

UNIVERZA V LJUBLJANI
EKONOMSKA FAKULTETA

MAGISTRSKO DELO

**IZDELAVA EKSPERTNEGA MODELA ZA SPREMLJANJE KREDITNIH
TVEGANJ**

Ljubljana, februar 2023

PETRA KRIŽAJ

IZJAVA O AVTORSTVU

Podpisana Petra Križaj, študentka Ekonomske fakultete Univerze v Ljubljani, avtorica predloženega dela z naslovom Izdelava ekspertnega modela za spremljanje kreditnih tveganj, pripravljenega v sodelovanju s svetovalcem izr. prof. dr. Igorjem Lončarskim,

IZJAVLJAM

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

V Ljubljani, dne _____

Podpis študentke: _____

KAZALO

UVOD	1
1 KREDITNO TVEGANJE IN MSRP 9	2
2 ANALIZA BILANČNIH PODATKOV IN ALTMANOV Z-SCORE.....	6
3 PRIMERJALNA ANALIZA NA PODLAGI KREDITNIH RAZPONOV	9
3.1 Bonitetne ocene	9
3.1.1 Zgodovina bonitetnih ocen	9
3.1.2 Proces bonitetnega ocenjevanja	11
3.2 Časovni razpon	13
3.2.1 Krivulja donosnosti	13
3.2.2 Razpon donosnosti	15
3.3 Opcijsko prilagojen razpon	16
3.3.1 Finančni indeksi	16
3.3.2 Opcijsko prilagojen razpon	16
3.4 Hazard rate	18
3.5 Likvidnost	19
4 ANALIZA VERJETNOSTI NEPLAČILA	19
4.1 Mertonov model.....	20
4.1.1 Predpostavke modela.....	20
4.1.2 Mertonov model	21
4.2 KMV model.....	23
4.3 Verjetnost neplačila in pričakovana frekvenca neplačila.....	24
5 ALTERNATIVNI MODEL ZA SPREMLJANJE KREDITNIH TVEGANJ IN OCEN NALOŽB	25
5.1 Vhodni podatki modela.....	25
5.2 Združitev različnih metod analize	26
5.2.1 Modeliranje bilančne analize.....	28
5.2.2 Modeliranje analize razpona	28
5.2.3 Modeliranje verjetnosti neplačila	32
5.3 Merila	35
5.4 Dodatna analiza	36
5.4.1 Logistična regresija	37
5.4.2 Odločitvena drevesa	38
5.4.3 Specifike panog in prilagoditve modela.....	40
5.5 Rezultat modela	41

6	TEST MODELA NA HISTORIČNIH PODATKIH	42
6.1	Vrste testiranja	42
6.2	Test modela	43
6.3	Scenarij ravnanja z naložbami brez modela	45
6.4	Scenarij ravnanja z naložbami z modelom	46
7	UPORABNOST IN OMEJITVE MODELA	46
	SKLEP	50
	LITERATURA IN VIRI	51
	PRILOGE	60

KAZALO TABEL

Tabela 1:	Ključne razlike med Basel III. in MSRP 9	5
Tabela 2:	Primer obravnave bilančnih podatkov s pomočjo Altmanovega modela Z-Score ...	28
Tabela 3:	Primer obravnave podatkov za analizo razpona in izračun vrednosti z-razpona	29
Tabela 4:	Analiza razpona in primerjava med z-razponom in OAS	29
Tabela 5:	Prilagojen z-razpon	30
Tabela 6:	Analiza sprememb bonitetnih ocen naložb	31
Tabela 7:	Analiza razpona in primerjava med z-razponom in bonitetnimi ocenami	31
Tabela 8:	Analiza verjetnosti neplačila na dan testiranja in ob pripoznavi	32
Tabela 9:	Primerjava PD in stopnje nevarnosti	33
Tabela 10:	Izračuni po modelu KMV	34
Tabela 11:	Uporabljena razmerja v odločitvenih drevesih	39
Tabela 12:	Binarne oznake rdečih zastavic	41
Tabela 13:	Napaka Tipa 1 in Tipa 2	42
Tabela 14:	Primerjava vrednosti Z-Score in bonitetnih ocen	45
Tabela 15:	Primerjava bonitetnih ocen, z-razpona in opcijsko prilagojenega razpona	45
Tabela 16:	Končni izračuni	47
Tabela 17:	Končni izračuni 1	47
Tabela 18:	Opozorila ločenih kazalnikov	48

KAZALO SLIK

Slika 1:	Primerjava označevanja bonitetnih ocen treh različnih bonitetnih agencij	10
Slika 2:	Historične stopnje neplačila	12
Slika 3:	Primer migracijske matrike	13
Slika 4:	Normalna krivulja donosnosti	14
Slika 5:	Vizualizacija procesa modela	27

Slika 6: Vizualizacija vhodnih podatkov	27
Slika 7: Gibanje sredstev in obveznosti	34
Slika 8: Gibanje PD.....	35
Slika 9: Gibanje DD	35
Slika 10: Rezultati odločitvenega drevesa za nefinančne družbe.....	44
Slika 11: OOB za nefinančne družbe	44

KAZALO PRILOG

Priloga 1: Vizualizacija procesa model.....	1
Priloga 2: Kazalniki in formule.....	2

SEZNAM KRATIC

angl. – angleško

AIC – Akaikov informacijski kriterij

BDP – bruto domači proizvod

CDS – (angl. credit default swap); kreditna zamenjava

DD – (angl. distance to default); razdalja do neplačila

DJIA – (angl. Dow Jones Industrial Average); industrijsko povprečje Dow Jones

EAD – (angl. exposure at default); izpostavljenost zaradi neplačila

ECB – Evropska centralna banka

ECL – (angl. expected credit loss); pričakovana kreditna izguba

EBIT – (angl. earnings before interest and taxes); razširjen celotni poslovni izid

EDF – (angl. expected default frequency); pričakovana frekvenca neplačila

EDTF – (angl. The Enhanced Disclosure Task Force); delovna skupina za izboljšano razkritje

EIOPA – (angl. European insurance and occupational pensions authority); Evropski organ za zavarovanja in poklicne pokojnine

EURIBOR– (angl. Euro Interbank Offered Rate); evropska medbančna obrestna mera

FSB – (angl. Financial Stability Board); odbor za finančno stabilnost

KMV – ekonomski model avtorjev Stephena Kealhoferja, Johna McQuowna in Oldricha Vasicka

LGD – (angl. loss given default); izguba zaradi neplačila

LIBOR – (angl. London Interbank Offered Rate); londonska medbančna obrestna mera

MSRP – (angl. International financial reporting standards, kratko IFRS); Mednarodni standardi računovodskega poročanja

OAS – (angl. option adjusted spread); opcijsko prilagojen razpon

OOB – (angl. out-of-beg error); povprečna napaka

PD – (angl. probability of default); verjetnost neplačila

PIT – (angl. point-in-time); točka v takratnem času

PV – (angl. present value); trenutna oziroma sedanja vrednost

SB – (angl. second best rating); druga najboljša bonitetna ocena

SEC – (angl. Securities and Exchange Commission); komisija za vrednostne papirje in borzo

TTC – (angl. through-the-cycle); skozi cikel

ZZavar-1 – Zakon o zavarovalništvu

UVOD

Novi Mednarodni standardi računovodskega poročanja (v nadaljevanju MSRP 9) od finančnih institucij zahtevajo lastno modeliranje kreditnih tveganj, kar v analizo vključuje tudi spremljanje trenutnih tržnih razmer. Potreba po alternativnem preverjanju kreditnega tveganja se je pojavila predvsem s finančno krizo leta 2008, kjer se je izkazalo, da v določenih segmentih finančnih trgov bonitetne ocene niso realno odražale tveganj. Direktiva Solventnost 2 in MSRP 9 zahtevata od finančnih institucij presojo kreditnega tveganja, ki je neodvisna od uradno objavljenih ocen bonitetnih agencij. Problematika bonitetnih agencij izhaja iz dejstva, da se presoja kreditnega tveganja izvaja enkrat letno, prav tako pa prihaja do slabšega poznavanja specifičnih panog oziroma trgov. Posledica novih zahtev bo zahtevano večje nadomestilo za izgube dolžniških vrednostnih papirjev v bankah in podobnih finančnih institucijah (EY, 2018).

Ključna problematika, s katero se ukvarja magistrsko delo, je izdelava in preizkus ekspertnega modela, ki prikazuje bolj ažurne informacije, ki morda na trgu niso jasno opazne. Specifičnih smernic za izdelavo alternativnega modela zakonodaja ne podaja, kar pomeni, da so finančne institucije prepuščene lastni interpretaciji pri izdelavi modela. V kolikor finančne institucije ne razvijejo popolnoma inovativnega pristopa za zaznavanje kreditnih tveganj, uporabijo že preizkušene svetovno znane modele. Slednje odpira nova vprašanja glede ustreznosti uporabljenih modelov in uresničitve namena zakonodaje, ki teži k večji pozornosti na področju kreditnega tveganja.

Magistrsko delo sledi ključnemu namenu in več ciljem. Namen naloge je izdelava ekspertnega modela za praktično rabo v izbrani finančni instituciji. Prvi cilj magistrskega dela je razviti samostojni model presoje primernosti bonitetnih ocen z združitvijo že preizkušenih metod. Drugi cilj je opisati metodologijo izdelave ekspertnega modela, ki bo s pomočjo združitve različnih že obstoječih modelov identificiral naložbe, pri katerih tržni oziroma finančni podatki niso skladni z bonitetno oceno. Zaradi podrobnega preučevanja različnih naložb je eden izmed ciljev magistrskega dela tudi izpostaviti specifične določene teoretičnih modelov glede na panogo naložbe. Zadnji cilj pa je dokazati, da lahko s pomočjo modela predčasno zaznamo spremembe kreditnega tveganja določenih naložb. Doprinos magistrskega dela k znanosti predstavlja raziskava in preizkus izdelanega modela, ki ustreza zakonodajnim napotkom.

Ekspertni model za izbrano finančno institucijo je sestavljen iz treh delov. Kot ključne indikatorje kreditnega tveganja vključuje različne vrste modelov, ki temeljijo na podlagi različnih analiz. Del modela predstavlja analiza bilančnih podatkov, kjer je kot ključni pokazatelj tveganj uporabljen Altmanov model Z-Score. Sledi analiza pribitkov, kjer je opravljena primerjava stopenj nevarnosti (angl. hazard rate) in bonitetnih ocen. Zadnja med vrstami analiz je analiza verjetnosti neplačila, kjer je uporabljen Morganov kreditni

model – model KMV, prav tako pa je opravljena tudi primerjava verjetnosti neplačil v različnih časovnih obdobjih. Magistrsko delo je aplikativne narave in bo posledično tudi uporabljeno s strani izbrane finančne institucije. Sestava in zasnova modela sta v skladu s predpisi MSRP 9 in Solventnost 2. Izdelava modela je optimizacijske narave, saj stremi k boljši uporabi že obstoječih podatkov na podlagi dodatnih izračunov in primerjav.

Sestavljeni model je preizkušen na fiktivnem portfelju. S preizkusom modela na fiktivnem portfelju želim preveriti, ali ekspertni model na podlagi zgodovinskih podatkov prepozna večjo stopnjo tveganja, kar bi pomenilo, da je s tem njegova uporaba smotrna. V tem primeru lahko sklepamo, da lahko finančne institucije z modeli, ki so preizkušeni in javno dostopni, že v realnem času oziroma vnaprej bolje nadzorujejo kreditno tveganje. S končnim testom želim preveriti, ali bi s pomočjo podobnih alternativnih modelov finančne institucije lahko predčasno zaznale kreditno tveganje svojih naložb, kar je tudi namen zakonodaje MSRP 9.

Model zajema različne že dobro znane metode za preverbo stopenj tveganja in jih združi v samostojno in homogeno enoto. V prvem delu študije je predstavljena teoretična zasnova vsakega posameznega modela (Altmanov model Z-Score, Mertonov model za kreditna tveganja, model KMV, primerjava stopenj nevarnosti in bonitetnih ocen ...), v drugem delu pa je predstavljen in izdelan ekspertni model za izbrano finančno institucijo. Kot že omenjeno, različne panoge naložb od modela zahtevajo specifično obravnavo. Posledično so v naslednjem delu študije predstavljene ugotovitve glede umerjanja samega modela, vezano na panožno specifično. V zadnjem delu magistrskega dela so predstavljeni rezultati in specifikacije modela, ki so vključene za namene praktične uporabe v izbrani finančni instituciji.

1 KREDITNO TVEGANJE IN MSRP 9

Finančne institucije v panogi zavarovalništva se srečujejo z različnimi vrstami tveganj, ki morajo biti v skladu z Zakonom o zavarovalništvu (v nadaljevanju ZZavar-1), Ur. l. RS. Št. 93/2015. Tveganja je treba ažurno meriti, ocenjevati, spremljati in poročati Agenciji za zavarovalni nadzor (AZN). Saunders in Cornett (2006) sta tveganja, s katerimi se srečujejo finančne institucije, razdelila v deset osnovnih kategorij – tveganje spremembe obrestne mere (angl. interest rate risk), tržno tveganje (angl. market risk), kreditno tveganje (angl. credit risk), tveganje izvenbilančnega poslovanja (angl. off-balance-sheet risk), tehnološko tveganje (angl. technology risk), operativno tveganje (angl. operational risk), tveganje spremembe deviznega tečaja (angl. foreign exchange risk), državno tveganje (angl. sovereign risk), likvidnostno tveganje (angl. liquidity risk) in tveganje solventnosti (angl. insolvency risk). V magistrskem delu se bom osredotočila na kreditno tveganje in njegovo ocenjevanje. Ta vrsta tveganja nastane zaradi obstoja verjetnosti, da

finančne institucije ne bodo zmožne poplačati svojih obveznosti, kot so obveznice in posojila (Saunders & Cornett, 2006). V ZZavar-1 je kreditno tveganje definirano kot tveganje izgube ali neugodne spremembe v finančnem položaju zavarovalnice zaradi nihanj v kreditnem položaju izdajateljev vrednostnih papirjev, nasprotnih strank in morebitnih dolžnikov, ki so jim izpostavljene zavarovalnice v obliki tveganja neplačila nasprotne stranke, tveganja spremembe kreditnega pribitka in tveganja koncentracije tržnega tveganja (ZZavar-1).

Merjenje kreditnega tveganja se je v zadnjih petdesetih letih drastično spreminjalo in razvijalo. Vzroke za to lahko najdemo v globalizaciji, razvoju finančnih trgov, povečanem številu stečajev in tudi v finančni krizi leta 2008. Akademiki so se skozi čas trudili razviti modele, ki bi predčasno opozorili na tveganje (angl. early-warning systems) ali pa, da bi se na podlagi bilančnih podatkov kar se da približali realni bonitetni oceni. Tveganja niso opazovali zgolj na ravni posamezne naložbe, ampak tudi na portfeljski ravni.

Glede na naravo kreditnega tveganja avtor Corelli (2014) kot eno ključnih vprašanj te tematike izpostavlja sam opis postopka neplačila. Literatura je razvila tri vrste modelov – t. i. strukturne modele (angl. structural models), empirične modele (angl. empirical models) in modele v reducirani obliki (angl. reduced form models). Prva oblika želi posnemati podjetje in njegovo ekonomsko strukturo (Berk Skok, 2020). Strukturni modeli torej obdelujejo informacije o razvoju strukturnih spremenljivk podjetja kot sredstva in obveznosti ter na podlagi tega določijo verjetnost in čas neplačila. Pristop nam omogoča modeliranje kreditnih dogodkov, ki temeljijo neposredno na ekonomskih osnovah, kot je na primer kapitalska struktura podjetja. Gonilni dejavniki v strukturnih modelih so vrednost družb in prag neplačila. Priljubljen strukturni pristop je model, ki ga je leta 1974 razvil Robert Merton. Empirični modeli temeljijo na primerjavi historičnih finančnih podatkov tistih podjetij, ki so šla v stečaj, in tistih, ki so preživela (Berk Skok, 2020). S pomočjo primerjave in analiziranja korelacij tovrstni modeli poskušajo poiskati vzporednice med podatki in posledičnim stečajem. Modeli z reducirano obliko temeljijo na eksogenih neplačilih, nevtralnem tveganem ukrepih in odsotnosti arbitraže (Corelli, 2014). Verjetnost neplačila je torej povezana z nekimi zunanjimi signali v obliki statistične vrednosti (Berk Skok, 2020). V tem magistrskem delu bo več pozornosti posvečene modelom s strukturnim pristopom.

Zakonodaja in računovodski standardi od finančnih institucij zahtevajo opis in ugotovitev znatnega povečanja kreditnega tveganja. Specifičnih smernic za izdelavo alternativnega modela zakonodaja ne podaja, zato so finančne institucije prepuščene lastni interpretaciji pri kreiranju modela. Družbe si zato dodatno pomagajo tudi s smernicami raznih finančnih odborov in revizijskih družb.

Delegirana uredba Komisije EU narekuje smernice za upravljanje naložbenega tveganja. Zavarovalnice ali pozavarovalnice naj pripravijo lastno notranjo oceno za kreditna tveganja nasprotnih naložbenih strank in instrumentov. Uporabijo naj postopke za oceno tveganja instrumentov po načelih upravljanja tveganj (Publications Office of the European Union, 2015).

MSRP 9 od podjetij zahteva, da družbe same presodijo, ali se je kreditno tveganje naložb bistveno povečalo. Narekuje, naj upoštevajo razumne in dokazljive informacije, ki so na voljo brez ustvarjanja nepotrebnih stroškov. Analiza kreditnega tveganja je lahko večfaktorska ali celostna. Eden izmed omenjenih faktorjev je na primer relevantnost določenega dejavnika, ki je odvisna od vrste produkta, značilnosti finančnih instrumentov in zemljepisne regije. Pri ocenjevanju sprememb kreditnega tveganja je lahko relevantna pomembna sprememba notranjih cenovnih kazalnikov kreditnega tveganja zaradi spremembe kreditnega tveganja od nastanka. Relevantne so tudi znatne spremembe zunanjih tržnih kazalnikov kreditnega tveganja za določen finančni instrument ali podobne finančne instrumente z istim pričakovanim obdobjem trajanja. Spremembe tržnih kazalnikov kreditnega tveganja med drugim vključujejo dejansko ali pričakovano pomembno spremembo zunanje bonitetne ocene. Po navodilih MSRP 9 so notranje bonitetne ocene ali notranje ocene preteklega obnašanja zanesljivejše, kadar so navezane na zunanje ocene ali podprte z analizo neplačil.

Do leta 2017 so finančne institucije izračunavale kreditno izgubo z modelom nastale izgube (angl. incurred loss model). Od leta 2018 pa MSRP 9 od finančnih institucij zahteva rezervacije za prihodnje oslabitve posojil, ocenjene s pomočjo ocen pričakovanih izgub (angl. expected loss). Prav tako pa tudi smernice Basel III. zahtevajo od finančnih institucij rezervacije, ocenjene s pomočjo ocen pričakovanih kreditnih izgub (angl. expected credit loss) (Mahat, 2020). Način pridobivanja ocen po zahtevah MSRP 9 in Basel III. se v določenih segmentih razlikuje. Razlike so prikazane v tabeli 1.

Tabela 1: Ključne razlike med Basel III. in MSRP 9

	ključni parameter tveganja	Basel III	MSRP 9
Verjetnost neplačila (PD)	merilni standard	Povprečje neplačila v naslednjih 12 mesecih.	Odvisno od stanja naložbe se PD meri bodisi za naslednjih 12 mesecev (Stage 1), bodisi za preostalo življenjsko dobo finančnega instrumenta (Stage 2 in Stage 3).
	obdobje merjenja (pogled predhodnega obdobja)	Ocene, ki temeljijo na dolgoročni povprečni stopnji neplačila, od trenutka do celotnega cikla (od PIT do TTC).	PIT ocene na datum poročanja o sedanjih in pričakovanih prihodnjih razmerah, ki odražajo prihodnje ekonomske cikle.
izguba zaradi neplačila (LGD)	namen ocene	Upad LGD odraža neugodne ekonomske scenarije.	Sedanji ali prihodnji LGD, ki odraža vpliv ekonomskih scenarijev.
	stroški zbiranja	Upošteva neposredne in posredne stroške, povezane z zbiranjem izpostavljenosti.	Upošteva samo stroške, ki jih je mogoče neposredno pripisati izterjavi.
	diskontna stopnja	Določena na podlagi tehtane povprečne cene kapitala ali netvegane obrestne mere.	Odvisno od vrste finančnega instrumenta, vendar na splošno temelji na efektivni obrestni meri.
	obdobje opazovanja	Najmanj pet let za izpostavljenosti do maloprodaje ter sedem let za izpostavljenosti do držav, podjetij in bank.	Ni posebnih zahtev glede obdobja opazovanja ali zbiranja zgodovinskih podatkov.
izpostavljenost zaradi neplačila (EAD)	namen ocene	Upad EAD odraža, kaj pričakovati v obdobju gospodarske recesije.	Upošteva vse pogodbene pogoje v času trajanja instrumenta.
	obdobje opazovanja	Najmanj pet let za izpostavljenosti do maloprodaje ter sedem let za izpostavljenosti do držav, podjetij in bank.	Ni posebnih zahtev glede obdobja opazovanja ali zbiranja zgodovinskih podatkov.
pričakovana kreditna izguba (ECL)	izračun	Zmnožek PD in LGD predstavlja EAD.	Zmnožek PD in sedanje vrednosti denarnih izgub predstavlja verjetnostno tehtano oceno kreditne izgube.
	ekonomske predpostavke	Odražajo upad LGD in EAD (upoštevanje makroekonomskih stresnih razmer).	Odraža nepristransko verjetnostno tehtano vrednost, določeno z ovrednotenjem razpona možnih rezultatov.

Prirjeno po Moody's analytics (2011).

Po MSRP 9 so kreditne naložbe razdeljene v tri različne razrede. Prvi razred (Stage 1) vsebuje naložbe, pri katerih se kreditno tveganje od začetnega pripoznanja ni bistveno povečalo. Za finančna sredstva v prvem razredu mora družba pripoznati 12-mesečno pričakovano kreditno izgubo (v nadaljevanju ECL) in pripoznati prihodke od obresti na bruto osnovi. V drugem razredu (Stage 2) so naložbe, pri katerih se je kreditno tveganje od začetnega pripoznanja znatno povečalo. Ko se finančno sredstvo prenese iz prvega v drugi razred, mora družba pripoznati doživljenjski ECL, prihodki od obresti pa še naprej ostanejo na bruto osnovi. V tretjem razredu (Stage 3) so naložbe, ki so kreditno oslabiljene. To je dejansko točka, na kateri je po modelu MRS 39 nastal škodni dogodek. Pri finančnih sredstvih v tretjem razredu družba še naprej pripoznava doživljenjski ECL, vendar z razliko pripoznave prihodkov od obresti na neto osnovi. To pomeni, da so prihodki od obresti izračunani na podlagi bruto knjigovodske vrednosti finančnega sredstva, ki je zmanjšana za ECL (Taylor, 2017).

Leta 2012 je bila s strani Finančnega odbora za stabilnost (angl. Financial Stability Board – FSB) ustanovljena delovna skupina za izboljšano razkritje (angl. The Enhanced Disclosure Task Force – EDTF). Ta si prizadeva za izboljšanje kakovosti, primerljivosti in preglednost razkritij tveganj z združevanjem bank, vlagateljev, analitikov in revizorjev. EDTF za finančne institucije in njihovo lastno oceno kreditnega tveganja navaja naslednja priporočila. Priporočena je uporaba kazalnikov, kot so bonitetne ocene, zapadlost in verjetnost neplačila. Zaželeno je razlaga klasifikacije za zaznavanje naložb z znatnim povečanjem kreditnega tveganja. Predlagan je opis postopka obravnave naložbe,

ko je ta predstavljena v Stage 2. MSRP 7 zahteva, da družba pojasni vhodne podatke, predpostavke in tehnike ocenjevanja, uporabljene za uporabo zahtev glede oslabitve iz MSRP 9. Osnova vhodnih podatkov naj temelji na 12-mesečnih in celotnih vrednostih ECL. Analiza kreditnih tveganj naj vsebuje prepoznavo, ali se je kreditno tveganje znatno povečalo od datuma pripoznave, ter ugotovitev, ali je naložba kreditno oslABLJENA. Omenjene analize so lahko opravljene s pomočjo notranjih historičnih podatkov družbe, s pomočjo bonitetnih ocen, ali s pomočjo pričakovane življenjske dobe naložb (EY, 2018).

2 ANALIZA BILANČNIH PODATKOV IN ALTMANOV Z-SCORE

Da bi se izdelave modela lotili kar se da celostno, so v ekspertnem modelu združene različne vrste že obstoječih kreditnih modelov. Prvi izmed njih, Altmanov model, spada med empirične modele, saj poskuša identificirati verjetnost neplačila na podlagi značilnosti podjetij (Berk Skok, 2020).

Ena izmed metod modeliranja kreditnega tveganja temelji na bilančnih podatkih, ki naj bi opisovali značilnosti podjetja. Ta je lahko osredotočena na eno spremenljivko ali več spremenljivk (univariatni in multivariatni modeli). Pri prvi govorimo o kreditnem točkovanju, kjer se opravi primerjava s točkovanjem konkurence v panogi. Lahko pa je modeliranje osredotočeno na več spremenljivk, ki jih sestavljajo razmerja bilančnih podatkov. Slednja metoda z utežmi združi spremenljivke in ustvari kreditno oceno. Če kreditna ocena doseže neko kritično referenčno mejo, je za dotično naložbo oziroma družbo treba povečati pozornost pri nadzoru nadaljnjih sprememb. Obstajajo vsaj štiri metodološki pristopi k razvoju multivariatnih bonitetnih sistemov: linearni verjetnostni model, logistična regresija (angl. logit model), probit model in model diskriminantne analize (angl. discriminant analysis model). Primer diskriminantne analize je Altmanov model Z-Score. Najpogostejša oblika take analize želi poiskati linearno funkcijo med računovodskimi in tržnimi spremenljivkami, ki najlepše ločuje med dvema skupinama opazovanih objektov. Loči jih na tiste, ki so plačilno zmožni, in na tiste, ki so plačilno nezmožni. To je storjeno z analizo skupine spremenljivk, kjer je zaznana maksimalna varianca med skupinami in minimalna varianca znotraj skupin. Podobno tudi analiza logit uporabi bilančne podatke za izračun verjetnosti neplačila ob predpostavki, da je verjetnost neplačila porazdeljena med 0 in 1. Vseeno je treba poudariti najpogostejši kritiki, ki se nanašata na tovrstne modele. Prva se nanaša na knjigovodsko vrednost bilančnih podatkov, ki lahko ne prikaže hitrih sprememb, ki se bolje odražajo v tržni vrednosti. Druga kritika pa se nanaša na predpostavko linearnosti, ker vpliva na manjšo natančnost napovedi modela (Altman & Saunders, 1998).

Za obravnavo verjetnosti neplačila iz vidika bilančnih podatkov je v ekspertnem modelu uporabljen Altmanov model Z-Score ali model ZETA. Gre za prvo multivariatno diskriminantno analizo za zaznavanje insolventnosti podjetij, ki jo je razvil in objavil Edward I. Altman leta 1968. Gre za vrsto empiričnega modela za kreditno tveganje, saj temelji na primerjavi tistih podjetij, ki so zapadla, in tistih, ki so preživela. Kljub temu, da je bil model razvit pred več kot petdesetimi leti, še danes velja za aktualno in uporabno orodje po vsem svetu. Altman je v svoji prvi objavi predstavil formulo, ki z vsoto in utežmi petih opazovanih razmerij opredeli solventnost obravnavanega podjetja. Kot ključne vhodne spremenljivke in indikatorje je avtor izbral razmerja med bilančnimi podatki določenega podjetja.

$$X_1 = \text{obratna sredstva/celotna sredstva} \quad (1)$$

$$X_2 = \text{kapital/celotna sredstva} \quad (2)$$

$$X_3 = \text{EBITDA/celotna sredstva} \quad (3)$$

$$X_4 = \text{tržna vrednost/celotne obveznosti} \quad (4)$$

$$X_5 = \text{prihodki/celotna sredstva} \quad (5)$$

Vsakemu razmerju je pripisal utež in vsoto produktov poimenoval Z-Score.

$$Z = 1,2 * X_1 + 1,4 * X_2 + 3,3 * X_3 + 0,6 * X_4 + 0,99 * X_5 \quad (6)$$

Po višini rezultata Z-Score je avtor razporedil podjetja v tri razrede. Podjetja z vrednostjo Z-Score nad 2,99 so v »varnem območju« (angl. safe zone), podjetja med 1,8 in 2,99 se uvrščajo v sivo cono (angl. grey zone), Z-Score pod 1,8 pa pade v območje propada (angl. distress zone) (Altman, 1968). Slednje označuje jasno opozorilo na visoko verjetnost neplačila. Kljub priznanosti Altmanovega modela Z-Score je treba opozoriti na pomanjkljivosti. Model je bil leta 1968 razvit na majhnem vzorcu ameriških podjetij določenih panog. V zadnjih petdesetih letih sta tako struktura podjetij kot sama panožna struktura doživeli ogromen razvoj in spremembe. Posledično je uporabnost modela vprašljiva.

Prvotni model je bil razvit za analizo kotirajočih proizvodnih podjetij, kasneje pa sta bili razviti tudi nadgradnji za nekotirajoča podjetja in za podjetja v razvijajočem se trgu.

Z'-Score, objavljen leta 1983, je namenjen analizi zasebnih podjetij, Altman ga je poimenoval Revidiran model Z-Score (angl. revised Z-Score model) (Altman, 1968). V četrti spremenljivki je namesto tržne vrednosti lastniškega kapitala uporabil knjigovodsko vrednost lastniškega kapitala (Majcan, 2020).

$$Z' = 7,17 * X_1 + 8,47 * X_2 + 31,07 * X_3 + 4,2 * X_4 + 0,998 * X_5 \quad (7)$$

Podjetja z vrednostjo Z' -Score nad 2,9 so v »varnem območju«, med 1,23 in 2,9 se uvrščajo v sivo cono, Z' -Score pod 1,23 pa spada v območje propada (Altman, 1983).

Z'' -Score, objavljen leta 1993, je namenjen analizi podjetij na razvijajočem se trgu (angl. emerging market). Zaradi specifik vključenih podjetij Altman izpusti zadnje peto razmerje.

$$Z'' = 6,56 * X_1 + 3,26 * X_2 + 6,72 * X_3 + 10,5 * X_4 \quad (8)$$

Podjetja z vrednostjo Z'' -Score nad 2,6 so v »varnem območju«, med 1,1 in 2,6 se uvrščajo v sivo cono, Z'' -Score pod 1,1 pa v območje propada (Caoette, Altman, Narayanan & Nimmo, 2008). Po navedbah Mednarodnega monetarnega sklada v razvijajoči se trg uvrščamo države, kot so Indija, Kitajska, Rusija, Brazilija, Mehika, Savdska Arabija, Nigerija in Južna Afrika (International Monetary Fund, 2021).

Čeprav se dogodki neplačil pojavljajo stohastično, torej z naključno verjetnostjo, se lahko informacije o kapitalskih trgih uporabijo učinkovito tudi za razvoj modelov napovedovanja propada družb (Barabozza, Kimura & Altman, 2017). Za obravnavo verjetnosti neplačila iz vidika bilančnih podatkov je bil v procesu izdelave ekspertnega modela zato uporabljen Altmanov model kot prvi preizkuševalec kreditnega tveganja naložb.

Vrednost Z -Score pa seveda ni popolni pokazatelj stanja opazovanega podjetja. Rezultat je treba skrbno in previdno interpretirati. Podatki prikazujejo pravo sliko zgolj v primeru, da so pravi in realistični, kar pa pri izkazih ni vedno samoumevno. Prav tako se problem pojavi pri novejših podjetjih ali tako imenovanih start-up podjetjih, saj imajo zelo malo, ali pa celo nič zaslužka. Posledično bodo podjetja ne glede na njihovo uspešnost dosegala zelo nizke ocene pri Altmanovih izračunih. Poleg tega Z -Score neposredno ne obravnava vprašanja denarnih tokov, temveč nanj le namiguje z uporabo razmerja kapitala in sredstev. Navsezadnje pa je za plačilo računov potrebna gotovina. Z -Score vrednosti lahko nihajo med kvartali, saj podjetje beleži enkratne odpise. Ti lahko spremenijo končni rezultat, kar pomeni, da je podjetje, ki ni ogroženo, po rezultatih sodeč na robu bankrota. Glede na pomanjkljivosti je Altmanovo vrednost Z -Score verjetno bolje uporabiti kot merilo relativnega finančnega zdravja in ne kot napovedovalca. Model je najbolje uporabiti kot hitro preverjanje ekonomskega zdravja, v primeru težav pa je pokazatelj potrebe po podrobnejši analizi (McClure, 2022).

3 PRIMERJALNA ANALIZA NA PODLAGI KREDITNIH RAZPONOV

Naslednja izmed metod modeliranja kreditnega tveganja temelji na podlagi bonitetnih ocen in razponov donosa, kjer ponovno govorimo o empiričnem modelu. Za to vrsto modelov smo omenili, da temeljijo na primerjavi historičnih finančnih podatkov tistih podjetij, ki so šla v stečaj, in tistih, ki so preživela.

V tem poglavju se najprej posvetimo zgodovinski zasnovi bonitetnih ocen, nato pa procesu bonitetnega ocenjevanja. V kolikor želimo s svojim modelom sami podati bonitetno oceno, je ključno dobro razumevanje sestave le-te. V nadaljevanju poglavja so opisane ključne značilnosti krivulje donosa in najpomembnejše tržne obrestne mere ter njihove glavne značilnosti. Kot dodatna indikatorja sta bila prepoznana tudi stopnja tveganja in likvidnost, ki sta prav tako predstavljena v zadnjem razdelku. Tudi drugi indikatorji kreditnega tveganja so osnovani na primerjanju.

3.1 Bonitetne ocene

Pod pojmom bonitetne ocene danes razumemo skupek lastnosti podjetja, ki predstavlja neko stanje v hierarhični porazdelitvi, ni pa bilo vedno tako. Včasih je ta izraz označeval le privilegije nekaterih oseb glede na njihov položaj, starostno skupino, položaj na delu, pa tudi položaj stvari, na primer zemljišč (Knez-Riedl, 1998). Beseda boniteta izvira iz latinske besede »bonus«, kar pomeni dober, sposoben in prednosten. Prav tako je povezana z latinsko besedo »bonitas«, ki predstavlja ugodnost, dobroto, odličnost in pravičnost. Boniteto lahko zato razumemo kot kakovost (Brvar, 1998). Danes boniteto v ekonomski terminologiji obravnavamo kot informacijo o finančnem in premoženjskem stanju podjetja. Prav tako nam veliko pove o uspešnosti poslovanja podjetja, poslovodstvu in statusu (Škrjanerc, 2009). Enotne definicije za podajo bonitetne ocene ni, so pa ene izmed ključnih informacij za vse udeležence na finančnem trgu.

3.1.1 Zgodovina bonitetnih ocen

Leta 1909 je John Moody objavil prve javno dostopne bonitetne ocene, ki so bile v celoti osredotočene na železniške obveznice. Za tem so mu sledili Poor's Publishing leta 1916, Standard Statistics Company leta 1922 in Fitch Publishing 1924. Skozi čas so se na trgu uveljavile tri najpomembnejše bonitetne agencije, in sicer Moody's, Standard & Poor's in Fitch. Uspešne ocene teh treh agencij so bile ključne za veliko prodajo vrednostnih papirjev na podlagi hipotekarnih kreditov in drugih dolžniških naložb, kar se je jasno izkazalo v krizi leta 2008. V prvih letih so agencije služile s prodajo svojih ocen kreditnih sposobnosti vlagateljem, dokler ni Komisija za vrednostne papirje in borzo (angl. Securities and Exchange Commission – SEC) leta 1934 zahtevala, da družbe izdajajo

standardizirane finančne izkaze. Bonitetne ocene so bile posledično javno objavljene in podane v obliki črkovnih ocen. Bančni regulatorji so želeli spodbuditi banke, naj vlagajo le v varne obveznice, zato so leta 1936 izdali predpise, ki so bankam prepovedovali vlaganje v špekulativne naložbene vrednostne papirje z nizkimi bonitetnimi ocenami (angl. junk bonds). S tem so želeli omejiti volatilitnost bank, ki bi v svojih portfeljih držale zgolj obveznice z visokimi bonitetnimi ocenami (angl. investment grade). V naslednjih desetletjih so zavarovalniški regulatorji sledili podobni poti kot bančni. Določili so minimalne kapitalske zahteve, ki so bile prilagojene bonitetnim ocenam obveznic. Skozi čas so se razvila regulativna pravila, ki so v veliki večini v ospredje postavljala bonitetne ocene. Banke in zavarovalnice so posledično obravnavale lastno kreditno presojo na podlagi bonitetnih ocen obveznic in s tem izpolnile varnostne zahteve regulatorjev (White, 2010). Omenjenim trem bonitetnim agencijam je zakonodaja na nek način odprla vrata, saj finančne institucije od takrat niso več svobodno odločale, kateri vir informacij je zanesljiv in verodostojen, ampak so bile prisiljene upoštevati ocene takrat vodilnih bonitetnih agencij (Marčuk, 2014). Ironija, ki jo je razkrila kriza leta 2008, je, da so imele bonitetne agencije pod svojimi ocenami izjavo: »Vsak uporabnik informacij, ki jih vsebuje ta dokument, se ne bi smel zanašati na nobeno bonitetno oceno ali drugo mnenje, ki ga ta dokument vsebuje« (White, 2010). Vseeno pa so bonitetne agencije med najpomembnejšimi akterji na finančnem trgu, saj njihove analize in ocene uporabljamo vsi, od izdajateljev in regulatorjev pa vse do velikih in malih investitorjev. Lahko bi rekli, da bonitetne agencije opravljajo vlogo posrednika informacij med vlagatelji v obveznice in izdajatelji obveznic. Njihove dejavnosti se večinoma financirajo s provizijami, ki jih plačujejo banke (Corelli, 2014). Kljub uveljavitvi drugih bonitetnih agencij omenjene vodilne tri (Moody's, Standard & Poor's, Fitch) še danes pokrivajo kar 95 % svetovnega trga. Oznake bonitetnih ocen se med bonitetnimi agencijami deloma razlikujejo, kot je razvidno iz slike 1.

Slika 1: Primerjava označevanja bonitetnih ocen treh različnih bonitetnih agencij

Characterization of debt and issuer (source: Moody's)	Rating			Linear transformations	
	S&P	Moody's	Fitch	Scale 21	Scale 17
Highest quality	AAA	Aaa	AAA	21	17
High quality	AA+	Aa1	AA+	20	16
	AA	Aa2	AA	19	15
	AA-	Aa3	AA-	18	14
Strong payment capacity	A+	A1	A+	17	13
	A	A2	A	16	12
	A-	A3	A-	15	11
Adequate payment capacity	BBB+	Baa1	BBB+	14	10
	BBB	Baa2	BBB	13	9
	BBB-	Baa3	BBB-	12	8
Likely to fulfil obligations, ongoing uncertainty	BB+	Ba1	BB+	11	7
	BB	Ba2	BB	10	6
	BB-	Ba3	BB-	9	5
High credit risk	B+	B1	B+	8	4
	B	B2	B	7	3
	B-	B3	B-	6	2
Very high credit risk	CCC+	Caa1	CCC+	5	
	CCC	Caa2	CCC	4	
	CCC-	Caa3	CCC-	3	
Near default with possibility of recovery	CC	Ca	CC	2	1
			C		
Default	SD	C	DDD		
	D		DD	1	
			D		

Vir: Afonso (2007).

3.1.2 Proces bonitetnega ocenjevanja

Analiza za bonitetno ocenjevanje po navadi preučuje poslovna in finančna tveganja. Analiza poslovnega tveganja v veliki meri temelji na subjektivni strokovni oceni bonitetne agencije, kjer so zajete spremenljivke, kot so država oziroma regija, dinamika panoge, konkurenčni tržni položaj, sposobnost vodstva in dobičkonosnost. Pri analizi finančnega tveganja gre za bolj objektivno oceno na podlagi kvantitativnih metod, ki vključujejo računovodske in informacijske karakteristike, analizo denarnih tokov, strukture kapitala in likvidnosti. Rezultat procesa bonitetnega ocenjevanja je sintetična ocena na podlagi kvantitativnih ocen in subjektivne presoje (Corelli, 2014).

Bonitetne agencije objavljajo dve vrsti ocen. Z enimi ocenjujejo izdane vrednostne papirje, z drugimi pa izdajatelje v splošnem. Ocena izdanega vrednostnega papirja je odvisna od trenutne ocene kreditne sposobnosti izdajatelja, da poplača svoj dolg za dani vrednostni papir, medtem ko je ocena izdajatelja odvisna od njegove skupne kreditne sposobnosti in napoveduje verjetnost neplačila za vse vrednostne papirje tega izdajatelja. Po enakem principu, kot se bonitetne ocene dodeljujejo izdajateljem, jih lahko pripišemo tudi državam. Bonitetne agencije uporabljajo različne metode vrednotenja in skale bonitetnih razredov. V tej študiji bo uporabljena skala S&P, kjer AAA predstavlja najboljšo kreditno oceno, D pa stanje, ko družba ni več zmožna poravnati svojih obveznosti (Marčuk, 2014). V investicijski razred uvrščamo naložbe z ocenami med AAA in BBB-, v špekulativni pa vse pod BBB-. Po regulatornih napotkih Solventnosti 2 je treba uporabiti drugo najboljšo bonitetno oceno (angl. second best rating). Če je na voljo samo ena ocena, uporabimo to oceno. Če pa sta na voljo dve oceni, je treba uporabiti slabšo oceno (Natixis asset management, 2016).

Spoznati se je treba še z enim zelo pomembnim terminom pri obravnavanju kreditnega tveganja, in sicer stopnjo zapadlosti oziroma stopnjo neplačila (angl. default rate). Stopnja neplačila je odstotek vseh neporavnanih posojil, ki jih je posojilodajalec odpisal kot neplačane po daljšem obdobju zamujenih plačil (Kagan, 2020).

Mejno stopnjo neplačila definiramo kot:

$$d_N(R) = \frac{m[t + N|R(t)]}{n[t + N|R(t)]} \quad (9),$$

kjer $m[t + N|R(t)]$ predstavlja število izdajateljev z oceno R ob koncu leta t, ki so zapadli v letu $T = t + N$. Imenovalec $n[t + N|R(t)]$ predstavlja število izdajateljev z oceno R ob koncu leta t, ki do začetka leta T niso zapadli (Jorion, 2009). Povprečno letno stopnjo neplačila definiramo kot

$$C_N = 1 - \prod_{i=1}^N (1 - d_i) = 1 - (1 - d)^N . \quad (10)$$

Na podlagi opazovanja historičnih podatkov lahko stopnje neplačila zapišemo kar v matriko, kot je prikazano v sliki 2.

Slika 2: Historične stopnje neplačila

Rating	Year														
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
AAA	0.00	0.00	0.03	0.07	0.11	0.20	0.30	0.47	0.54	0.61	0.61	0.61	0.61	0.75	0.92
AA	0.01	0.03	0.08	0.17	0.28	0.42	0.61	0.77	0.90	1.06	1.20	1.37	1.51	1.63	1.77
A	0.05	0.15	0.30	0.48	0.71	0.94	1.19	1.46	1.78	2.10	2.37	2.60	2.84	3.08	3.46
BBB	0.36	0.96	1.61	2.58	3.53	4.49	5.33	6.10	6.77	7.60	8.48	9.34	10.22	11.28	12.44
BB	1.47	4.49	8.18	11.69	14.77	17.99	20.43	22.63	24.85	26.61	28.47	29.76	30.98	31.70	32.56
B	6.72	14.99	22.19	27.83	31.99	35.37	38.56	41.25	42.90	44.59	45.84	46.92	47.71	48.68	49.57
CCC	30.95	40.35	46.43	51.25	56.77	58.74	59.46	59.85	61.57	62.92	63.41	63.41	63.41	64.25	64.25
Inv.	0.13	0.34	0.59	0.93	1.29	1.65	1.99	2.33	2.64	2.99	3.32	3.63	3.95	4.30	4.75
Spec.	5.56	11.39	16.86	21.43	25.12	28.35	31.02	33.32	35.24	36.94	38.40	39.48	40.40	41.24	42.05
All	1.73	3.51	5.12	6.48	7.57	8.52	9.33	10.04	10.66	11.27	11.81	12.28	12.71	13.17	13.69

Vir: S&P (2002).

Intuitivno je, da imajo bonitetne ocene investicijskega razreda nižje stopnje neplačila kot tiste iz špekulativnega. Jasen trend je opazen tudi pri časovni oddaljenosti, stopnja neplačila se torej pri vseh bonitetnih ocenah zvišuje, ko se časovno premikamo stran od $t=0$.

Na podlagi historičnih podatkov in vključitvi trenutnih tržnih razmer finančni analitiki pripravijo simulacije in napovedi za pričakovane stopnje neplačila v prihodnosti. Take vrste tabel imenujemo tudi migracijske matrike, uporabljene pa so bile tudi v ekspertnem modelu. Mera stopnje neplačila je na dolgi rok lahko odvisna od manjših vzorcev opazovanja. Druga možnost pa je, da izračune poenostavimo s predpostavko Markovskega procesa za migracijo ocen, ki ga opisuje prehodna ali migracijska matrika (angl. tranzision matrix), prikazana na sliki 3. Prehodna matrika prikazuje verjetnost prehoda iz ene ocene na drugo, odvisno od ocene na začetku obdobja. Ob tem upoštevamo predpostavko Markovskega procesa, ki pravi, da je selitev med stanji neodvisna med obdobji. Markovska veriga opisuje proces, kjer je pogojna porazdelitev konstantna skozi čas glede na današnjo vrednost (Jorion, 2009).

Slika 3: Primer migracijske matrike

Initial Rating	Rating at year end (%)							
	AAA	AA	A	BBB	BB	B	CCC	Default
AAA	87.74	10.93	0.45	0.63	0.12	0.10	0.02	0.02
AA	0.84	88.23	7.47	2.16	1.11	0.13	0.05	0.02
A	0.27	1.59	89.05	7.40	1.48	0.13	0.06	0.03
BBB	1.84	1.89	5.00	84.21	6.51	0.32	0.16	0.07
BB	0.08	2.91	3.29	5.53	74.68	8.05	4.14	1.32
B	0.21	0.36	9.25	8.29	2.31	63.89	10.13	5.58
CCC	0.06	0.25	1.85	2.06	12.34	24.86	39.97	18.60

Vir: RiskMetrics Group (2007).

Pomanjkljivost, ki je ni mogoče prezreti, je predpostavka Markovskega procesa, ki pravi, da je verjetnost v nekem obdobju neodvisna od stanj v preteklosti. Obstajajo pa dokazi, da so te verjetnosti avtokorelirane skozi čas (Naglič, 2010). Poleg tega je treba izpostaviti tudi ustaljenost migracijskih matrik. Pri uporabi slednjih gre za uporabe enotne matrike ne glede na panogo, kar ponovno predstavlja pomanjkljivost uporabe le-teh.


3.2 Časovni razpon

Da bi kreditno tveganje uspeli opazovati iz različnih zornih kotov, je v modelsko analizo dodan tudi z-razpon, ki je indikator razpon donosa. Ta s pomočjo določene referenčne vrednosti prikazuje tržno vrednost finančnega instrumenta. Da bi razpon donosa dodobra razumeli, pogledjmo najprej, kaj sploh predstavlja krivulja donosnosti določene naložbe.

3.2.1 Krivulja donosnosti

Pri ocenjevanju kreditnega tveganja je zelo pomembno poznavanje krivulje donosnosti (angl. yield curve) in njeno obnašanje. Gre za časovno strukturo obrestnih mer, ki opisuje razmerje med donosnostjo posameznega instrumenta in njegovim časom do dospetja. Časovno strukturo obrestnih mer prikazujemo s krivuljo donosnosti, ki je predstavljena z grafom razmerja med donosnostjo in ročnostjo vrednostnih papirjev s konstantnim donosom (angl. fixed income securities) (Ahčin, 2019). Primer normalne krivulje donosnosti je prikazan na sliki 4.

Slika 4: Normalna krivulja donosnosti



Vir: Hayes (2022).

Tipična krivulja donosnosti temelji na donosnosti do dospelja (angl. yield to maturity) različnih kuponskih obveznic. Donosnost do dospelja je definirana kot obrestna mera, pri kateri je sedanja vrednost prihodnjih denarnih tokov obveznice enaka njeni trenutni tržni ceni. Kot taka donosnost do dospelja predstavlja tehtano povprečje zahtevanih stopenj donosa denarnih tokov, ki jih investitorji pričakujejo v času trajanja obveznice (Ahčin, 2019).

Intuitivno opazimo, da imajo naložbe s krajšim časom do dospelja manjši donos, saj krajše časovno obdobje predstavlja manjšo verjetnost, da se bo v tem času zgodil tržni šok (Čop, 2013). Donosnost dolžniškega vrednostnega papirja označimo z γ_n in jo lahko določimo kot seštevek donosnosti netveganega vrednostnega papirja $R_{f,n}$, premije za tveganje neplačila PD, likvidnostne premije LP in prilagoditve davčnih razlik T (Čop, 2013).

$$\gamma_n = R_{f,n} + PD + LP + T \quad (11)$$

V krizi leta 2008 so imele makroekonomske in fiskalne spremembe, kot so inflacija, gospodarska rast in brezposelnost, večji vpliv, kot je bilo sprva pričakovano. Ker so se makroekonomski in fiskalni kazalci gibalno različno glede na državo, se je to odrazilo tudi v različnih bonitetnih ocenah držav. Znižanja državnih bonitetnih ocen so povečala razlike med donosnostmi državnih obveznic. Razlike so se nanašale predvsem na splošno finančno stabilnost države, kar seveda zajema tudi likvidnost. Iz krivulj donosnosti je mogoče razbrati pomembne informacije o gospodarskih obetih in pogojih na finančnih trgih. Oblika krivulje opozarja vlagatelje na prihajajočo recesijo oziroma konjunkturo in potrebo po spremembi pogleda na razvoj gospodarstva v prihodnosti (Ahčin, 2019).

Prvo vprašanje, s katerim se soočamo pri konstrukciji krivulj donosnosti, je izbira referenčne obrestne mere. Referenčne obrestne mere so pomembne, saj olajšajo

standardizacijo, kar vodi do nižjih transakcijskih stroškov in večje likvidnosti. V tem poglavju so opisane najpomembnejše tržne obrestne mere in njihove glavne značilnosti. Poznavanje značilnosti obrestnih mer je ključnega pomena za razumevanje pojavov na finančnih trgih (Ahčin, 2019).

Najbolj znana tržna obrestna mera je LIBOR (angl. London Interbank Offered Rate), saj gre za referenčno obrestno mero za različne instrumente s fiksnim donosom. LIBOR je obrestna mera, po kateri si lahko največje banke na londonskem denarnem trgu izposojajo ali posojajo finančna sredstva na nezavarovani osnovi. Obrestne mere LIBOR so objavljene vsak delovni dan v petih valutah za sedem različnih ročnosti. Za vsako valuto je izbran drug spekter, ki ga sestavlja od 11 do 18 bank. V evroobmočju se nezavarovana medbančna obrestna mera z zelo podobnimi značilnostmi kot LIBOR imenuje EURIBOR (angl. Euro Interbank Offered Rate). EURIBOR je obrestna mera, po kateri primarna banka ponudi nezavarovane medbančne depozite drugi primarni banki znotraj Evropske monetarne unije (Ahčin, 2019).

3.2.2 Razpon donosnosti

Razpon donosnosti (angl. yield spread) je razlika med donosom do zapadlosti kreditno tvegane obveznice in referenčne državne obveznice z enako ali podobno zapadlostjo. Z-razpon (angl. z-spread) je zgrajen na krivulji LIBOR brezkuponske obveznice. Na splošno je z-razpon definiran kot razpon, ki ga je treba dodati promptni (angl. spot) krivulji LIBOR, da dobimo tržno ceno obveznice. Lahko pa se ga izračuna tudi glede na krivuljo državne obveznice (Malz, 2011). Gre torej za vrednost, ki je enaka sedanji vrednosti denarnih tokov obveznice glede na trenutno tržno ceno. Prednost uporabe z-razpona kot kazalnika tveganja je, da nanj gledamo kot na neposredni kazalnik kreditnega tveganja države, ki je določen v posamezni obveznici. Poleg tega ga lahko neposredno primerjamo z razponom zaradi zamenjave kreditnih neplačil (angl. credit default swap – v nadaljevanju CDS) v državah. Negativne vrednosti z-razpona označujejo manjše tveganje, pozitivne pa večje relativno tveganje. Treba je opozoriti, da se razlike v likvidnosti obveznic odražajo v različnih likvidnostnih premijah v razponih (Kalteier, Molt & Nguyen, 2014).

Vlagatelji merijo relativno tržno vrednost poslovne obveznice z merjenjem razpona glede na določeno referenčno vrednost. Gre za razpon nad referenčno vrednostjo, ki predstavlja donos korporativne obveznice (Choudhry, 2006). Pri ekspertnem modelu smo za osnovo obrestnih mer uporabljali brezkuponske obveznice za valuti EUR in USD. Za ostale valute so bile zaradi poenostavitve uporabljene netvegane obrestne mere EIOPA.

3.3 Opcijsko prilagojen razpon

Še ena izmed mer za razpon je opsijsko prilagojen razpon (angl. option adjusted spread – v nadaljevanju OAS), ki meri razliko v donosnosti med obveznico z vgrajeno opcijo in donosom državne obveznice (Chen, 2021b). Gre za mero, ki s pomočjo opazovanja povprečja indeksov, prikazuje tržne razmere za določeno kategorijo naložb glede na bonitetno oceno in vrsto naložbe.

3.3.1 Finančni indeksi

V tem procesu smo torej vključili tudi pojem finančnih indeksov. Indeks je metoda za spremljanje uspešnosti skupine sredstev na standardiziran način. Indeksi običajno merijo uspešnost košarice vrednostnih papirjev, ki je namenjena ponovitvi določenega področja trga. V finančni terminologiji se beseda indeks običajno nanaša na statistično merilo sprememb na trgu vrednostnih papirjev. V primeru finančnih trgov so indeksi delniškega in obvezniškega trga sestavljeni iz hipotetičnega portfelja vrednostnih papirjev, ki predstavljajo določen trg ali njegov segment (Chen, 2021a). Vlagatelji z namenom spremljanja razmer na trgu sledijo različnim tržnim indeksom. Trije najbolj priljubljeni borzni indeksi za sledenje uspešnosti ameriškega trga so Dow Jones Industrial Average (DJIA), S&P 500 Index in Nasdaq Composite Index. Na trgu obveznic je Bloomberg vodilni ponudnik tržnih indeksov z Bloombergovim indeksom ameriških obveznic, ki je eden izmed najbolj priljubljenih posrednikov za ameriške obveznice. Tovrstni portfelji se na splošno uporabljajo kot merila uspešnosti ali za razvoj indeksnih skladov (Young, 2022).

Z družbenega vidika in konkretnega spremljanja indeksov se uporabi tiste, ki najbolj povzemajo pestrost njihovega portfelja. Družba torej izbere indeks, ki vsebuje določeno število naložb s podobnimi značilnostmi, kot so bonitetne ocene, panoga in trajanje. Da bi pestrost portfelja zajeli kar se da natančno, lahko indekse pripišemo tudi optimizacijskim razredom in tako za portfelj uporabimo kombinacijo indeksov.

3.3.2 Opcijsko prilagojen razpon

Za razliko od predhodno omenjenega z-razpona OAS upošteva vgrajeno opcijo v obveznico in kako ta lahko spremeni prihodnje denarne tokove in celotno vrednost obveznice (ProQuest LLC, 2019). Vgrajene opcije so nekakšne provizije, ki so vključene v vrednostne papirje s stalnim donosom, kar vlagatelju ali izdajatelju omogoča izvajanje določenih dejanj, na primer vpoklic izdaje. OAS je izpeljan s postavitvijo niza poti obrestnih mer. Gre za uporabo multinomne rešetke ali simulacijskih tehnik, ki so skladne s strukturo državne obveznice. Poti obrestnih mer se nato uporabijo za diskontiranje

denarnih tokov iz nedržavnih vrednostnih papirjev za doseg sedanje vrednosti (Chen, 2021b). OAS lahko izračunamo po naslednji enačbi:

$$P = \frac{1}{S} \sum_{s=1}^S \sum_{t=1}^T \frac{cf_t^S}{\prod_{i=1}^t (1 + r_t^S + oas)} \quad (12),$$

kjer P predstavlja tržno ceno, T predstavlja čas, S predstavlja število poti obrestnih mer, cf predstavlja denarni tok, r pa kratkoročno diskontno stopnjo (Babbel & Zenios, 1992).

Opcijsko prilagojen razpon pomaga vlagateljem primerjati denarne tokove vrednostnega papirja s stalnim donosom z referenčnimi obrestnimi merami, hkrati pa ovrednotiti vgrajene opcije glede na splošno nestanovitnost trga. Z ločeno analizo vrednostnega papirja v obveznici in vgrajeno opcijo lahko analitik ugotovi, ali je naložba pravilno vrednotena. Metoda OAS je natančnejša od preproste primerjave donosnosti obveznice do zapadlosti z referenčno vrednostjo. Razpon upošteva pretekle podatke za pregled variabilnosti obrestnih mer. Izračuni poskušajo modelirati prihodnje spremembe obrestnih mer. Za napovedovanje verjetnosti se pogosto uporabljajo naprednejše metode statističnega modeliranja, kot je analiza Monte Carlo (Chen, 2021b).

OAS ima številne prednosti pred običajnimi merami donosa za izračun pričakovanega donosa. Kot je bilo že omenjeno, model zajame nestanovitnost obrestnih mer, obenem pa upošteva tudi morebitno občutljivost denarnih tokov na gibanje obrestnih mer. Model vrednotenja preslika prihodnje denarne tokove na obrestne mere in poti, ki jim sledijo. OAS različnih vrednostnih papirjev je mogoče smiselno primerjati, saj se pokažejo relativne pričakovane razlike v donosnosti, kar je tudi glavni razlog za široko uporabo modela (Babbel & Zenios, 1992).

Kot pri vsakem modelu se tudi tukaj najdejo določene pomanjkljivosti. OAS je modelsko odvisen. Pri merjenju razpona se OAS sklicuje na predpostavko, da je model oblikovanja cen, ki se uporablja, pravilen in da glede na cenovni model obstaja opcijsko prilagojen razpon v velikosti x bazičnih točk. Ko govorimo o pravilnem modelu oblikovanja cen, mislimo na pravilno modelirane obrestne mere in denarne tokove (Babbel & Zenios, 1992).

Ker gre pri uporabi vrednosti OAS za veliko količino podatkov in sprotno spremljanje, v praksi finančne družbe večinoma uporabijo zunanjega izvajalca oziroma ponudnika podatkov. Družbe glede na svoje investicijsko zanimanje in svoj portfelj izberejo indekse, ki najboljše povzemajo pestrost njihovega portfelja. Posamezen indeks vsebuje določeno število naložb s podobnimi značilnostmi in tako predstavlja povprečje vrednosti OAS.

Uporabnik s pomočjo indeksa in njegove vrednosti OAS opazuje, kako se njegova konkretna naložba giba glede na ostalo populacijo naložb s podobnimi karakteristikami.

3.4 Stopnja tveganja (angl. hazard rate)

Stopnja tveganja (angl. hazard rate), imenovana tudi intenzivnost neplačila (angl. default intensity), je vodilni parameter neplačila. Parameter vsebuje časovno razsežnost, za katero predpostavljamo, da je letna (Malz, 2011). Stopnja tveganja predstavlja pogojno verjetnost pojava neplačila v majhnem časovnem intervalu $[t, t + dt]$ ob predpostavki, da se dogodek neplačila še ni zgodil do časa t (Bielecki, Jeanblanc & Rutkowski, 2009).

Za primer vzemimo netvegano brezkuponsko obveznico, ki jo poganja deterministična kratkoročna obrestna mera $(r(t), t \in \mathbb{R}_+)$, in tržno okolje, v katerem kotirajo samo taki instrumenti. Predpostavimo, da je čas neplačila (angl. default time) τ poljubno definirana pozitivna naključna spremenljivka. Naj bo F kumulativna porazdelitvena funkcija naključne spremenljivke τ , tako da je

$$F(t) = \mathbb{Q}(\tau \leq t) = \int_0^t f(u) du, \quad (13),$$

poleg tega pa predpostavimo, da za vsak $t \in \mathbb{R}_+$ velja $F(t) < 1$. Stopnjo nevarnosti lahko sedaj izpeljemo iz funkcije nevarnosti. Funkcijo nevarnosti zapišemo kot

$$\Gamma(t) = -\ln(1 - F(t)). \quad (14)$$

Če je kumulativna porazdelitvena funkcija F absolutno neprekinjena, lahko funkcijo nevarnosti zapišemo tudi kot

$$\Gamma(t) = \int_0^t \gamma(u) du, \quad (15),$$

kjer za vsak $t \in \mathbb{R}_+$ velja

$$\gamma(t) = f(t)(1 - F(t))^{-1}. \quad (16)$$

Funkcijo γ torej imenujemo stopnja tveganja v času neplačila oziroma zapadlosti τ . Kot že omenjeno, predstavlja pogojno verjetnost pojava neplačila v časovnem intervalu $[t, t+dt]$, v kolikor se dogodek neplačila še ni zgodil do časa t (Bielecki, Jeanblanc & Rutkowski, 2009).

3.5 Likvidnost

Pri obravnavi in merjenju kreditnega tveganja moramo biti kot investitorji pozorni na več kazalnikov. Eden izmed teh je tudi likvidnostna premija, ki je bila prav tako vključena v ekspertni model. Če smo v vlogi investitorja, ki namerava držati obveznico do dospelja, nam likvidnostna premija predstavlja netvegan donos. Če kot investitor kupimo obveznico z namenom trgovanja, želimo biti seznanjeni z likvidnostno premijo, saj nam ta pove, kako težko jo bo prodati. Z vprašanjem likvidnostne premije se stroka ukvarja že več kot trideset let. Prvi modeli avtorjev Amihuda in Mendelsoona na to temo so bili objavljeni leta 1986. V teoriji likvidnostno premijo definiramo kot razliko med kreditnim razponom obveznice in kreditnim razponom enake, vendar popolnoma likvidne obveznice. Likvidnostna premija za investitorja predstavlja pomemben sestavni del kreditnega razpona in s tem tudi tveganja. Gre namreč za edino komponento, ki ni povezana z možnostjo propada obveznice, temveč z možnostjo prodaje obveznice. Likvidnostno premijo lahko merimo s pomočjo več kazalnikov, ki pa med seboj niso združljivi zaradi prevelike medsebojne korelacije (Perme, 2018). Vsak izmed kazalnikov ima torej določene prednosti uporabe in določene slabosti. Eden izmed kazalnikov je razpon ponudbe in povpraševanja (angl. Bid-ask spread). Težava, ki se pojavlja pri uporabi razpona ponudbe in povpraševanja, je razpon, ki ni posledica zgolj likvidnosti, ampak še drugih dejavnikov.

$$\text{Razpon ponudbe in povpraševanja} = \frac{\text{povpraševanje} - \text{ponudba}}{\text{povpraševanje}} \quad (17)$$

$$\text{bid ask spread} = \frac{\text{ask} - \text{bid}}{\text{bid}} \quad (18)$$

Za kazalnik likvidnosti smo uporabili likvidnostno premijo (angl. Liquidity premium), ki jo lahko izračunamo kot razliko med z-razponom in razponom ponudbe in povpraševanja. Kot drugi kazalnik pa lahko vzamemo razliko med stopnjo nevarnosti in likvidnostno premijo.

4 ANALIZA VERJETNOSTI NEPLAČILA

Kreditno tveganje je mogoče oceniti tudi na podlagi tržnih cen podjetniških obveznic. Cene takšnih vrednostnih papirjev bi morale odražati novejšo in natančnejšo merjenje kreditnega tveganja. S tem namenom je bila pestrost ekspertnega modela razširjena tako, da je v analizo vključen tudi del strukturnega modela. Strukturni modeli poskušajo posnemati podjetje in njegovo ekonomsko strukturo. Osnovni princip tovrstnih modelov

temelji na ideji, da podjetje ne izpolni svojih obveznosti, ko je vrednost njegovega premoženja nižja kot njegov dolg oziroma obveznosti. Strukturni modeli za oceno kreditnega tveganja uporabijo bilanco stanja in kapitalsko strukturo podjetja. Po takem principu bi na trgu lahko preprosto opazovali kreditne razlike, ker pa seveda nikoli ne govorimo o popolnem trgu, na podlagi teh težko podamo tehtne sklepe. Omejitve, ki so prisotne pri tovrstnih modelih, so zgodovinske nabavne vrednosti, ki ne odražajo ekonomske vrednosti. Prav tako se s sredstvi in dolgom po navadi ne trguje, kar je še dodaten razlog za težko implementacijo tovrstnih modelov v praktično ocenjevanje (Berk Skok, 2020).

Tretji sklop ekspertnega modela, izdelanega za izbrano finančno institucijo, predstavlja analiza verjetnosti neplačila. V poglavju je najprej predstavljen Mertonov model in njegove predpostavke, nato pa še njegova nadgradnja, in sicer model KMV. Sledi predstavitev verjetnosti neplačila in njena primerjava v različnih časovnih obdobjih ter predstavitev pojma pričakovana frekvenca neplačila.

4.1 Mertonov model

Glede na naravo kreditnega tveganja je eno glavnih vprašanj opisati proces neplačila. Kot že omenjeno, strukturni modeli obdelujejo informacije o razvoju strukturnih spremenljivk podjetja, kot so sredstva in obveznosti, in s tem določijo čas neplačila. Tak pristop omogoča modeliranje kreditnih dogodkov, ki temeljijo neposredno na ekonomskih osnovah, kot je na primer kapitalna struktura podjetja. Gonilni dejavniki v strukturnih modelih so vrednost premoženja podjetja in prag neplačila. Najbolj priljubljen med strukturnimi pristopi je Mertonov model. Model namreč poenostavlja strukturo podjetja, ki je v vsakem času sestavljeno iz lastniškega kapitala in zneska dolga (Corelli, 2014). Robert Cox Merton je ameriški ekonomist in Nobelov nagrajenec, znan predvsem po pionirskem modelu določanja cen v neprekinjenem časovnem obdobju: model Black–Scholes–Merton. Leta 1997 je Merton skupaj s Scholesom prejel Nobelovo nagrado za ekonomske vede za metodo določanja vrednosti izvedenih finančnih instrumentov (Wikipedia, 2021b). Priljubljen strukturni pristop je Merton razvil leta 1974, temelji pa na predpostavkah modela Black–Scholes.

4.1.1 Predpostavke modela

Predpostavke Black-Scholesovega modela po Mertonu (1974):

- (1) Ni transakcijskih stroškov, davkov ali ovir z nedeljivostjo premoženja.
- (2) Obstaja zadostna količina premoženja in zadostno število vlagateljev za vse nakupe in prodaje.
- (3) Obstaja trg za najem in izdajo posojil po enaki obrestni meri.

- (4) Kratke prodaje vseh sredstev s polno porabo prihodkov so dovoljene.
- (5) Trgovanje sredstev časovno ni prekinjeno.
- (6) Velja Modigliani-Millerjev izrek, ki pravi, da je vrednost podjetja neodvisna od kapitalne strukture oziroma od načina financiranja.
- (7) Cena netvegane diskontirane obveznice, ki obljublja plačilo ene enote denarja v času t , je $P(t) = e^{-rt}$, kjer r predstavlja netvegano obrestno mero skozi ves čas.
- (8) Dinamiko vrednosti podjetja skozi čas je mogoče opisati s stohastičnim procesom in jo zapisati z diferencialno enačbo $dV = (\alpha V - C)dt + \sigma V dZ$, kjer je α trenutna pričakovana stopnja donosa na enoto časa, C so skupna dolarska izplačila podjetja svojim upnikom, σ^2 je varianca donosnosti podjetja, dZ pa standardni Gauss-Wienerjev proces ali Brownovo gibanje.

Brownovo gibanje (angl. Brownian motion) je Wienerjev stohastični proces z neodvisnim prirastkom in zvezno verjetnostjo. Gre za matematični model, ki opisuje problem naključnega sprehoda (Wikipedia, 2021a). Proces v kvantitativno teorijo vpelje Albert Einstein leta 1905. Proces na intervalu $[0, T]$ opisuje slučajna spremenljivka $W(t)$, ki je odvisna od $t \in [0, T]$. Za to slučajno spremenljivko velja naslednje:

- (1) $W(0) = 0$
- (2) Za poljubna s in t , kjer je $0 \leq s < t \leq T$, velja da $W(t) - W(s) \sim \sqrt{t-s} N(0, 1)$.
- (3) Za s, t, u in v , kjer je $0 \leq s < t < u < v \leq T$, sta slučajni spremenljivki $W(t) - W(s)$ in $W(v) - W(u)$ neodvisni (Merton, 1974).

4.1.2 Mertonov model

Mertonov enofaktorski model je osnova za ocenjevanje porazdelitvene funkcije stopenj neplačljivosti. Stanje neplačljivosti sproži sprememba v vrednosti osnovnega sredstva oziroma v vrednosti podjetja (Krković, 2018). Posledično nadaljnja analiza temelji na spremenljivki vrednosti podjetja V_t . Ideja modela je, da je podjetje financirano tako iz lastniškega kapitala kot tudi iz dolga. Vrednost podjetja V_t je v vsakem času t sestavljena iz kapitala (E_t) in dolga (D_t), ki je predstavljen z brezakuponsko obveznico z zapadlostjo v času T v vrednosti D_T . Na kapital družbe lahko gledamo tudi kot na evropsko nakupno opcijo:

$$E_T = \max(0, V_T - D) \quad (19)$$

Če je skupna vrednost podjetja dovolj velika za poplačilo nominalne vrednosti dolga, delničarji prejmejo svoj pričakovani delež, ki ostane po plačilu dolgov. Če je dolg višji od vrednosti premoženja, pride do dogodka neplačila in s tem imetniki obveznic prevzamejo nadzor družbe, medtem ko delničarji ne prejmejo ničesar. Če predpostavimo, da do dogodka neplačila pride lahko samo v času T , to opišemo s procesom:

$$dV_t = rV_t dt + \sigma_V V_t dW_t \quad (20),$$

kjer σ_V predstavlja volatilitnost vrednosti družbe. V tem koraku lahko uporabimo formulo Black-Scholes-Merton za oceno kapitala:

$$E_T = e^{-r\Delta t} (e^{r\Delta t} V_t N(d_1) - D * N(d_2)) \quad (21),$$

kjer sta

$$d_1 = \frac{\ln\left(\frac{e^{r\Delta t} V_t}{D}\right) + \frac{1}{2} \sigma_V^2 \Delta t}{\sigma_V \sqrt{\Delta t}} \quad (22)$$

$$d_2 = d_1 - \sigma_V \sqrt{\Delta t} \quad (23)$$

Vrednost $-d_2$ je definirana tudi kot razdalja do zapadlosti (angl. Distance to default – v nadaljevanju DD), verjetnost neplačila v času t pa kot

$$\pi = \Pr(V_t < D_t) = N(-d_2) \quad (24)$$

Z nadaljevanjem izpeljave formul pridemo tudi do vrednosti pričakovane izgube (angl. Expected loss):

$$L_E = F(N(-d_2) - \frac{e^{r\Delta t} V_t}{D} N(-d_2 - \sigma_V \sqrt{\Delta t})) \quad (25)$$

Pričakovana izguba je vsota vrednosti vseh možnih izgub, vsaka je pomnožena z verjetnostjo nastanka te izgube (Wikipedia, 2022a). Hkrati izpeljemo tudi enačbo izgube zaradi neplačila:

$$L_{GD} = \frac{e^{r\Delta t} V_t}{D} * \frac{N(-d_2 - \sigma_V \sqrt{\Delta t})}{N(-d_2)} \quad (26)$$

Izguba zaradi neplačila (angl. loss given default – v nadaljevanju LGD) je delež sredstva, ki je izgubljen, če posojilojemalec ne izpolni obveznosti. Gre za običajen parameter v modelih tveganja in tudi parameter, ki se uporablja pri izračunu ekonomskega kapitala in regulatornega kapitala po regulativi Basel II za finančne institucije. Gre torej za atribut vsake izpostavljenosti (Wikipedia, 2022b).

Očitek predpostavkam, ki so se skozi čas izkazale za nepraktične, je predpostavka o konstantni obrestni meri in izključitev davkov. Mertonov model je torej obvezen za oceno vrednosti družbe in njene volatilitosti. Strukturiran je tako, da ne dopušča neplačila pred zapadlostjo (Corelli, 2014). To lastnost lahko štejemo kot eno izmed ključnih omejitev tega pristopa, saj ne upošteva možnosti, da vrednost dolga lahko pade do minimalne vrednosti še pred zapadlostjo dolga. Drugi strukturni modeli temeljijo na predpostavkah, da se dogodek neplačila zgodi že pred zapadlostjo. V njih je čas neplačila določen s prvim eksogenim skokom. Parametri, s katerimi se meri stopnjo tveganja neplačila (angl. Default hazard rate), so izračunani iz tržnih podatkov. Ti modeli uporabljajo javno dostopne informacije na trgih dolžniških instrumentov in CDS-ov za ugotavljanje verjetnosti neplačila nasprotnih strank. Eden izmed teh je tudi model KMV (Corelli, 2014).

Še ena kritika se naslanja na predvidljivost neplačila. Upoštevamo predpostavke, da je vrednost podjetja Brownovo gibanje, hkrati pa se neplačilo lahko zgodi le ob dospelosti dolga. Ko se torej čas zapadlosti bliža, lahko z večjo natančnostjo napovemo, kaj se bo zgodilo. Potem neplačilo ni več presenečenje (Pogačar, 2011).

4.2 Model KMV

Model KMV je osnovan na delu treh raziskovalcev – Stephena Kealhoferja, Johna McQuowna in Oldricha Vasicka (Moody's Analytics, 2021). Model KMV temelji na Mertonovem strukturnem pristopu, ki pa neposredno ne opazuje niti vrednosti družbe niti njene volatilitosti. Če kljub pomanjkljivostim ohranimo predpostavke Mertonovega pristopa, lahko vrednosti spremenljivk podjetja izpeljemo iz opazovanega lastniškega kapitala s hkratnim reševanjem sistema enačb. Če zanemarimo t , lahko vrednost podjetja izrazimo kot

$$E = VN(d_1) - e^{-r\Delta t} DN(d_2). \quad (27)$$

V naslednjem koraku je uporabljena Itô lema. Gre za proces, ki zadošča stohastični diferencialni enačbi

$$dX = a(X, t)dt + b(X, t)dW. \quad (28)$$

Zvezno in dvakrat odvedljivo funkcijo lahko zato zapišemo kot

$$dF(X, t) = \left(a \frac{\partial F}{\partial X} + \frac{\partial F}{\partial t} + \frac{1}{2} b^2 \frac{\partial^2 F}{\partial X^2} \right) dt + b \frac{\partial F}{\partial X} dW. \quad (29)$$

Z uporabo Ito leme lahko volatilitnost kapitala zapišemo tudi kot

$$\sigma_E = \left(\frac{V}{E}\right) \frac{\partial E}{\partial V} \sigma_V. \quad (30)$$

V naslednjem koraku uporabimo model BSM

$$\frac{\partial E}{\partial V} = N(d_1) \quad (31),$$

iz česar sledi, da je volatilitnost kapitala enaka

$$\sigma_E = \left(\frac{V}{E}\right) N(d_1) \sigma_V. \quad (32)$$

Prvi korak pri praktični uporabi Mertonovega modela KMV je ocena σ_E . To lahko storimo na podlagi historičnih podatkov donosov delnic ali pa na podlagi opcij. Po oceni volatilitnosti kapitala je treba določiti uporabljeno netvegano obrestno mero in izbrati napovedno okno, ki bo uporabljeno kot merilo nominalne vrednosti dolga podjetja. Z omenjenimi podatki spremenljivk lahko izračunamo volatilitnost kapitala in vrednost kapitala (Corelli, 2014).

4.3 Verjetnost neplačila in pričakovana frekvenca neplačila

Verjetnost neplačila (angl. probability of default – v nadaljevanju PD) je verjetnost prehoda iz stanja plačljivosti (angl. performing) v stanje neplačljivosti (angl. nonperforming). Definicijo dogodka neplačljivosti definira vsaka finančna institucija ločeno, osnovni pogled na verjetnost neplačila pa je poenoten in je osnova vseh modelov. Gre za osnovni parameter tveganja pri ugotavljanju pričakovane kreditne izgube (Pogačar, 2018). Zapišemo jo kot binarno spremenljivko v statičnem modelu, ki predstavlja pričakovano verjetnost neplačila (Krković, 2018).

$$PD = \begin{cases} 0, & \text{če ne izpolnjuje kriterijev neplačljivosti} \\ 1, & \text{če izpolnjuje kriterij neplačljivosti} \end{cases} \quad (33)$$

Iz regulatornega vidika je po ZZavar-1 mera tveganja matematični izraz, ki določeni napovedi v obliki verjetnostne porazdelitve dodeli denarni znesek in se monotono poveča s povečanjem tveganj, na katerih temelji napoved. Napoved v obliki verjetnostne porazdelitve pa je matematični izraz, ki obsežnemu nizu medsebojno izključujočih se prihodnjih dogodkov dodeli verjetnost uresničitve (ZZavar-1).

Iz ekonomske logike in analize podatkov o plačilni disciplini strank banke je jasno razvidno, da se frekvenca dogodkov neplačila med podjetji in fizičnimi osebami v času recesije poveča (Pogačar, 2018).

Pričakovana frekvenca neplačila (angl. expected default frequency – v nadaljevanju EDF) je mera kreditnega tveganja, ki so jo razvili v podjetju Moody's Analytics kot del modela KMV (CFI, 2021). Corelli je izpostavil eno ključnih vprašanj, in sicer opis postopka neplačila. EDF je torej Moody's-ova definicija verjetnosti neplačila v določenem časovnem obdobju, po navadi po enem letu. Neplačilo je definirano kot neuspeh plačila glavnice ali obresti. Podjetje se po njihovi teoriji sooči z dogodkom neplačila, ko vrednost premoženja pade pod vrednost obveznosti. Kot tri ključne indikatorje frekvenca neplačila navajajo tržno vrednost podjetja oziroma sredstev, vrednost obveznosti podjetja in dovzetnost tržne vrednosti podjetja za velike spremembe.

Moody's-ov EDF se v določenih pogledih razlikuje od običajnih in drugih statističnih pristopov za merjenje tveganja neplačila. Gre za dinamičen pristop, katerega pozornost je usmerjena v napoved prihodnosti za razliko od alternativ, ki se na splošno zanašajo na računovodske in historične podatke. EDF temelji na vzročno-posledičnem modelu, ki ni statistično prilagojen za napovedovanje neplačila. Ker mere EDF niso primerne za napovedovanje neplačila, jih je mogoče natančno preveriti s testom na historičnih podatkih (Moody's analytics, 2011).

5 ALTERNATIVNI MODEL ZA SPREMLJANJE KREDITNIH TVEGANJ IN OCEN NALOŽB

Ekspertni model za izbrano finančno institucijo je sestavljen iz treh delov. Prvi del predstavlja vnos podatkov, kar je v našem primeru baza dejanskih naložb oziroma fiktivni portfelj. Drugi del predstavlja model, ki na več nivojih s pomočjo že obstoječih modelov preveri kreditno tveganje naložb portfelja. Tretji del pa predstavljajo izhodni podatki ekspertnega modela oziroma seznam naložb, kjer je potrebna posebna pozornost pri nadzoru kreditnega tveganja.

5.1 Vhodni podatki modela

Kot pri veliki večini raziskovalnih del je bil tudi tukaj eden izmed ključnih izzivov pridobivanje podatkov. Ker model obsega širši nabor modelov, je posledično potreben tudi širši spekter podatkov. Podatki v procesu raziskovanja so bili pridobljeni iz spletnih strani YahooFinance, Bloomberg, Intercontinental Exchange – ICE, World Bank Group, Moody's, Trading Economics in arhivov izbrane finančne institucije. Za namene izračunov so bili uporabljeni devizni tečaji ECB na datum testiranja. Naložbe za fiktivni

portfelj smo izbirali med državnimi obveznicami, običajnimi poslovnimi obveznicami, podrejenimi obveznicami, poslovnimi obveznicami z državnim jamstvom in kritimi obveznicami. Za začetek analize in izvedbo Altmanovega modela Z-Score so potrebni bilančni podatki za podjetja v fiktivnem portfelju. Vežano na potrebne spremenljivke v formulah so bili uporabljeni podatki za obratna sredstva, celotna sredstva, kapital, EBIDTA, tržna vrednost, celotne obveznosti in prihodki. Informacije o bonitetnih ocenah naložb v fiktivnem portfelju so ocene, pridobljene na podlagi vodilnih svetovnih bonitetnih agencij. Za izračune in primerjave so uporabljene bonitetne ocene v različnih časovnih obdobjih ob nakupu in na dan testiranja. Uporabljene so nakupne cene naložb, ki so bile za fiktivni portfelj kupljene na fiktivni datum. Uporabljene so Moody'sove migracijske matrike bonitetnih ocen na različne datume, ki so uporabljeni kot fiktivni datumi nakupa in testiranja.

Za potrebe primerjav bonitetnih ocen, verjetnosti dogodka neplačila in vrednosti z-razpona so bile uporabljene bonitetne ocene na dan nakupa in na dan testiranja, nabavna vrednost, datum izdaje, kuponska obrestna mera, datumi izplačil obresti in tržna vrednost na dan testiranja. Referenčni obrestni meri za krivuljo donosnosti, ki sta uporabljeni v modelu, sta LIBOR in EURIBOR, ki sta vzeti preko funkcije Quandl iz baze Nasdaq. Pri izračunih so prav tako uporabljene tudi nemške in ameriške brezcuponske državne obveznice in njihove obrestne mere. Za potrebe odločitvenega drevesa so bili uporabljeni različni količniki, vezani na panogo opazovane naložbe (obračanje sredstev, poslovni prihodki, zadržani dobiček ...) in klasični makroekonomski indikatorji (bruto domači proizvod (v nadaljevanju BDP), inflacija, brezposelnost ...), ki so bili pridobljeni iz strani World Bank Group.

V procesu testiranja napovedne moči modela je bila uporabljena tudi multinomska logistična regresija. Ta je pri uporabi regresije za modeliranje napovedi izkazovala slabšo napovedno moč kot odločitvena drevesa.

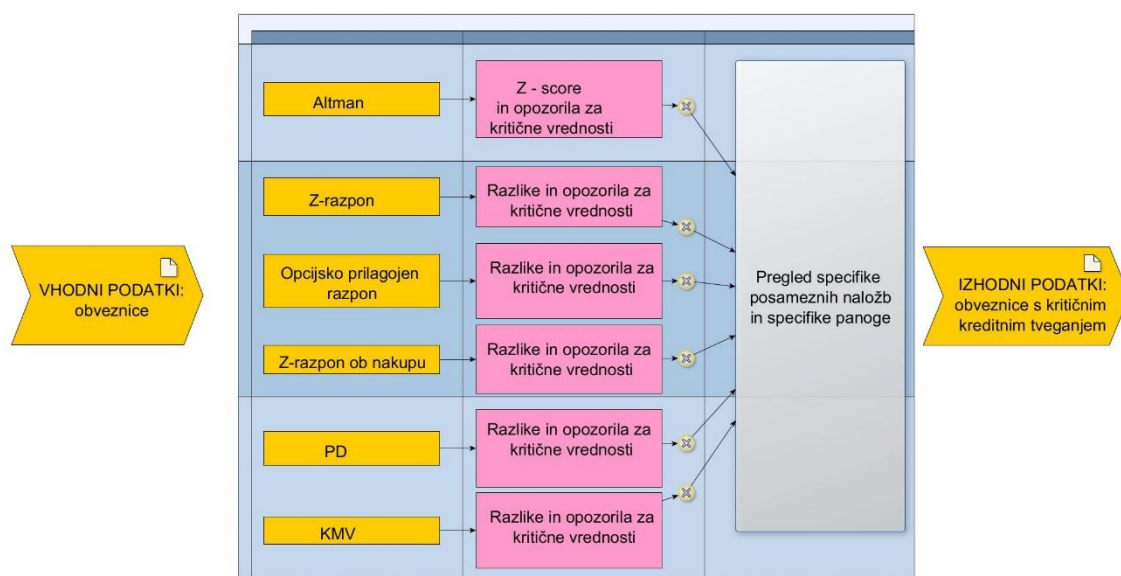
5.2 Združitev različnih metod analize

Pri izdelavi ekspertnega modela je delo potekalo postopoma. Vsak posamezni model je bil sprva izdelan in preverjen samostojno, na koncu pa so bili vsi modeli združeni v homogeno celoto. Če določen model pri konkretnih podatkih ni izkazoval dovolj visoke statistične značilnosti ali napovedne moči, je bil iz končne verzije modela izločen.

Vsak model temelji na vhodnih podatkih, kar je v našem primeru fiktivni portfelj z različnimi naložbami. Vsi modeli so napisani v programskem jeziku R in so obravnavani v programu R studio. Vsak posamezni model s pomočjo klicanja različnih definiranih funkcij na podlagi podatkov iz Excela izračuna nove kazalnike za analizo. V naslednji fazi so kazalniki analizirani glede na njihovo vrednost, vrsto naložbe in panogo. Vsak

posamezni model javi naložbe, ki imajo po njegovih standardih povečano kreditno tveganje. Naložbe, ki izkazujejo povečano tveganje, so prenesene v izhodno fazo modela, kjer so izpostavljene kot naložbe, ki potrebujejo posebno pozornost in večji nadzor. Vizualizacija procesa modela je prikazana na sliki 5, v Prilogi 1 pa je prikazana še bolj podrobna vizualizacija procesa modela.


Slika 5: Vizualizacija procesa modela



Vir: lastno delo.

Če na model pogledamo še iz tehničnega vidika, so bili vhodni podatki obravnavani v dveh sklopih. Naložba X je bila sočasno opazovana glede na trenutne podatke in glede na njen historični razvoj. Za potrebe izračunavanja kazalnikov bonitetnih ocen, verjetnosti neplačila, z-razpona, stopnje nevarnosti, opcijsko prilagojenega razpona in likvidnosti so bili uporabljeni statični podatki na določen dan. Za potrebe izračunavanja kazalnikov vrednosti Altmanovega modela Z-Score in modela KMV pa so bile uporabljene časovne vrste zaporednih historičnih podatkov o izdajateljih naložb s pomočjo njihovih preteklih izkazov. Vizualizacija vhodnih podatkov je prikazana na sliki 6.

Slika 6: Vizualizacija vhodnih podatkov



Vir: lastno delo.

5.2.1 Modeliranje bilančne analize

Pri modeliranju bilančne analize so bili vhodni podatki v prvem delu obravnavani s pomočjo Altmanovega modela Z-Score.

Sprva so bili izračunani potrebni količniki, nato pa še Z-Score glede na vrsto panoge, v kateri se nahaja izdajatelj. Primer obravnave s pomočjo Altmanovega modela je prikazan v tabeli 2.

Tabela 2: Primer obravnave bilančnih podatkov s pomočjo Altmanovega modela Z-Score

Izdajatelj	Datum	Celotna sredstva	Trenutna sredstva	Trenutne obveznosti	Obratna sredstva	Kapital	EBITDA	Tržna vrednost	Celotne obveznosti	Prihodki	z1	z2	z3	z4	z5	z_score
Izdajatelj X	11.30.2005	28.349,00	2.121,00	5.185,00	-3.064,00	24.235,00	3.541,00	52.043,92	11.466,00	11.094,00	-0,11	0,85	0,12	4,54	0,39	4,59
Izdajatelj X	11.30.2004	27.636,00	1.728,00	5.034,00	-3.306,00	23.713,00	2.985,00	52.739,06	11.876,00	9.727,00	-0,12	0,86	0,11	4,44	0,35	4,43
Izdajatelj X	11.30.2003	24.491,00	2.132,00	3.315,00	-1.183,00	21.197,00	1.968,00	34.824,27	10.698,00	6.718,00	-0,05	0,87	0,08	3,26	0,27	3,65
Izdajatelj X	11.30.2002	6.331,70	538,50	987,20	-448,70	5.448,00	589,60	7.862,19	3.517,70	2.526,80	-0,07	0,86	0,09	2,24	0,40	3,17

Vir: lastno delo.

Kot je razvidno iz rezultatov v tabeli 2, se je v dotičnem primeru vrednost Z-Score zviševala v letih od 2002 do 2005. Vrednost nakazuje, da v teh letih družbo uvrščamo v stabilno in varno območje, saj se njena vrednost Z-Score ni znižala pod vrednost 1,8. Ob tem je treba opomniti, da je uporaba Altmanovega modela lahko problematična zaradi zastarelih parametrov iz drugega gospodarskega okolja.

5.2.2 Modeliranje analize razpona

Pri izračunu razpona so bili uporabljeni podatki o datumu kupona, o datumu nakupa naložbe, o datumu izdaje, o datumu dospelosti, o datumu testiranja, o vrsti kupona (fiksni, variabilni ali mešan), o netvegani obrestni meri, LIBOR, EURIBOR in indeksi opcijско prilagojenih razponov. Na podlagi podatkov o datumih in izplačilih kuponov so izračunani denarni tokovi, iz teh pa nato teoretična vrednost obveznice. Kot je že omenjeno, se z-razpon določa kot število bazičnih točk, ki jih moramo dodati krivulji netveganih obrestnih mer do te mere, da bo neto sedanja vrednost bodočih denarnih tokov enaka trenutni tržni ceni. Vrednost z-razpona je bila izračunana na dan testiranja in na datum nakupa obveznice. Pri analizi razpona je bila sprva uporabljena preprosta metoda primerjave historične in trenutne vrednosti z-razpona. Za primerjavo vzamemo vrednost z-razpona ob datumu nakupa naložbe in na trenutni datum ter opazujemo absolutno in relativno razliko.

Tabela 3: Primer obravnave podatkov za analizo razpona in izračun vrednosti z-razpona

Izdajatelj	Originalna valuta	Datum izdaje	Datum nakupa	Datum dospelosti	Datum testiranja	Nabavna vrednost v originalni valuti	Frekvenca kupona	Datum izplačila obresti	Panoga	Tržna vrednost v originalni valuti	Kuponska obrestna mera	Z-razpon ob nakupu	Z-razpon	Razlika z-spread	Razlika z-razpona
Izdajatelj X	EUR	6.13.2019	6.5.2019	7.13.2022	12.31.2021	1,995,940.00		13.07.	trajne potrosne dobrine	2,006,811.23	0.13	0.0034	0.0018	0.0016	-0.0016
Izdajatelj Y	EUR	6.12.2018	6.5.2018	6.12.2023	12.31.2021	198,660.00		13.06.	osnovne potrosne dobrine	203,322.49	0.88	0.0056	0.0056	0.0000	0.0000
Izdajatelj Z	EUR	4.22.2016	4.18.2016	4.22.2026	12.31.2021	496,910.00		12.04.	preskrbovalna podjetja	518,087.53	0.88	0.0029	0.0030	-0.0001	0.0001
Izdajatelj XX	EUR	4.5.2016	3.29.2016	4.5.2024	12.31.2021	1,987,600.00		10.04.	industrija	2,041,126.58	0.63	0.0022	0.0028	-0.0006	0.0006
Izdajatelj YY	EUR	9.22.2015	9.10.2015	9.22.2023	12.31.2021	911,600.10		12.09.	preskrbovalna podjetja	936,325.36	2.38	0.0033	0.0086	-0.0053	0.0053
Izdajatelj ZZ	EUR	3.8.2017	2.27.2017	3.8.2023	12.31.2021	997,920.00		10.03.	trajne potrosne dobrine	1,014,564.38	1.00	0.0039	0.0101	-0.0062	0.0062
Izdajatelj XXX	EUR	10.28.2019	10.21.2019	10.28.2029	12.31.2021	1,194,900.00		12.10.	trajne potrosne dobrine	903,556.11	1.00	0.0064	0.0483	-0.0419	0.0419

Vir: lastno delo.

Negativne vrednosti z-razpona označujejo manjše tveganje, pozitivne pa večje relativno tveganje. V primerih v tabeli 3 lahko opazujemo pozitivni razpon v vseh primerih. Ta se je v prvih dveh primerih zmanjšal od nakupa, kar nakazuje na zmanjšanje tveganja, pri ostalih pa povečal, kar nakazuje na povečanje tveganja.

Naslednji del analize razpona se nanaša na opcijsko prilagojen razpon. Vse naložbe, ki so vnesene v model, so klasificirane v optimizacijske razrede glede na vrsto naložbe, bonitetno oceno naložbe, valuto in trajanje do dospelosti. Za primer vzemimo optimizacijski razred z oznako »FI NONFIN EUR AAA-A 2-5«. Gre torej za razred z naložbami s stalnim donosom (angl. fixed income), ki jih ne uvrščamo v finančno panogo (angl. non-financial), ki imajo bonitetne ocene v razredih med AAA in A ter je njihovo trajanje do dospelosti trenutno med dve in pet let.

Glede na datum testiranja in optimizacijske razrede so naložbam pripisani opcijsko prilagojeni razponi. Opcijsko prilagojeni razponi so za posamezne optimizacijske razrede sestavljeni in izračunani iz združenih indeksov.

Tabela 4: Analiza razpona in primerjava med z-razponom in OAS

Izdajatelj	Originalna valuta	Datum nakupa	Datum testiranja	Bonitetna ocena na datum testiranja	Z-razpon ob nakupu	Z-razpon	Optimizacijski razred na dan nakupa	Optimizacijski razred na dan testiranja	OAS na dan nakupa	OAS na dan testiranja	Absolutna razlika z-razpon in OAS - nakup	Relativna razlika z-razpon in OAS - nakup
Izdajatelj X	EUR	5.06.2019	31.12.2021	A	0.0034	0.0018	FI NONFIN EUR AAA-A 2-5	FI NONFIN EUR AAA-A 2-5	0.0073	0.0063	-0.0039	0.4670
Izdajatelj Y	EUR	14.03.2018	31.12.2021	A+	0.0032	0.0042	FI NONFIN EUR AAA-A 2-5	FI NONFIN EUR AAA-A 2-5	0.0053	0.0063	-0.0021	0.6055
Izdajatelj Z	EUR	19.04.2016	31.12.2021	BBB	0.0029	0.0050	FI NONFIN EUR BBB 2-5	FI NONFIN EUR BBB 2-5	0.0143	0.0110	-0.0114	0.2020
Izdajatelj XX	EUR	10.09.2015	31.12.2021	BBB-	0.0043	0.0086	FI NONFIN EUR BBB 2-5	FI NONFIN EUR BBB 2-5	0.0146	0.0110	-0.0103	0.2967
Izdajatelj YY	EUR	27.02.2017	31.12.2021	BB+	0.0039	0.0101	FI NONFIN EUR BBB 2-5	FI NONFIN EUR HY 2-5	0.0133	0.0334	-0.0094	0.2927
Izdajatelj ZZ	EUR	21.05.2015	31.12.2021	A+	-0.0089	0.0030	FI NONFIN EUR AAA-A 2-5	FI NONFIN EUR AAA-A 2-5	0.0053	0.0063	-0.0142	-1.6830
Izdajatelj XXX	EUR	21.10.2019	31.12.2021	B-	0.0064	0.0483	FI NONFIN EUR HY 2-5	FI NONFIN EUR HY 2-5	0.0364	0.0334	-0.0300	0.1751

Vir: lastno delo.

Za primerjavo vzamemo vrednost z-razpona ob datumu nakupa naložbe in ga primerjamo z OAS glede na optimizacijski razred, v katerega je bila uvrščena naložba ob nakupu. Po enakem principu primerjamo tudi z-razpon na dan testiranja in OAS za optimizacijski razred, v katerem je naložba na trenutni datum. Pri primerjavah opazujemo absolutno in relativno razliko, kot je prikazano v tabeli 4. Pri primerjavi vrednosti z-razpona in OAS moramo biti pozorni predvsem, kadar se z-razpon giba v nasprotno smer kot OAS. Če vrednosti OAS izkazujejo dokaj majhno tveganje, z-razpon pa se povečuje, je treba naložbi posvetiti dodatno pozornost, saj po tem lahko sklepamo, da se ta naložba obnaša bolj tvegano kot njene sorodne naložbe, ki temeljijo na podobnih predpostavkah.

Pri obdelavi podatkov in testiranju modela je bil celoten z-razpon sprva obračunan na osnovi netveganih obrestnih mer EIOPA. Kasneje se je zaradi primerljivosti z OAS porodila ideja za prilagojen izračun z-razpona, kjer je bila za osnovo uporabljena brezkuponska obveznica za valuti EUR in USD. Poleg tega je bil v procesu razvijanja modela dodan še dodatno prilagojen z-razpon, ki je prilagojen s spremenljivko trajanja do dospeljta zaradi boljše primerjave naložb.

Tabela 5: Prilagojen z-razpon

Izdajatelj	Vrsta naložbe	Rating nakup	Država	Bonitetna ocena	Optimizacijski razred danes	Z-razpon	Prilagojen z-razpon	Leta do dospeljta	Z dospelostjo prilagojen z-razpon	OAS danes
Izdajatelj X	občajne poslovne obveznice	A-	Velika Britanija	B-	FI NONFIN EUR HY 2-5	0.0456	0.0513	7.7753	0.0059	0.0406
Izdajatelj Y	občajne poslovne obveznice	BB+	Francija	BB+	FI NONFIN EUR HY 2-5	0.0333	0.0386	5.3062	0.0063	0.0406
Izdajatelj Z	občajne poslovne obveznice	BBB+	Nizozemska	BB-	FI NONFIN EUR HY 2-5	0.0265	0.0292	1.0253	0.0258	0.0406

Vir: lastno delo.

Kot je razvidno iz tabele 5, se s prvo prilagoditvijo Z_spread_adj bolj približamo OAS. Z dodatno prilagoditvijo $Z_spread_adj_dur$, kjer je dodatno vključeno še trajanje do dospeljta, pa se jasno prikaže, da gre za naložbe, ki imajo še malo višji razpon kot ostale naložbe s podobnimi lastnostmi.

Sočasno opazujemo tudi bonitetno oceno naložbe ob nakupu in bonitetno oceno na dan testiranja. Seveda večji poudarek namenimo naložbam, ki beležijo večjo spremembo v padcu bonitetne ocene v času od nakupa.

Tabela 6: Analiza sprememb bonitetnih ocen naložb

Izdajatelj	Vrsta naložbe	Panoga	Numerična bonitetna ocena ob nakupu	Numerična bonitetna ocena na dan testiranja	Sprememba bonitetne ocene
Izdajatelj X	običajne poslovne obveznice	trajne potrošne dobrine	6	7	-1
Izdajatelj Y	običajne poslovne obveznice	industrija	5	6	-1
Izdajatelj Z	običajne poslovne obveznice	osnovne potrošne dobrine	9	10	-1
Izdajatelj XX	običajne poslovne obveznice	preskrbovalna panoga	10	11	-1
Izdajatelj YY	običajne poslovne obveznice	trajne potrošne dobrine	11	12	-1
Izdajatelj ZZ	običajne poslovne obveznice	preskrbovalna panoga	5	6	-1
Izdajatelj XXX	običajne poslovne obveznice	trajne potrošne dobrine	15	17	-2

Vir: lastno delo.

V tabeli 6 so prikazani primeri naložb, kjer se je bonitetna ocena od nakupa naložbe do datuma testiranja zmanjšala. Intuitivno, večje kot je zmanjšanje bonitetne ocene, večja mora biti naša pozornost pri naložbi.

Zadnji del analize razpona zajema primerjavo vrednosti z-razpona z bonitetno oceno naložbe oziroma s spremembo bonitetne ocene naložbe. Posebno pozornost je treba nameniti naložbam, kjer bonitetna ocena pada, vrednost z-razpona pa se povečuje.

Tabela 7: Analiza razpona in primerjava med z-razponom in bonitetnimi ocenami

Izdajatelj	Vrsta naložbe	Bonitetna ocena ob nakupu	Bonitetna ocena na datum testiranja	Numerična bonitetna ocena ob nakupu	Numerična bonitetna ocena na dan testiranja	Sprememba bonitetne ocene	Z-razpon ob nakupu	Z-razpon	Sprememba z-razpon
Izdajatelj X	običajne poslovne obveznice	A+	A	6	7	-1	0.0034	0.0018	0.0016
Izdajatelj Y	običajne poslovne obveznice	AA-	A+	5	6	-1	0.0032	0.0042	-0.0009
Izdajatelj Z	običajne poslovne obveznice	BBB+	BBB	9	10	-1	0.0029	0.0050	-0.0021
Izdajatelj XX	običajne poslovne obveznice	BBB	BBB-	10	11	-1	0.0043	0.0086	-0.0043
Izdajatelj YY	običajne poslovne obveznice	BBB-	BB+	11	12	-1	0.0039	0.0101	-0.0062
Izdajatelj ZZ	običajne poslovne obveznice	AA-	A+	5	6	-1	-0.0089	0.0030	-0.0120
Izdajatelj XXX	običajne poslovne obveznice	B+	B-	15	17	-2	0.0064	0.0483	-0.0419

Vir: lastno delo.

V tabeli 7 so prikazani primeri naložb, kjer se je bonitetna ocena od nakupa naložbe do datuma testiranja zmanjšala, ter izračuni vrednosti z-razpona. Najmanj zaskrbljujoča je prva naložba, kjer se je bonitetna ocena naložbe sicer zmanjšala za en razred, vendar vrednost z-razpona nakazuje na zmanjšanje tveganja. Najbolj zaskrbljujoča pa je zadnja naložba, kjer se je bonitetna ocena zmanjšala za kar dva razreda, razlika v z-razponu vrednosti pa najbolj povečala. Gre torej za znatno povečanje tveganja.

5.2.3 Modeliranje verjetnosti neplačila

Pri modeliranju verjetnosti neplačila je bila sprva uporabljena preprosta metoda primerjave historične in trenutne verjetnosti neplačila. Verjetnost neplačila je bila izračunana na dan testiranja glede na datum nakupa in na dan testiranja glede na datum izdaje obveznice. Pri historični verjetnosti neplačila se je smiselno predvsem osredotočiti na verjetnost na dan, ko smo naložbo kupili, čemur pravimo datum pripoznave. Za primerjavo vzamemo verjetnost neplačila na trenutni datum oziroma datum testiranja. Med verjetnostima opazujemo absolutno in relativno razliko. Pri rezultatih iz tabele 8 smo najbolj pozorni na naložbe, ki izkazujejo visoko verjetnost neplačila, in na naložbe, pri katerih se verjetnost neplačila povečuje.

Tabela 8: Analiza verjetnosti neplačila na dan testiranja in ob pripoznavi

Izdajatelj	Datum izdaje	Datum nakupa	Datum testiranja	Datum dospelosti	Bonitetna ocena ob nakupu	Bonitetna ocena na datum testiranja	PD ob pripoznavi	PD na dan testiranja	Absolutna razlika PD	Relativna razlika PD
Izdajatelj X	13.06.2019	5.06.2019	31.12.2021	13.07.2022	A+	A	0.0092	0.0003	-0.0089	-0.9704
Izdajatelj Y	21.03.2018	14.03.2018	31.12.2021	21.03.2023	AA-	A+	0.0006	0.0006	0.0000	0.0385
Izdajatelj Z	26.04.2016	19.04.2016	31.12.2021	26.04.2024	BBB+	BBB	0.0087	0.0043	-0.0044	-0.5012
Izdajatelj XX	22.09.2015	10.09.2015	31.12.2021	22.09.2023	BBB	BBB-	0.0176	0.0030	-0.0147	-0.8321
Izdajatelj YY	8.03.2017	27.02.2017	31.12.2021	8.03.2023	BBB-	BB+	0.0031	0.0106	0.0075	2.4156
Izdajatelj ZZ	13.11.2012	21.05.2015	31.12.2021	14.11.2022	AA-	A+	0.0008	0.0004	-0.0004	-0.4596
Izdajatelj XXX	28.10.2019	21.10.2019	31.12.2021	28.10.2029	B+	B-	0.5981	0.2742	-0.3239	-0.5415

Vir: lastno delo.

V naslednjem delu analize je bila izračunana stopnja tveganja s pomočjo podatkov o razponu in vrednosti izgube zaradi neplačila. Ocena stopnje nevarnosti je bila izračunana kot količnik vrednosti z-razpona in vrednosti izgube zaradi neplačila, ki je odvisna od vrste naložbe. Podrejene obveznice imajo vrednost LGD višjo kot državne obveznice. S tem na podlagi vrst naložb dodamo uteži bolj tveganim vrstam naložbe. V naslednjem

koraku je stopnja tveganja primerjana z verjetnostjo neplačila. Do primerjave pridemo z izračunom:

$$PD_{Hr} = 1 - e^{-Hr + \left(\frac{\text{Datum dospelosti} - \text{Datum testiranja}}{365}\right)} \quad (34)$$

V tem primeru pridemo do izračuna verjetnosti neplačila s pomočjo dveh različnih metod. Prvi kazalnik PD smo pridobili s pomočjo uporabe historičnih migracijskih matrik, torej posredno na podlagi historičnih podatkov, drugi PD kazalnik pa s pomočjo vrednosti z-razpona, torej posredno s pomočjo netvegane obrestne mere. Primerjava slednjih je prikazana v tabeli 9.

Tabela 9: Primerjava PD in stopnje nevarnosti

Izdajatelj	PD ob pripoznavi	PD na dan testiranja	LGD	Hazard rate	Hazard rate ob nakupu	Absolutna razlika hazard rate	Relativna razlika hazard rate	Leta do dospelosti	PD & Hazard rate	PD & hazard rate ob nakupu	Absolutna razlika PD & Hazard rate	Relativna razlika PD & Hazard rate	PD & Hazard rate (1leto)	PD & Hazard rate ob nakupu (1leto)	Absolutna razlika PD & Hazard rate (1leto)	Relativna razlika PD & Hazard rate (1leto)
Izdajatelj X	0.0092	0.0003	0.6000	0.0030	0.0057	-0.0027	-0.4685	0.5449	0.0016	0.0031	-0.0014	-0.4681	0.0030	0.0057	-0.0026	-0.4677
Izdajatelj Y	0.0006	0.0006	0.6000	0.0069	0.0053	0.0016	0.2940	1.2500	0.0086	0.0067	0.0020	0.2927	0.0069	0.0053	0.0016	0.2929
Izdajatelj Z	0.0087	0.0043	0.6000	0.0084	0.0048	0.0035	0.7344	2.3792	0.0197	0.0114	0.0083	0.7271	0.0083	0.0048	0.0035	0.7313
Izdajatelj XX	0.0176	0.0030	0.6000	0.0143	0.0072	0.0071	0.9871	1.7697	0.0251	0.0127	0.0124	0.9746	0.0142	0.0072	0.0071	0.9800
Izdajatelj YY	0.0031	0.0106	0.6000	0.0168	0.0065	0.0103	1.5854	1.2135	0.0201	0.0078	0.0123	1.5693	0.0166	0.0065	0.0102	1.5721
Izdajatelj ZZ	0.0008	0.0004	0.6000	0.0051	-0.0149	0.0199	-1.3399	0.8933	0.0045	-0.0134	0.0179	-1.3369	0.0050	-0.0150	0.0200	-1.3365
Izdajatelj XXX	0.5981	0.2742	0.6000	0.0805	0.0106	0.0699	6.5796	8.0281	0.4761	0.0817	0.3943	4.8238	0.0774	0.0106	0.0668	6.3212

Vir: lastno delo.

V naslednjem delu analize je bil uporabljen model KMV. Prvi korak modela je ocena σ_E , ki je bila narejena na podlagi historičnih podatkov donosov delnic. Po oceni volatilitnosti kapitala določimo uporabljeno netvegano obrestno mero, kar storimo na podlagi valute, v kateri je bila naložba kupljena. Izberemo napovedno okno za obdobje enega leta, ki je merilo nominalne vrednosti dolga podjetja. Vrednost DD je definirana kot razdalja do zapadlosti, verjetnost neplačila v času t pa kot PD . Razdalja do zapadlosti predstavlja razdaljo med pričakovano vrednostjo sredstva in točko zapadlosti (Tetereva, 2021). Z izpeljavo formul pridemo do vrednosti pričakovane izgube L_E in do enačbe izgube zaradi neplačila: L_{GD} .

Poleg nizke verjetnosti neplačila si želimo kar se da nizke parametre vrednosti pričakovane izgube in izgube zaradi neplačila. Skozi letno časovno komponento opazujemo razvoj vrednosti pri posamezni naložbi. Izračuni so prikazani v tabeli 10.

Tabela 10: Izračuni po modelu KMV

Izdajatelj	Datum	Cena	Lastniške delnice	Volatilnost	Kratkoročni očni dolg	Dolgoročni dolg	Donos	Donos (360dni)	Tržna vrednost kapitala	Obveznosti	Sigma	Datum netvegane obrestne mere	Rfr	DD - Distanca to default	PD- Probabilnost	DC- Distanca to Capital	PD_C	DD_2	PD_2	DC_2	PD_C2
Izdajatelj Z	28.06.2019	151.2	295.09	27.64	85514	112574	0.01	0.05	44602.85	141801	0.28	31.03.2019	-0.33	-1.13	0.87	-1.18	0.88	11.36	0.00	9.73	0.00
Izdajatelj Z	31.12.2018	138	295.09	26.52	89757	101126	-0.01	-0.23	40722.42	140320	0.27	31.12.2018	-0.33	-1.28	0.90	-1.33	0.91	6.36	0.00	4.54	0.00
Izdajatelj Z	29.12.2017	168.7	295.09	19.02	81844	81628	-0.01	0.14	49766.93	122658	0.19	30.09.2017	-0.36	-4.12	1.00	-4.56	1.00	17.60	0.00	15.62	0.00
Izdajatelj Z	30.12.2016	136.8	295.09	42.89	88462	68216	-0.01	0.08	40353.56	122570	0.43	30.09.2016	-0.31	-1.01	0.84	-1.06	0.86	7.14	0.00	6.15	0.00
Izdajatelj Z	31.12.2015	142.8	295.09	39.62	72312	73291	0.01	-0.21	42138.85	108958	0.40	31.12.2015	-0.16	-1.04	0.85	-1.09	0.86	2.27	0.01	1.43	0.08

Vir: lastno delo.

V modelu je opravljenih več iteracij izračunov. Iteracija v matematičnem žargonu predstavlja postopek, ki temelji na ponavljanju. Gre za večkratno ali neomejeno ponavljanje procesa z namenom kreiranja zaporedja rezultatov. Vsaka ponovitev postopka je samostojna, rezultat vsake ponovitve pa je nato izhodišče naslednje ponovitve (Timperley, Wilson, Barrar & Fung, 2021). V tabeli 10 so iteracije označene z zaporednimi številkami.

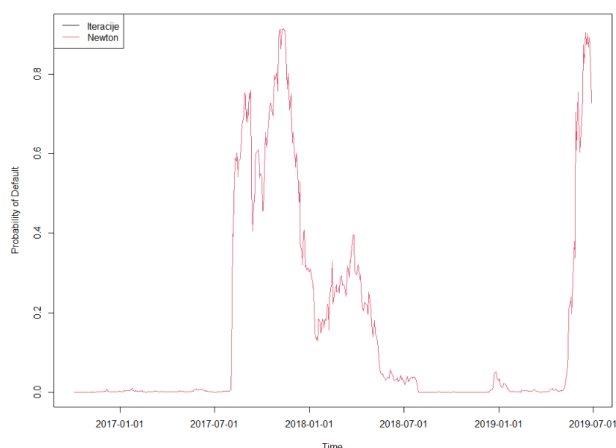
Tako kot pri Altmanu tudi tukaj opazujemo razvoj vrednosti PD skozi čas. Intuitivno je, da večji PD izkazuje večje tveganje. Tovrstni razvoj lahko seveda prikažemo tudi grafično kot na primeru slike 7, 8 in 9.

Slika 7: Gibanje sredstev in obveznosti




Vir: lastno delo.

Slika 8: Gibanje PD



Vir: lastno delo.

Slika 9: Gibanje DD



Vir: lastno delo.

V model je bil vključen tudi kazalnik likvidnosti, ki pa se v našem primeru ni izkazal za statistično značilnega. Do vrednosti likvidnostne premije smo prišli z razliko med z-razponom in razponom ponudbe in povpraševanja. Kot drugi kazalnik smo vzeli razliko med stopnjo nevarnosti in likvidnostno premijo. Ker se je tekom testiranja izkazalo, da kazalnik likvidnosti z dostopnimi podatki ni bil statistično značilen, v končno verzijo modela ni bil vključen.

5.3 Merila

Pri modeliranju meril tveganj gre za subjektivno oceno, ki jo je mogoče še spremeniti, v kolikor bi bilo ugotovljeno, da gre za previsoka ali prenizka merila. Kjer so avtorji posameznih modelov že ponudili kritične meje, so uporabljene te.

Pri modeliranju bilančne analize sta bila glede na klasifikacijo izdajatelja izračunana Z-Score in Z"-Score. Slednji je bil izračunan za izdajatelje, ki jih umeščamo v razvijajoč se trg. Vse naložbe, pri katerih je bila vrednost Z-Score nižja od 1,8, in vrednost Z"-Score nižja od 1,1, so bile označene z »rdečo zastavico«, kar opozarja na potrebo po posebni pozornosti pri dotični naložbi.

Pri modeliranju analize razpona je bila izračunana vrednost z-razpona ob različnih datumih. Z »rdečo« zastavico so bile označene vse naložbe, pri katerih se bonitetna ocena zmanjša za dva razreda. Prav tako so bile z »rdečo« zastavico označene vse naložbe, pri katerih se z-razpon poveča glede na z-razpon ob nakupu. Z »rdečo« zastavico so bile označene vse naložbe, pri katerih se z-razpon relativno povečuje glede na OAS. Označene so bile tudi naložbe, pri katerih je zaznано zmanjšanje bonitetne ocene in povečanje vrednosti z-razpona.

Pri modeliranju verjetnosti neplačila je bila izračunana vrednost PD. Z »rdečo zastavico« so bile označene vse naložbe, pri katerih se verjetnost neplačila poveča, in naložbe, pri katerih je zaznано zmanjšanje bonitetne ocene in povečanje verjetnosti neplačila. Numerične meje na tem mestu niso bile enolično določene. Določitev le-teh je priložnost za nadgradnjo modela.

Pri modeliranju modela KMV so bile izračunane vrednosti PD, DD, LGD. Z »rdečo zastavico« so bile označene vse naložbe, pri katerih PD konstantno narašča.

Ob koncu tega poglavja je treba poudariti, da vsaka »rdeča zastavica« še ne pomeni napovedi, da bo obveznica v kratkem prišla do dogodka zapadlosti oziroma neplačila. Gre zgolj za opozorila, ki iz različnih zornih kotov opazujejo in opozarjajo na smer, v katero se giba naložba. Ravno s tem namenom je poleg označb z rdečimi zastavicami v ekspertni model vključena dodatna analiza, ki tovrstna opozorila prečisti. Meje rdečih zastavic so grobo določene in ne odražajo končnega rezultata modela.

5.4 Dodatna analiza

Za izdelavo ekspertnega modela je bilo treba poleg združitve različnih modelov dodati tudi neko lastno in preprosto modeliranje ocene, ki bo primerjano z rezultati ostalih modelov. S tem namenom sta v model vpeljani še logistična regresija in modeliranje z odločitvenimi drevesi. Multinomska logistična regresija je po rezultatih izkazovala slabšo napovedno moč kot odločitvena drevesa.

Kot narekuje zakonodaja, so notranje ocene preteklega obnašanja zanesljivejše, kadar so navezane na zunanje ocene ali podprte z analizo neplačil. Analizo neplačil smo že

vključili v ekspertni model, prav tako tudi zunanje ocene. V kolikor s pomočjo odločitvenega drevesa zaradi manjkajočih podatkov ni bilo mogoče podati interne napovedi bonitetne ocene, se je ekspertni model osredotočil na že podano zunanjo bonitetno oceno. V tem primeru se je zunanjo bonitetno oceno prepoznalo tudi za interno primerno ali pa za deloma tvegano, ki potrebuje dodatno pozornost.

5.4.1 Logistična regresija

V večini statističnih raziskav se srečujemo z regresijsko analizo, ki preučuje odvisnost slučajne spremenljivke od ene ali več pojasnjevalnih spremenljivk. Cilj regresijske analize je, da čim lepše in točno povzame opazovane podatke (Herga, 2011). Skozi celotno magistrsko delo se srečujemo z vprašanjem, ali se bo določeno podjetje soočilo z dogodkom neplačila ali ne. Gre za neregresijsko vprašanje, ki je kategoričnega tipa, z odgovorom »da« ali »ne«. Rezultat dogodka neplačila je torej slučajna spremenljivka, ki jo skušamo pojasniti z različnimi pojasnjevalnimi spremenljivkami. Da bi na to vprašanje vseeno lahko odgovorili s pomočjo regresije, verjetnost dogodka numerično označimo z 0 in 1. Vrednost 0 pripišemo, če ne izpolnjuje kriterijev neplačljivosti, in vrednost 1, če izpolnjuje kriterije neplačljivosti. To vrednost sedaj obravnavamo kot zvezno vrednost odvisne spremenljivke razreda y . V primeru logistične regresije imamo dano množico pojasnjevalnih spremenljivk X , zanima pa nas pogojna verjetnost $P(Y = 1|X = x)$. V naslednjem koraku uporabimo logistično funkcijo, ki je zvezna, monotona, odvedljiva pri vseh vrednostih parametra in zapisana z enačbo:

$$g(z) = \frac{1}{1 + e^{-z}} \quad (35)$$

Za neodvisno spremenljivko z velja naslednje:

$$g(z) \xrightarrow{z \rightarrow -\infty} 0 \quad (36)$$

$$g(z) \xrightarrow{z \rightarrow \infty} 1 \quad (37)$$

Model z uporabo logistične funkcije imenujemo logistična regresija in ga zapišemo s formulo:

$$h_{\theta}(x) = g(\theta_0 + \theta_1 x_1 + \dots + \theta_n x_n) = g(\theta^T x) = \frac{1}{1 + e^{-\theta^T x}} \quad (38)$$

Opisana logistična regresija je bila v večini uporabljena v razvoju posameznih že obstoječih modelov, kot so Altman in podobni. V ekspertnem modelu je bila uporabljena multinomska logistična regresija. Gre za generalizacijo logistične regresije, za klasifikacijsko metodo, ki se uporablja za klasifikacijo večrazrednih problemov (Premoša, 2021). Uporabljena je bila za preizkus napovedi interne bonitetne ocene za

naložbe. Pri uporabi regresije za modeliranje napovedi je v našem primeru ta izkazovala slabšo napovedno moč kot odločitvena drevesa.

5.4.2 Odločitvena drevesa

Ko je bila zbrana dovolj velika baza ustreznih in raznolikih podatkov za analizo, smo v ekspertni model vključili še eno metodo za lažje podajanje samostojne ocene kreditnega tveganja, in sicer odločitveno drevo, ki se prevaja tudi kot naključni gozdovi.

Odločitveno drevo (angl. decision tree) je podporno orodje pri odločanju, ki uporablja model drevesa za prikazovanje odločitev in možnih posledic. Tehnika je bila prvotno razvita za potrebe statistike, danes pa je uporabljena za avtomatizacijo procesov odločanja (Zeme, 2018). Je metoda strojnega učenja, enostavna za razumevanje (Vodopivec, 2020). Gre za graf oziroma risbo, ki nam služi kot navodilo za odločanje. Sestavljeno je iz vozlišč, ki tvorijo »ukoreninjeno drevo« (Maimon & Rokach, 2005). Drevesa odločanja so ena od tehnik rudarjenja podatkov, ki jo je mogoče uporabiti za izdelavo modela za napovedovanje ciljnih spremenljivk na podlagi izbranih vplivnih spremenljivk (Bezjak, Zabret & Šraj, 2018). Z njegovo pomočjo lahko grafično prikažemo stopnje odločanja, torej vse možne izbire in pripadajoče posledice. Na koncu je lahko prikazana tudi verjetnost, da posamezen rezultat resnično spada v kategorijo, in kakšna je verjetnost, da v resnici spada v katero drugo kategorijo (Vodopivec, 2020). Združevanje velikega števila dreves pogosto povzroči izboljšave v natančnosti napovedi na račun določene izgube pri interpretaciji. Odločitvena drevesa se lahko uporabijo tako za regresijske kot tudi za klasifikacijske probleme (James, Witten, Hastie & Tibshirani, 2013). V zadnjih desetletjih so postala priljubljena kot alternativa diskriminantni analizi in drugim metodam (Vodopivec, 2020). Pri izbiri optimalnega števila dreves n v gozdu moramo upoštevati predvsem to, da večji kot je gozd, večja je uspešnost metode, vendar pa se tudi kompleksnost in časovna zahtevnost algoritma hitro povečujeta (Kosec, 2014).

Odločitvena drevesa so bila v ekspertnem modelu uporabljena na dveh podmnožicah. Naložbe so bile v podmnožico uvrščene glede na panogo oziroma ali gre za finančnega ali nefinančnega izdajatelja naložbe. Glede na to, da so v vzorcu zajete različno velike družbe, so bila v model kot spremenljivke vnesena predvsem razmerja, ki so bolj smiselno primerljiva od bilančnih podatkov. V odločitvenih drevesih so bila uporabljena razmerja, ki jih je bilo mogoče izračunati na podlagi najbolj dostopnih parametrov, in razmerja, ki so izkazovala najvišjo statistično značilnost. Uporabljena so bila razmerja, ki so zapisana v tabeli 11. Razširjen celotni poslovni izid, (angl. earnings before interest and taxes – v nadaljevanju EBIT) je izračunan kot razlika med prihodki in seštevkom odhodkov (poslovnih, drugih in finančnih), razen obrestnih odhodkov. Čisti dobiček je izračunan kot razlika med vsoto prodajnih vrednosti in vsoto nabavnih vrednosti prodanega blaga

ter pripadajočih stroškov, obresti in davkov. Formule za izračun razmerji so prikazane v prilogi 2.

Tabela 11: Uporabljena razmerja v odločitvenih drevesih

Obratna sredstva
Razmerje med dolgom in lastniškim kapitalom
Razmerje med EBIT in obrestmi
Razmerje med trajnim kapitalom in (dolgoročno) zadolženostjo
Razmerje med dobičkom in prihodki
Razmerje med zadržanim dobičkom in dolžniškim kapitalom
Donosnost sredstev
Razmerje med delniškim kapitalom in sredstvi
Razmerje med dobičkom in prihodki
Razmerje med dobičkom in sredstvi
Razmerje med delniškim kapitalom in sredstvi
Razmerje med administrativnimi stroški in prihodki
Marža čistega dohodka
Normalizirana marža čistega dohodka
Razmerje med povprečnim delniškim kapitalom in povprečnimi sredstvi
Razmerje med povprečnim lastniškim kapitalom in povprečnimi sredstvi
Razredčen EPS pred dodatno rastjo

Vir: lastno delo.

Odločitveno drevo se je sprva učilo na testni bazi, ki je zajemala 316 opazovanj podatkov nefinančnih podjetij in 129 opazovanj podatkov finančnih podjetji, nato pa je smernice uporabilo na pravih podatkih in tako podalo napoved bonitetne ocene. Poleg razmerij na podlagi bilančnih podatkov so bili v podatke vključene tudi bonitetne ocene držav, saj so že avtorji Zhao, Moreira & Wang leta 2019 v svoji raziskavi omenjali ključno povezavo med ocenami države in stanjem družb v državi.

Model na podlagi bilančnih podatkov in izračunanih kazalnikov pripiše lastno bonitetno oceno. To stori s pomočjo odločitvenega drevesa in učenja iz preteklih vnosov podatkov. V procesu je programsko izdelanih približno 800 dreves. Model je s pravilnostjo 85,33 % na testni množici napovedal bonitetne ocene nefinančnih družb in s pravilnostjo 85,71 % napovedal bonitetne ocene finančnih družb.

Omejitev metode z odločitvenimi drevesi se je izkazala predvsem v primerih nepopolnih ali manjkajočih podatkov. V primeru manjkajočih podatkov izdajatelja naložbe ni mogoče vključiti v odločitveno drevo, s tem pa se manjša bazen podatkov in posledično višina moči napovedi. V fazi testiranja z izpopolnjeno bazo podatkov ima drevo torej

večjo napovedno moč kot v realnosti, ko iščemo izključno konkretne podatke o izdajateljih v portfelju izbrane finančne institucije.

5.4.3 Specifike panog in prilagoditve modela

Kriza v letu 2008 je izpostavila potrebno debato o korelaciji med bonitetno oceno držav in uspešnostjo bank. Finančne panoge, kamor zajemamo banke in zavarovalnice, imajo stroške financiranja visoko korelirane z državnim dolgom, ki je v lasti teh institucij, zaradi česar so ti stroški občutljivi na bonitetne ocene držav. Raziskave kažejo, da padec državne bonitetne ocene daje zelo negativen signal o fiskalnem stanju države in zmanjšuje povpraševanje po finančnih storitvah (Zhao, Moreira & Wang, 2019). S tem namenom je bil v ekspertni model vključen poseben poudarek pri korelaciji med finančno panogo in bonitetnimi ocenami držav. Državne bonitetne ocene so ocene zmožnosti in pripravljenosti države, da odplača svoj državni dolg, medtem ko gre pri bankah za ocene verjetnosti, da banka ne bo izpolnila obveznosti ali ne bo mogla odplačati vlog vlagateljem (Zhao, Moreira & Wang, 2019).

Najbolj panožno specifičen kazalnik je vrednost OAS. Uporabljene so torej vrednosti indeksov, ki v svojo zgradbo zajamejo naložbe določenih značilnosti. V model so bili torej vključeni indeksi, ki v svojo zbirko zajemajo tudi panožno različne naložbe. Uporabljen je na primer indeks, ki v svojo zbirko zajema zgolj obveznice zavarovalniških družb, pa spet drug, ki v svojo zbirko zajema zgolj obveznice bančnih družb. S pomočjo interne klasifikacije naložb smo različnim razredom naložb pripisali različne indekse in primerjali obnašanje naložb iz iste panoge na trgu in naše konkretne naložbe.

Kljub uporabi indeksov OAS je pri ostalih delih modela smiselno uporabiti tudi specifične količnike, izračunane na podlagi podatkov iz bilance stanja in izkaza poslovnega izida. Naložbe so razporejene na podlagi vrste naložbe in panoge. Med preizkušanjem ekspertnega modela se je pokazala potreba po prilagoditvi modela na določenih segmentih. Prilagoditve so bile narejene na izračunih z-razpona pri nemških in ameriških poslovnih obveznicah, saj je bila posledično primerjava z OAS bolj natančna.

Zaradi slabšega ujemanja podatkov so rezultati naložb za valute razvijajočih se držav, ki so dokaj nelikvidne, manj uporabne kot podatki o tržnem in ekonomskem stanju držav izdajateljev tovrstnih naložb. Za dodatno vključitev gibanja makroekonomskih indikatorjev smo v opazovanje poleg bonitetnih ocen držav vključili se BDP, inflacijo, stopnjo brezposelnosti, indeks cen življenjskih potrebščin in gospodinjski dolg.

5.5 Rezultat modela

Rezultat modela je seznam tistih naložb, ki so v procesu zaznane kot tvegane oziroma označene z »rdečo« zastavico. Izhodni seznam je izhodiščna točka za subjektivno presojo uporabnika modela. Uporabnik na podlagi izkušenj in informacij o trgu lahko kritično presodi, katerim od izhodnih naložb je treba posvetiti dodatno pozornost.

V obliki, kot je prikazano v tabeli 12, so označene rdeče zastavice oziroma naložbe, ki zaradi postavljenih omejitev presegajo določene meje. Več mej kot naložba preseže, iz več področij je tveganje zaznano.

Tabela 12: Binarne oznake rdečih zastavic

Oznaka naložbe	Sprememba bonitetne ocene	Z-razpon	Z-razpon nakup	Prilagojen z-razpon	Opozorilo PD razlika pripoz	Opozorilo PD 1	Opozorilo PD hazard	Opozorilo z razpon	Opozorilo z-razpon 1	Opozorilo z-razpon 2	Opozorilo z-razpon prilag ojen	Opozorilo z-razpon prilag ojen2	Opozorilo rilo OAS	Opozorilo rilo OAS prilag ojen	Opozorilo z-razpon 3
abc1	0	0.0043	0.0049	0.0083	1	0	0	0	0	0	0	0	0	0	0
abc2	0	0.0069	0.0132	0.0107	1	0	0	0	0	0	0	0	0	0	0
abc3	0	0.0017	-0.0034	0.0017	1	0	0	0	0	0	0	0	0	0	0
abc4	0	-0.0006	-0.0197	-0.0006	0	0	0	0	0	0	0	0	0	0	0
abc5	0	-0.0030	-0.0027	0.0009	0	0	0	0	0	0	0	0	0	0	0
abc6	0	-0.0030	-0.0027	0.0009	0	0	0	0	0	0	0	0	0	0	0
abc7	0	0.0050	0.0012	0.0055	0	0	1	0	0	1	0	0	0	0	0
abc8	0	0.0050	0.0012	0.0055	0	0	1	0	0	1	0	0	0	0	0
abc9	0	0.0050	0.0029	0.0055	0	0	0	0	0	1	0	0	0	0	0
abc10	0	-0.0021	0.0057	0.0016	0	0	0	0	0	0	0	0	0	0	0
abc11	0	-0.0021	0.0008	0.0016	0	0	0	0	0	0	0	0	0	0	0
abc12	0	0.0005	0.0010	0.0026	0	0	0	0	0	0	0	0	0	0	0
abc13	-2	0.0109	0.0010	0.0116	0	0	1	0	0	1	0	1	0	0	0
abc14	-2	0.0109	0.0048	0.0116	0	0	0	0	0	1	0	0	0	0	0
abc15	0	0.0169	0.0074	0.0176	0	0	0	0	0	1	0	1	1	1	0
abc16	2	0.0026	-0.0084	0.0032	0	0	0	0	0	0	0	0	0	1	0
abc17	2	0.0026	-0.0085	0.0032	0	0	0	0	0	0	0	0	0	1	0

Vir: lastno delo.

Ker je ekspertni model še vedno v fazi razvoja, je treba kritično presoditi, ali je naložba, ki je označena z »rdečo zastavico« oziroma opozorilom, morda prikazala rezultate zaradi svojih specifičnih značilnosti, ki v sistem izločanja še niso bile vključene. Prav tako je treba rezultate kritično obravnavati in pri zelo ekstremnih rezultatih preveriti, da ni prišlo do napake v procesu izračunavanja. Napake v izračunih se po navadi pojavijo zaradi nekonsistentnosti oblike vhodnih podatkov, zato je treba skozi celoten proces pozornost nameniti tudi obliki rezultatov in morebitnim ekstremom.

6 TEST MODELA NA HISTORIČNIH PODATKIH

Ekspertni model za izbrano finančno institucijo je preizkušen na historičnih podatkih. Za vnos podatkov sem uporabila vzorec naložb, ki so v preteklosti presenetile finančne institucije in s tem ogrozile njihovo kreditno tveganje. Majhen fiktivni portfelj je zajemal

naložbe različnih panog s specifičnimi lastnostmi, kot so državne naložbe, finančne in zavarovalniške dejavnosti, korporativne dejavnosti itd. Rezultati, pridobljeni na podlagi modela, so primerjani z javno dostopnimi informacijami o bonitetnih ocenah. Ob zaključenem umerjanju je bil opravljen preizkus modela na podlagi zgodovinskih podatkov (angl. backtesting). Preverbo in potrditev modela je izvedel notranji odbor za upravljanje tveganj znotraj obravnavane izbrane finančne institucije. V odboru sodelujejo oddelki financ, aktuarjev in služba za upravljanje tveganj.

6.1 Vrste testiranja

Najosnovnejša oblika testiranja je vizualni test, kjer s pomočjo grafa in izstopajočih vrednosti zaznamo povečano tveganje. V splošnem je pri modeliranju pomembno, da se izognemo napakam tipa 1 in tipa 2. Napaka tipa 1 opisuje primer, ko napačno zavračamo pravi model, napaka tipa 2 pa primer, ko napačno sprejemamo napačen model. Tipa napak sta prikazana v tabeli 13.

Tabela 13: Napaka Tipa 1 in Tipa 2

	Ničelna domneva je pravilna	Ničelna domneva je napačna
Zavrremo ničelno domnevo	Napaka tipa 1 Napačno pozitivna	Pravilen rezultat Pravilno pozitivna
Ne zavrremo ničelne domneve	Pravilen rezultat Pravilno negativna	Napaka tipa 2 Napačno negativna

Vir: lastno delo.

Obstajata dva načina za testiranje ustreznosti modelov za tveganje. Prvi se osredotoča na frekvenco izgub na repu porazdelitve, drugi pa na velikost izgube repa porazdelitve. Prvega je mogoče oblikovati kot test, kjer opazujemo verjetnost višjega pojavljanja izgub na repu porazdelitve od stopnje zaupanja, kar imenujemo test Kupiec. Slednji preizkuša, ali je opažena frekvenca izgub repa porazdelitve skladna s pogostostjo izgub repa porazdelitve, ki jih predvideva model (Berk Skok, 2020). Za ničelno hipotezo vzamemo, da je model "dober", torej skladen s podatki, število izgub repa porazdelitve x pa sledi binomski porazdelitvi, kjer n predstavlja število opazovanj, p napoved frekvence izgub repa porazdelitve, i pa število dogodkov.

$$\Pr(x|n, p) = \frac{n!}{i!(n-i)!} p^i (1-p)^{n-i} \quad (39)$$

Omejitve testa Kupiec so, da je primeren zgolj za velike vzorce in ne upošteva dejanske velikosti izgube repa porazdelitve (Berk Skok, 2020).

Lahko pa testiranje oblikujemo tudi kot opazovanje časa do prve izgube repa porazdelitve. Verjetnost opazovanja prve izgube repa porazdelitve do časa T zapišemo s formulo:

$$1 - [(1 - p)^T]. \quad (40)$$

Pri tem je treba opozoriti, da se ta test uporablja izključno kot diagnostično orodje, ki se uporablja sočasno z močnejšimi testi (Berk Skok, 2020). Slabost tovrstnega testiranja je izguba vseh ostalih informacij, razen časa, kar ga postavlja na slabšo pozicijo od testa Kupiec. Oba opisana načina ignorirata dejansko velikost izgube repa porazdelitve, zato se pojavi potreba po testiranju, ali so repi pri realizaciji konsistentni s predvidenim modelom. Običajen postopek se osredotoči samo na opazovanja, kjer se izgube repa pojavijo, ostala opazovanja pa so izločena. Prav tako obdrži porazdelitev izgub repov in jo primerja s porazdelitvijo predvidevanj, na katerih je zgrajen model, s pomočjo Kolmogorov-Smirnovega testa (Berk Skok, 2020). Med ostale vrste testiranja uvrščamo še stresne teste, ki pa jih v primeru ekspertnega modela nismo uporabili.

V modelu je uporabljen tudi Akaikov informacijski kriterij (v nadaljevanju AIC). Gre za kriterij, ki ocenjuje napako napovedovanja in ponuja primerjavo kakovosti statističnih modelov. Ob podanih več modelih AIC za vsakega določi kvaliteto glede na ostale modele, kar omogoča izbiro modela. Izvira iz teorije informacij in predstavlja kompromis med kvaliteto prileganja in enostavnostjo modela. Kriterij nagradi dobro prileganje, kaznuje pa kompleksnost modela, izraženo s številom parametrov (Pirnovar, 2020).

V modelu je izračunana povprečna napaka za vsak z_i (angl. out-of-bag error – v nadaljevanju OOB) izračunan z uporabo napovedi dreves, ki ne vsebujejo ustreznega vzorca (Scikit, 2022). Želimo si seveda kar se da nizko OOB, kar pomeni višjo napovedno moč.

6.2 Test modela

Pri testiranju ekspertnega modela ni bilo mogoče enoznačno določiti izbire testa zaradi same narave združevanja več modelov. Ker je ekspertni model še v fazi razvoja in naj bi s sprotno uporabo pridobil vrednost, je skoraj nemogoče s številsko gotovostjo opisati pravilnost modela. Razlog pa izhaja tudi iz tega, da končni rezultat modela še ni končni seznam, saj je potrebna strokovna presoja uporabnika modela, da določi, katere naložbe resnično spadajo v kritični bazen. Pri sprotne obravnavanju razponov in postavljanju mej pa je treba uporabiti strokovno znanje. Ekspertni model je zgolj orodje, ki zagotavlja izračune za nadaljnjo subjektivno presojo.

V vzorcu naložb pri historični primerjavi ni bilo opaženih pretiranih tveganih sprememb, ki bi investitorja spodbudile k večji pozornosti. Bonitetne ocene niso odražale realne situacije samega sredstva oziroma so stanje ocenile z veliko zamudo. Kot je že omenjeno, je bil tudi to eden od razlogov, da zakonodajalec naroča finančnim družbam uporabo internih modelov. Prvi tak primer lahko opazujemo pri uporabi Altmanovega modela v tabeli 14.

Tabela 14: Primerjava vrednosti Z-Score in bonitetnih ocen

Izdajatelj	Datum	Celotna sredstva	Trenutna sredstva	Trenutne obveznosti	Obratna sredstva	Kapital	EBITDA	Tržna vrednost	Celotne obveznosti	Prihodki	z_score	Bonitetna ocena S&P	Absolutna sprememba Z-score	Relativna sprememba Z-score
Izdajatelj X	31.12.2020	50640	13005	13164	-159	37577	-2015	38993	39578	16659	1.8235	BB-	-0.1569	-0.0792
Izdajatelj X	31.12.2019	57470	13464	13673	-209	42524	1279	41128	42407	16887	1.9804	BB	0.0056	0.0028
Izdajatelj X	31.12.2018	60683	13794	14322	-528	44701	205	48039	44889	18271	1.9749	BB	0.7099	0.5612
Izdajatelj X	31.12.2017	70615	15382	17921	-2539	51218	-15372	60677	51870	21853	1.2650	BBB-	-1.0131	-0.4447
Izdajatelj X	31.12.2016	92890	16961	18519	-1558	70791	3678	83467	57897	21903	2.2780	BBB	-1.2087	-0.3467
Izdajatelj X	31.12.2015	54258	18398	13005	5393	39884	4660	68658	24331	19652	3.4867	BBB+	0.0593	0.0173
Izdajatelj X	31.12.2014	46420	14396	12289	2107	33639	5459	58971	23065	20272	3.4274	A-	0.5659	0.1978
Izdajatelj X	31.12.2013	47508	13720	11965	1755	34391	3291	47587	24872	20314	2.8615	A-	0.0623	0.0223
Izdajatelj X	31.12.2012	50609	16355	12888	3467	37476	3913	47350	27742	20317	2.7992	A-	0.0027	0.0010
Izdajatelj X	31.12.2011	50142	14453	13847	606	36275	4178	52323	27799	18312	2.7965	A-	-1.1220	-0.2863
Izdajatelj X	31.12.2010	38152	12042	9694	2348	27421	4848	53750	16150	16121	3.9184	A-	-0.3110	-0.0735
Izdajatelj X	31.12.2009	33810	12141	7602	4539	24871	3313	55886	14551	13899	4.2294	BBB+	0.7613	0.2195
Izdajatelj X	31.12.2008	32904	11426	8481	2945	24803	3164	45539	16544	11085	3.4681	BBB+	-1.0103	-0.2256
Izdajatelj X	31.12.2007	23412	9859	5371	4488	18948	2916	37045	9652	9408	4.4784	BBB	0.5419	0.1377
Izdajatelj X	31.12.2006	20471	7640	4071	3569	16504	2623	27347	9294	8408	3.9365	BBB	-2.3346	-0.3723
Izdajatelj X	31.12.2005	10387	5505	2260	3245	8199	1555	27411	4337	5250	6.2711	BBB	1.0611	0.2037
Izdajatelj X	31.12.2004	9632	4202	2204	1998	7689	1425	20158	4232	4799	5.2100	BBB	-0.8894	-0.1458
Izdajatelj X	31.12.2003	5916	3716	1695	2022	4403	913	15654	2620	3276	6.0995	BBB	1.5957	0.3543
Izdajatelj X	31.12.2002	4627	2901	1524	1377	3172	621	10240	2793	2519	4.50378	BBB		

Vir: lastno delo.

Če pozornost usmerimo na zadnje štiri stolpce, lahko jasno opazimo pozno zaznavo bonitetnih ocen. Naši izračuni vrednosti Z-Score so večje spremembe beležili že leta 2006, ko je Z-Score relativno padel za kar 37 %. Prav tako je Z-Score v obdobju od leta 2008 do 2011 v povprečju padal, bonitetna ocena pa je z letom 2008 šele začela naraščati. Manjše znižanje bonitetne ocene se je pričelo šele z letom 2014. Izdajatelja X uvrščamo v farmacevtsko panogo, kar po vsej verjetnosti pojasnjuje visoke bonitetne ocene. Ravno tovrstni primeri dokazujejo, da je podaja interne presoje bonitetne ocene smiselna in smotrna. Podoben primer, ki sicer ni tako izrazit kot prejšnji, je primerjava sprememb bonitetnih ocen, vrednosti z-razpona in opcijsko prilagojenega razpona, viden v tabeli 15.

Tabela 15: Primerjava bonitetnih ocen, z-razpona in opcijsko prilagojenega razpona

Izdajatelj	Datum nakupa	Datum testiranja	Bonitetna ocena na dan testiranja	Bonitetna ocena ob nakupu (numerično)	Bonitetna ocena danes (numerično)	Sprememba bonitetne ocene	Z-razpon	Z-razpon ob nakupu	Sprememba z-razpona	Optimizacijski razred na dan nakupa	Optimizacijski razred na dan testiranja	OAS nakup	OAS danes	Absolutna razlika z-razpona ob nakupu glede na OAS	Relativna razlika z-razpona ob nakupu glede na OAS	Absolutna razlika z-razpona danes glede na OAS	Relativna razlika z-razpona danes glede na OAS
Izdajatelj Y	3.20.2017	31.12.2021	A+	6	6	0	0.0049	0.0032	0.0017	FI NONFIN EUR AAA-A 2-5	FI NONFIN EUR AAA-A 2-5	0.0080	0.0063	-0.0048	0.4006	-0.0014	0.7821
Izdajatelj Y	3.21.2017	31.12.2021	A+	6	6	0	0.0049	0.0034	0.0015	FI NONFIN EUR AAA-A 2-5	FI NONFIN EUR AAA-A 2-5	0.0079	0.0063	-0.0045	0.4350	-0.0014	0.7821
Izdajatelj Y	3.20.2017	31.12.2021	A+	6	6	0	0.0049	0.0033	0.0016	FI NONFIN EUR AAA-A 2-5	FI NONFIN EUR AAA-A 2-5	0.0080	0.0063	-0.0047	0.4138	-0.0014	0.7821

Vir: lastno delo.

Opazimo, da se bonitetna ocena od leta 2017 do 2021 ni spremenila. Če preverimo OAS, opazimo, da se je razpon, ki predstavlja tveganje, v primerjavi z letom 2017 zmanjšal. Vrednost, ki opozarja na potrebno pozornost, je z-razpon, ki se v nasprotju z OAS zvišuje. V tem primeru gledamo seveda manjše spremembe, vendar je tudi tem treba nameniti nekaj pozornosti.

6.4 Scenarij ravnanja z naložbami z modelom

V vzorcu naložb pri historični primerjavi je bilo opaženih nekaj naložb z »rdečo« zastavico, ki bi investitorja spodbudile k večji pozornosti. Bonitetne ocene niso odražale realne situacije samega sredstva. Ekspertni model je s pomočjo analize in napovedi izpostavil kritične naložbe, s tem pa je investitor lahko bolj pozoren na svoja vlaganja.

Če se vrnemo na primer iz tabele 14, je jasno, da bi v primeru predhodne uporabe kreditnega modela na naložbo postali pozorni že leta 2006 in ne šele 2015, ko se je rating vrnil na prvotno mesto, oziroma leta 2018, ko se je znižal glede na bonitetno oceno ob pripoznavi. Posledica in ukrep, ki ga finančni oddelek družbe sprejme na podlagi ekspertnega modela, ni več predmet te raziskave. Od tukaj dalje gre za strokovno presojo upravljalcev, ali je na naložbo potrebno biti zgolj pozoren ali pa se jo slabi oziroma v celoti proda.

Iz primera v tabeli 15 je izkazano tveganje manj intenzivno, vseeno pa je prisotno. Z uporabo ekspertnega modela na tovrstne naložbe postanemo pozorni in o tem obvestimo pristojne.

7 UPORABNOST IN OMEJITVE MODELA

Ob koncu je smiselno pregledati celostno uporabnost modela, ki je bil do sedaj predstavljen bolj razdrobljeno in poglobljeno. Prednost ekspertnega modela za spremljanje kreditnih tveganj je predvsem združitev različnih zornih kotov, iz katerih kreditno tveganje lahko opazujemo. Pogled na kreditno tveganje iz zgolj ene perspektive v analizi predstavlja različne omejitve, ki so bile omenjene pri posameznih vrstah izračuna. S pomočjo uporabe različnih pogledov povečamo verjetnost zaznave tveganja. Kot je prikazano na sliki 6, v modelu vsako naložbo obravnavamo iz dveh vidikov. Prvi vidik se nanaša na historični razvoj naložbe, drugi vidik pa na trenutno stanje. Pri opazovanju trenutnega stanja naložbi pripišemo vrednosti PD, z-razpon in OAS. Pri opazovanju historičnega razvoja izdajatelja pa naložbi pripišemo Altmanov rezultat Z-Score, vrednosti KMV in bilančne količnike. Vsi naštetih uporabljeni pristopi so kot samostojni modeli seveda zelo uporabni, vendar je z združitvijo vseh zornih kotov

portfeljska slika bolj jasna. Prednost modela je seveda tudi to, da poleg obravnave konkretne naložbe opazuje tudi njenega izdajatelja.

Uporabnik modela kot končni seznam rezultatov prejme velik seznam z vsemi izračuni. Ker je, kot je bilo omenjeno, potrebna tudi strokovna presoja rezultatov, je seznam rezultatov za uporabnika zelo koristen, saj so vsi podatki in rezultati zbrani na enem mestu, kot je razvidno iz tabel spodaj. Zaradi preglednosti in dolžine tabel so rezultati prikazani ločeno. V končni obliki so rezultati zapisani v Excelovi datoteki, kjer so v prvih zavihkih zabeleženi vsi izračuni, v zadnjih zavihkih pa seznamami z izpostavljenimi naložbami, ki izkazujejo povečano tveganje iz več zornih kotov. Primera rezultatov sta prikazana v tabelah 16 in 17.

Tabela 16: Končni izračuni

Izdajatelj	Originalna valuta	Datum izdaje	Datum nakupa	Datum testiranja	Datum dospelosti	Bonitetna ocena ob nakupu	Bonitetna ocena na datum testiranja	PD ob pripoznavi	PD na dan testiranja	Z-razpon ob nakupu	Z-razpon	PD & Hazard rate	PD & hazard rate ob nakupu	Optimizacijski razred na dan nakupa	Optimizacijski razred na dan testiranja	OAS na dan nakupa	OAS na dan testiranja
Izdajatelj X	EUR	13.06.2019	5.06.2019	31.12.2021	13.07.2022	A+	A	0.0092	0.0003	0.0034	0.0018	0.0016	0.0031	FI NONFIN EUR AAA-A 2-5	FI NONFIN EUR AAA-A 2-5	0.0073	0.0063
Izdajatelj Y	EUR	21.03.2018	14.03.2018	31.12.2021	21.03.2023	AA-	A+	0.0006	0.0006	0.0032	0.0042	0.0086	0.0067	FI NONFIN EUR AAA-A 2-5	FI NONFIN EUR AAA-A 2-5	0.0053	0.0063
Izdajatelj Z	EUR	26.04.2016	19.04.2016	31.12.2021	26.04.2024	BBB+	BBB	0.0087	0.0043	0.0029	0.0050	0.0197	0.0114	FI NONFIN EUR BBB 2-5	FI NONFIN EUR BBB 2-5	0.0143	0.0110
Izdajatelj XX	EUR	22.09.2015	10.09.2015	31.12.2021	22.09.2023	BBB	BBB-	0.0176	0.0030	0.0043	0.0086	0.0251	0.0127	FI NONFIN EUR BBB 2-5	FI NONFIN EUR BBB 2-5	0.0146	0.0110
Izdajatelj YY	EUR	8.03.2017	27.02.2017	31.12.2021	8.03.2023	BBB-	BB+	0.0031	0.0106	0.0039	0.0101	0.0201	0.0078	FI NONFIN EUR BBB 2-5	FI NONFIN EUR HY 2-5	0.0133	0.0334
Izdajatelj ZZ	EUR	13.11.2012	21.05.2015	31.12.2021	14.11.2022	AA-	A+	0.0008	0.0004	-0.0089	0.0030	0.0045	-0.0134	FI NONFIN EUR AAA-A 2-5	FI NONFIN EUR AAA-A 2-5	0.0053	0.0063
Izdajatelj XXX	EUR	28.10.2019	21.10.2019	31.12.2021	28.10.2029	B+	B-	0.5981	0.2742	0.0064	0.0483	0.4761	0.0817	FI NONFIN EUR HY 2-5	FI NONFIN EUR HY 2-5	0.0364	0.0334

Vir: lastno delo.

Tabela 17: Končni izračuni 1

Izdajatelj	Datum	Cena	Lastniške delnice	Volatilnost	Kratkoročni dolg	Dolgoročni dolg	Donos (360dni)	Tržna vrednost kapitala	Obveznosti	Sigma	Datum netvegane obrestne mere	DD - Distanca to default	PD - Probabilnost of	DC - Distanca to Capital	PD_C	DD_2	PD_2	DC_2	PD_C_2		
Izdajatelj Z	28.06.2019	151.2	295.09	27.64	85514	112574	0.01	0.05	44602.85	141801	0.28	31.03.2019	-0.33	-1.13	0.87	-1.18	0.88	11.36	0.00	9.73	0.00
Izdajatelj Z	31.12.2018	138	295.09	26.52	89757	101126	-0.01	-0.23	40722.42	140320	0.27	31.12.2018	-0.33	-1.28	0.90	-1.33	0.91	6.36	0.00	4.54	0.00
Izdajatelj Z	29.12.2017	168.7	295.09	19.02	81844	81628	-0.01	0.14	49766.93	122658	0.19	30.09.2017	-0.36	-4.12	1.00	-4.56	1.00	17.60	0.00	15.62	0.00
Izdajatelj Z	30.12.2016	136.8	295.09	42.89	88462	68216	-0.01	0.08	40353.56	122570	0.43	30.09.2016	-0.31	-1.01	0.84	-1.06	0.86	7.14	0.00	6.15	0.00
Izdajatelj Z	31.12.2015	142.8	295.09	39.62	72312	73291	0.01	-0.21	42138.85	108958	0.40	31.12.2015	-0.16	-1.04	0.85	-1.09	0.86	2.27	0.01	1.43	0.08

Vir: lastno delo.

Uporabnost modela se kaže predvsem v primeru finančnih institucij, ki v svojih portfeljih držijo večje število različnih vrednostnih papirjev v daljšem časovnem obdobju, vendar nimajo časa in kapacitet za redno nadzorovanje vsakega izmed njih. Ekspertni model za vhodne podatke vzame torej celoten portfelj, kot rezultat pa vrne izpostavljene obveznice, ki izkazujejo povečano tveganje. Smiselno je torej, da uporabnik v zaporedju smiselnih časovnih obdobj, na primer kvartalno, uporabi ekspertni model in tako spremlja, katere naložbe se na novo pojavijo v izhodnem seznamu. Ker izhodna datoteka vsebuje vse izračune, uporabnik s pregledom rezultatov hitro opazi, kaj je razlog za pojav nove naložbe na seznamu tveganih obveznic. Posledično uporabnik lažje presodi svoje

nadaljnje poteze pri investiranju portfelja, kar pa je ravno eden izmed ciljev izdelave ekspertnega modela.

S pomočjo različnih pristopov opazovanja kreditnega tveganja posledično pridobimo tudi različne rezultate. Prednost modela se kaže ravno v tem, da se sledi tveganjem pri določenih obveznicah, ki jih drugače ne bi zaznali kot tvegane, razkrijejo pa se slutnje o povečanem tveganju, ki se podkrepijo s pomočjo več modelov. S tem se izkazuje namen in razlog uporabnosti samega modela. V kolikor bi uporabili izključno specifični model (npr. samo z-razpon), bi tveganje pri posamezni naložbi lahko podcenili oziroma precenili. Prednosti modela se kažejo torej v obeh smereh. Določeni del modela lahko zgolj opozori na morebitno povečanje tveganja pri izdajatelju, kar nam pomaga, da smo lahko na to naložbo bolj pozorni. Po drugi strani pa lahko v primerih, ko pri določeni naložbi večje število posameznih modelov izkazuje opozorilo o povečanem tveganju, z večjo gotovostjo trdimo, da se pri posamezni naložbi tveganje resnično povečuje. Opisana dinamika je prikazana v tabeli 18.

Tabela 18: Opozorila ločenih kazalnikov

Izdajatelj	Opozorilo bonitetne ocene	Opozorilo PD	Opozorilo z-spread	Opozorilo OAS	Opozorilo Altman	Opozorilo KMV
Izdajatelj A		x				
Izdajatelj B	x	x				
Izdajatelj C						
Izdajatelj D	x					
Izdajatelj E	x	x				
Izdajatelj F	x	x	x		x	x
Izdajatelj G	x	x	x			
Izdajatelj H			x	x		
Izdajatelj I	x		x			
Izdajatelj J	x		x			
Izdajatelj K		x	x		x	
Izdajatelj L		x	x			

Vir: lastno delo.

Finančne institucije zaradi zakonodaje spremljajo spremembo bonitetne ocene in PD. Velikokrat pa je to tudi edini indikator tveganja na posameznih vrednostnih papirjih. V tabeli 18 sem za prikaz uporabnosti modela izbrala dvanajst različnih izdajateljev, pri katerih je model opozoril na povečano tveganje pri dotični obveznici. Če bi za opazovanje tveganja uporabljali izključno bonitetne ocene in PD, bi kot enakovredne in bolj tvegane opredelili Izdajatelje B, E, F in G. V primeru ekspertnega modela pa lahko na primeru teh obveznic vidimo širšo sliko. Če za primer vzamemo Izdajatelja F, opazimo, da je ekspertni model na povečanje tveganja opozoril na kar petih različnih segmentih za

razliko od Izdajatelja B. Če bi torej tveganje preučevali izključno glede na PD in bonitetne ocene, bi tveganje Izdajatelja B precenili, tveganje Izdajatelja F pa podcenili. Slabše bi bilo seveda podcenjevanje tveganja Izdajatelja F. S tovrstnimi primerjavami in konkretnimi izračuni model izkazuje dodano vrednost, saj uporabniku na preprost način prikaže tveganja iz različnih zornih kotov.

Tako kot pri vsakem modelu se tudi pri ekspertnem modelu odpirajo priložnosti in ideje za nadgradnje in izboljšave. Prva in tudi največja ovira, na katero sem naletela, je dostopnost podatkov. V Sloveniji so družbe zakonsko zavezane letno poročati in objaviti svoje bilančne in ostale podatke preko platforme AJPES. V tujini pa zakonodaja ne zahteva objave vseh teh podatkov, kar pomeni, da modelov ni mogoče uporabiti v polni meri, četudi so primerni. Posledično se v ekspertnem modelu pri določenih naložbah nekateri kazalniki tveganja ne izračunajo.

Nadgradnje bi bilo smiselno dodati tudi pri panožnih specifikacijah. Z večjim številom podatkov pri vsaki panogi bi lahko z večjo statistično gotovostjo določili merila tveganja, ki bi bila zelo specifična za vsako posamezno panogo. Tovrstna nadgradnja bo v ekspertnem modelu mogoča s sprotnim opazovanjem in nadgrajevanjem v prihodnjih letih.

Uporaba bilančnih podatkov odraža stanje družbe v preteklem letu. Posledično tisti deli modela, ki temeljijo na tovrstnih podatkih, odražajo rezultate na podlagi podatkov prejšnjega leta. Kljub temu pa na enakih podatkih temeljijo tudi bonitetne ocene agencij. S pridobitvijo kvartalnih bilančnih podatkov izdajateljev bi močno izboljšali zaznavno in napovedno moč modela, kar pa je seveda zelo težko izvedljivo.

Del analize, ki temelji na historičnem razvoju naložbe oziroma njenega izdajatelja, je omejen predvsem pri državnih obveznicah, ker v tem primeru ne moremo opazovati razvoja bilančnih podatkov. V tem primeru smo torej primorani uporabiti zgolj izračune glede na trenutne podatke. Alternativa, ki smo jo posledično vključili, so makro kazalniki, kot so BDP, inflacija, brezposelnost itd., ki pa še ne povzemajo popolnoma prave slike vrednostnega papirja.

Sama ideja modela in njegovi izračuni so zelo specifično zasnovani, kar pa še ne potrjuje njihove uporabnosti. Primerjave podatkov o stanju naložb pri nakupu in danes so smiselne predvsem pri tistih naložbah, ki so bile kupljene v relativno kratkem predhodnem obdobju. Posamezne dele modela je torej smiselno prilagoditi glede na dinamiko portfelja in njegovo strukturno sestavo, saj s tem povečamo uporabnost, kakovost interpretacij in smiselnost.

Omejitev modela je prav tako njegova trenutna tehnična zasnova in izgled. Zaradi velike količine kod je za uporabnika model zelo zahteven. V prihodnosti bi bilo torej smiselno vpeljati celotni ekspertni model in njegovo kodo v neko aplikacijo, ki bi lepše in bolj jasno prikazala vmesne in končne rezultate.

SKLEP

Ker računovodski standardi MSRP 9 zaradi ažurnosti bonitetnih ocen od finančnih institucij zahtevajo lastno modeliranje kreditnih tveganj, je v tem magistrskem delu predstavljena izdelava ekspertnega modela za zaznavo kreditnega tveganja. Gre za model, izdelan za izbrano finančno institucijo, ki v zaključeno celoto združuje bolj znane modele za preverbo kreditnega tveganja. S pomočjo združitve neodvisnih pristopov lahko kreditno tveganje naložbenega portfelja pogledamo iz več zornih kotov.

Magistrsko delo zasleduje tri ključne cilje, in sicer razvoj modela, opis metodologije in dokaz smiselnosti njegove uporabe. Delo opisuje idejo in namen razvoja samostojnega modela presoje primernosti bonitetnih ocen. Z združitvijo že preizkušenih metod in opisom metodologije izdelave ekspertnega modela je bilo mogoče identificirati naložbe, pri katerih tržni oziroma finančni podatki morebiti niso skladni z bonitetno oceno. S pomočjo preizkusa modela je dokazano, da tovrstni interni ekspertni modeli pomagajo družbam pri boljšem nadzoru sprememb stanja njihovih naložb, s čimer lahko upravičimo zahteve novih računovodskih standardov.

Ekspertni model je sestavljen iz treh delov, in sicer vhodnih podatkov, izdelave izračunov in izhodnih podatkov. Model kot ključne indikatorje kreditnega tveganja vključuje različne vrste analiz. Del modela predstavlja analiza bilančnih podatkov, kjer je kot ključni pokazatelj tveganj uporabljen Altmanov model Z-Score. Sledi analiza pribitkov, kjer je opravljena primerjava vrednosti z-razpona in bonitetnih ocen. Zadnja med vrstami analiz je analiza verjetnosti neplačila, kjer je uporabljen model KMV, prav tako pa je opravljena tudi primerjava verjetnosti neplačil v različnih časovnih obdobjih. Ekspertni model je aplikativne narave in ga bo posledično uporabila izbrana finančna institucija. Sestava in zasnova modela sta v skladu s predpisi MSRP 9 in Solventnost 2, izdelava modela pa je optimizacijske narave, saj stremi k optimizaciji informativne uporabe dosegljivih podatkov.

Tako kot pri vsakem modelu se tudi pri ekspertnem modelu odpirajo priložnosti za nadgradnje in izboljšave. Nadgradnje bi bilo smiselno dodati pri panožnih specifikacijah. Z večjim številom podatkov pri vsaki panogi bi lahko z večjo statistično gotovostjo določili merila tveganja, ki bi bila zelo specifična za vsako posamezno panogo. Zaenkrat to ovirajo manjkajoči podatki, zaradi katerih so izračuni nepopolni in napovedi manj

natančne. Po izdelavi vseh delov ekspertnega modela se je izkazalo, da je uporaba posameznih izračunov pri določenih naložbah bolj smiselna kot pri drugih. Posledično so bile na ekspertnem modelu opravljene prilagoditve glede na lastnosti in panogo naložb oziroma izdajateljev.

LITERATURA IN VIRI

1. Afonso, A. (2007). What 'Hides' Behind Sovereign Debt Ratings?. *Research Gate*. Pridobljeno 2. februar 2023 iz: https://www.researchgate.net/figure/S-P-Moodys-and-Fitch-rating-systems-and-linear-transformations_tbl1_256069934
2. Ahčin, N. (2019). *Konstrukcija krivulje donosnosti* (magistrsko delo). Ljubljana: Fakulteta za matematiko in fiziko.
3. Altman, E. I. (1968). Financial ratios, discriminant analysis and prediction of corporate bankruptcy. *The Journal of Finance*, 23(4), 589-609.
4. Altman, E. I. (1983). *Corporate Financial Distress. A Complete Guide to Predicting, Avoiding, and Dealing With Bankruptcy*. John Wiley and Sons.
5. Altman, E. I. & Saunders, A. (1998). Credit risk measurement: Developments over the last 20 years. *Journal of Banking & Finance*, 21(11/12), 1721-1742.
6. Babbel, D. F. & Zenios, S. A. (1992). Pitfalls in the Analysis of Option-Adjusted Spreads. *Financial Analysts Journal*, 48(4), 65-69.
7. Baraboza, F., Kimura, H. & Altman, E. I. (2017). Machine learning models and bankruptcy prediction. *Expert Systems with Applications*, 83(1), 405-417.
8. Berk Skok, A. (2020). Credit risk. *Risk Management* (prosojnice). Ljubljana: Ekonomska fakulteta.
9. Bezak, N., Zabret, K. & Šraj, M. (2018, 27. julij). Application of Copula Functions for Rainfall Interception Modelling. *Water* 2018, 10(8), 995.
10. Bielecki, T. R., Jeanblanc, M. & Rutkowski, M. (2009). *Credit risk modeling*. Osaka: Center for the Study of Finance and Insurance, Osaka University.
11. Black, F. & Scholes, M. (1973). The pricing of options and corporate liabilities. *Journal of political economy*, 81(3), 637-654.
12. Brvar, A. (1998). *Bonitetna poročila in bonitete podjetji*. Ljubljana: Kapital.
13. Caoette, J. B., Altman, E. I., Narayanan, P. & Nimmo, R. (2008). *Managing Credit Risk: The great challenge for the Global Financial Markets*. John Wiley & Sons, Inc.
14. CFI. (2021, 16. november). *Expected Default Frequency*. Pridobljeno 12. septembra 2022 iz <https://corporatefinanceinstitute.com/resources/knowledge/credit/expected-default-frequency-edf/>

15. Chen, J. (2021a). What Is an Index?. *Investopedia*. Pridobljeno 7. junija 2022 iz <https://www.investopedia.com/terms/i/index.asp>
16. Chen, J. (2021b). Option-Adjusted Spread (OAS). *Investopedia*. Pridobljeno 3. januarja 2022 iz <https://www.investopedia.com/terms/o/optionadjustedspread.asp>
17. Chen, L., Collin-Dufresne, P. & Goldstein, R. S. (2009). *On the relation between the credit spread puzzle and the equity premium puzzle*. Oxford University Press.
18. Chen, L., Lesmond, D. A. & Wei, J. (2007). Corporate yields spreads and bond liquidity. *The journal of finance*, 62(1), 119-149.
19. Choudhry, M. (2006). *The Futures Bond Basis* (2. izd.). Wiley.
20. Corelli, A. (2014). *Understanding financial risk management* (1. izd.). New York: Routledge.
21. Corporation, S. A. (1996). *Standard & Poor's CreditWeek*. Michigan: Standard & Poor's Corporation.
22. Čop, A. (2013). *Teorija bonitetnih ocen* (diplomska naloga). Ljubljana: Fakulteta za matematiko in fiziko.
23. Einstein A. (1926). Investigations on the theory of the Brownian movement. *Dover Publications*, 7(10), 124.
24. EIOPA - European insurance and occupational pensions authority. (2017). *Technical documentation of the methodology to derive EIOPA's risk-free interest rate term structures*. Frankfurt: EIOPA.
25. European Central Bank. (2022, 30. marec). *European central bank - Eurosystem*. Pridobljeno 24. marca 2022 iz https://www.ecb.europa.eu/stats/financial_markets_and_interest_rates/euro_area_yield_curves/html/index.en.html
26. EY. (2018). *Applying IFRS Impairment of financial instruments under IFRS 9*. EY's International Financial Reporting Standards Group.
27. Hayes, A. (2022, 13. januar). Yield curve. *Investopedia*. Pridobljeno 18. aprila 2022 iz <https://www.investopedia.com/terms/y/yieldcurve.asp>
28. Herga, Z. (2011). *Logistična regresija* (diplomski seminar). Ljubljana: Fakulteta za matematiko in fiziko.
29. International Monetary Fund. (2021). *The World Economic Outlook: Recovery during a Pandemic—Health Concerns, Supply Disruptions, Price Pressures*. Washington, DC: International Monetary Fund.
30. James, G., Witten, D., Hastie, T. & Tibshirani, R. (2013). *An Introduction to Statistical Learning*. Springer.
31. Jorion, P. (2009). *Risk Management Lessons from the Credit Crisis*. Nantes: European Financial Management Symposium.
32. Kagan, J. (2020, 30. november). Default rate. *Investopedia*. Pridobljeno 5. junija 2022 iz <https://www.investopedia.com/terms/d/defaultrate.asp>

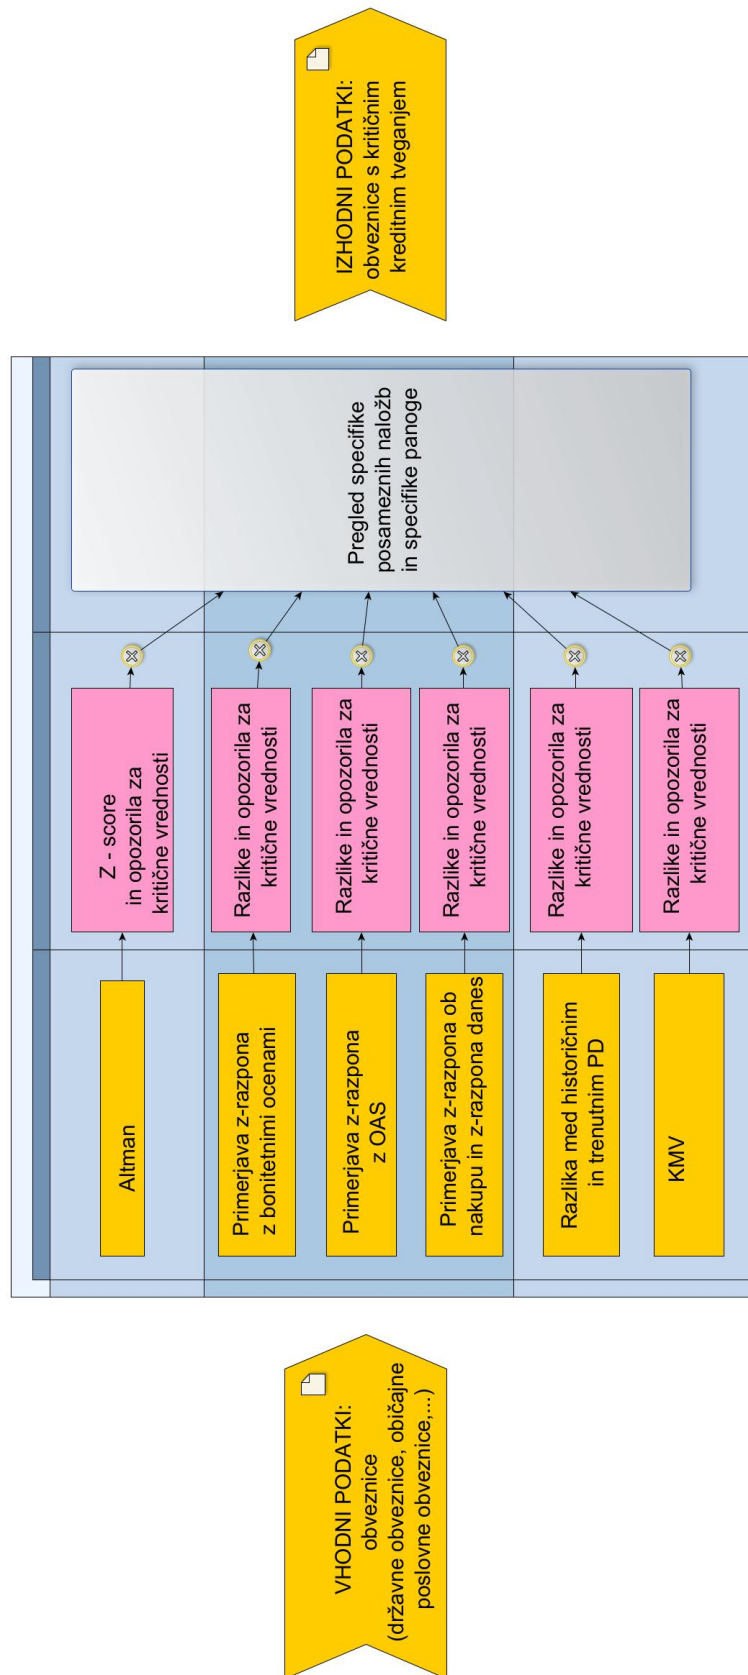
33. Kalteier, E.-M., Molt, S. & Nguyen, T. (2014). *Value-based assessment of sovereign risk* (doktorska študija). Walden: Walden University, College of Management and Technology.
34. Knez-Riedl, J. (1998). *Objektivizacija presoje bonitete podjetja s pomočjo panožnih dejavnikov* (doktorska disertacija). Maribor: Ekonomsko-poslovna fakulteta.
35. Kosec, U. (2014). *Napovedovanje čistvene naravnosti avtorjev v spletnih komentarjih* (diplomska naloga). Ljubljana: Fakulteta za računalništvo in informatiko.
36. KPMG. (2017). *Demystifying Expected credit loss (ECL)*. Pridobljeno 15. maja 2022 iz <https://assets.kpmg.com/content/dam/kpmg/in/pdf/2017/07/Demystifying-Expected-Credit-Loss.pdf>
37. Krković, M. (2018). *Modeliranje verjetnosti neplačila v bančnem sektorju* (magistrska naloga). Ljubljana: Fakulteta za matematiko in fiziko.
38. Li, C. & Li, X. (2018, 3. november). Hazard rate and reversed hazard rate orders on extremes of heterogeneous and dependent random variables. *Statistics and Probability Letters*, 146(1), 104-111.
39. Mahat, L. (2020). Expected Credit Loss: basel III vs IFRS 9 [YouTube]. Pridobljeno 24. januarja 2022 iz <https://www.youtube.com/watch?v=5CAWuNaoecY>
40. Maimon, O. & Rokach, L. (2005). *Data Mining and Knowledge Discovery Handbook*. ZDA: Springer Science+Business Media.
41. Majcan, A. (2020). *Uspešnost modelov napovedovanja propada podjetja*. (diplomska naloga). Maribor: Ekonomsko-poslovna fakulteta.
42. Malz, A. (2011). *Financial Risk Management: Models, History and Institutions*. Hoboken: John Wiley & Sons.
43. Marčuk, J. (2014). *Modeliranje verjetnosti neplačila: obstoj generatorja prehodnih matrik in algoritmi za iskanje* (diplomsko delo). Ljubljana: Fakulteta za matematiko in fiziko.
44. McClure, B. (2022, 20. maj). *How to calculate an Altman Z-Score*. Pridobljeno 3. januarja 2022 iz <https://www.investopedia.com/articles/fundamental/04/021104.asp>
45. Merton, R. C. (1974). On the Pricing of Corporate Debt: The Risk Structure of Interest Rates. *The Journal of Finance*, 29(2), 449-470.
46. Moody, J. (1909). The recovery from the depression. *The annals of the American Academy of political and social science*, 34(3), 146-153.
47. Moody's. (2022, 27. januar). *Default Trends and Rating Transitions*. Pridobljeno 12. aprila 2022 iz <https://www.moody.com/creditfoundations/Default-Trends-and-Rating-Transitions-05E002/reports>

48. Moody's analytics. (2011). *EDF Overview*. Pridobljeno 8. aprila 2022 iz <https://www.moodyanalytics.com/-/media/products/EDF-Expected-Default-Frequency-Overview.pdf>
49. Moody's Analytics. (2021, 16. november). *History of KMV*. Pridobljeno 17. marca 2022 iz <https://www.moodyanalytics.com/about-us/history/kmv-history>
50. Naglič, A. (2010). *Ocena kreditnega tveganja in migracijske matrike* (diplomska naloga). Ljubljana: Fakulteta za matematiko in fiziko.
51. Natixis asset management. (2016). *Solvency II Capital Requirements for Debt Instruments*. Pridobljeno 2. maja 2022 iz <https://www.im.natixis.com/en-institutional/resources/solvency-ii-capital-requirements-for-debt-instruments>
52. Perme, J. (2018). *Modeliranje likvidnostne premije na podjetniških obveznicah* (diplomska naloga). Ljubljana: Fakulteta za matematiko in fiziko.
53. Pirnovar, A. (2020). *Modeliranje verjetnosti neplačila s kupolami* (magistrsko delo). Ljubljana: Fakulteta za matematiko in fiziko.
54. Pluto, K. & Tasche, D. (2005, 4. april). *The Basel II Risk Parameters* (2. izd.) Springer.
55. Pogačar, A. (2011). *Mertonov model kreditnega tveganja* (diplomska naloga). Ljubljana: Fakulteta za matematiko in fiziko.
56. Pogačar, J. (2013). *Uporaba Bayesove formule pri ocenjevanju stopnje poplačila slabih naložb* (diplomski seminar). Ljubljana: Fakulteta za matematiko in fiziko.
57. Pogačar, J. (2018). *Modeliranje verjetnosti neplačila po standardih računovodskega poročanja* (magistrsko delo). Ljubljana: Fakulteta za matematiko in fiziko.
58. Premoša, L. (2021). *Napovedna moč klasifikacije gostotnih skupin po BI-RADS kriteriju na procesiranih in neprocesiranih mamografskih slikah* (magistrsko delo). Ljubljana: Fakulteta za matematiko in fiziko.
59. ProQuest LLC. (2019, 6. april). *Option-Adjusted Spread vs. Z-Spread: What's the Difference?* Pridobljeno 12. marca 2022 iz <https://www.proquest.com/docview/2251464639?accountid=28926>
60. RiskMetrics Group. (2007) *CreditMetrics – Tehnical Document*. Pridobljeno 12. marca 2022 iz <https://www.msci.com/documents/10199/93396227-d449-4229-9143-24a94dab122f>
61. S&P. (2022, 28. januar). *S&P Ratings*. Pridobljeno 12. marca 2022 iz <https://www.spglobal.com/ratings/en/>
62. Saunders, A. & Cornett, M. (2006). *Financial Institutions Management A risk management approach* (6. izd.). New York: McGraw-Hill/Irwin.
63. Scikit. (2022). *Scikit learn*. Pridobljeno 11. marca 2022 iz https://scikit-learn.org/stable/auto_examples/ensemble/plot_ensemble_oob.html
64. Škrjanerc, D. (2009). *Izdelava in primerjava bonitetne ocene dveh podjetij v isti panogi* (diplomsko delo). Ljubljana: Ekonomska fakulteta.

65. Taylor, D. (2017, 20. september). *IFRS 9 Explained – the new expected credit loss model*. Pridobljeno 12. februarja 2022 iz <https://www.bdo.co.uk/en-gb/insights/business-edge/business-edge-2017/ifrs-9-explained-the-new-expected>
66. Teterova, A. (2021). Distance-to-Default (According to KMV model). *Numerical Introductory Course*. Pridobljeno 11. marca 2022 iz http://home.lu.lv/~valeinis/lv/seminars/Teterova_05042012.pdf
67. The World Bank. (2022, 21. april). *World Bank Open Data*. Pridobljeno 11. aprila 2022 iz <https://www.worldbank.org/en/home>
68. Timperley, H., Wilson, A., Barrar, H. & Fung, I. (2021, 19. september). *Iteration*. Pridobljeno 24. maja 2022 iz <https://en.wikipedia.org/wiki/Iteration>
69. Trading Economics. (2022, 24. maj). *Indicators*. Pridobljeno 30. marca 2022 iz <https://tradingeconomics.com/>
70. Vodopivec, L. (2020). *Karakterizacija in razpoznavanje zvokov ventilov ogrevalnih sistemov* (magistrsko delo). Ljubljana: Fakulteta za strojništvo.
71. White, L. J. (2010). The Credit Rating Agencies. *Journal of Economic Perspectives*, 24(2), 211–226.
72. Wikipedia. (2021a, 14. november). *Brownovo gibanje*. Pridobljeno 12. junija 2022 iz https://sl.wikipedia.org/wiki/Brownovo_gibanje
73. Wikipedia. (2021b, 14. november). *Robert C. Merton*. Pridobljeno 13. junija 2022 iz https://en.wikipedia.org/wiki/Robert_C._Merton
74. Wikipedia. (2022a, 21. februar). *Expected loss*. Pridobljeno 20. julija 2022 iz https://en.wikipedia.org/wiki/Expected_loss
75. Wikipedia. (2022b, 13. januar). *Loss given default*. Pridobljeno 24. julija 2022 iz https://en.wikipedia.org/wiki/Loss_given_default
76. Young, J. (2022, 2. februar). *Market Index*. Pridobljeno 12. maja 2022 iz <https://www.investopedia.com/terms/m/marketindex.asp>
77. Zeme, N. (2018). *Napovedovanje tveganja za ponovno hospitalizacijo pacientov s sladkorno boleznijo na osnovi podatkov v bolnišničnih obravnavah* (magistrsko delo). Maribor: Fakulteta za zdravstvene vede.
78. Zhao, S., Moreira, F. & Wang, T. (2019). *The Relationship among Sovereign Ratings, Bank Ratings and Bank Performances: Evidence from European Commercial Banks* (strokovni članek). Edinburgh: University of Edinburgh Business School.

PRILOGE

Priloga 1: Vizualizacija procesa modela



Vir: lastno delo.

Priloga 2: Kazalniki in formule

Kazalnik	Formula
Obratna sredstva	$\text{Skupni prihodki} / ((\text{Sredstva} + \text{Sredstva v prejšnjem letu})/2)$
Razmerje med dolgom in lastniškim kapitalom	$\text{Dolg}/(\text{Dolg} + \text{Skupni lastniški bruto manjšinski delež})$
Razmerje med EBIT in obrestmi	$\text{EBIT} / \text{Obrestni odhodki}$
Razmerje med trajnim kapitalom in (dolgoročno) zadolženostjo	$\text{Dolgoročni dolg} / \text{Bruto manjšinski delež skupnega lastniškega kapitala}$
Razmerje med zadržanim dobičkom in dolžniškim kapitalom	$\text{Zadržani dobiček}/(\text{Skupni dolg} + \text{Skupni lastniški kapital bruto manjšinski delež})$
Donosnost sredstev	$\text{EBIT} * 0,625 / ((\text{Skupna sredstva} + \text{Skupna sredstva prejšnje leto}) / 2)$
Razmerje med dobičkom in prihodki	$\text{EBIT} / \text{Skupni prihodki}$
Razmerje med dobičkom in sredstvi	$\text{EBIT} / \text{Skupna sredstva}$
Donosnost sredstev	$(\text{EBIT} * 0,625) / ((\text{Skupna sredstva} + \text{Skupna sredstva prejšnje leto}) / 2)$
Razmerje med administrativnimi stroški in prihodki	$\text{Splošni in administrativni stroški} / \text{Skupni prihodki}$
Marža čistega dohodka	$\text{Čisti dohodek} / \text{Skupni prihodki}$
Normalizirana marža čistega dohodka	$\text{Normalizirani dohodek} / \text{Skupni prihodki}$
Razmerje med povprečnim lastniškim kapitalom in povprečnimi sredstvi	$((\text{Navadni delniški kapital} + \text{Navadni delniški kapital prejšnje leto}) / 2) / ((\text{Skupna sredstva} + \text{Skupna sredstva prejšnje leto})/2)$
Razredčen EPS pred dodatno rastjo	$(\text{Popravljeni dobiček na delnico} - \text{Čisti dobiček iz neprekinjenega in ustavljenega poslovanja} / \text{Popravljeni dobiček na delnico} - \text{Čisti dobiček iz nadaljevanja in ustavljenega poslovanja v prejšnjem letu-1})$

Vir: lastno delo.