,000	1,000	
	Plača8	1	,000	,000	,000	,000	,000	,000	,000	
Delovna Doba-razredi	DD1	224	1,000	,000	,000	,000	,000			
	DD2	2	,000	1,000	,000	,000	,000			
	DD3	1	,000	,000	1,000	,000	,000			
	DD4	2	,000	,000	,000	1,000	,000			
	DD5	2	,000	,000	,000	,000	1,000			
	DD6	1	,000	,000	,000	,000	,000			
Vrsta delovnega mesta	DM1	4	1,000	,000	,000					
	DM2	76	,000	1,000	,000					
	DM3	18	,000	,000	1,000					
	DM4	134	,000	,000	,000					
Spol	Ženska	146	1,000							
	Moški	86	,000							

Block 0: Beginning Block

Classification Table^{a,b}

			Predicted		
			Default (prejeti opomin)		Percentage Correct
			ni opomina	prejeti opomin	
Observed	Step 0	Default (prejeti opomin)	ni opomina	prejeti opomin	Percentage Correct
		ni opomina	179	0	100,0
		prejeti opomin	53	0	,0
Overall Percentage					77,2

a. Constant is included in the model.

b. The cut value is ,500

Variables in the Equation

		B	S.E.	Wald	df	Sig.	Exp(B)
Step 0	Constant	-1,217	,156	60,574	1	,000	,296

Variables not in the Equation

			Score	df	Sig.
Step 0	Variables	DM	5,139	3	,162
		DM1	1,205	1	,272
		DM2	3,529	1	,060
		DM3	,269	1	,604
		Spol	,192	1	,661
		Regija	15,916	7	,026
		Reg1	,790	1	,374
		Reg2	,045	1	,831
		Reg3	1,625	1	,202
		Reg4	2,489	1	,115
		Reg5	,423	1	,516
		Reg6	9,471	1	,002
		Reg7	2,678	1	,102
		Star	7,763	8	,457
		StarA	4,883	1	,027
		StarB	1,753	1	,186
		StarC	,023	1	,881
		StarD	,036	1	,849
		StarE	,021	1	,884
		StarF	,276	1	,599
		StarG	1,278	1	,258
		StarH	,384	1	,535
		Plača	15,875	7	,026
		Plača1	,002	1	,964
		Plača2	3,210	1	,073
		Plača3	6,095	1	,014
		Plača4	,978	1	,323
		Plača5	4,002	1	,045
		Plača6	,190	1	,663
		Plača7	,297	1	,586
		DD	11,977	5	,035
		DD1	3,466	1	,063
		DD2	,844	1	,358
		DD3	3,392	1	,066
		DD4	,597	1	,440
		DD5	6,813	1	,009
	Overall Statistics		50,420	31	,015

Block 1: Method = Enter**Omnibus Tests of Model Coefficients**

		Chi-square	df	Sig.
Step 1	Step	50,622	31	,015
	Block	50,622	31	,015
	Model	50,622	31	,015

Model Summary

Step	-2 Log likelihood	Cox & Snell R Square	Nagelkerke R Square
1	198,729 ^a	,196	,298

a. Estimation terminated at iteration number 20 because maximum iterations has been reached. Final solution cannot be found.

Hosmer and Lemeshow Test

Step	Chi-square	df	Sig.
1	7,146	8	,521

Contingency Table for Hosmer and Lemeshow Test

		Default (prejeti opomin) = ni opomina		Default (prejeti opomin) = prejeti opomin		Total
		Observed	Expected	Observed	Expected	
Step 1	1	22	22,383	1	,617	23
	2	23	23,175	2	1,825	25
	3	21	22,411	4	2,589	25
	4	22	19,992	1	3,008	23
	5	19	19,443	4	3,557	23
	6	17	18,624	6	4,376	23
	7	18	17,427	5	5,573	23
	8	17	16,233	6	6,767	23
	9	17	13,770	6	9,230	23
	10	3	5,543	18	15,457	21

Classification Table^a

Observed			Predicted		
			Default (prejeti opomin)		Percentage Correct
			ni opomina	prejeti opomin	
Step 1	Default (prejeti opomin)	ni opomina	176	3	98,3
		prejeti opomin	34	19	35,8
Overall Percentage					84,1

a. The cut value is ,500

Variables in the Equation

		B	S.E.	Wald	df	Sig.	Exp(B)	95% C.I. for EXP(B)	
								Lower	Upper
Step 1 ^a	DM			3,399	3	,334			
	DM1	-19,069	19819,662	,000	1	,999	,000	,000	.
	DM2	,517	,393	1,734	1	,188	1,678	,777	3,624
	DM3	-1,376	1,293	1,132	1	,287	,253	,020	3,185
	Spol	-,211	,394	,287	1	,592	,810	,374	1,753
	Regija			12,178	7	,095			
	Reg1	,374	1,026	,133	1	,715	1,454	,195	10,863
	Reg2	,345	,977	,125	1	,724	1,412	,208	9,572
	Reg3	-,041	,940	,002	1	,965	,959	,152	6,052
	Reg4	-,333	,762	,191	1	,662	,717	,161	3,192
	Reg5	,928	,820	1,282	1	,257	2,530	,507	12,616
	Reg6	3,813	1,506	6,411	1	,011	45,282	2,367	866,362
	Reg7	,467	,995	,220	1	,639	1,596	,227	11,219
	Star			7,473	8	,487			
	StarA	20,316	40192,624	,000	1	1,000	6,657E8	,000	.
	StarB	19,035	40192,624	,000	1	1,000	1,848E8	,000	.
	StarC	19,445	40192,624	,000	1	1,000	2,784E8	,000	.
	StarD	18,864	40192,624	,000	1	1,000	1,557E8	,000	.
	starE	19,139	40192,624	,000	1	1,000	2,052E8	,000	.
	StarF	19,667	40192,624	,000	1	1,000	3,478E8	,000	.
	StarG	18,370	40192,624	,000	1	1,000	9,508E7	,000	.
	StarH	18,449	40192,624	,000	1	1,000	1,028E8	,000	.
	Plača			10,684	7	,153			
	Plača1	-25,725	40193,042	,000	1	,999	,000	,000	.
	Plača2	-25,333	40193,042	,000	1	,999	,000	,000	.
	Plača3	-24,158	40193,042	,000	1	1,000	,000	,000	.
	Plača4	-25,049	40193,042	,000	1	1,000	,000	,000	.
	Plača5	-21,691	40193,042	,000	1	1,000	,000	,000	.
	Plača6	-23,588	40193,042	,000	1	1,000	,000	,000	.
	Plača7	-42,821	56841,494	,000	1	,999	,000	,000	.
	DD			,019	5	1,000			
	DD1	20,517	40192,933	,000	1	1,000	8,139E8	,000	.
	DD2	20,745	40192,933	,000	1	1,000	1,022E9	,000	.
	DD3	43,228	56841,418	,000	1	,999	5,936E18	,000	.
	DD4	1,347	49223,995	,000	1	1,000	3,847	,000	.
	DD%	43,029	49210,501	,000	1	,999	4,867E18	,000	.
	Constant	-16,055	69616,005	,000	1	1,000	,000		

a. Variable(s) entered on step 1: DM, Spol, Regija, Star, Plača, DD.

Observed Groups and Predicted Probabilities

Predicted Probability is of Membership for prejeti opomin
The Cut Value is ,50
Symbols: n - ni opomina
p - prejeti opomin
Each Symbol Represents 1 Case.