

UNIVERZA V MARIBORU
EKONOMSKO-POSLOVNA FAKULTETA

DIPLOMSKO DELO

Daniel Zdolšek

Grobelno, september 2006

UNIVERZA V MARIBORU
EKONOMSKO-POSLOVNA FAKULTETA

DIPLOMSKO DELO

**IDENTIFIKACIJA VRSTE
REVIZIJSKEGA MNENJA Z UPORABO
RAČUNOVODSKIH KAZALNIKOV**

Kandidat:	Daniel Zdolšek
Številka indeksa:	Študent rednega študija 81585735
Program:	Univerzitetni
Študijska smer:	Računovodstvo in revizija
Mentor:	dr. Timotej Jagrič
Somentor:	dr. Franc Koletnik

Grobelno, september 2006

IZJAVA

Kandidat: Daniel Zdolšek,
absolventk študijske smeri: Računovodstvo in revizija,
študijskega programa: Univerzitetni/96,

izjavljam, da sem avtor tega diplomskega dela, ki sem ga napisal

pod mentorstvom: dr. Timoteja Jagriča
in somentorstvom: dr. Franca Koletnika
in uspešno zagovarjal: 25. septembra 2006.

Zagotavljam, da je besedilo diplomskega dela v tiskani in elektronski obliki istovetno in brez virusov.

Ekonomsko-poslovni fakulteti dovoljujem, da lahko diplomsko delo bralci uporabijo za svoje izobraževalne in raziskovalne namene s povzemanjem posameznih misli, idej, konceptov oziroma delov teksta iz diplomskega dela ob upoštevanju avtorstva in korektnem citiranju.

Na Grobelnem, dne 25.9.2006

Podpis:



PREDGOVOR

Proučitev tematike s področja revizije, ki jo odraža naslov pričujočega dela, ima svoj pglavitni vzrok vsaj v enem preprostem objektivnem dejstvu, da lahko uporabnikom, tj. večinoma oz. pogosto revizorjem, predstavljeno orodje/pripomoček zagotovi potrebno in/ali dodatno informacijo, ki je potrebna pri revizorjevi odločitvi glede vrste revizijskega mnenja. Namen je torej zagotoviti: prvič, boljšo (kakovostnejšo) informacijsko podlago revizorjem pri odločanju oz. verifikaciji glede že odločenega in pokazati, da obstaja neko razmerje med posamezno vrsto revizijskega mnenja in izbrano kombinacijo kazalnikov. In drugič, zagotoviti takšen model/pripomoček, ki bo uporabljen v dejanski/realni situaciji.

Naslov naloge in v nalogi zastavljen problem pa niti ne razkriva interdisciplinarnosti proučevanega področja. Konsistentno predstavljeni osnovni elementi revizije, posebej analitični postopki, tvorijo s predstavljenou metodologijo o klasifikaciji in merjenju uspešnosti razvitih modelov le izhodišče za razvoj modela. Ključno pri razvoju modela logistične regresije je seveda poznavanje vsebinskih, tj. teoretičnih, izhodišč in na podlagi slednjih v kombinaciji z empiričnim raziskovanjem razrešitev vprašanja, ali je možno z izbrano kombinacijo računovodskih kazalnikov identificirati oz. napovedati vrsto revizijskega mnenja. Ugotovitve naloge pokažejo, da je slednje možno, s čimer je potrjena v večini preteklih študij implicitna predpostavka o možni uporabi računovodskih in finančnih kazalnikov pri napovedi vrste revizijskega mnenja. Ker temelji model na tehniki logistične regresije, predstavlja končni izid modela verjetnost, da bo podjetje prejelo modificirano vrsto revizijskega mnenja.

Vendar zaradi različnosti same poslovne in osebne narave posameznega subjekta, kompleksnosti in dinamičnosti poslovnega okolja, predstavljen model pogosto ni optimalen za uporabnika, saj se preference in/ali zahteve uporabnikov modela lahko močno razlikujejo. Ocenitev uspešnosti modela zato zahteva podrobnejšo obravnavo in posebno pozornost, kajti posplošitev, da je model pri različnih preferencah uporabnika modela enako uspešen, je zavajajoča in tudi napačna. Prilagoditev modela, kot je prikazano v nalogi, je zato nujna/priporočljiva. Slednje sicer lahko zahteva, relativno gledano, le nekoliko kompleksnejšo rabo/uporabo predstavljenega modela. Potrebna podatkovna podlaga, tj. podatki, ki so potrebni pri dveh izmed možnih prilagoditev modela glede na uporabnikove preference (tj. minimizacija števila napačno podeljenih mnenj pri uporabi modela ali minimizacija povprečnih stroškov napačno podeljenih mnenj gospodarskim družbam pri uporabi modela), je podana v nalogi.

Glede na proučeno širšo preteklo literaturo z obravnavanega področja je dodana vrednost pričujočega dela predvsem v drugem delu naloge, ki po vključitvi odločitvene analize (tj. odločitvenega procesa) in ob vpeljavi kompleksnejših kriterijev uspešnosti, ki realneje pokažejo/prikažejo identifikacijsko/klasifikacijsko moč/zmožnost modela, pomembno razširi uporabnost končnega modela in omogoči po optimizaciji modela uporabniku najboljšo možno uporabo/rešitev glede na njegove preference. Ne glede na v nalogi predstavljene probleme (npr. velja opozoriti, da na raziskavo vplivajo razpoložljivi oz. dosegljivi podatki) ima predstavljen model, ki vključuje 6 računovodskih kazalnikov, visoko generalizacijsko sposobnost in je tudi neobčutljiv na spremembe v predpostavljenih pogojih/okolijščinah.*

* Korespondenca z avtorjem možna na naslov: Daniel Zdolšek, Grobelno 124, 3231 Grobelno, Slovenija. Elektronski naslov: Daniel.Zdolsek@Uni-mb.si, Daniel.Zdolsek@Siol.net in/ali Daniel.Zdolsek@Gmail.com.

KAZALO

1	UVOD.....	1
1.1	OPREDELITEV PODROČJA IN OPIS PROBLEMA	1
1.2	NAMEN, CILJI IN OSNOVNE TRDITVE.....	2
1.3	PREDPOSTAVKE IN OMEJITVE RAZISKAVE	3
1.4	METODE RAZISKOVANJA.....	4
2	MNENJE REVIZORJA IN IDENTIFIKACIJSKI MODELI	5
2.1	OSNOVNE ZNAČILNOSTI ZUNANJE REVIZIJE.....	5
2.1.1	<i>Namen in vloga revizijskega poročila</i>	<i>5</i>
2.1.2	<i>Vrste revizijskih poročil.....</i>	<i>6</i>
2.1.3	<i>Razlogi za razvoj pripomočkov oz. modelov v reviziji</i>	<i>8</i>
2.2	PROCES REVIDIRANJA RAČUNOVODSKIH IZKAZOV	9
2.2.1	<i>Analitični postopki.....</i>	<i>10</i>
2.2.2	<i>Vrste metod in tehnik pri uporabi analitičnih postopkov.....</i>	<i>12</i>
2.3	DEJAVNIKI, KI VPLIVAJO NA PROCES REVIZIJE IN MNENJE REVIZORJA	14
2.4	TVEGANJE REVIZORJA.....	15
2.5	MODELI ZA IDENTIFICIRANJE VRSTE REVIZIJSKEGA MNENJA.....	16
2.6	SKLEPNA MISEL K POGLAVJU O REVIZIJI.....	18
3	METODOLOGIJA	19
3.1	KLASIFIKACIJSKI MODEL IN LOGISTIČNA REGRESIJA	19
3.1.1	<i>Bivariantna klasifikacija.....</i>	<i>20</i>
3.1.2	<i>Uporaba logistične regresije pri problemu klasifikacije</i>	<i>22</i>
3.2	KRITERIJI (MERILA) ZA OCENO USPEŠNOSTI MODELA.....	24
3.2.1	<i>Klasični kriteriji za ocenjevanje uspešnosti klasifikacijskih modelov</i>	<i>26</i>
3.2.2	<i>ROC krivulja.....</i>	<i>31</i>
3.2.3	<i>Občutljivost in zmožnost generalizacije klasifikacijskega modela</i>	<i>39</i>
3.2.4	<i>Prilagoditev parametrov klasifikacijskega modela.....</i>	<i>39</i>
3.3	SKLEPNA MISEL K POGLAVJU O METODOLOGIJI.....	40
4	SESTAVA MODELA ZA IDENTIFIKACIJO VRSTE MNENJA	43
4.1	VZOREC IN NJEGOVE (STATISTIČNE) ZNAČILNOSTI.....	43
4.1.1	<i>Metodologija pri vzorčenju.....</i>	<i>43</i>
4.1.2	<i>Izbrani vzorec podatkov.....</i>	<i>45</i>
4.1.3	<i>Analiza manjkajočih podatkov in imputacija manjkajočih vrednosti</i>	<i>46</i>
4.1.4	<i>Deskriptivna statistika izbranega vzorca.....</i>	<i>48</i>
4.2	IZBOR SPREMENLJIVK	48
4.2.1	<i>Nabor spremenljivk.....</i>	<i>48</i>
4.2.2	<i>Proces izbora (redukcije števila) spremenljivk.....</i>	<i>50</i>
4.3	KONSTRUIRANJE MODELA.....	51
4.4	SKLEPNA MISEL K POGLAVJU O KONSTRUKCIJI MODELA	53
5	ANALIZA REZULTATOV.....	55
5.1	ANALIZA PARAMETROV MODELA KLASIFIKACIJE.....	55
5.2	PRIMERJALNA ANALIZA MODELOV.....	57
5.2.1	<i>Klasična merila uspešnosti.....</i>	<i>57</i>
5.2.2	<i>Grafični prikaz klasifikacije in analiza s pomočjo ROC krivulj</i>	<i>58</i>
5.2.3	<i>Primerjava modelov s pomočjo kriterija AUC</i>	<i>62</i>
5.3	PRILAGODITEV MODELOV KLASIFIKACIJE	63
5.4	ANALIZA OBČUTLJIVOSTI.....	67
5.5	SKLEPNA MISEL K ANALIZI REZULTATOV	69
6	SKLEP.....	71
7	POVZETEK.....	75
7.1	POVZETEK V SLOVENŠČINI.....	75
7.2	ABSTRACT IN ENGLISH	75

8	LITERATURA IN VIRI.....	77
8.1	LITERATURA	77
8.2	VIRI	81
9	SEZNAM OKRAJŠAV IN OZNAK.....	83
10	KAZALO SEZNAMOV	85
10.1	SEZNAM TABEL	85
10.2	SEZNAM SLIK	85
10.3	SEZNAM GRAFIKONOV	85
11	PRILOGE	87
11.1	PRILOGE K 4. POGLAVJU.....	87
11.1.1	<i>Priloga 1: Deskriptivna statistika prilagojenega vzorca</i>	<i>87</i>
11.1.2	<i>Priloga 2: Analiza manjkajočih podatkov pri posameznih spremenljivkah.....</i>	<i>88</i>
11.1.3	<i>Priloga 3: Kruskal-Wallis H-test za imputiran in neimputiran vzorec</i>	<i>89</i>
11.1.4	<i>Priloga 4: Računovodski kazalniki</i>	<i>90</i>
11.1.5	<i>Priloga 5: Proces izbora spremenljivk</i>	<i>94</i>
11.1.6	<i>Priloga 6: Deskriptivna statistika izbranih spremenljivk</i>	<i>95</i>
11.1.7	<i>Priloga 7: Korelacijska analiza</i>	<i>96</i>
11.1.8	<i>Priloga 8: Deskriptivna statistika izbranega vzorca in Kruskal-Wallis test.....</i>	<i>98</i>
11.2	PRILOGE K 5. POGLAVJU.....	99
11.2.1	<i>Priloga 9: Analiza spremenljivk posameznega modela</i>	<i>99</i>
11.2.2	<i>Priloga 10: Stroški pri uporabi modela</i>	<i>101</i>

1 UVOD

1.1 Opredelitev področja in opis problema

Zunanji revizor po opravljeni reviziji v revizijskem poročilu poda mnenje o računovodskih izkazih, na katerega se večkrat opira širša in ožja javnost. Investitorji na trgu kapitala so le ena skupina izmed zainteresiranih udeležencev, ki jih zanima, katero vrsto mnenja bo pridobilo podjetje¹, saj imajo v podjetju ali vložen kapital ali pa ga nameravajo vložiti. Odločitev zunanjega revizorja, katero vrsto mnenja bo podal, je odvisna od proučitve stanj, procesov, poročil, informacij itd. podjetja, ki so predmet revidiranja, in njegove presoje, ali je slednje prikazano na strokovno neoporečen, tj. na resničen in pošten, način. Po standardih se revizor lahko odloči med pozitivnim (pritrdilnim; angl. *Unqualified audit opinion*)² in več vrstami modificiranih mnenj (angl. *Modified audit opinion*), ki nakazujejo neko deviacijo od normalnega stanja v podjetju; v kolikor se odloči za modificirano mnenje (vzrok je npr. negotovost, nesoglasja z upravo organizacije, vrsta in kakovost revizijskih dokazov itd.), se nato na drugi stopnji odločitvenega procesa glede na vrsto in moč deviacije opredeli ali bo podal mnenje s pridržkom (angl. *Qualified audit opinion*) ali negativno mnenje³.

Mednarodni revizijski standardi od revizorjev zahtevajo, da se v revizijskem postopku presodijo podatki o organizaciji, ki so večinoma vrednostne/kvantitativne (npr. podatki iz izkazov itd.) in nevrednostne/kvalitativne oblike (npr. podatki o strategiji organizacije itd.), in se na tej podlagi oblikuje mnenje. Standardi navajajo nekatere napotke, ki usmerjajo k predvideni vrsti mnenja glede na ugotovljeno stanje v organizaciji, in možne (analitične) postopke, vendar je odločitev še vedno v rokah revizorja, ki se sicer odloča subjektivno in na podlagi lastnih izkušenj⁴. Nekateri raziskovalci so za namen identificiranja organizacije, katera naj bi si glede na izkazano stanje prislužila modificirano obliko mnenja (tj. katerokoli obliko modificiranega mnenja)⁵, razvili različne statistične modele z uporabo različnih regresijskih tehnik modeliranja, kot so npr. multipla diskriminantna analiza, logistična regresija itd. Enotnega mnenja, kateri razvit model je boljši in bi bil vsesplošno uporabljen, med raziskovalci ni. Vzrok je v prednostih in slabostih posameznega modela. Večina teh modelov je razvita s pozitivističnim pristopom, saj so raziskovalci pogosto razvili model na podlagi empiričnih podatkov⁶; medtem ko so modeli, kjer bi bila v ospredju predvsem teorija o reviziji, organizaciji, trgu ipd. zelo malo.

¹ V nalogi, ko govorimo o podaji mnenja revizorja gospodarski družbi, ne razlikujemo med pojmom družba in podjetje in uporabljamo pojem podjetje. Vendar opozarjamo, da s pravno-formalnega vidika je razlika in revizor izrazi mnenje o računovodskih izkazih in letnem poročilu družbe. Več o tem glej pod opombo številka 32.

² Med pritrdilna mnenja po Mednarodnih revizijskih standardih (angl. *IAS – International Auditing Standards*) prištevamo tudi pritrdilno mnenje, ki vsebuje zadeve, ki ne vplivajo na revizijsko mnenje. Takšno pozitivno mnenje vsebuje pojasnjevalni odstavek, ki opozori na kakšno zadevo (angl. *Emphasis of matter*), ki pa ne vpliva na spremembo revizijskega mnenja. Več o tem v poglavju 2.1.2 Vrste revizijskih poročil.

³ Pod negativno mnenje prištevamo zavrnitev mnenja (angl. *Disclaimer of opinion*) in odklonitev mnenja (angl. *Adverse opinion*). Več o tem v poglavju 2.1.2 Vrste revizijskih poročil.

⁴ Računovodski izkazi podjetja naj bi predstavljali resnično in pošteno sliko podjetja, vendar je dejstvo, da zunanji revizor z možnim vpogledom v celotno dokumentacijo podjetja lahko vidi več kot zunanji opazovalec (analitik) izkazov podjetja. S tem ostaja odprta možnost, da lahko revizor poda mnenje, ki glede na prikazano stanje v izkazih ni pričakovano s strani zunanjega analitika.

⁵ Velja tudi obratno, da se lahko s takšnimi modeli identificira organizacijo, ki bo prejela pozitivno (nemodificirano) mnenje.

⁶ Izbor potencialnih spremenljivk se je večinoma izvršil na podlagi intuicije, popularnosti preteklih študij in predikcijske uspešnosti spremenljivk/modelov v preteklih študijah. Več o tem v poglavju 2.5 Modeli za identificiranje vrste revizijskega mnenja.

Identifikacijska oz. predikcijska moč konstruiranega modela (za identifikacijo oz. napoved podjetij, ki (naj) prejmejo modificirano vrsto mnenja) je odvisna (predvsem) od uporabljenih spremenljivk v modelu. Z uporabo različnih kombinacij vhodnih spremenljivk so avtorji svojih modelov osamili nekatere ključne spremenljivke (večinoma so to vrednostni/kvantitativni računovodski kazalniki), katerim je pripisana večja pomembnost in večja pozornost v konstruiranem modelu. Ključ, po katerem so se raziskovalci odločali, je različen, in sicer od uporabe ugotovitev preteklih študij (npr. Altman (1968), Beaver (1966)), logike organizacijskega ipd. poslovanja, zmožnosti statističnih metod do naključnih izborov spremenljivk. V večini teh študij pa ni opredeljeno, ampak se implicitno predpostavlja, da je možno uporabiti računovodske (finančne) kazalnike⁷ in da imajo ti npr. izpovedno moč pri konstruiranju modela za identifikacijo vrste revizijskega mnenja.

Večina raziskovalcev je pri razvoju modelov imela za cilj (in s tem uporabnost osnovanega modela) identifikacijo podjetja, ki bo prejelo pozitivno mnenje, ali podjetja, ki bo prejelo modificirano mnenje. Kot glavno merilo so večinoma uporabili odstotek pravilno razvrščenih organizacij v skupino organizacij s pozitivnimi mnenji ali skupino organizacij z modificirani mnenji. Uspešnost modelov je zelo različna – po študijah variira od 60 pa tudi tja do 90 odstotne zmožnosti pravilne klasifikacije podjetij⁸. Vendar glede na usmerjenost oz. namenjeno uporabnost modela to ni vedno najboljše merilo. Pogosto namreč relativni stroški med napakama tipa 1 in 2⁹ niso enaki in, hipotetično gledano, ob uporabi modela lahko npr. pri napravljeni napaki tipa 2 (tj. podjetju, ki dejansko prejme modificirano mnenje, pripiše model nemodificirano/pozitivno mnenje) revizor utрпи večjo škodo kot ob napaki tipa 1 (tj. podjetju, ki dejansko prejme nemodificirano mnenje, model pripiše modificirano mnenje)¹⁰. Pričakovanja/želje revizorja (uporabnika modela) so posledično lahko usmerjene v minimizacijo možnih napačnih klasifikacij (napak tipa 1 in 2) in ne vedno v minimizacijo celotnih povprečnih stroškov.

1.2 Namen, cilji in osnovne trditve

Namen diplomskega dela je konstruirati model z uporabo običajnih oz. splošnih računovodskih kazalnikov in logistične regresije, ki bo omogočal identifikacijo vrste revizijskega mnenja. Zunanja revizija je namreč kompleksen proces in s pomočjo tako konstruiranega modela, osnovanega na javno dostopnih podatkih, je možno določiti in razložiti vzrok, zakaj neko podjetje prejme modificirano mnenje (vsebinska uporabnost modela). Zunanji revizor pa lahko model uporabi kot pripomoček pri usmeritvi v pripravljalni fazi revidiranja (npr. za določitev potrebnih resursov, občutljivih področij

⁷ Ker se finančni (angl. *financial ratios*) in računovodski kazalniki (angl. *accounting ratios*) delno prekrivajo v nalogi ne razlikujemo posebej finančnih in računovodskih kazalnikov, vendar kot navaja Turk (2002, 123 in 615) razlika med obema vrstama kazalnikov je, in sicer se finančni kazalniki uporabljajo pri odločanju na področju financ in se delno prekrivajo tudi z računovodskimi kazalniki, ki jih Turk opredeli kot kazalnike, ki temeljijo na računovodskih podatkih. V nalogi predstavljajo izhodišče računovodski izkazi/podatki družb, zato govorimo o računovodskih kazalnikih.

⁸ Variacije je možno razložiti z uporabo različnih velikosti vzorcev, njihove različne sestave, testiranja v različnih obdobjih, uporabe različnih kazalnikov ipd.

⁹ Napaka tipa 1 je, ko podjetje, ki bi moralo prejeti pozitivno mnenje, zaradi napake pridobi modificirano mnenje; napaka tipa 2 je, ko podjetje, ki bi moralo dobiti modificirano mnenje, pridobi pozitivno mnenje. Več o napakah in pripadajočih stroških v poglavju 3.2.1.2 Napaka tipa 1 in 2 in stroški napravljenih napak.

¹⁰ Absolutni stroški so težko merljivi, enako velja za relativne stroške, ki so znani le revizorjem samim oz. njihovim revizijskim hišam. Stroški se kažejo v obliki možnih tožb s strani strank, tudi javnosti, ob izgubah strank ipd. Več o stroških v poglavju 3.2.1.2 Napaka tipa 1 in 2 in stroški napravljenih napak.

ipd.) ali pri verifikaciji že sprejete odločitve glede vrste podanega mnenja (praktična uporabnost modela).

Cilji naloge, s katerimi želimo zadostiti predstavljenemu namenu, so:

1. Prikazati pomen oz. vlogo analitičnih postopkov in modelov za identifikacijo (napoved) vrste revizijskega mnenja v zunanji reviziji.
2. Konstruirati model na vzorcu podjetij iz podatkovne baze F.A.M.E.¹¹ in vanj vključiti računovodske kazalnike, ki so v nekaterih preteklih raziskavah pogosto uporabljeni in ki imajo osnovo tudi v teoretični razlagi (tj. vključeni so na podlagi nekega preteklega teoretičnega temeljnega znanja).
3. S pomočjo izbranih kriterijev za ocenjevanje modela ugotoviti uspešnost in ustreznost modela – tj. poizkusiti opredeliti, kakšna je identifikacijska zmožnost modela (angl. *performance*), zmožnost posplošitve modela (angl. *generalizability*) in kakšna stabilnost modela (angl. *robustness*) – in na podlagi izidov, če je potrebno, prilagoditi (kalibrirati) model, da bo omogočil optimalno uspešnost glede na izbrane uspešnostne kriterije.

Z obravnavo zastavljene problematike želimo potrditi naslednje trditve:

1. Z razvojem modela ugotoviti, da obstaja med klasičnimi računovodskimi kazalniki in različnimi vrstami revizijskih mnenj povezava oz. da na katerokoli vrsto revizijskega mnenja vplivajo računovodski kazalniki¹².
2. Z razvojem modela s pomočjo logistične regresije lahko izmed širšega nabora različnih spremenljivk z različnih področij poslovanja identificiramo oz. določimo ožji nabor spremenljivk (računovodskih kazalnikov), ki omogočijo identifikacijo predvidene vrste revizijskega mnenja.

1.3 Predpostavke in omejitve raziskave

V nalogi uporabimo več različnih metodologij in šele njihova kombinacija omogoči formiranje sklepne misli/zaključka. Za vsako izmed izbranih metod veljajo specifične predpostavke ter omejitve, ki so sproti predstavljene pri predstavitvi posamezne metode. V empiričnem delu naloge je za konstruiranje, ocenjevanje parametrov modela in ostalih izidov uporabljena logistična regresija, katere predpostavke predstavljamo v poglavju 3.1.2 Uporaba logistične regresije pri problemu klasifikacije. Poleg teh predpostavk še dodatno predpostavljamo, da:

- ima posamezen računovodski kazalnik informacijsko vsebino, ki predstavlja določen vidik podjetniškega stanja in/ali uspešnosti;
- da so podana mnenja revizorjev pravilna in da pri revizorjih ni prišlo do *trade-off* odločitev, kjer so se npr. revizorji po ugotovljenih izpolnjenih kriterijih za modificirano mnenje vseeno odločili za podelitev pritrdilnega mnenja (tj. ni kršeno načelo neodvisnosti in nepristranskosti);
- se v proučevanem obdobju standardi, zakonodaja in ostali napotki za revidiranje z vsebinskega vidika niso spremenili v takšnem obsegu, da bi spremembe vplivale na drugačno modifikacijo vrste revizijskega mnenja v istem proučevanem obdobju;

¹¹ Gre za podatkovno bazo (F.A.M.E. – *Financial Analysis Made Easy*), ki vključuje okoli 2,5 milijona javnih in privatnih podjetij iz Velike Britanije in Irske.

¹² Gre za razreševanje vprašanja, ali je možno iz računovodskih kazalnikov – tj. večinoma samo podatkov iz računovodskih izkazov – ugotoviti, katero vrsto revizijskega mnenja bo neko podjetje dobilo. Revizija je namreč tudi subjektiven proces, saj se v končni fazi odloča revizor sam in ni nujno, da izkazi podjetja izražajo sliko, ki jo vidi zunanji revizor po opravljeni reviziji. Glej tudi opombo pod številko 4.

- so pridobljeni podatki iz podatkovne baze F.A.M.E. verodostojni (tj. podatki iz računovodskih izkazov so preverljivi¹³) ter da je izbrani vzorec podjetij dovolj reprezentativen, da je raziskava sploh smiselna in da je možno konstruirati model preveriti;
- je v raziskavi uporabljena ustrezna metodologija ter da so za njeno uporabo izpolnjene vse potrebne predpostavke; identično predpostavljamo za uporabljena orodja ter da so ta uporabljena na pravilen način, s čimer se zagotovijo zanesljivi in objektivni rezultati raziskave.

Proučevano področje v nalogi je področje zunanje revizije. Zaradi omejene razpoložljivosti podatkov – tj. za večino podjetij v vzorcu nam niso dosegljiva celotna revizijska poročila, kar bi omogočilo natančno identifikacijo vzroka (ne)modifikacije mnenja, se omejujemo le na proučevanje odločitve podaje revizorja med pritrdilnim (nemodificiranim) in modificiranim mnenjem. Ker je namen naloge razvoj pripomočka/modela, ki naj bi bil v pomoč predvsem revizorjem, je v nalogi predstavljena problematika predvsem s perspektive/vidika revizorja.

1.4 Metode raziskovanja

Raziskava je poslovna in statična. Pri opredelitvi tematike in pojmov s področja revidiranja (2. poglavje) in pojmov ter v nalogi uporabljene metodologije (3. poglavje) je uporabljen deskriptivni način raziskovanja. Uporabljene so tehnike deskripcije, komparacije in kompilacije. Pri obdelavi podatkov, sestavi vzorcev, konstrukciji modela (4. poglavje) in izvedbi analize kazalnikov in posameznega modela ter analize občutljivosti (5. poglavje) je uporabljen analitični način raziskovanja (tj. indukcija kot tudi dedukcija v začetnih fazah sklepanja).

Osnovni podatki o metodologiji in s področja revidiranja so bili pridobljeni v osnovni literaturi; podrobnejši podatki pa v izbranih strokovnih in znanstvenih člankih. Gradivo za nalogo je bilo pridobljeno v različnih knjižnicah po Sloveniji, na internetu in po dosegljivih on-line bazah podatkov. Podatki o podjetjih so bili pridobljeni v specializirani podatkovni bazi F.A.M.E.

¹³ Podatki so preverljivi, če dva ali več posameznikov pri neodvisnem delovanju podata enak zaključek po opravljenem preverjanju o podatkih.

2 MNENJE REVIZORJA IN IDENTIFIKACIJSKI MODELI

2.1 Osnovne značilnosti zunanje revizije

Revizija računovodskih izkazov (angl. *Financial Statement Audit*)¹⁴ je opravilo posebnih gospodarskih strokovnjakov – tj. pooblaščenih revizorjev in/ali revizorjev – ki po naročilu lastnikov družbe, vrhovnega posloводства družbe ali drugih zainteresiranih oseb preizkušajo in ocenjujejo pravilnost in resničnost postopkov, stanj in drugih dejstev v računovodskih izkazih družb in drugih poslovnih oseb (Koletnik 2005, 169; IFAC 2005, 200 in 207). Pod takšno definicijo revizije izkazov se dejansko skriva veliko različnih aktivnosti, ki zahtevajo sistematičen proces objektivnega zbiranja in ocenjevanja pridobljenih dokazov o ekonomskih dejavnostih in dogodkih, da bi lahko podali mnenje o računovodskih izkazih oz. zagotovilo o tem, da so izkazi v vseh pogledih pripravljeni skladno z možnim računovodskim okvirom poročanja¹⁵ (IFAC 2005, 207).

Neizogibnost revizije izkazov družb¹⁶ je možno iskati v dejstvu, da je revizija letnih poročil družb in s tem računovodskih izkazov, dodatnih razkritij k izkazom in dela poslovnega poročila, ki se navezuje na izkaze in dodatna razkritja družb, pomembna pri delovanju nacionalnih in globalnih finančnih trgov. Stabilnost in transparentnost na finančnih trgih (in nasploh pri poslovanju med podjetji) sta namreč le dve pomembni komponenti, ki sta v interesu države in udeležencev na trgu. Problemi – tj. finančne prevare, poneverbe izkazov itd. – v zadnjih dveh desetletjih na področju poslovanja podjetij ter področju revizije so izpostavili nekatere probleme samega revizijskega procesa.

2.1.1 Namen in vloga revizijskega poročila

Dejstvo je, da veliko deležnikov (npr. lastniki, investitorji, posojilodajalci itd.), ki so tako ali drugače povezani s finančnim trgom in specifičnim subjektom na njem, zanima natančnost in objektivnost finančnega poslovanja in uspeha družbe¹⁷. Revizorji¹⁸, kot neodvisni in objektivni subjekti, so postavljeni v položaj, kjer nadzorujejo in kontrolirajo procese v družbah (Koskivaara 2004, 191). Revizija predstavlja obliko zunanjega nadzora v družbi in s tem zagotavlja zaščito interesov udeležencev finančnega trga pred napačnimi

¹⁴ Kot sinonim za izraz 'revizija računovodskih izkazov' se uporablja tudi izraz 'zunanja gospodarska revizija' in/ali izraz 'revizija letnega poročila'. Dejansko je pri reviziji računovodskih izkazov hkrati opravljena tudi revizija letnega poročila gospodarske družbe, dodatnih razkritij k računovodskim izkazom ter del poslovnega poročila, ki se navezuje na računovodske izkaze in dodatna razkritja družbe.

¹⁵ Mednarodni standardi revizije (odslej MSRev) so podvrženi podobno kot Mednarodni standardi računovodskega poročanja (odslej MSRP) nenehnim izboljšavam in posodobitvam. Razvoj MSRP-jev in njihova uporaba v Evropski uniji je povzročila večje spremembe tudi pri Mednarodnih standardih revidiranja. V nalogi bodo že nakazane spremembe in upoštevanji prenovljeni standardi, ki so že sprejeti in so ali pa še bodo stopili kmalu v praktično uporabo.

¹⁶ Revizija računovodskih izkazov/letnih poročil gospodarskih družb je neizogibna po večini nacionalnih zakonodaj, ki predpišejo obvezno revizijo računovodskih izkazov za družbe, ki so klasificirane po velikosti kot velike ali srednje ali s katerih vrednostnimi papirji se trguje na organiziranem trgu.

¹⁷ Udeleženci želijo imeti stalen ali vsaj občasen vpogled v položaj in uspeh gospodarske družbe. Pri tem mislimo na stanja in spremembe sredstev ter virov sredstev in na poslovno in finančno uspešnost (Koletnik 2005, 205). Zaradi obilice poslovnih dogodkov so interesantom potrebna redna letna poročila.

¹⁸ Pooblaščen oz. zunanji revizor je oseba, ki ni vključena v poslovne procesa in/ali stanja, ki so predmet revidiranja. Zaradi zahteve po kvalitetno opravljeni storitvi, kar je bistveno pri zagotavljanju zaupanja in verodostojnosti pri različnih strankah, nadzornikih in javnosti, mora revizor delovati v skladu s strokovnimi in poklicnoetičnimi načeli in standardi (Boynton in drugi 2001, 28-35), kot so npr. (i) pravila posamezne države (večinoma so pravila zapisana v različnih nacionalnih zakonih); (ii) pravila stroke (npr. revizijska načela Mednarodnega združenja računovodij (IFAC), Mednarodni standardi revidiranja, Mednarodna stališča o revidiranju ipd.) in (iii) interna pravila revizijske družbe in kakršnokoli dodatno izpopolnjevanje revizorjev itd.

in neresničnimi navedbami družb v svojih računovodskih izkazih in letnih poročilih. Brez opravljene revizije so udeleženci finančnega trga izpostavljeni informacijskemu tveganju¹⁹.

Nekateri dejavniki informacijskega tveganja in razlogi, zakaj si različni udeleženci želijo, da bi poseben strokovnjak izrazil mnenje o izkazih, so npr. konflikt različnih interesov med udeleženci, večje negativne posledice zaradi konfliktnih interesov, kompleksnost priprave izkazov in okvira računovodskega poročanja itd.²⁰ Na ravni podjetja, finančnega trga itd. namreč udeleženci reagirajo na informacije o uspešnosti družbe. Npr., če se pokaže vprašljiv obstoj nadaljnjega delovanja podjetja, sta že Altman (1969) in Beaver (1968) pokazala, da obstaja negativna reakcija trga, ki vpliva na vrednost delnice, ko se podjetje približuje bankrotu (Lensberg 2006, 678). Zanesljivost (tj. informacije so resnične in poštene) in bistvenost (tj. informacije imajo relativno visoko (uporabno) vrednost z vidika odločevalca) sta lastnosti informacij, ki jih uporabnik potrebuje pri gospodarskem odločanju in ki ju mora po Mednarodnih standardih računovodskega poročanja (odslej MSRP) zagotoviti vodstvo podjetja (glej 7. člen MRS 1 – podrobneje EC (2003, 11)). Vprašanje, ali je obstoj slednjih lastnosti informacij potrdil tudi revizor, je ključno za uporabnike poročil²¹ (Boynton in drugi 2001, 46-47).

Z vidika podjetja so prednosti revizije vidne predvsem v ekonomskih posledicah pri poslovanju (Boynton in drugi 2001, 47-48). Tako se na primer: (1) podjetju omogoči lažji dostop do finančnih trgov; (2) znižajo stroški kapitala (možnost lažjega najema kreditov po nižji obrestni meri; nižja zahtevana stopnja donosnosti s strani lastnikov); (3) vzpostavi se neka vrste obramba pred neučinkovitostjo in prevarami v podjetju – če zaposleni vedo, da bo opravljena revizija, so učinkovitejši in tudi nagnjenost k prevaram je nižja; podobno velja tudi za management; (4) v podjetju se izboljša nadzor in poslovni procesi – npr. na podlagi predlogov revizorjev se izboljšajo kontrolne točke, učinkovitost procesov itd.

Revizijsko poročilo, v katerem po opravljeni reviziji revizor izrazi mnenje o računovodskih izkazih revidirane družbe, ima v strokovni (podučeni) javnosti in med udeleženci finančnega trga večjo izrazno vrednost (tj. dodatno informacijsko vsebino, ki jo udeleženci trga želijo poznati) in uživa tudi večje zaupanje (Koletnik 2005, 170). Revizorjevo poročilo namreč vsebuje navedbo, ali izkazi družbe predstavljajo resnično in pošteno sliko družbe v skladu z možnim okvirom računovodskega poročanja (Boynton in drugi 2001, 5-8; IFAC 2005, 208).

2.1.2 Vrste revizijskih poročil

V revizijskem poročilu revizor izrazi mnenje o računovodskih izkazih podjetja, če ti predstavljajo resnično in pošteno sliko podjetja v vseh pogledih in če so v skladu z možnim

¹⁹ Pod izrazom 'informacijsko tveganje' pojmujeemo tveganje, da so računovodski izkazi in/ali letna poročila gospodarskih družb nepravilna, nepopolna, neresnična/ponarejena in/ali pristranska.

²⁰ Razloge za revizijo podrobneje prikažejo Boynton in drugi (2001, 46-47). Nekateri najpomembnejši med njimi so: (1) konflikt interesov – uporabniki izkazov so zaskrbljeni zaradi konfliktov interesov med njimi in upravo družbe (npr. strah zaradi pristranskosti managementa). Enako velja za razmerje med posojilodajalci in lastniki družbe. (2) Možne negativne posledice – računovodski izkazi so lahko edina in v večini primerov pomembna uporabljena informacija pri odločitvi o investiranju, kreditiranju itd. (3) Kompleksnost – proces priprave izkazov in izkazi so izredno kompleksni in z naraščanjem kompleksnosti poročanja, narašča tudi tveganje napačnih razumevanj in nenamernih napak. (4) Čas in stroški – razdalje, čas in stroški napravijo tudi najbolj večim uporabnikom izkazov proučevanje izkazov nepraktično, da bi iskali direktno po računovodskih zapisih in sami ocenjevali izkaze itd.

²¹ Revizija izkazov in ostalih informacij družbe povečuje kredibilnost teh izkazov in zmanjšuje informacijsko tveganje udeležencev na finančnem trgu.

načinom računovodskega poročanja. Glede na ugotovljeno nepravilnost v podjetju in jakost te deviacije pa so možne različne oblike mnenj in posledično revizijskih poročil.

Revizor lahko po MSRev 700 – Revizorjevo poročilo o računovodskih izkazih poda različne vrste poročil oz. izrazi različne vrste mnenj, kar prikazujemo v Tabeli 1 spodaj (IFAC 2005, 571-580, 594-596 in 604-609)²². V levem stolpcu tabele prikazujemo pogoje, katere lahko ugotovi revizor in kateri so predvideni po standardu. V glavi tabele (zgornja vrstica tabele) prikazujemo vrste revizijskih poročil in vrsto mnenja, ki je povezano s posameznim revizijskim poročilom. Zadeve/pogoji, ki vplivajo na revizorjevo mnenje in zaradi katerih revizor ne more podati nemodificiranega mnenja, so: (1) omejitve pri pridobivanju revizijskih dokazov in/ali (2) nesoglasja med upravo podjetja in revizorjem glede ustreznosti računovodskih usmeritev podjetja, uporabljenih metod/tehnika ali primernosti dodatnih razkritij v izkazih.

Tabela 1: Oblike poročil in vrste revizijskih mnenj

Vrsta poročila ►	Standardno revizijsko poročilo	Odmik od standardnega poročila			
		Standardno poročilo z razlagalnim odstavkom	Druge vrste poročil		
Vrsta mnenja ►	Nemodificirano mnenje	Nemodificirano mnenje	Modificirano mnenje	Odklonilno mnenje	Zavrnitev mnenja
Pogoji ▼	<i>Unqualified Opinion</i>	<i>Emphasis of Matter</i>	<i>Qualified Opinion</i>	<i>Adverse Opinion</i>	<i>Disclaimer of Opinion</i>
A Računovodski izkazi so usklajeni z možnim okvirom računovodskega poročanja, revizija opravljena v skladu z MSRev in:					
1 Pogoji, ki bi zahtevali razlagalni odstavek, ne obstajajo.	Da ¹				
2 Pogoji, ki zahtevajo razlagalni odstavek, so prisotni.		Da ²			
B Računovodski izkazi vsebujejo deviacije od možnega okvira računovodskega poročanja			Da ³ (materialne)	Da ⁴ (ekstremne materialne)	
C Revizor ne more pridobiti zadostnih dokazov			Da ³ (materialne)		Da ⁵ (materialne)

Opomba:

¹ Nemodificirano mnenje pomeni, da so izkazi resnični in pošteni in v vseh pogledih skladni z možnim okvirom računovodskega poročanja.

² Poročilo, ki vsebuje razlagalni odstavek, je še vedno v skladu z možnim okvirom računovodskega poročanja, vendar se pojavijo okoliščine, ki zahtevajo podajo dodatnega razlagalnega odstavka (npr. vzrok je lahko sprememba računovodske metode ipd.). Razlagalni odstavek pa ne vpliva na revizijsko mnenje.

³ Modificirano mnenje je podano v primeru, če ne more biti podano nemodificirano mnenje in da kakršnokoli nesoglasje z upravo ali kakršnokoli omejitve pri pridobivanju dokazov niso tako velike, da bi zahtevale odklonilno mnenje ali odklonitev mnenja.

⁴ Negativno mnenje je podano v primeru, ko izkazi niso pripravljeni v skladu z možnim okvirom računovodskega poročanja in ne prikazujejo resnične in poštene slike podjetja, temveč lahko izkazi vsebujejo nepopolne in zavajajoče informacije.

⁵ Revizor odkloni izdelavo mnenja v primeru, ko ne more pridobiti zadostnih in prepričljivih dokazov o izkazih podjetja in posledično ne more oblikovati mnenja o izkazih.

Vir podatkov:

Prirejeno po IFAC (2005, 571-610).

²² Trenutno je v veljavi še starejša verzija Mednarodnega standarda revidiranja 700 – Revizorjevo poročilo o računovodskih izkazih (ISA 700 – *The Auditor's Report on Financial Statements*), ki je v veljavi od 30.9.2002. Z letom 2007 stopi v veljavo prenovljena verzija standarda, ki se bo uporabljala od 31.12.2006 in ki je razdeljena na dva dela, in sicer na MSRev 700 – Neodvisno revizorjevo poročilo o računovodskih izkazih (ISA 700 (*Revised*) – *The Independent Auditor's Report on a Complete Set of General Purpose Financial Statements*) in MSRev 701 – Modifikacije neodvisnega revizorjevega poročila (ISA 701 – *Modifications to the Independent Auditor's Report*).

2.1.3 Razlogi za razvoj pripomočkov oz. modelov v reviziji

Obremenjenost revizorjev z veliko količino informacij, obsegom revizije, časovnimi in stroškovnimi omejitvami itd. so dejavniki, ki vplivajo na dejstvo, da revizorji potrebujejo orodja in metode, ki bi jih zalagale z objektivnimi informacijami o stranki (Bazerman 2002, 102). Eden izmed problemov revizorjev je tudi posluževanje revizorjev hitrejših postopkov testiranja z uporabo napačnih metod in/ali tehnik. Wilson in Page (1996; povzeto po Koskivaara 2000, 1060) sta razkrila, da so razlogi za slednje v: (1) proračunskem pritisku (61 %); (2) dolgočasnem delu (30 %) in/ali (3) nepomembnem delu (41 %). Le 22 % revizorjev je trdilo, da se ni nikoli poslužilo testiranja z uporabo napačne metode/tehnike. Po tej raziskavi so najpogostejše revizijske nepravilnosti naslednje: izločitev problematičnih transakcij iz vzorca (54 %); testiranje manj transakcij od poročenih (27 %); ali sprejem dvomljivega revizijskega dokaza (24 %). Čeprav so vprašanja revizorjem v raziskavi bila postavljena indirektno zaradi občutljive narave raziskave, rezultati podajo neko sliko (tudi dokaz, op.p.) o nepravilnostih v reviziji.

Različni avtorji so že razvijali modele oz. pripomočke z različnim namenom na revizijskem področju. Npr. Laitinen in Laitinen razvrščata predhodne raziskave razvoja modelov, ki identificirajo/klasificirajo vrsto revizijskega mnenja v tri kategorije (Laitinen in Laitinen 1998; povzeto po Gaganis in drugi 2006, 2): (1) v prvi skupini raziskav se uporabljajo informacije iz revizorjevega poročila za konstruiranje modelov za napoved bankrota podjetja; (2) druga skupina raziskav se ukvarja prav tako z bankrotom, in sicer konstruiranjem modelov za podajo modificiranega (kvalificiranega) mnenja glede vprašljivega nadaljnjega obstoja podjetja in (3) tretja skupina raziskav konstruira modele za razlago ali napoved (identifikacijo/klasifikacijo) modifikacije revizorjevega mnenja.

Glede na zastavljen namen in vsebino naloge lahko klasificiramo pričujočo raziskavo v tretjo skupino raziskav. Lahko pa se vprašamo – kar nekoliko nerodno vprašanje – zakaj bi s pripomočkom oz. modelom poskušali napovedati, katero vrsto mnenja bo oz. naj bi revizor podal v revizijskem poročilu? Gre za težavno vprašanje, na katerega je težko najti za vsakogar utemeljen odgovor. Verjetno lahko rečemo, da se ukvarjamo s problemom, kjer obstaja 'očiten' praktičen interes. Pojavi se dodatno vprašanje, kajti realni praktični problemi imajo večinoma možnih več rešitev ali vsaj navidezno možnih več rešitev. Zagotovo lahko trdimo, da nobeden odločitveni problem nima po naravi samo dihotomne dvostranske možnosti/odločitve, kot je modificirano proti nemodificiranemu (pozitivnem) mnenju revizorja in da obstaja več možnih ravni/stopenj rešitev. Vendar lahko rečemo, da je problem modificiranega proti nemodificiranemu mnenju groba (sprejemljiva) aproksimacija nekega hipotetičnega odločitvenega problema. Vodilo pri razvoju pripomočka/modela je, da se poskuša vzpostaviti relativno uporaben odločitveni model glede na razpoložljive podatke, trenutni vzpostavljen odločitveni proces revizorja in glede na alternativne obstoječe/poznane odločitvene modele.

Razvoj enostavnega pripomočka/modela, ki bi omogočil identifikacijo podjetij, ki bi prejela modificirano ali nemodificirano (pozitivno) mnenje, bi omogočil večjo gotovost revizorja pri podaji mnenja (kot pripomoček pri oblikovanju revizijskega mnenja) ali pri načrtovanju revizije (predhodno predvidevanje ter alokacijo resursov in aktivnosti) (Bell 1997, 249). Revizorjeva naloga oblikovati mnenje o izkazih je zahtevna in kompleksna naloga, ki se lahko olajša s pomočjo takšnega odločevalnega pripomočka oz. orodja in vzpostavitev novega odločitvenega modela glede vrste mnenja lahko zmanjša stroške

revizije in mogoče tudi zmanjša potrebo po specialistu za posamezno področje revizije. Dodatni revizijski napor na določenem področju, ki je izveden na podlagi sugestije modela, lahko tudi razkrije probleme, ki bi ostali drugače nezaznani oz. zakriti (McKeown in drugi 1991; povzeto po Lenard in drugi 2000, 881). Pretekle raziskave so tudi nakazale, da revizorji v določenih situacijah vidijo lastne odločitve in lastno podobo pozitivneje, če uporabljajo računalniško (matematično) podprte modele/pripomočke za odločitev glede podeljenega revizijskega mnenja (Lenard in drugi 1998; povzeto po Lenard in drugi 2000, 881).

Druge oblike uporabe revizijskega modela s strani revizorja so lahko tudi za ocenjevanje potencialnih strank ali kot za primerjalno vrednost, ki predstavlja verjetnost, da bo revizor podal modificirano revizijsko mnenje za proučevano podjetje. Primerjalna ocena bi bila koristna tudi pri verifikaciji ali pri sodnih primerih, ko so pod vprašanjem revizorjeva neodvisnost in njegova strokovnost (gre za vprašanje velike malomarnosti revizorja). Raziskovalci lahko uporabijo model tudi kot približek za investitorjeva pričakovanja, katero vrsto mnenja bo podal revizor (Dupoch 1987, 431; Ireland 2003, 979; Koh in Killough 1990, 189).

2.2 Proces revidiranja računovodskih izkazov

Revizor za pridobitev dokazov, na podlagi katerih lahko oblikuje mnenje o računovodskih izkazih, izvaja različne revizijske postopke. Gre za uporabo različnih metod in izvedbo različnih aktivnosti s strani revizorja med revizijo. Revizijski proces, ki obsega planiranje, testiranje in končno verifikacijo narejenega, obsega revizijske postopke, ki vključujejo različne aktivnosti kot npr. preštevanje denarja, inventurne preglede itd. (Boynton in drugi 2001, 57). Namen izvajanja revizijskih postopkov je v pridobitvi dodatnih spoznanj in dokazov (Boynton in drugi 2001, 178-179): (1) o poslovanju revidirane stranke s pomočjo nadrobnih testiranj in generalnih testov (angl. *substantive tests*) in (2) o kontrolah s testiranjem kontrol.

Od revizorja se ne pričakuje ali zahteva, da bo imel absolutno natančne osnove za podajo mnenja. Zahteva po razumni/sprejemljivi osnovi se nanaša na stopnjo zagotovila, ki jo potrebuje revizor po zaključeni reviziji, da lahko izrazi mnenje o računovodskih izkazih. Za zadovoljivo osnovo za mnenje o računovodskih izkazih pa je potrebna prevlada izstopajočih ugotovitev oz. dokazov, ki so ključni. Kajti, če revizor ne zbere dovolj zadostnih dokazov za nemodificirano mnenje, potem naj poda modificirano mnenje ali negativno mnenje (IFAC 2005, 575 in 588; Boynton in drugi 2001, 180-181).

Vedeti moramo, da ročno revidiranje ali revidiranje velike količine podatkov praktično ni več mogoče; izjema so lahko le zelo majhna podjetja. Prav tako je hitrost, s katero nastajajo informacije, ki morajo biti revidirane, tako visoka, da se posameznik (tj. uporabnik informacij, op.p.) upravičeno lahko sprašuje, ali so relevantne informacije sploh zanesljive in resnično pravilno revidirane (Koskivaara 2004, 191). Revizija tako večkrat ne pokrije vseh možnih razpoložljivih podatkov popolnoma in v vseh podrobnostih. Naloga revizorja, da oceni, ali so izkazi brez napak, je težka brez primernih orodij oz. testov. Možnost ocenjevanja podatkov podajo standardi s pomočjo ti. analitičnih postopkov (angl. *analytical procedures*), ki so procesi za oceno natančnosti in pravilnosti izkazov brez natančnega proučevanja individualnih transakcij, ki tvorijo končno vsoto računa (Knechel 1986; povzeto po Koskivaara 2000, 1060). Prednost uporabe tehnik analitičnih postopkov

je v povečani objektivnosti revizijskih testov (Lev 1980; povzeto po Koskivaara 2000, 1060), kar pomeni, da je odločitev kako in v kakšnem obsegu opraviti nadaljnja testiranja, narejena bolj objektivno in manj intuitivno. Vrste metod in tehnik, ki so možne v okviru analitičnih postopkov, so podane v nadaljevanju naloge, vendar zaradi koherentnosti naloge za poglavjem, ki podaja natančno definicijo analitičnih postopkov, možna področja uporabe in nekatere dejavnike, ki vplivajo na uporabo analitičnih postopkov.


2.2.1 Analitični postopki

Vloga različnih (analitičnih) postopkov v reviziji je v pridobivanju (analitičnih) revizijskih dokazov in pod okrilje (analitičnih) postopkov pojmuje različne (analitične) procese. Veliko različnih metod in tehnik je lahko uporabljenih v postopku analitičnih procesov. Z analitičnimi postopki (angl. *analytical procedures*) so mišljene analize in primerjave razmerij med podatki. Ti postopki vključujejo kalkulacije in uporabo preprostih kazalnikov, vertikalnih analiz ali izkazov pogostih velikosti, primerjave dejanskih vrednosti s preteklimi ali prihodnjimi vrednostmi in tudi uporabo matematičnih in statističnih modelov, kot je npr. regresijska analiza. Slednje lahko vključuje uporabo računovodskih podatkov kot tudi neračunovodskih podatkov (npr. število zaposlenih). Analitični postopki velikokrat vključujejo meritve podjetniških aktivnosti in operacij ter primerjavo meril ključnih ekonomskih indikatorjev s povezanimi poslovnimi rezultati/izidi. Analitični postopki so pogosto uporabljeni pri revizijskem pristopu od zgoraj navzdol za razvoj pričakovanj glede postavk v računovodskih izkazih in za oceno upravičenosti (angl. *reasonableness*) postavk v računovodskih izkazih (Boynton in drugi 2001, 204).

MSRev 520 – Analitični postopki (ISA 520 – *Analytical Procedures*) definira analitične postopke kot »ocenjevanje računovodskih (tudi finančnih, op.p.) informacij pridobljenih z analizo možnih razmerij med računovodskimi in neračunovodskimi podatki (tudi finančnimi in nefinančnimi podatki, op.p.)« (IFAC 2005, 464). Gre za uporabo primerjav in razmerij za oceno ali je račun (izkaz) izravnal in ali so ostali podatki logični. Takšni postopki vključujejo vse od enostavne primerjave do uporabe kompleksnih matematičnih in statističnih modelov, ki vključujejo več razmerij in podatkov (IFAC 2005, 464; Boynton in drugi 2001, 255-256). Prav tako se v okviru analitičnih postopkov lotimo raziskovanja identificiranih fluktuacij in razmerij, ki so nekonsistentne z relevantnimi informacijami ali pa se te signifikantno odklanjajo od napovedanih vrednosti. Revizorjeva odločitev za analitične postopke, metodo in stopnjo njihove aplikacije je stvar njegove profesionalne (strokovne) presoje (IFAC 2005, 464).

S pomočjo analitičnih postopkov lahko revizor pridobi (dodatne) analitične dokaze/evidence, ki jih uporabi pri formulaciji mnenja o računovodskih izkazih revidiranega podjetja. Proces pridobitve takšnih dokazov prikazujemo z odločitvenim diagramom spodaj (glej Sliko 1), ki nakazuje, da je možno v proces revizije vključiti tako razpoložljive analitične dokaze kot tiste, ki so pridobljeni s pomočjo analitičnih postopkov. Prav tako bo revizor, kjer je to primerno in praktično, uporabil eksterno pridobljene dokaze kot tudi interni dokazni material. Termina eksterno in interno povezujemo z dokazi, ki jih je neodvisno pridobil revizor sam in dokazi kreiranimi znotraj podjetja (Koskivaara 2004, 192).

Slika 1: Diagram poteka analitičnih postopkov



Vir podatkov: Woolf (1994; povzeto po Koskivaara 2004, 193).

V reviziji se analitični postopki uporabljajo za naslednje namene oz. v fazah planiranja, testiranja in verifikacije revizije (IFAC 2005, 465-469; Boynton in drugi 2001, 256):

- (1) v fazi planiranja revizije (angl. *risk assessment procedures*) – kot pripomoček, ki revizorju pomaga pri ocenjevanju tveganja in spoznavanju podjetja, njegovega poslovanja in okolja. Rezultati se uporabijo za planiranje obsega, časa in vsebine posameznih revizijskih postopkov. Uporaba analitičnih postopkov lahko nakaže različne vidike podjetja, katerih se revizor pred tem ni zavedal in mu pomaga pri ocenitvi tveganja napačnih navedb v izkazih oz. identifikaciji neobičajnih razmerij in nepričakovanih fluktuacij v podatkih, ki lahko nakažejo področja večjega tveganja napačnih navedb.²³ Slednje je večkrat opisano kot cilj analitičnih postopkov z namenom opozorila in nadaljnje napotitve;
- (2) v fazi testiranja (angl. *substantive procedures*) – kot osnovni test za pridobitev dokaznega gradiva o določenih navedbah povezanih s posameznimi računi ali transakcijami. Sama njihova uporaba je lahko učinkovitejša in uspešnejša od nadrobnejših testov pri zmanjševanju tveganja napačnih navedb v izkazih;

²³ Dodatne napotke o uporabi analitičnih postopkov pri ocenitvi tveganja navaja tudi standard MSRev 315 – Razumevanje podjetja in njegovega okolja in ocena tveganj napačnih navedb (ISA 315 – *Understanding the Entity and Its Environment and Assessing the Risk of Material Misstatement*) v 10. odstavku.

- (3) v fazi zaključka revizije (angl. *overall review*) – pri zadnjem pregledu celotne sprejemljivosti revidiranih računovodskih izkazov. Po standardu mora revizor uporabiti analitične postopke na koncu ali blizu konca revizije, ko oblikuje končno mnenje ali so izkazi kot celota konsistentni z revizorjevim pogledom/razumevanjem podjetja. Takšni zaključki so namenjeni podprtju zaključkov individualnih delov revizije in kot pripomoček pri oblikovanju mnenja. Lahko seveda prepoznajo tudi predhodne nezaznano tveganje napačnih navedb. V takšnih primerih mora revizor ponovno oceniti planirane revizijske procese.

Prva in tretja uporaba je potrebna/obvezna pri reviziji računovodskih izkazov. Druga uporaba je neobvezna, vendar strokovnjaki priporočajo konstruiranje analitičnih modelov in uporabo postopkov, da bi pridobili dokazno gradivo o navedbah na računu ali v povezavi s transakcijami. Odločitev, katere revizijske postopke uporabiti (ali posamezne nadrobne teste ali analitične postopke), da bi dosegli določen revizijski cilj, je odvisna od revizorjeve presoje o pričakovani uspešnosti in učinkovitosti razpoložljivih revizijskih postopkov in v zmanjševanju tveganja napačnih navedb na dovolj nizko raven (IFAC 2005, 465). Boynton in drugi (2001, 256) navajajo, da so analitični postopki običajno zelo stroškovno učinkovit (angl. *cost-effective*) pripomoček in drugič, da zagotavljajo uravnoteženost med pristopom od zgoraj navzdol in spodaj navzgor²⁴.

Pri konstruiranju in uporabi analitičnih postopkov kot osnovnih postopkov testiranja (angl. *substantive procedures*) mora revizor upoštevati različne dejavnike, kot so: (1) primernost uporabe analitičnih postopkov; (2) zanesljivost podatkov (internih/eksternih), iz katerih so osnovana pričakovanja; (3) natančnost pričakovanj pri identifikaciji napačnih navedb na določeni stopnji gotovosti; (4) meje sprejemljivosti razlik dejanskih rezultatov od pričakovanih. Podrobnejše napotke pri ocenjevanju dejavnikov podaja MSRev 520 v odstavkih od 12 do 12g (IFAC 2005, 466-469).

2.2.2 Vrste metod in tehnik pri uporabi analitičnih postopkov

Analitični postopki uporabljajo metode in tehnike, ki omogočajo izboljšanje uspešnosti revizije in razvoj revizorjevih lastnih pričakovanj ter primerjavo teh s knjižbami podjetja. Uporaba analitičnih postopkov omogoči testiranje pravilnosti računovodskih izkazov (posredno letnega poročila, op.p.), ne da bi proučevali individualne transakcije, ki sestavljajo računovodske izkaze. S tem igrajo analitični postopki pomembno vlogo v pomoč revizorju in pri oblikovanju narave (poteka), časa in obsega subjektivnega testiranja posameznega podjetja; ter pri oblikovanju končnega mnenja glede na upravičenost/razumnost in logičnost zapisanih vrednosti knjižb. V osnovi analitični postopki omogočajo primerjavo pričakovanih razmerij med podatki z dejansko zasledenimi razmerji (Koskivaara 2004, 193).

Pomemben del pri uporabi analitičnih postopkov je izbira najprimernejšega analitičnega postopka. Obstaja pet glavnih vrst analitičnih postopkov (Arens 2003; povzeto po Koskivaara 2004, 193) na področju primerjave stranke in: (1) industrijskih podatkov; (2) preteklih podatkov stranke; (3) napovedi stranke; (4) revizorjevih pričakovanj; (5) pričakovanih izidov z uporabo neračunovodskih/nefinančnih informacij.

²⁴ Pristop od zgoraj navzdol (angl. *top-down*) pomeni najprej proučevanje izkazov in nato posameznih transakcij in postavk izkazov; pristop od spodaj navzgor (angl. *bottom-up*) pomeni najprej proučevanje posameznih transakcij in postavk izkazov in na koncu računovodskih izkazov.

Kompleksnost in obseg uporabljenih analitičnih postopkov je odvisna od velikosti in kompleksnosti revidiranega podjetja, razpoložljivosti podatkov in revizorjeve subjektivne odločitve o uporabi analitičnih postopkov. Vrste možnih metod in tehnik, ki so vključene v analitične postopke, so po težavnosti lahko najlažji pregledi oz. primerjave (absolutnih podatkov podjetja, odstotkov, raznih kazalnikov, analize trenda) do uporabe zapletenih statističnih metod/tehnik in tudi do uporabe tehnik za kopanje po podatkih (angl. *data-mining methods*) (npr. nevronske mreže, genetsko programiranje itd.). Običajno je v praksi posebej pomembna primerjava računovodskih/finančnih informacij z relevantnimi neračunovodskimi/nefinančnimi informacijami (Boynton in drugi 2001, 255). Neračunovodski/nefinančni podatki kot je npr. število zaposlenih, kvadratna površina prostora, število proizvodov ipd. so lahko uporabljeni pri ocenjevanju povezanih računovodskih računov kot npr. izplačilo plač, prodaje, stroški proizvodnje proizvodov ipd. Neračunovodske/nefinančne informacije so lahko pomembno merilo temeljnih ekonomskih aktivnosti, ki omogočijo poslovne rezultate.

Ker imajo omenjene tehnike razpon od nekvantitativnih do kompleksnih kvantitativnih tehnik, so analitični postopki med seboj zelo različni v zmožnosti identifikacije možnih odklonov oz. napačnih navedb (angl. *misstatements*). Tehnika ocenjevanja je sestavljena iz subjektivnih ocen, osnovanih na znanju o stranki in preteklih izkušnjah. Analiza trenda ocenjuje ali je prisotno funkcionalno razmerje med variablami v različnih obdobjih. Analiza kazalnikov direktno proučuje pričakovano razmerje med dvema ali več spremenljivkami oz. kazalniki. Čeprav so kazalniki enostavni za izračun, kar delno razloži njihovo široko uporabo, je lahko njihova interpretacija problematična, še posebej če dva ali več kazalnikov nakazujejo različne (konfliktne) signale. Analiza kazalnikov je večkrat kritizirana zaradi subjektivnosti, npr. revizor sam izbere in opredeli kazalnike, ki jih želi uporabiti pri oceni poslovanja stranke. Pri najpreprostejšem testu logičnosti/upravičenosti je pričakovan končni izid določen z referenco do podatka delno ali popolnoma neodvisno od računovodskega informacijskega sistema in zaradi tega razloga je končni izid oz. dokaz pridobljen z aplikacijo takšnega testa lahko bolj zanesljiv kot dokaz pridobljen z analitičnimi postopki (Koskivaara 2004, 195). Kvantitativno zahtevnejša regresijska analiza napoveduje/oceni računovodske in finančne podatke z vključitvijo ekonomskih in okoljskih faktorjev/dejavnikov v konstruiran model. Npr. tehnika nevronske mreže omogoča povezovanje velike količine vhodnih podatkov v kompleksen sistem, ki pa ima zmožnost učenja na videnih primerih in nadaljnje uporabe na novih še ne videnih podatkovnih primerih.

Zaradi zahtev po gospodarni, učinkoviti in uspešno izvedeni reviziji ni potrebno posebej izpostavljati, da revizorji potrebujejo orodja in metode, ki jim bodo zagotovile objektivne informacije o stranki in njenem podjetju (Willet in Page 1996; Lee 2002; povzeto po Koskivaara 2004, 192; Bazerman in drugi 2002, 102). Vendar mora revizor pri uvedbi nekaj novih orodij/postopkov/tehnik vedno odgovoriti na nekatera ključna vprašanja (Metaxiotis in Psarras 2004, 230): (1) ali lahko nova tehnika, postopek itd. pomaga pri odločitvenih procesih revizorja; (2) ali že obstajajo uspešni pretekli dokazi o tem in (3) ali je to praktična rešitev ali pa samo 'akademski oz. teoretični mit'? Razvoj zahtevnejših revizijskih orodij je nedvoumno lahko ena izmed alternativnih rešitev, ki lahko omogoči boljšo izvedbo revizijskega procesa, stroškovno učinkovitejšo in tudi uspešnejšo izvedbo. Prav tako lahko na enostaven način preprečujejo podjetjem, da manipulirajo z vrednostmi v izkazih.

2.3 Dejavniki, ki vplivajo na proces revizije in mnenje revizorja

Revizija je storitev, ki jo opravljajo specializirane osebe in za katero se po opravljeni storitvi pričakuje/zahteva protiplačilo. Ker gre za storitev, ki je tržno naravnana in katere ceno vsaj delno določa konkurenca na trgu, se pojavljajo tudi nekatere omejitve, s katerimi se sreča revizor. Tako je osnovna omejitev ta, da revizor opravi svojo storitev v okviru restriktivnih ekonomskih meja. Neločljivi omejitvi od slednje sta (Boynton in drugi 2001, 49): (1) razumna/sprejemljiva višina stroškov (angl. *reasonable costs*) – omejitev, ki vpliva na selektivno testiranje in/ali vzorčenje podatkov in (2) razumno omejen čas za revizijo (angl. *reasonable length of time*) – časovna omejitev²⁵, ki vpliva na količino dokazov, ki jih lahko revizor v tem času pridobi.

Obnašanje in delovanje revizorja in dejavnike, ki neposredno ali posredno vplivajo nanj in na njegovo obnašanje, so proučevali že različni avtorji. Ker so večinoma bili cilji teh raziskav različni in so nekatere raziskave bile omejene s predpostavkami, brez predhodnega preverjanja vsesplošna generalizacija posameznih spoznanj oz. ugotovitev ni mogoča. Vendar to ni cilj naloge, zato bomo v nadaljevanju v obliki tabele podali le kratek pregled nekaterih raziskav in njihove najpomembnejše ugotovitve.

Tabela 2: Dejavniki, ki vplivajo na revizorja

Avtorji raziskave	Leto objave	Predmet raziskave	Ugotovitve
1	2	3	4
1.	Dupoch in drugi	1987	Proučevanje možnosti razvoja modela za napoved vrste revizijskega mnenja
2.	Dupoch in drugi	1986	Proučevanje vpliva razkritij medijev o modifikaciji mnenja v podjetju
3.	Lee in drugi	2005	Proučevanje izpovedne moči različnih kazalnikov pri modifikaciji revizijskega mnenja zaradi vprašljivega nadaljnjega delovanja podjetja
4.	Mutcher in drugi	1997	Proučevanje dejavnikov v primeru podaje modificiranega revizijskega mnenja za primer vprašljivega nadaljevanje poslovanja podjetja

(Nadaljevanje na naslednji strani.) ▼

²⁵ Časovna omejitev je večkrat navedena tudi v zakonih, kjer morajo uprave gospodarskih družb predložiti revidirana letna poročila nadzornim svetom v z zakonom določenem časovnem roku. V Sloveniji je slednje urejeno z Zakonom o gospodarskih družbah (glej 57. člen). Več o tem glej Kocbek in Prelič (2006, 209-210).

1	2	3	4
5.	LaSalle in drugi	1996	Proučevanje odločitev revizorjev med podajo odklonilnega mnenja in zavrnitvijo podaje mnenja ► Podjetja, ki prejmejo modificirano mnenje, imajo ponavadi več slabih novic v medijih, manj dobrih novic in slabšo kakovost notranjih kontrol (ustroja notranjih kontrol, op.p.) v primerjavi s podjetji, ki prejmejo nemodificirano mnenje.
6.	Bazerman in drugi	2002	Proučevanje dejavnikov, ki vplivajo na pristransko odločitev revizorja in proučevanje pojava pristranskosti ► Problem za revizorje predstavlja nezavedna pristranskost pri odločanju v korist stranke. Dodatno je pristranskost problem v primerih, ko: (1) je možno informacijo interpretirati na več različnih načinov; (2) prihaja do prevelike navezanosti na stranko in preveč prijateljskih odnosov; (3) obstaja preveliko odobravanje pri napačnih odločitvah glede računovodenja v podjetjih; (4) obstaja osebno poznanstvo stranke; (5) pri velikem časovnem zamiku/pritisku ob napačnih odločitvah revizorji te večkrat rajši prikrijejo kot razkrijejo; (6) v primeru slabega mnenja prihaja večkrat do zavlačevanja s podajo mnenja itd. ► Revizorji se večkrat rajši zanesejo na strankine številke, mnenja in ugotovitve, kot pa da bi do teh prišli sami. ► Samo namig o hipotetičnem razmerju s stranko večkrat zamegli revizorjevo odločitev in jo napravi pristransko.
7.	Ireland	2003	Proučevanje dejavnikov revizijskih poročil ► Podjetja s slabim likvidnim stanjem, višjim finančnim tveganjem, podjetja, ki poročajo o pomembnih odloženih obveznostih in podjetja, ki ne izplačujejo dividend, so podjetja z višjo verjetnostjo možne modifikacije mnenja kot ostala podjetja na področju Velike Britanije. ► Nekatere variable so pomembne pri odločitvi za eno vrsto mnenja, ni pa nujno, da so te variable pomembne tudi pri odločitvi za drugo vrsto mnenja.
8.	Krishnan in Krishnan	1996	Proučevanje hipoteze kompetentnosti revizorja in hipoteze neodvisnosti revizorja ► Proces podaje revizijskega mnenja je dvostopenjski proces: na prvi stopnji se na podlagi revizijskih dokazov in opravljene revizije revizor opredeli, katero revizijsko mnenje je ustrezno in nato se na drugi stopnji odloči, ali bo takšno mnenje tudi podano stranki. ► Odločitev o vrsti revizijskega mnenja vključuje ekonomsko <i>trade-off</i> odločitev revizorja. Pomembni dejavniki so: (1) pravno tveganje, (2) delež zunanega lastništva v revidiranem podjetju, (3) relativna pomembnost revidirane stranke v portfelju revizorja in (4) predvidena prihodnja rast podjetja. ► Velikost podjetja je pomembna pri vprašanju, ali podeliti modificirano mnenje.
9.	Hopwood in drugi	1987	Proučevanje povezave med revizijskim poročilom in bankrotom podjetja ► Z uporabo računovodskih in tržnih podatkov je možno razviti model, kjer imajo te variable neko razlagalno moč in ki nakazuje povezavo med različnimi vrstami revizijskih mnenj in bankrotom podjetja. ► Možnost podaje napačnega mnenja (tj. revizijske napake) podjetju vpliva na odločanje revizorja in s tem povezane stroške.
10.	Menon in Schwartz	1987	Proučevanje hipoteze kompetentnosti revizorja in hipoteze neodvisnosti revizorja ► Podjetja, ki so v finančnem neravnovesju in ki prejmejo modificirano mnenje, so v korelaciji z variablami iz računovodskih izkazov. ► Poleg računovodskih kazalnikov vplivajo na podajo modificiranega mnenja tudi drugi dejavniki – npr. informacije o strankah, njihovem poslovnem okolju, industriji, konkurentih itd.
11.	Barnes	2004	Proučevanje pogajanj in stroškov, ki jih lahko utrpijo revizorji z napačnimi odločitvami ► Pogajanja revizorja in stranke igrajo pomembno vlogo v razmerju med revizorjem in stranko. Npr. stranka in revizor se poizkušata dogovoriti o možnosti spremembe računovodske metode, če je ta sporna. ► Povečana relativna pogajalska moč revizorja lahko vodi do dejstva, da poskuša stranka revizorja zavesti.

Vir podatkov: Barnes (2004), Bazerman in drugi (2002), Dupoch in drugi (1987; 1986), Hopwood in drugi (1987), Ireland (2003), Krishnan in Krishnan (1996), LaSalle in drugi (1996), Lee in drugi (2005), Menon in Schwartz (1987) in Mutcher in drugi (1997).

2.4 Tveganje revizorja

V standardnem revizijskem poročilu po opravljeni reviziji revizor poda zagotovilo z določeno gotovostjo, da revidirani računovodski izkazi ne vsebujejo navedb, ki so pomembno napačne. Ker pa ne more v popolnosti zagotoviti, da so računovodski izkazi brez napačnih navedb, je določena stopnja tveganja, da so napačne navedbe ostale

nezaznane, vedno prisotna. Pomemben dejavnik pri tem je, ali je napačna navedba pomembno²⁶ napačna in izkrivlja premoženjsko-finančno sliko in uspešnost podjetja. Standard MSRev 200 v 14. členu definira revizijsko tveganje kot tveganje, da » [...] revizor ne-bo podal modificiranega revizijskega mnenja o računovodskih izkazih, kjer so navedbe v izkazih pomembno napačne«²⁷.

Splošno sprejet revizijski model tveganja (angl. *Audit risk model*), ki omogoči ovrednotenje tveganja, je odvisen od tveganja pri delovanju (angl. *inherent risk*), tveganja pri kontroliranju (angl. *control risk*) in tveganja pri odkrivanju (angl. *detection risk*)²⁸. Če revizor poda zagotovilo z 99 % gotovostjo, da izkazi ne vsebujejo pomembno napačnih navedb, potem je revizijsko tveganje 1 %. V primeru različnih uporabljenih revizijskih postopkov, ki jih izberejo revizorji, je pomembna zadnja komponenta revizijskega tveganja – tj. tveganje pri odkrivanju, da revizorjevi postopki preizkušanja podatkov ne bodo zaznali/odkrili napačne navedbe pri saldu na kontu ali vrsti poslov, ki je posamično ali v povezavi z napačnimi navedbami pri drugih saldih ali vrstah poslov lahko pomembna (IFAC 2005, 205; Koletnik 2005, 229). Takšno tveganje pri odkrivanju je funkcija uspešnosti revizijskih postopkov in pripomočkov, ki jih uporabi revizor.

Razmerje med posameznimi uporabljenimi revizijskimi postopki in tveganjem pri delovanju pa pomeni (ne)posredno razmerje tudi z uporabljenimi analitičnimi postopki. V MSRev 315 in MSRev 520²⁹, ki obravnavata tveganje revizorja in analitične postopke, se zato predlaga razširjen splošni model revizijskega tveganja, ki vsebuje dodatni komponenti tveganja pri analitičnem preiskovanju (angl. *analytical procedured risk*) in tveganja pri podrobnem testiranju (angl. *test of details risk*). Tveganje pri analitičnem raziskovanju vsebuje oceno revizorja glede izbora neprimerne/nepravilne revizijske metode, tehnike in/ali postopka, napačne uporabe primerne revizijske metode, tehnike in/ali postopka ter možne napačne interpretacije revizijskih rezultatov (IFAC 2005, 205). Tveganje namreč ni mogoče odpraviti v popolnosti, ker revizor ne preizkuša vseh razpoložljivih stanj, transakcij, razkritij, ostalih dogodkov in ostalih z revizijo povezanih dejavnikov. Z razširjenim revizijskim modelom je revizorju zagotovljeno orodje, ki omogoči podajo zagotovila ob uporabi analitičnih postopkov.

2.5 Modeli za identificiranje vrste revizijskega mnenja

V literaturi preteklih dveh desetletij je možno zaslediti več različnih poizkusov konstruiranja modelov, ki so povezani z identifikacijo različnih vrst revizijskih mnenj. Enega izmed prvih modelov so osnovali Dupoch in drugi (1987) in z njim poizkusili napovedati/uganiti vrsto podanega revizijskega mnenja na podlagi računovodskih/finančnih in tržnih podatkov, ki so javno dostopni. Pri tem so se opirali tudi na ugotovitve predhodnih raziskav avtorjev Kida (1980), Mutchler in drugi (1985) in Menon in Schwartz (1987), ki so razvili modele za identifikacijo vrste revizijskega mnenja v primeru vprašljivega nadaljnjega delovanja podjetja (angl. *going concern status*). Podobno kot

²⁶ Več o pomembnosti v MSRev 320 (ISA 320 – *Audit Materiality*) (IFAC 2005, 398-402).

²⁷ Glej MSRev 200 (ISA 200 – *Objective and General Principles Governing an Audit of Financial Statements*) (IFAC 2005, 202-206 in 211-214).

²⁸ Za podrobnejšo razlago o tveganjih in dejavnikih glej 20. do 23. člen MSRev 200 (IFAC 2005, 204-206), Boynton in drugi (2001, 172-175 in 292-310) in Koletnik (2005, 226-231). Matematično je ovrednoteno tveganje v preprostem revizijskem modelu tveganja enako produktu posameznih komponent tveganja.

²⁹ Glej MSRev 315 (ISA 315 – *Understanding the Entity and Its Environment and Assessing the Risks of Material Misstatement*) in MSRev 520 (ISA 520 – *Analytical Procedures*) (IFAC 2005, 349-397 in 463-470).

Dupoch in drugi (1987) so Keasey in drugi (1988) razvili model za identifikacijo vrste revizijskega mnenja za majhna podjetja (Gaganis in drugi 2006, 2); Krishnan in Krishnan (1996) sta vključila v model tudi revizorjev odločitveni proces pri odločitvi glede vrste mnenja; Laitinen in Laitinen (1998) sta razvila model za identifikacijo vrste revizijskega mnenja za velika podjetja na Finskem (Gaganis in drugi 2006, 2).

Omenjene raziskave/modeli temeljijo na klasičnih statističnih tehnikah (diskriminantna analiza, logistična regresija itd.). Tam in Kiang (1992) ter Hansen in drugi (1992) so v začetku devetdesetih dvajsetega stoletja predstavili prve pripomočke/modele na revizijskem in računovodskem področju, ki so temeljili na zahtevnejših metodah/tehnikah, kot so npr. nevronske mreže, odločitvena drevesa itd. Hansen in drugi (1992) in kasneje Spathis in drugi (2003) ter Gaganis in drugi (2006) so konstruirali model za identifikacijo vrste revizijskega mnenja; medtem ko sta se Tam in Kiang (1992) in kasneje Chen in Church (1992), Lenard in drugi (1994), Mutcher in drugi (1997), Anandrajan in Anandrajan (1999), Lenard in drugi (2001) ter Lee in drugi (2005) osredotočili na identifikacijo vrste revizijskega mnenja v primeru vprašljivega nadaljnjega delovanja podjetja.

Raziskovalci za razvoj modelov so večinoma uporabili podatkovne baze, v katerih so kotirajoča podjetja iz območja Z.D.A.; le Spathis in drugi (2003) so uporabili podatkovno bazo podjetij iz Grčije in Gaganis in drugi (2006) podatkovno bazo podjetij iz Velike Britanije. Pri definiranju (izboru) ključnih spremenljivk modela se avtorji zatečejo k arbitrarnem/selektivnem izboru spremenljivk, ki imajo temelj v pretekli raziskavi ali pa glede na vsebinski pomen spremenljivk. Kompleksnejših tehnik pri izboru nabora spremenljivk se ne poslužijo; izjema so le Gaganis in drugi (2006), ki uporabijo analizo glavnih komponent. Tako kot variira način izbora spremenljivk od raziskave do raziskave, variira tudi število spremenljivk, ki so vključene v posamezen model. V prvi raziskavi npr. Dupoch in drugi (1987) uporabijo le 9 različnih kvalitativnih in kvantitativnih (tj. vrednostno in nevrednostno izraženih, op.p.) spremenljivk, Hansen in drugi (1992) 12 spremenljivk, Laitinen in Laitinen (1998) 17 spremenljivk (Gaganis in drugi 2006, 2), Spathis in drugi (2003), v eni izmed raziskav zadnjega obdobja, pa npr. že 20 različnih kvalitativnih in kvantitativnih spremenljivk. Kljub povečanemu številu spremenljivk pa se glede na v raziskavah predstavljene kriterije uspešnosti (v večini raziskav je to stopnja natančnosti in/ali stopnja napak tipa 1 in 2) uspešnost modelov (angl. *performance*) ni pretirano izboljšala (uspešnost variira med 60 in 80 %, redko pa preseže 80 %).

Večinoma pri razvoju v raziskavah predstavljenih modelov za identifikacijo vrste revizijskega mnenja niso bili uporabljeni pretirano veliki vzorci podjetij. Tako so po dosegljivih podatkih Hansen in drugi (1992) npr. uporabili le vzorec 80. podjetij za razvoj modela, Spathis in drugi (2003) le 50. podjetij; medtem ko so npr. že Dupoch in drugi (1987) uporabili vzorec 564. podjetij, vendar predvsem zaradi vključitve dolgega časovnega horizonta. Le Hansen in drugi (1992) in Spathis in drugi (2003) so pri snovanju modela uporabili uravnotežen vzorec podjetij. Validacijo modela na testnih podatkih, ki niso uporabljeni pri razvoju modelov, so izvedli le Dupoch in drugi (1987), Spathis in drugi (2003) ter Gaganis in drugi (2006).

2.6 Sklepna misel k poglavju o reviziji

S pregledom osnovnih elementov revizijskega procesa (tj. vrste mnenj, poročil, dejavnikov revizije, revizijskih tveganj itd.) je v pričujočem poglavju o reviziji podan vpogled v kompleksnost samega procesa zunanje revizije. Kompleksnost, dinamičnost procesa in okolja, časovni in ostali pritiski, s katerimi se srečujejo revizorji, in ostali problemi, s katerimi se spopadajo revizorji, zahtevajo razvoj orodij oz. pripomočkov, ki bi revizorjem omogočili priskrbo objektivnih informacij o revidirani stranki. Možnost (tj. izhodišče) za razvoj takšnih orodij/pripomočkov predvidijo MSRev v okviru analitičnih postopkov.

Analitični postopki omogočijo pridobivanje analitičnih dokazov na podlagi analiz in primerjav razmerij med podatki in vključujejo vse od enostavnejših primerjav do uporabe kompleksnih matematičnih in statističnih modelov. Nekaj poizkusov konstruiranja zahtevnejših statističnih modelov, ki bi omogočili identifikacijo vrste revizijskega mnenja, obstaja. Najizrazitejši razlog (vzrok, op.p.) oz. korist pri uporabi takšnega modela bi imeli predvsem revizorji, saj bi, v kolikor je model uporabljen pravilno in je njegova uspešnost dokazana, lahko izvedli revizijski proces gospodarnejše, učinkoviteje in uspešneje. Možnost uporabe tudi v druge namene (npr. pregled potencialnih strank, primerjalna ocena v spornih primerih itd.) so dodatne prednosti uporabe različnih modelov.

S prikazano vsebino o pomenu oz. vlogi analitičnih postopkov in različnih modelov v reviziji je postavljen z vsebinskega vidika prvi temelj za razvoj modela za identifikacijo (napoved) vrste revizijskega mnenja. Sami MSRev hkrati, ko dovoljujejo uporabo analitičnih postopkov, opominjajo, da morajo uporabniki matematično-statističnih modelov biti interdisciplinarni v njihovem znanju in poleg poznavanja revizije in računovodstva morajo biti vešči tudi v matematičnih in statističnih metodah/vedah. Uporaba različnih modelov namreč zahteva razrešitev vprašanj, kot so npr. kako uporabiti (razviti) model, kdaj je uspešnost modela zadovoljiva in kako jo oceniti ipd. Takšna in podobna vprašanja so del statistične metodologije (tj. statistike), ki predstavlja drugi temelj (izhodišče), ki omogoči razvoj modela za identifikacijo (napoved) vrste revizijskega mnenja in katerega predstavljamo v naslednjem poglavju.

3 METODOLOGIJA

Konstrukcija modela za identifikacijo vrste revizijskega mnenja ni možna brez primerne statistične metodologije. Navzven večkrat nezaznana interdisciplinarnost problema zahteva obravnavo/predstavitev uporabljene statistične tehnike, ki je predstavljena v prvem delu poglavja. Drug problem, ki ga različni avtorji z različnih področij (posebej računovodstva in revizije) pri konstruiranju modelov večkrat ne izpostavijo, je problem merjenja uspešnosti konstruiranega modela in določitve primernih kriterijev za oceno uspešnosti. Slednje je predstavljeno v drugem delu poglavja, kjer je v zadnjem delu nakazana tudi možnost prilagoditve izbranega modela, da bo le-ta glede na postavljen kriterij/preference uporabnika optimalen. Pogoji za možnost prilagoditve modela je neobčutljivost modela na spremembe pogojev/predpostavk. Ocenitev občutljivosti modela je podana skupaj z možnostjo prilagoditve modela v zadnjem delu poglavja.

3.1 Klasifikacijski model in logistična regresija

Področje zaznavanja in interpretiranja določenih pojavov samoumevnih zakonitosti in/ali lastnosti (angl. *pattern recognition*) zajema celoten proces raziskovanja od začetne stopnje zaznavanja in formulacije problema, zbiranja podatkov z uporabo diskriminacije in/ali klasifikacije do končnih izidov raziskave in njihove interpretacije (Webb 2002, 1). Logika je preprosta, in sicer pridobiti pripomoček (model), ki bo glede na pridobljene podatke omogočil razvrstitev opazovanega pojava v želeni razred³⁰.

S konstruiranjem modela za klasifikacijo³¹ posameznih podjetij³² (tj. podatkovnih nizov kombinacije kazalnikov³³) se določijo parametri modela (klasifikatorja), da bo le-ta zmožen doseči optimalno razlikovanje med posameznimi podjetji. Output oz. odziv modela na predstavljen vhodni podatkovni niz (vstopno kombinacijo podatkov) je ocena predvidenega razreda, ki naj bi mu posamezno podjetje pripadalo.

Sama oblika in zahtevnost modela klasifikacije je odvisna od številnih različnih dejavnikov, ki vplivajo na odločitev o klasifikaciji, kot npr. od porazdelitve podatkov za razvoj modela in predpostavk glede njihove porazdelitve. Pomemben dejavnik so tudi stroški napačne klasifikacije (angl. *misclassification costs*) – tj. stroški napravljene napačne odločitve. V več aplikacijah je stroške napačne klasifikacije težko kvantificirati, kar je predvsem posledica različnih kombinacij stroškov od čistih monetarnih stroškov, časovnih in drugih bolj subjektivnih stroškov (Webb 2002, 2). Dodatni dejavniki so tudi

³⁰ Pojem 'klasifikacije' podjetij se uporablja pretežno pri razvrščanju podjetij v različne razrede na podlagi podatkov, ki so uporabljeni za razvoj posameznega modela. Pojem 'prognostiranje/napovedovanje' razreda podjetja pa se uporablja pri razvrščanju podjetij na podlagi podatkov, ki so namenjeni testiranju modela ali podatkov, ki niso bili uporabljeni pri razvoju modela.

³¹ V tehničnem jeziku je analogen pojem 'diskriminacija' (angl. *pattern classifier design, discrimination*).

³² V nadaljevanju naloge, ko govorimo o klasifikacijskem modelu in njegovih zmožnostih, ne razlikujemo med pojmom podjetje in družba in uporabljamo pojem podjetje. Vendar opozarjamo, da s pravno-formalnega vidika razlika je, in sicer je družba nosilec pravne osebnosti (subjektivitete) – več o tem v 5. členu Zakona o gospodarskih družbah (odslej ZGD), kar si pridobi z vpisom v sodni register; medtem ko je podjetje pravni objekt oz. sredstvo družbe. Podjetje nima pravne osebnosti in po ZGD ne more biti nosilec dejavnosti in nastopati v pravnem prometu – torej zanj ne velja 5. člen ZGD (več o tem glej Kocbek in Prelič (2006, 187-188)). Slednjo vsebinsko razliko izpostavljamo zaradi različnih interesov uprave in nadzornega sveta, kajti uprava vodi podjetje in je predstavnik podjetja, medtem ko je nadzorni svet 'izbran' predstavnik lastnikov, torej družbe, in sledi interesom družbe.

³³ Hierarhija, ki je uporabljena v nalogi, je naslednja: (1) celotni vzorec različnih podatkovnih nizov; (2) podatkovni niz, ki vključuje niz podatkov o posameznem podjetju – tj. kombinacijo kazalnikov posameznega podjetja; (3) računovodski kazalniki, ki predstavljajo podatke oz. lastnosti (tudi attribute) posameznega podjetja.

nepoznavanje posameznih variant ali njihovih možnih kombinacij, velike količine variant; nepoznavanja odločitvenega problema in ciljev odločitve; nesoglasje med ljudmi, ki sodelujejo pri odločanju; drastičnih posledic napak; omejenih sredstev (čas, denar, strokovnjaki itd.).


Dodatni problem, ki je večkrat časovno najobsežnejši, je, da je pred samo uporabo vhodnih podatkov na podatkih večkrat potrebno opraviti mnogo transformacij (angl. *preprocessing*), da se npr. zmanjša dimenzionalnost podatkov (zmanjšanje števila podatkov znotraj podatkovnega niza), odstranijo opustljive in nerelevantne informacije in transformacije podatkov v obliko, ki je primernejša za kasnejšo klasifikacijo. Pri predprocesiranju podatkov pride do izbora/oblikovanja variabel na podlagi meritev, ki jih vsebuje prvotni vektor podatkov.

Večinoma se lahko obravnavajo različne vrste problemov: binarni klasifikacijski problemi in večrazredni klasifikacijski problemi. Binarni klasifikacijski problem je poseben primer večvariantnega problema, ki je rešljiv s tehniko logistične regresije, ki je predstavljena za poglavjem, ki podrobneje predstavlja osnovne lastnosti bivariantnega klasifikacijskega problema.

3.1.1 Bivariantna klasifikacija

Na Sliki 2 spodaj, predstavljamo v dvodimenzionalnem prostoru (ravnini) porazdelitev dveh različnih razredov podatkovnih nizov (lahko podjetij, op.p.), in sicer v obliki modrih in belih krogov. Najenostavnejša možnost ločitve/razdelitve je linearna ločitev s pomočjo premice oz. odločitvene meje (angl. *decision boundary*), ki je na sliki spodaj prikazana v modri barvi. Gre za linearno ločljiv oz. rešljiv problem (angl. *linearly seperable*).

Slika 2: Linearno ločljiv problem



Vir podatkov: Lastni prikaz.

Zgornji prikaz ločitve je možno prikazati tudi z matematičnim zapisom. Označimo podatkovni niz kazalnikov podjetja z vektorjem x_i , kjer $i = 1, \dots, N$, in razred z ω_j , kjer $j = 1, \dots, C$. Za bivariantni problem je j enak 1 ali 2. Poiskati moramo takšen vektor s pripadajočimi koeficienti b in mejno vrednost a (angl. *threshold*), da bo veljalo (Webb 2002, 124):

$$b^T x_i + a \begin{cases} > 0 \\ < 0 \end{cases} \Rightarrow x_i \in \begin{cases} \omega_1 \\ \omega_2 \end{cases} \quad (3.1).$$

Zapis preprostega modela je torej enak

$$y_i = f(b^T x_i + a) \quad (3.2),$$

kjer y predstavlja output modela, tj. odgovor, kateremu razredu ω_j pripada posamezno podjetje, ki ima pripadajočo kombinacijo posameznih kazalnikov, ki jih predstavlja vektor x_i . Funkcijska transformacija f je v našem preprostem primeru enaka linearni transformaciji. Identičen zapis ob predpostavki $y = z$ je v tem primeru enak

$$z_i = b^T x_i + a \quad (3.3),$$

oz.


$$z_i = \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n + a \quad (3.4)$$

kar predstavljamo tudi na shemi spodaj. V kolikor je vstopni vektor $b^T x_i > -a$, potem pripada vektor x_i razredu ω_1 . V nasprotnem primeru pripada razredu ω_2 . Takšno delitev na dve polravnini oz. dve skupini podjetij predstavljamo na zgornji Sliki 2, kjer vse točke na odločitveni meji (modra premica) zadovoljijo pogoji

$$b^T x + a = 0 \quad (3.5).$$

Premica, ki na Sliki 2 predstavlja odločitveno pravilo/mejo, je ortogonalna na vektor s koeficienti. Sprememba pozicije meje (odločitvenega pravila) je možna s spremembo a . Sivo področje slike zgoraj predstavlja vse vstopne vektorje, za katere je izid preprostega modela zapisanega z enačbo (3.3) večji od 0. Izid bo manjši od 0 za vse ostale vstopne vektorje.

Slika 3: Shematičen prikaz zapisa preprostega modela




Opomba: x , a in z predstavljajo vektorje dimenzije $N \times 1$, $M \times 1$ in $M \times 1$. B predstavlja matriko koeficientov dimenzije $M \times N$. Črno obarvan pravokotnik predstavlja vstopne podatke. Plus predstavlja operacijo seštevanja. Puščice nakazujejo smer gibanja/operacije.

Vir podatkov: Lastni prikaz.

Ker je predstavljeno odločitveno pravilo/meja linearna, lahko preprosti model, ki je matematično zapisan z enačbo (3.3), uporabimo le pri za prepoznavanje vzorcev, ki so linearno ločljivi. Problemi, kot jih prikazujemo na Sliki 4 spodaj, sicer večkrat niso linearno ločljivi v popolnosti oz. so linearno neločljivi. Če se jih kljub temu lotimo s

pomočjo linearnega odločitvenega pravila prihaja do napačnih klasifikacij, še posebej npr. na področjih blizu odločitvene meje.

Slika 4: Linearno nerešljivi problemi



3.1.2 Uporaba logistične regresije pri problemu klasifikacije

Logistična regresija je le ena izmed enostavnejših metod³⁴, ki jo lahko uporabimo v primeru klasifikacije različnih podatkovnih nizov. Gre za statistično tehniko, na osnovi katere je možno osnovati odločitveni model na osnovi podatkov in s pomočjo modela odkriti zanimive zakonitosti v izbrani bazi podatkov.

Preprosti klasifikacijski/ločitveni model, ki je predstavljen z enačbo (3.3) oz. (3.4), omogoči klasifikacijo problemov v razred ω_j , vendar velja, da je $z \in (-\infty, \infty)$, kar pa ne omogoča neke vsebinsko preprosto razumljive/smiselne interpretacije. Želja uporabnika pri razvrščanju elementov/podjetij v posamezne razrede je, da bi izid klasifikacijskega modela podal nedvoumen odgovor, kjer bi bila možna dva izida in bi npr. izid 0 pomenil negativen odgovor (tj. podjetje ni element množice podjetij z modificiranimi mnenju) in izid 1 pozitiven odgovor (tj. podjetje pripada množici podjetij z modificiranimi mnenji).

V primerjavi z linearnimi statističnimi modeli logistična regresija omogoči transformacijo/pretvorbo vrednosti na interval $[0,1]$ (na Sliki 5 spodaj je slednje prikazano skrajno desno), kjer izid klasifikacijskega modela na osnovi logistične regresije ne gre pod vrednost 0 ali nad vrednost 1³⁵. Transformacija temelji na logistični funkciji, ki je sigmoidne oblike in se z naraščanjem oz. padanjem z proti ∞ oziroma proti $-\infty$ asimptotično približuje 1 oziroma 0. Enačba transformacijske funkcije je


$$y_i = f(z_i) = \frac{1}{1 + e^{-z_i}} \text{ oziroma } f(z_i) = \frac{e^{z_i}}{1 + e^{z_i}} \quad (3.6a) \text{ in } (3.6b),$$

³⁴ Nekateri avtorji (npr. Webb 2002, Bell 1997, Shahian in drugi 2004 itd.) uvrščajo logistično regresijo med tehnike za odkrivanje znanja v podatkih (angl. *knowledge discovery in databases*) oz. 'data mining' tehnike. Področje odkrivanja znanja v podatkih vključuje tehnike za gradnjo odločitvenih modelov na osnovi podatkov, ki omogočajo odkrivanje zakonitosti v bazah podatkov. Tehnike oz. metode so npr. naslednje: statistična logistična regresija, diskriminantna analiza, vizualizacija, odločitvena drevesa, odločitvena pravila, asociacijska pravila (npr. nakupovalna košarica), nevronske mreže, genetski algoritmi itd.

³⁵ Druge lastnosti/predpostavke logistične regresije so, da ne zahteva (Gujarati 2003, 595-597): (1) linearnega razmerja med prediktorji in odvisno spremenljivko; (2) enakih varianc napak pri različnih vrednostih X_i – tj. ni predpostavke o homoskedastičnosti; (3) ni zahtevana normalna porazdelitev napak. Velja pa še predpostavka, da ne sme obstajati multikolinearnost neodvisnih spremenljivk ter predpostavka, da je napaka neodvisna od posameznih spremenljivk.

kjer so neodvisne spremenljivke X_i , $i = 1, \dots, k$, preko linearne kombinacije $z_i = \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n + a$ vključene v model klasifikacije na osnovi logistične regresije³⁶.

Slika 5: Shematičen prikaz zapisa logističnega modela



Opomba: Oznake imajo enak pomen, kot je predstavljen v opombi k Sliki 3. y predstavlja vektor dimenzije $M \times 1$. Pravokotnik, ki znotraj vsebuje krivuljo v obliki črke S, predstavlja transformacijo vstopnih elementov v izhodne s pomočjo sigmoidne funkcije.

Vir podatkov: Lastni prikaz.

Vsebinsko lahko katerokoli vrednost z iz intervala $[0,1]$, ki je posledica transformacije, interpretiramo kot pričakovana ocenjena verjetnost, da podatkovni niz x_i pripada razredu ω_j . Slednje zapišemo kot

$$y_i = f(z_i) = E(Y = 1 | X_i) = p(x | \omega_1) \quad (3.7)$$

za primer, ko podjetje pripada razredu podjetij z modificiranimi mnenji in kot

$$y_i = f(z_i) = E(Y = 0 | X_i) = p(x | \omega_0) = 1 - p(x | \omega_1) \quad (3.8)$$

za primer, ko podjetje pripada razredu podjetij s pozitivnimi (nemodificiranimi) mnenji.

Povečanje $\sum_{i=1}^n \beta_i X_i$ (in posredno vrednosti z) pomeni približevanje vrednosti k 1 in tudi povečanje pogojne verjetnosti možnega izida 1. Kljub transformaciji je nov model v osnovi linearen, saj obstaja še vedno linearna zveza med prediktorji in napovedano verjetnostjo, podvrženo logistični transformaciji – tj. naravnemu logaritmu obojnih (Webb 2002, 162; Gujarati 2003, 596):

$$\ln\left(\frac{p(x | \omega_1)}{1 - p(x | \omega_1)}\right) = \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n + a \quad (3.9).$$

Odločitveno pravilo/meja med razredi ω_j je odvisna od razmerja $\frac{p(x | \omega_1)}{p(x | \omega_0)}$ in velja, da je

$$x \in \begin{cases} \omega_0 & \text{če je } \frac{p(x | \omega_1)}{p(x | \omega_0)} < 1 \\ \omega_1 & \text{če je } \frac{p(x | \omega_1)}{p(x | \omega_0)} > 1 \end{cases} \quad (3.10)$$

³⁶ Predpostavka $y = z$ ne velja več.

oziroma če substituiraemo z enačbo (3.4), da dobimo odločitveno pravilo odvisno le od linearne funkcije $\beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n + a$ velja, da je

$$x \in \begin{cases} \omega_0 & \text{če je } \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n + a < 0 \\ \omega_1 & \text{če je } \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n + a > 0 \end{cases} \quad (3.11).$$

Logistična regresija je vključena v večino sodobnih statističnih programskih paketov, ki omogočajo več različnih pristopov k ocenjevanju parametrov modela. V večini primerov se ob zadostno velikem vzorcu uporablja metoda največjega/maksimalnega verjetja (angl. *maximum likelihood method*)³⁷.

3.1.2.1 Napoved vrednosti in razmerje obetov tveganj

Namen razvoja modela je v njegovi uporabi na primerih, ki jih ni v testnih in razvojnih podatkih. Napoved/predikcija vrednosti y oz. $f(\mathbf{z})$ je možna z vstavitvijo vrednosti X_i (posameznih kazalnikov) v logističen model z ocenjenimi regresijskimi koeficienti (glej enačbo (3.6a) ali (3.6b)). Pri razvoju modela in ocenjevanju parametrov modela je odločitvena meja/pravilo (angl. *cut-off point, threshold*) določena/predpostavljena pri 0,5, kar pomeni, da pri $p(x|\omega_1) > 0,5$ razvrstimo podjetje v razred ω_1 in če $p(x|\omega_1) < 0,5$ razvrstimo podjetje v razred ω_0 . Slednje odločitveno pravilo/meja ni vedno najprimernejše. Problematiko določitve optimalne odločitvene meje za model klasifikacije oz. predikcije predstavljamo posebej v poglavju 3.2.4 Prilagoditev parametrov klasifikacijskega modela.

Problematika medsebojne povezanosti različnih parametrov modela oz. značilnosti logistično-regresijske analize zahteva obsežen in celovit pregled. Omejimo se le na prikaz razmerja obetov tveganj³⁸ (angl. *odds ratio*), ki poda primerjavo med dvema sklopoma vrednosti prediktorjev/neodvisnih spremenljivk glede napovedane vrednosti y , praviloma pa ga izračunamo za primer, ki se razlikuje le v eni vrednosti prediktorja.

3.2 Kriteriji (merila) za oceno uspešnosti modela

Ocena uspešnosti klasifikacijskega oz. predikcijskega modela je pomemben del celotnega procesa prepoznavanja vzorcev oz. zakonitosti v podatkovnih bazah. Vsak model ne glede na uporabljeno metodo/tehniko mora biti natančno in temeljito preverjen, da se lahko poda ocena, ali model funkcionira zanesljivo za pričakovan namen (Shahian in drugi 2001, 1870). S konstruiranjem modela se namreč postavlja vprašanje, kako dober je konstruiran model³⁹, kako dober je v primerjavi s konkurenčnimi tehnikami in dodatno ali se lahko

³⁷ Več o metodi največjega verjetja (angl. *maximum likelihood method*) glej Gujarati (2003, 633-635).

³⁸ Razmerje obetov tveganj (angl. *odds ratio*) je razmerje med obeti (angl. *odds*), da se zgodi dogodek v razredu ω_i v primerjavi z obeti, da se zgodi dogodek v razredu ω_j , kjer $i \neq j$. Če je razmerje obetov tveganj enako 1, je verjetnost dogodka enaka v obeh razredih. V kolikor je razmerje obetov tveganj večje od 1, je verjetnost dogodka večja za razred, ki je v imenovalcu razmerja obetov tveganj in obratno, če je razmerje obetov tveganj manjše od 1, je verjetnost dogodka za razred, ki je v imenovalcu razmerja obetov tveganj, manjša.

³⁹ Pod kontekst dobrega modela pojmujeemo ocene modela z različnih vidikov (Daley 1994; povzeto po Shahian in drugi 2004, 1870): (1) kolikšna je osnovna razumljivost modela (angl. *face validity*) – tj. ali je model razumljiv strokovnjakom; (2) ali je model vsebinsko razumljiv (angl. *content validity*) – tj. ali so v model vključene vse signifikantne in ostale vsebinsko pomembne variable; (3) kakšna je zmožnost prilagodljivosti modela (angl. *attributonal validity*) – tj. ali je npr. prilagoditev za tveganja primerna in je zagotovljeno, da razlike v izidih niso posledica različnih karakteristik

izboljša uspešnost modela s prilagoditvijo parametrov po končanem razvoju modela ali pri njegovi uporabi, če to zahtevajo specifični pogoji. Še natančneje različna področja, ki jih je potrebno oceniti, definirata Chung in Gray (1999; povzeto po Sinha in May 2005, 262), ki navajata, da je potrebno razrešiti vprašanje kvalitete odkritega znanja, ali enaka metoda dosega enake rezultate pod drugačnimi pogoji, kateri dejavniki vplivajo na uspešnost modela itd.

Različni avtorji (Shahian in drugi 2004, 1871; Sinha in May 2005, 262 in Webb 2002, 252) predlagajo, da se pri ocenjevanju modela klasifikacije/predikcije prouči (vsaj) naslednji dve področji: (1) klasifikacijsko zmožnost modela (angl. *discriminability, resolution*) in (2) kalibracijo modela (angl. *reliability, calibration*). Na področju klasifikacijske zmožnosti modela se prouči, kolikšna je diskriminatorna/identifikacijska zmožnost modela na do tedaj še nevidenih podatkih. Slednje vključuje analizo občutljivosti modela, proučitev vpliva na specifičnost in občutljivost modela pri različnih točkah tveganja (npr. kolikšna je verjetnost, da se pripiše določen podatkovni niz predvidenemu razredu itd.). Na področju kalibracije se ocenjuje vrednosti novih neodvisnih spremenljivk na osnovi novih primerov odvisnih spremenljivk (tj. prilagoditev modela novim podatkom).

Metoda *hold-out* (angl. *hold-out sample validation, train-and-test method*) je pogosto uporabljena pri ocenjevanju klasifikacijskih modelov (glej npr. Sinha in May 2005, 262; Webb 2002, 253; Dupoch in drugi 1987, 448; Anandarajan in Anandarajan 1999, 385-386; Gaganis in drugi 2006, 3 itd.). Pri tem postopku razdelimo celotno podatkovno bazo na dva neodvisna dela, kjer je prvi del uporabljen pri konstruiranju klasifikacijskega modela in drugi del uporabljen za testiranje modela. Uspešna uporaba metode je zagotovljena na dovolj velikih vzorcih (napotki kolikšna naj bo zadostna velikost vzorca, variira po različnih avtorjih, op.p.), medtem ko je pri razmeroma majhnih vzorcih uporaba te metode lahko vprašljiva, saj pri majhnem slučajno sestavljenem vzorcu ocenjujemo napako, ki je lahko zaradi majhnosti vzorca pristranska (Weiss in Kulikowski 1991; povzeto po Sinha in May 2005, 262). Prava stopnja napake (angl. *error rate*) je v takšnem primeru le delno zanesljiva⁴⁰.

Struktura poglavja o kriterijih (merilih) za oceno uspešnosti modela klasifikacije/identifikacije je zastavljena v štirih delih. V prvem delu so predstavljeni pogosto uporabljeni kriteriji – tj. klasični kriteriji za ocenjevanje uspešnosti modelov, kot je na primer stopnja natančnosti – in zaradi možnih napačnih klasifikacij napaki tipa 1 in 2 in razmerje med njima ter klasičnimi kriteriji. Prav tako so podrobneje predstavljeni tudi pripadajoči stroški napravljenih napak in razmerje med stroški in klasičnimi kriteriji. V drugem delu poglavja so predstavljeni alternativni kriteriji za ocenjevanje uspešnosti modelov klasifikacije – tj. ROC krivulja, kriterij AUC in krivulje enake uspešnosti. V tretjem delu poglavja je predstavljen kriterij, s pomočjo katerega se oceni občutljivost modela klasifikacije. V zadnjem, četrtem, delu poglavja je predstavljena možnost prilagoditve modela klasifikacije.

proučevanega pojava in (4) kakšna je zmožnosti klasifikacije/napovedi modela (angl. *predictive validity*) – tj. kako dobro model funkcionira na podatkih, na katerih ni bil razvit.

⁴⁰ To omejitve *hold-out* metode je možno odpraviti z uporabo različnih statističnih tehnik, ki jih npr. na kratko navaja Webb (2002, 253-258): (1) navzkrižno ocenjevanje (angl. *cross-validation*), (2) vsakokratno izpuščanje enega primera (angl. *jackknife*) ali (3) metoda kljukca (angl. *bootstrap*).

3.2.1 Klasični kriteriji za ocenjevanje uspešnosti klasifikacijskih modelov

3.2.1.1 Kontingenčna tabela možnih izidov

Pred predstavitvijo osnovnih kriterijev za ocenjevanje uspešnosti modela moramo predstaviti možne izide, ki jih lahko doseže klasifikacijski/predikcijski model. Za problem le z dvema možnima izidoma je možno izračunati/prikazati kontingenčno tabelo/matriko (angl. *confusion matrix*, *contingency table*, *misclassification matrix*) velikosti 2×2 , ki jo prikazujemo v Tabeli 3 spodaj. Vsak klasifikator namreč podatkovni niz (podjetje) pripiše pozitivnemu (ω_1) ali negativnemu (ω_0) razredu glede na odločitveno pravilo (oz. postavljeno odločitveno mejo). Glede na prikaz spodaj so možne 4 različne vrste izhodov/izidov:

- če je prognozirani pozitiven razred in je dejansko tudi resnično pozitiven, potem štejemo podatkovni niz med resnično pozitivne podatkovne nize (angl. *true positive*);
- če je podatkovni niz klasificiran kot negativen, dejansko pa pozitiven, je to napačna negativna klasifikacija (angl. *false negative*);
- če je prognoza, da je podatkovni niz negativen in dejansko tudi je, ga štejemo med resnično negativne (angl. *true negative*);
- in če je dejansko negativen, klasificiran pa kot pozitiven, pa štejemo podatkovni niz med napačne pozitivne (angl. *false positive*).

Tabela 3: Kontingenčna tabela

		Prognozirani razredi (Predicted class)			
		Pozitivni (+)	Negativni (-)		
Dejanski (resnični) razredi (True class)	Pozitivni (+)	Resnični pozitivni (TP – True positive)	Napačni negativni (FN – False negative)	Stopnja resničnih pozitivnih (TPR – True positive rate)	
	Negativni (-)	Napačni pozitivni (FP – False positive)	Resnični negativni (TN – True negative)	Stopnja resničnih negativnih (TNR – True negative rate)	
		Natančnost (Precision)		Specifičnost (Specificity)	
				Stopnja natančnosti (Accuracy)	

Opomba: Način izračuna posameznih meril uspešnosti je podan v Tabeli 4.
Vir podatkov: Sinha in May (2005, 264) in Fawcett (2003,2).

Diagonala klasifikacijske matrike (od levo zgoraj do desno spodaj) torej predstavlja pravilne klasifikacije, medtem ko elementi, ki ne ležijo na omenjeni diagonali, predstavljajo napačno klasifikacijo (Fawcett 2003, 2-3). Gre za dve vrsti napravljenih napak oz. napačnih klasifikacij: (1) ali klasificiramo dejansko negativne kot pozitivne ali pa (2) klasificiramo dejansko pozitivne kot negativne. V statistiki se ti dve vrsti napak imenujeta napaka tipa 1 (angl. *type 1 error*) in napaka tipa 2 (angl. *type 2 error*). Najpogosteje uporabljeni kriteriji oz. merila za ocenjevanje uspešnosti klasifikacijskega modela, ki jih je možno izračunati iz kontingenčne matrike, in sam način izračuna predstavljamo v Tabeli 4 spodaj.

Tabela 4: Klasični kriteriji za ocenjevanje uspešnosti modela klasifikacije


Kriterij			Način izračuna	
Slovensko poimenovanje	Angleško poimenovanje	Oznaka	Polni zapis	Simbolni zapis
1	2	3	4	5
1. Natančnost	(Overall) Accuracy	Acc	$\frac{\text{Pravilno klasificirani primeri}}{\text{Vsi primeri}}$	$\frac{TP + TN}{TP + FP + FN + TN}$
2. Resnična pozitivna stopnja, Senzibilnost	True positive rate, Hit rate, Recall, Sensitivity	TPR	$\frac{\text{Pravilno klasificirani pozitivni primeri}}{\text{Vsi dejansko pozitivni primeri}}$	$\frac{TP}{TP + FN}$
3. Napačna pozitivna stopnja	False positive rate, False alarm rate	FPR	$\frac{\text{Nepravilno klasificirani negativni primeri}}{\text{Vsi dejansko negativni primeri}}$	$\frac{FP}{FP + TN}$
4. Natančnost	Precision	-	$\frac{\text{Pravilno klasificirani pozitivni primeri}}{\text{Vsi pozitivno prognozirani primeri}}$	$\frac{TP}{TP + FP}$
5. Specifičnost	Specificity	-	$\frac{\text{Pravilno klasificirani negativni primeri}}{\text{Vsi dejansko negativni primeri}}$	$\frac{TN}{TN + FP}$

Vir podatkov: Fawcett (2003, 2-3) in Sinha in May (2005, 264).

3.2.1.2 Napaka tipa 1 in 2 in stroški napravljenih napak

Pri razvoju klasifikacijskega modela seveda poskušamo razviti model, ki ima čim manjše število napak obeh tipov. Vendar sta večkrat obe napaki v nekem razmerju, in sicer, če se zmanjša število napak tipa 1, se poveča število napak tipa 2 in obratno (glej tudi Sliko 6 spodaj). Povedano drugače: če pri danem vzorcu podatkov zmanjšamo verjetnost zavrnitve pravilne klasifikacije, istočasno povečamo verjetnost sprejetja napačne klasifikacije⁴¹.

Slika 6: Venov diagram




Vir podatkov: Lastni prikaz.

Na Sliki 6 prikazujemo Venov diagram, kjer sta predstavljena razred 1 – podjetja s pozitivnimi (nemodificiranimi) mnenji in razred 2 – podjetja z modificiranimi mnenji. Navpična linija predstavlja odločitveno mejo med razredoma, medtem ko si v horizontalni liniji lahko predstavljamo tudi skalo, ki predstavlja verjetnost, da podjetje prejme modificirano mnenje (gre za vrednost, ki jo producira klasifikacijski model). Na sliki je dobro vidno, da se nekatera podjetja pojavijo v preseku obeh razredov (ti. porazdelitveni

⁴¹ Gre za premik odebeljene navpične črte, ki na Sliki 6 predstavlja odločitveno mejo. Več o tem v nadaljevanju poglavja.

prehod), kjer klasifikacijski model ne razlikuje podjetij s pozitivnimi (nemodificiranimi) mnenji pravilno od podjetij z modificiranimi mnenji (model torej nima stopnje natančnosti enake 100 %). Odločitvena meja/pravilo je izbrana tako, da model čim boljše razlikuje med podjetji s predvidenimi pozitivnimi in modificirani mnenji. Kot smo že povedali pa z odločitveno mejo determiniramo število resničnih pozitivnih klasifikacij (pravilno napovedanih), resničnih negativnih (pravilno nenapovedanih), napačnih pozitivnih (lažni alarm) in napačnih negativnih (zgrešeni pri napovedi). Glede na spreminjajoče pogoje je možna uporaba različnih odločitvenih mej v različnih situacijah, ko se želi minimizirati eno izmed napačnih odločitev modela, kar prikazujemo na Sliki 7 spodaj.

Slika 7: Primeri Venovih diagramov



Z Venovimi diagrami zgoraj prikazujemo vpliv odločitve za različna odločitvena pravila pri klasifikaciji podjetij. Nizek kriterij (levi diagram Slike 7) omogoča visoko stopnjo natančnosti, vendar je večja tudi stopnja napačnih pozitivnih, kar lahko vodi v nepotrebno večje proučevanje, povečanje stroškov zaradi napačnih klasifikacij in nezanesljivost modela. Visoko postavljen kriterij/odločitvena meja (desni diagram Slike 7) zniža stopnjo natančnosti, vendar se z visokim kriterijem zniža tudi stopnja napačnih pozitivnih na za uporabnika sprejemljivejšo raven.

Dober klasifikacijski model pri problemu identifikacije podjetij, ki naj bi prejela modificirano mnenje, identificira skupino podjetij, ki naj bi to modificirano mnenje prejela. Model je neuspešen, če identificira veliko število podjetij, ki naj bi prejela pozitivno (nemodificirano) mnenje, vendar se posledično pokaže, da prejmejo modificirano mnenje ali pa bi identificiral veliko število podjetij, ki naj bi prejela modificirano mnenje, vendar prejmejo dejansko pozitivno (nemodificirano) mnenje.

Stopnja natančnosti (angl. *accuracy*) naj bi pokazala agregatno zmožnost klasifikacijskega modela. Vendar se slabost stopnje pravilno razvrščenih podjetij (kriterija natančnosti) pokaže že v primeru neuravnoteženega vzorca. Dejansko je v primeru različnih frekvenc želenega pojava v vzorcu/populaciji kriterij natančnosti zavajajoč in nenatančen kriterij (Korobow in Stuhr 1985; povzeto po Jain in Nag 1997, 203). Vzemimo npr., da je v vzorcu le 10 % primerov skupine podjetij, ki morajo biti identificirana z modelom. Model klasificira vsa podjetja v razred s pozitivnim mnenjem. Posledično je stopnja pravilne klasifikacije enaka 90 %, čeprav niti eno podjetje manjšega razreda modificiranih mnenj ni razvrščeno pravilo. Podobno lahko imata dva modela enako stopnjo pravilne klasifikacije, vendar se signifikantno razlikujeta pri zmožnosti identificiranja manjše ciljne skupine podjetij z modificiranimi mnenji (Jain in Nag 1997, 210-211). Stopnja klasifikacije v teh primerih ne razkrije zmožnosti klasifikacijskega modela za želeni namen in potrebna je

vključitev dodatnih informacij, kot so npr. število napak tipa 1 in 2 in pripadajoči stroški, da bi se lahko boljše opredelila zmožnost modela klasifikacije (glej npr. Etheridge in drugi (2000, 542); Calderon in Cheh (2002, 227); Koh (2004, 475)).

Uporaba merila klasifikacijske natančnosti (angl. *accuracy*) je v večini predhodnih študij (glej npr. Dupoch in drugi (1987); Tam in Kiang (1992); Krishnan in Krishnan (1996); Spathis in drugi (2003); Gaganis in drugi (2006) itd.) pogosto uporabljena pri ocenjevanju in primerjavi uspešnosti različnih klasifikacijskih/predikcijskih modelov. Osnovni cilj avtorjev, ki uporabijo merilo natančnosti kot indikator uspešnosti, je v minimiziranju števila napak, ki ga napravi konstruiran klasifikator. V realni situaciji pa imajo različni tipi napačnih klasifikacij različne pripadajoče stroške in ne enake kot v predhodnih študijah implicitno predpostavljajo nekateri avtorji. Zaradi različnih stroškov je uporaba kriterija natančnosti kot merila za uspešnost modela neupravičena oz. nepravilna. Pri problemih, kot so klasifikacija vrste revizijskega mnenja, ocenjevanja kreditne zmožnosti, napovedovanja bankrota, prevar itd., stroški napačnih klasifikacij – tj. napravljenih napak tipa 1 ali 2 – niso enaki in kot takšne jih pojmujejo tudi revizorji (Jain in Nag 1997, 202; Sinha in May 2005, 264; Etheridge in drugi 2000, 542; Calderon in Cheh 2002, 227), kajti napačno izraženo mnenje znatno poveča tveganje, kateremu se izpostavi revizor. V teh primerih mora biti fokus na zmanjšanju oz. minimiziranju celotnih stroškov napačnih odločitev in ne na minimizaciji števila oz. stopnje napačnih odločitev (Elkan 2001; Provost in drugi 1998; povzeto po Sinha in May 2001, 250). Nazorneje prikažejo slednje Hand in drugi (2001, 361; povzeto po Sinha in May 2001, 250): »Stopnje napak (angl. *error rates*) pojmujejo napačno klasifikacijo vseh objektov kot enako pomembno. Vendar je to večkrat [...] nerealistično. Večkrat so nekatere napačne klasifikacije pomembnejše kot druge. Npr. napačna diagnoza pri pacientu z ozdravljivo boleznijo in v nasprotnem primeru z neozdravljivo boleznijo, da ima pacient le lahko obolenje, je bolj pomembno kot obratno. In v tem primeru bomo verjetno želeli pripisati stroške drugačni vrsti napačne klasifikacije. Le v primeru preproste stopnje napake pa bi iskali model, ki bi minimiziral celotno izgubo.« Etheridge in Sriram (1997; povzeto po Anandarajan in drugi 2001, 78-79) dodajata, da upoštevanje stroškov napačnih klasifikacij pripomore tudi k boljši interpretaciji modela z vsebinskega vidika.

Poznavanje stroškov napačnih klasifikacij, ki se pojavijo pri revizorjih in revizijskih družbah, v primeru podaje pravilnega še posebej pa nepravilnega mnenja revidiranemu podjetju, bi omogočilo (približno) oceno pričakovanih posledic uporabe klasifikacijskega modela (Koh 2004, 475). Praktičen/realen problem pa je seveda poznavanje realnih/dejanskih stroškov napak tipa 1 in 2. Kot navajata Calderon in Cheh (2002, 227) je tudi ocenitev/ocena stroškov napak praktično nemogoča, tako da so stroški večinoma neznani in/ali tudi težko ocenjeni, večkrat pa tudi nemerljivi (izjema so stroški, ki izhajajo iz tožb, op.p.) (Koh 1992, 189-190; Lee in drugi 2005, 68; Nanda in Pendharkar 2001, 155). Stroški napak tipa 1 in tipa 2 so namreč večinoma vezani na posledice, kot je npr. izguba sedanjih in/ali prihodnjih strank, ugleda revizorja in/ali revizijske družbe, izpostavitve večjem tveganjem in možnim tožbam s strani strank in/ali tretjih oseb.

Napaka tipa 1 (predvidevano modificirano mnenje, dejansko pa je pozitivno/nemodificirano), ki je napravljenega že v začetni fazi revizije, ima signifikanten vpliv na obseg in intenzivnost revizijskega programa in lahko vpliva na učinkovitost revizije. Revizor sicer lahko posledično identificira napako in ne izda napačnega mnenja. Vendar napaka tipa 2 (predvideno pozitivno/nemodificirano mnenje, dejansko pa je modificirano), storjena v začetnih fazah revizije, lahko vodi do podaje napačnega mnenja.

Neenaka velikost stroškov napake tipa 1 in 2 in nepoznavanje velikosti stroškov postavlja vprašanje, kateri stroški so večji oz. manjši.

Red velikosti stroškov je nedorečen, v kolikor stroški niso izmerljivi in/ali so nedosegljivi javnosti, medtem ko lahko uporabnik modela, ki stroške pozna, dosledneje določi njihovo velikost in slednje tudi upošteva pri razvoju modela klasifikacije. Na prvi pogled izgleda verjetno, da so verjetnost in povezani stroški (vključno s stroški tožb) pri izdaji napačnega revizijskega mnenja večji, če je v začetni fazi revizije (pri ocenjevanju) napaka tipa 2 napravljena v primerjavi z napako tipa 1. Zato so, kot navajajo nekateri avtorji (Lenard in drugi 1995; Salchenberger in drugi 1992; povzeto po Calderon in Cheh 2002, 227) pričakovani stroški napak tipa 2 višji kot pričakovani stroški napak tipa 1.

Druga skupina avtorjev (Koh 1992, 188; Lee in drugi 2005, 71; Lacher in drugi 1995, 64) pa zagovarjajo obratno tezo, in sicer, da so stroški napak tipa 1 relativno večji kot stroški napak tipa 2. Tako npr. v primeru napovedovanja bankrota in podeljevanja/izražanja mnenja, ki vsebuje dvom revizorja o nadaljnjem delovanju podjetja (angl. *going concern opinion*), avtorji (Sinkey 1975; Altman in drugi 1977; Hopwood in drugi 1989; Wilson in Sharda 1994; povzeto po Etheridge in drugi 2000, 533; Pompe in Bilderbeek 2005, 853; Anandarajan in drugi 2001, 79; Nanda in Pendharkar 2001, 156) navajajo, da revizorji pojmujejo napačno podeljeno pozitivno mnenje brez omembe dvoma o nadaljnjem delovanju bankrotiranemu podjetju (napaka tipa 1) kot dražjo napako v primerjavi s podelitvijo neogroženemu podjetju mnenja z dvomom o nadaljnjem delovanju (napaka tipa 2).

Dokončen sklep o razvrstitvi stroškov po velikosti ni možen, vendar sklepamo lahko, da je izhodiščno različno razvrščanje po velikosti zaradi različnih proučevanih vidikov. Zgornje razmerje, kjer so stroški napak tipa 2 večji od stroškov napak tipa 1, je predstavljeno z vidika revizorja, medtem ko je drugo razmerje stroškov, kjer so stroški napak tipa 1 večji od stroškov napak tipa 2, predstavljeno z vidika investitorjev in/ali lastnikov kapitala. Tako naj bi napaka tipa 1 pomenila za investitorja izgubo in/ali zmanjšanje vrednosti investicije, medtem ko bi napaka tipa 2 verjetno pomenila, da investitor ne-bo investiral, s čimer bo izgubil le dodatni možni donos iz kapitala. In v tem primeru so stroški napačnih odločitev z vidika revizorja veliko večji in pomembnejši pri napakah tipa 2 kot napakah tipa 1⁴². Vendar tako kot ne obstajajo informacije o absolutnih vrednostih stroškov napak tipa 1 in 2, obstaja tudi malo število informacij o relativnem razmerju stroškov napak tipa 1 in 2.

Pri konstruiranju klasifikacijskega/predikcijskega modela, ki upošteva napake in stroške napak, se določi tudi odločitveno mejo/pravilo, ki omogoči razvrščanje v posamezne razrede. S pomočjo Venovih diagramov (glej Sliko 6 in Sliko 7) smo pokazali, da sta napaki v medsebojnem razmerju. Pri dani velikosti vzorca torej obstaja *trade-off* odločitev med velikostjo ene in druge vrste napak. In kot navaja Gujarati (2003, 136) je »edini način, kako se lahko odločimo glede *trade-offa* (odločitvene meje, op.p.), da se poiščejo relativni stroški teh dveh vrst napak.« Kajti, če je »[...] napaka zavrnitve pravilno klasificiranega pozitivnega primera, ki je dejansko resničen (napaka tipa 1) relativno dražja od napake ne zavrnitve pravilno klasificiranega pozitivnega primera, ki je dejansko napačen (napaka tipa 2), bo racionalno, če postavimo verjetnost prvega tipa napake na nizek nivo. Če pa so na

⁴² Pri razvoju klasifikacijskega modela moramo upoštevati dejstvo, da razmerje med stroški napak tipa 1 in 2 in številom napak vpliva na sprejemljivost modela z vidika uporabnika. Tako bodo npr. revizorji sprejeli model z manj napakami tipa 2 kot sprejemljivejši in bolj uporaben kot model z nižjim številom napak tipa 1. Seveda slednje velja ob predpostavki, da so napake tipa 2 za revizorje dražje kot napake tipa 1.

drugi strani stroški narejene napake tipa 1 nizki relativno do stroškov napake tipa 2, je bolje, če je verjetnost napak tipa 1 visoka (in posledično je verjetnost napake tipa 2 nizka),« (Kmenta 1971, 126-127; povzeto po Gujarati 2003, 136).

Zaradi asimetrične strukture stroškov napačnih klasifikacij in nepoznavanja in/ali nemerljivosti stroškov napačnih klasifikacij predlagajo raziskovalci (Altman in drugi 1977; Zmijewski 1984; Dupoch in drugi 1986; Hopwood in drugi 1989; Koh 1992; povzeto po Etheridge in drugi 2000, 543; Koh 1991, 334; Tam in Kiang 1992, 936; Hand in drugi 2001, 361; povzeto po Sinha in May 2001, 250), da se uporabijo pri izračunavanju relativni ocenjeni stroški⁴³. Kot navajajo Anandarajan in drugi (2001, 78-79) pa je izbor primerne kazalnika stroškovnega razmerja med napakami tipa 1 in napakami tipa 2 odvisen od različnih dejavnikov, ki jih zazna in definira podjetje. Če upoštevamo poleg kazalnika stroškovnega razmerja še verjetnostne ocene pridobljene iz kontingenčne tabele, ki pripadajo posameznemu modelu klasifikacije, in izračunamo matriko možnih izgub/stroškov (angl. *loss matrix*), se lahko uporabnik/podjetje samo odloči za kombinacijo minimalnega sprejemljivega tveganja in pripadajočih stroškov (Beradi in Zhang 1999; povzeto po Anandarajan in drugi 2001, 78-79).

Uvedba kazalnika razmerja stroškov omogoči torej možnost določitve optimalne odločitvene meje, ki bi minimizirala stroške napačnih klasifikacij pri uporabi modela, kajti spregled različnih stroškov napačnih klasifikacij ima za posledico neoptimalen klasifikacijski model (Koh 1992, 188; Dupoch in drugi 1987, 447). Zanimivo pa je, da npr. Koh (1992, 189) in Lee in drugi (2005, 71) pokažejo, da se optimalna odločitvena meja pri kazalniku relativnih stroškov v intervalu od 1:1 do 71:1 in od 252:1 do 500:1 pri Koh-u in v intervalu od 6:1 do 72:1 in od 80:1 do 200:1 pri Lee-ju, Jiang-u in Anandarajan-u ne spremeni. V teh intervalih naj bi bila odločitvena meja neobčutljiva na stroške napačne klasifikacije. Podobno so v svoji raziskavi pred njimi predlagali že Dupoch in drugi (1987, 447).

Raziskovalci (Tam in Kiang 1992, 941; Koh 1991, 334; Calderon in Cheh 2002, 227; Lee in drugi 2005, 68; Anandarajan in drugi 2001, 78-79; Nanda in Pendharkar 2001, 155-157) so na osnovi nekaterih predpostavk glede relativne velikosti stroškov in verjetnosti pojava posamezne napake uporabili model za izračun pričakovanih stroškov napačnih klasifikacij. Prikaz modela in njegova izpeljava je prikazana v poglavju 3.2.2.2 Krivulje enake uspešnosti. Funkcija za izračun stroškov napačnih klasifikacij je relativno preprosta, vendar je zaenkrat edini zasledeni poizkus izračuna stroškov napačnih klasifikacij.

3.2.2 ROC krivulja

Enostavni kriteriji predstavljeni v predhodnem poglavju pogosto ne odražajo prave uspešnosti oz. zmožnosti klasifikacijskega modela. Prav tako so ta merila izračunana na relativno enostaven način, kar poudarja tudi Koh (2004, 475) in opozarja, da je potrebno za realen prikaz zmožnosti modela upoštevati tudi napačne klasifikacije in njihove relativne stroške. Zmožnost klasifikacijskega modela, da pravilno identificira pravilne pozitivne in


⁴³ Tako so npr. Tam in Kiang (1992), Anandarajan in drugi (2001), Hopwood in drugi (1989), Altman in drugi (1977), Zmijewski (1984), Lee in drugi (2005) in Dupoch in drugi (1986) v svojih člankih uvedli kazalnik razmerja stroškov napačnih klasifikacij napak tipa 1 proti napakam tipa 2, in sicer so večinoma predlagali razmerja 1:1, 1:10, 1:20, 1:30, 1:40 in 1:50. Kazalnik stroškovnega razmerja 1:1 (simetrična porazdelitev stroškov) so vključili, da bi zagotovili primerljivost s predhodnimi raziskavami.

pravilne negativne ob upoštevanju stroškov napačnih odločitev bi tako predstavljal primernejši kriterij od splošno pogosto uporabljenega kriterija natančnosti. Analiza s pomočjo ROC krivulje (angl. *receiver operating characteristics curve*) – tj. krivulje operative karakteristike modela – omogoči, da se oceni kriterij, ki upošteva pravilnost klasifikacije in pripadajoče stroške napačnih klasifikacij.

Prikaz ROC krivulje je tehnika, ki omogoča vizualen prikaz klasifikatorjeve uspešnosti in izbor klasifikacijskega modela na podlagi njegove uspešnosti. Prvotno so ROC krivulje razvili in uporabljali v teoriji zaznavanja signalov (angl. *signal detection theory*) med drugo svetovno vojno pri ugotavljanju uspešnosti oz. zmožnosti radarskih sistemov za zaznavanje signalov, in sicer z namenom, da bi lahko določili mejo (ločili, op.p.) med resničnimi pozitivnimi signali in napačnimi pozitivnimi signali (ti. lažnimi alarmi) radarja (Egan 1975; Swets, Dawes in Monahan 2000; povzeto po Fawcett 2003, 1). Danes se ROC krivulje uporablja na različnih področjih znanstvenega in raziskovalnega proučevanja pojavov, kot so npr. analiziranje obnašanja različnih diagnostičnih sistemov, njihovem vizualnem prikazu, medicinskem odločanju, epidemiologiji itd.

ROC krivulja je pripomoček, ki vizualno prikazuje klasifikatorjevo uspešnost preko celotnega spektra možnih odločitvenih mej (angl. *threshold*) in omogoča tudi izbor najprimernejše odločitvene meje/pravila. ROC krivulja je izrisana v dvodimenzionalnem prostoru (tj. ravnini), kjer je stopnja resničnih pozitivnih (*TPR*) na ordinatni osi prikazana glede na stopnjo napačnih pozitivnih (*FPR*) na abscisni osi (glej levi del Slike 8 spodaj). V terminologiji teorije zaznavanja signalov je to prikaz verjetnosti pravilnega zaznavanja glede na verjetnost nepravilnega zaznavanja, pri čemer pa odločitvena meja variira. Na področju medicinske statistike se je uveljavila drugačna terminologija, in sicer je ROC krivulja prikaz senzibilnosti (angl. *sensitivity*, *TPR*) proti *1-Specificity* (tj. *FPR*), kjer je *Specificity* specifičnost (angl. *specificity*, *TNR*) (Webb 2002, 260).

Slika 8: Grafikon ROC krivulje in Venovi diagrami



Prikaz ROC krivulje dejansko prikazuje stopnje resničnih pozitivnih glede na stopnjo napačnih pozitivnih primerov pri izbrani odločitveni meji. Npr. odločitveni kriterij pri meji 0,5 ustreza le eni točki na krivulji, ki je določena s *FPR* in *TPR* (Sinha in May 2005, 265). Premik po krivulji pomeni torej spremembo odločitvenega kriterija (višje ali nižje) in *trade-off* odločitev uporabnika med *TPR* – tj. koristmi modela in *FPR* – tj. stroški modela (Fawcett 2003, 3; Hunter in drugi 2000, 14). Pri tem moramo vedeti, da manjši kot je presek med razredoma podjetij s pozitivnimi (nemodificiranimi) in podjetij z

modificiranimi mnenji⁴⁴, bolj je klasifikacijski model lahko natančen – več pravih klasifikacij, manj nepravilnih. Slednje se odraža tudi pri izrisu ROC krivulje klasifikacijskega modela, kjer se boljši klasifikacijski model nahaja višje levo zgoraj v ROC ravnini (glej Sliko 8 zgoraj desno, kjer zgornjemu Venovemu diagramu z večjim presekom pripada nižja ROC krivulja in spodnjemu desnemu Venovemu diagramu z manjšim presekom pripada višja ROC krivulja).

V ravnini ROC krivulje ima poseben pomen več različnih točk, ki predstavljajo poseben primer klasifikacijske zmožnosti modela (Fawcett 2003, 4; Flach 2004, 10; Sinha in May 2005, 265), in sicer:

- točka (0,0) levo spodaj na grafikonu predstavlja strategijo klasifikacijskega modela, ki nikoli ne poda pozitivne klasifikacije (vedno poda negativno klasifikacijo). Takšen klasifikator ne naredi nobene napačne pozitivne napake, vendar tudi ne klasificira nobenega resnično pozitivnega primerja;
- točka (1,1) zgoraj desno na grafikonu predstavlja obratno strategijo, kjer klasifikator vedno poda pozitivno klasifikacijo, vendar naredi tudi napačne pozitivne klasifikacije;
- točka (0,1) levo zgoraj na grafikonu predstavlja perfektno klasifikacijsko (angl. *perfect classification*) zmožnost klasifikatorja⁴⁵.

Bolj kot se krivulja nahaja višje levo zgoraj, boljši je klasifikacijski model v povprečju – stopnja resničnih pozitivnih (*TPR*) je visoka, stopnja napačnih pozitivnih (*FPR*) je nizka ali kombinacija obojega (Sinha in May 2005, 265). Pri tem klasifikator, ki se nahaja v levem delu ravnine blizu leve osi, označujemo kot konservativnega: napravi pozitivno klasifikacijo, le če je močan dokaz, tako da posledično napravi manj napačnih pozitivnih napak, vendar ima tudi nižjo stopnjo resničnih pozitivnih (*TPR*). Klasifikator bližje zgornjemu desnemu kotu grafičnega prikaza ROC krivulje je liberalnejši, kar pomeni, da napravi pozitivno klasifikacijo tudi s šibkejšimi dokazi, kar ima za posledico več pozitivnih klasifikacij, vendar tudi višjo stopnjo napačnih pozitivnih (*FPR*) (Fawcett 2003, 4).

Diagonalna linija v ROC ravnini, kjer velja $FPR_i = TPR_i$, $i = 1, \dots, n$, predstavlja strategijo naključnega ugibanja razreda. Npr., če klasifikacijski model ugiba naključno (npr. met kovanca), lahko pričakujemo, da bo polovico primerov klasificiral kot pozitivnih in drugo polovico kot negativne, kar bi predstavljalo točko (0'5,0'5) v ROC ravnini. Če bo klasifikator nastavljen, da pripiše 90 % primerov pozitivnemu razredu, se lahko pričakuje, da ugani 90 % pozitivnih primerov pravilno, vendar tudi stopnja napačnih pozitivnih primerov se poveča na 90 %, kar predstavlja točko (0'9,0'9) v ROC ravnini. Katerikoli klasifikator, ki deluje na osnovi stohastičnosti, bo predstavljal ROC točke na diagonalni glede na frekventnost/pogostost, s katero identificira pozitivni razred (Sinha in May 2005, 265). Kot navaja Fawcett (2003, 4), da se klasifikacijski model ne-bi nahajal na diagonalni liniji, mora iz predstavljenih podatkov razbrati neke informacije. Glede na vsebinski

⁴⁴ Presek je manjši v primeru, da informacije omogočijo močan signal oz. nedvoumno razlikovanje med razredoma podjetij z različnimi vrstami mnenj. V tem primeru je izbor odločitvene meje lažji in omogoča popolno ali skoraj popolno natančnost klasifikacijskega modela z nič ali malo lažnimi signali.

⁴⁵ Kot navajajo Hunter in drugi (2000, 14) je model perfekte klasifikacije možno doseči v primeru, ko sta dva razreda med seboj popolnoma razdružljiva. V realnih primerih je slednje redek pojav, kajti vedno obstaja nekaj povezav med razredi (angl. *overlap*) in zato naj bi se optimalen klasifikacijski model, ki je možen, nahajal nekje v zgornjem levem delu ravnine blizu točke (0,1). Vendar, kot opozarjajo Hunter in drugi (2000, 14), ne vemo *a priori*, kakšen je optimalen dosegljiv rezultat.

pomen diagonale grafikona je vsak klasifikacijski model, ki se nahaja desno od diagonale slabši, kot če bi se uporabnik poslužil naključnega ugibanja.

Pomembna pozitivna lastnost ROC krivulje je v neodvisnosti od sprememb v razredni prerazporeditvi (Fawcett 2003, 7-8). Če se delež pozitivnih glede na negativne spremeni, se ROC krivulja ne spremeni. Katerokoli drug kriterij, ki za izračun uporabi vrednosti iz obeh stolpcev kontingenčne tabele, je odvisen od razredne porazdelitve podjetij oz. njihove razpršenosti. S spremembo razredne porazdelitve se spremenijo tudi merila, tudi če se uspešnost klasifikatorja s tem ne spremeni. Stopnja napačnih pozitivnih (*FPR*) in stopnja resničnih pozitivnih (*TPR*), ki sta osnova za prikaz ROC krivulje, sta samostojni merili in drug od drugega neodvisni, zato tudi nista odvisni od razredne porazdelitve.

Izris ROC krivulj klasifikacijskih modelov nam tudi omogoča vizualno primerjavo uspešnosti različnih modelov skozi celoten spekter odločitvenih mej neodvisno od predhodnih verjetnosti in stroškov napačnih klasifikacij (Sinha in May 2005, 265; Hunter in drugi 2000, 14). Če npr. ROC krivulja za podan model dominira nad drugim modelom čez celoten spekter, potem lahko zaključimo, da je predhodni model boljši kot drugi, vendar, kot je običajno primer, eden model je lahko boljši v nekaterih predelih in slabši v drugih od drugega modela⁴⁶.

Ocenjevanje uspešnosti klasifikacijskih modelov s pomočjo ROC krivulje pokaže spekter možnih alternativ, ki jih ima uporabnik/revizor pri odločanju. Vendar pa ima uporabnik večkrat željo že zaradi praktično operativnih razlogov, da bi imel na voljo številsko vrednost (skalar) kot indikator uspešnosti klasifikatorja, da bi lahko primerjal uspešnost različnih klasifikacijskih modelov (Webb 2002, 260). V nadaljevanju prikazujemo takšen kriterij, ki omogoča razlikovanje klasifikacijskih modelov na podlagi izračuna ene številске vrednosti.

3.2.2.1 Kriterij AUC (Področje pod krivuljo ROC)


ROC krivulja je dvodimenzionalna predstava klasifikatorjeve uspešnosti, ki je neodvisna od porazdelitve razredov in stroškov napačnih klasifikacij in je zato primeren kriterij za ocenjevanje uspešnosti modelov, ko predhodne verjetnosti in stroški ali niso znani ali so težko ocenljivi *a priori* ali so podvrženi nenehnim spremembam. Klasifikacijske modele pa lahko primerjamo tudi na podlagi ene same številke vrednosti/skalarja, ki predstavlja pričakovano uspešnost klasifikacijskega modela. Kot kriterij lahko uporabimo število, ki predstavlja izračunan površine (področja) pod krivuljo ROC (angl. *area under the curve*), označeno z AUC (Bradley 1997; Hanley in McNeil 1982; povzeto po Fawcett 2003, 13; Sinha in May 2005, 265). Kriterij AUC (tudi *c*-statistika oz. *c*-indeks (Shahian in drugi 2004, 1881)) je agregatni kriterij uspešnosti (angl. *aggregate performance measure*), ki oceni uspešnost modela preko celotnega razpona možnih odločitvenih mej⁴⁷ (Sinha in May 2005, 265) in je neodvisen od stroškov napačnih klasifikacij⁴⁸ (Webb 2002, 261).

⁴⁶ Glej npr. Sliko 9 v poglavju 3.2.2.1 Kriterij AUC (Področje pod krivuljo ROC).

⁴⁷ Dejansko AUC področje predstavlja zmožnost diskriminacije klasifikacijskega modela med pravnimi klasifikacijami podjetij s pozitivnimi mnenji in podjetij z modificiranimi mnenji.

⁴⁸ Predpostavlja se, da ničesar ni znanega o stroških napak tipa 1 in 2 in da ni vpliva dejavnikov, ki bi lahko vplivali na uporabo odločitvenega pravila oz. določitev odločitvene meje (Webb 2002, 261).

Slika 9: Področje pod krivuljo ROC



Vir podatkov: Lastni prikaz.

AUC torej predstavlja površino pod ROC krivuljo, katera vrednost bo na intervalu med 0 in 1, kajti maksimalna vrednost ordinatnih osi je enaka enotskemu vektorju 1. Ker pa naključno ugibanje predstavlja diagonalno linijo $FPR = TPR$, ki ima površino enako 0,5, ni realistično pričakovati, da bi klasifikacijski model imel AUC manjši od 0,5 (Fawcett 2003, 13). Splošno uporabljen napotek pri interpretaciji natančnosti modela klasifikacije je 5-stopenjski točkovni sistem, kjer velja, da je klasifikacijski model, ki ima AUC v intervalu (Schalkwyk in Schalkwyk 2003): (1) od 0,9 do 1 – odličen klasifikator (razred A); (2) od 0,8 do 0,9 – dober klasifikator (razred B); (3) od 0,7 do 0,8 – zadovoljiv klasifikator (razred C); (4) od 0,6 do 0,7 – slab klasifikator (razred D) in (5) od 0,5 do 0,6 – neuspešen klasifikator (razred E).

Enačba za izračun področja pod krivuljo (AUC) je integral funkcijske oblike ROC krivulje v mejah intervala $[0,1]$. Izpeljavo enačbe za izračun AUC podaja Webb (2002, 261-263); končna oblika enačbe za izračun AUC je:

$$AUC_i = \frac{1}{n_p n_m} \cdot \left(S_0 - \frac{1}{2} \cdot n_p \cdot (n_p + 1) \right) \quad (3.12),$$

kjer sta n_p in n_m število podjetij s pozitivnim (nemodificiranim) oz. modificiranim mnenjem in S_0 vsota rangov razreda podjetij s pozitivnimi (nemodificiranimi) mnenji za izbrani vzorec podatkov⁴⁹.

Pomembna statistična značilnost kriterija AUC je, da je vrednost AUC enaka verjetnosti, da bo model označil slučajen izbor podatkovnega niza prej pozitivno kot pa negativno, kar pa je po Hanley in McNeilu (1982; povzeto po Fawcett 2003, 13) ekvivalentno Wilcoxonovemu testu vsote rangov (tudi Man-Whitney test vsote rangov; angl. *Wilcoxon's rank sum test*). Slednje omogoča primerjavo dveh ROC krivulj in s tem primerjavo dveh klasifikacijskih modelov na podlagi statistične korelacije področij pod krivuljama ROC (Hanley in McNeil 1983; povzeto po Sinha in May 2005, 266; Flach 2004, 30; Schalkwyk in Schalkwyk 2003). Izračun vrednosti z , ki omogoča primerjavo, je enak

⁴⁹ Enačba dejansko predstavlja oceno verjetnosti, da ima slučajno izbrano podjetje iz razreda podjetij z modificiranimi mnenji nižjo verjetnost, da pripada razredu podjetij s pozitivnimi mnenji kot naključno izbrano podjetje iz razreda podjetij s pozitivnimi mnenji (Webb 2002, 262).

$$z = \frac{(AUC_i - AUC_j)}{\sqrt{SE_i^2 + SE_j^2 - 2r_{ij} \cdot SE_i \cdot SE_j}} \quad (3.13),$$

kjer sta AUC_i in AUC_j , $i, j = 1, \dots, n$ in $i \neq j$, enaka področju pod pripadajočo ROC krivuljo, SE_i in SE_j sta ocenjeni standardni napaki področja AUC_i ter AUC_j in r_{ij} je ocenjen korelacijski koeficient med AUC_i in AUC_j , kjer $i, j = 1, \dots, n$ in $i \neq j$. Vrednost z je determinirana z vrednostmi v tabeli za normalno porazdelitev⁵⁰ (Sinha in May 2005, 266; Schalkwyk in Schalkwyk 2003) in če je z nad določeno (arbitrarno izbrano) kritično vrednostjo (običajno 0'05), potem lahko zaključimo, da sta AUC_i in AUC_j različna. Enačba za izračun standardne napake pri izračunu AUC_i (angl. *standard error*) je

$$SE_i = \sqrt{\frac{AUC_i \cdot (1 - AUC_i) + (n_p - 1) \cdot (Q_0 - AUC_i)^2 + (n_m - 1) \cdot (Q_1 - AUC_i)^2}{n_p \cdot n_m}} \quad (3.14),$$

kjer so že uporabljene oznake enake predhodnim, Q_0 in Q_1 pa sta enaka (Schalkwyk in Schalkwyk 2003; Webb 2002, 262-263)

$$Q_0 = \frac{AUC_i}{2 - AUC_i} \quad \text{in} \quad Q_1 = \frac{2 \cdot AUC_i^2}{1 + AUC_i} \quad (3.15a) \text{ in } (3.15b).$$

Vrednost korelacijskega koeficienta r_{ij} med AUC_i in AUC_j je možno pridobiti na podlagi tabele korelacijskih koeficientov, ki jo podata avtorja metode izračuna vrednosti z Hanley in McNeil (1983, 841). Za izračun korelacijskega koeficienta sta potrebna dva korelacijska koeficienta⁵¹ med skupino, ki pripada razredu ω_i po AUC_i , in drugo skupino, ki tudi pripada razredu ω_i , vendar po AUC_j . Identično se izračuna korelacijski koeficient za vse ostale možne razrede/skupine⁵².

Kriterij AUC omogoči neposredno primerjavo dveh ali več klasifikacijskih modelov na podlagi numeričnih vrednosti. V kolikor ima klasifikator višjo vrednost AUC od drugega klasifikatorja, potem je uspešnost/zmožnost prvega klasifikatorja v povprečju boljša od drugega (višji AUC nakazuje klasifikatorjevo boljšo agregatno uspešnost). Vendar kot prikazujemo na Sliki 9, vedno obstaja možnost, da je klasifikacijski model z višjo vrednostjo AUC v nekaterih predelih ROC krivulje slabši od drugega klasifikacijskega modela z nižjim AUC.

Omenimo še, da je alternativna oblika zapisa kriterija AUC možna v obliki Ginijevega koeficienta⁵³ (angl. *Gini coefficient*) (Breiman in drugi 1984; povzeto po Fawcett 2003, 13), saj je področje pod krivuljo ROC povezano z Ginijevim koeficientom, ki je enak dvakratniku področja med diagonalo in ROC krivuljo. Hand in Till (2001; povzeto po Fawcett 2003, 13; Flach 2004, 30) opozorita, da velja:

⁵⁰ Obstajajo tudi druge možnosti za primerjavo modelov med seboj. Tako Luther (1998, 62), ki je uporabil v svoji raziskavi več različnih tehnik za razvoj modelov, primerja dva modela na podlagi t -statističnega testa.

⁵¹ Hanley in McNeil (1983, 840) dopušča možnost izračuna Pearsonevega korelacijskega koeficienta ali Kendalovega koeficienta korelacije rangov; lahko pa tudi katerega drugega.

⁵² Gre za izračun korelacijskega koeficienta med podjetji, ki prejmejo pozitivno mnenje, in podjetji, ki prejmejo modificirano vrsto mnenja.

⁵³ Izpeljano iz statistike o Lorenzovi krivulji.


$$\text{Gini coefficient} = 2 \cdot AUC_i - 1 \quad (3.16).$$

3.2.2.2 Krivulje enake uspešnosti

Prednost izrisa ROC krivulje in kriterija AUC je, da omogoča vizualizacijo oz. izračun klasifikatorjeve uspešnosti brez upoštevanja razredne porazdelitve ali stroškov napačnih klasifikacij. Vendar stroški napačnih klasifikacij lahko igrajo pomembno vlogo pri odločitvah uporabnikov, saj so odločitve lahko stroškovno zelo občutljive. Podobno velja tudi za razredne prerazporeditve oz. spremembo porazdelitve razredov. ROC krivulja in vrednost AUC se kljub spremembam v teh dveh komponentah ne spremenita (Fawcett 2003, 17-18), vendar pa se spremeni razpon/interval možnih odločitvenih mej, ki so v interesu uporabnika oz. za uporabnika sprejemljive.

Provost in Fawcett (2001; povzeto po Fawcett 2003, 18) sta pokazala, da je sklop spreminjajočih se operativnih pogojev možno prikazati s pomočjo linij enake uspešnosti (angl. *iso-performance lines*) v ROC ravnini. Linija enake uspešnosti posameznega klasifikacijskega modela je vizualen pripomoček, ki povezuje točke, kjer ima klasifikacijski model enake pričakovane stroške napačnih klasifikacij preko celotnega razpona možnih odločitvenih mej v ravnini ROC krivulje.

Slika 10: Linije enake uspešnosti



Vir podatkov: Lastni prikaz.

Da lahko prikažemo linije enake uspešnosti pa je potrebno v odločitveno analizo vključiti vse vrste stroškov, ki se pojavijo pri odločanju. Kot predlagajo Metz in drugi (1976; povzeto po Benttinger 2003, 5) je izračun povprečnih stroškov klasifikacijskega modela predstavljen z:

$$\begin{aligned} \bar{C} &= \bar{C}_0 + \sum_i \sum_j c_{ij} \cdot P(\text{Napovedano}_i, \text{Dejansko}_j) \\ &= \bar{C}_0 + \sum_i \sum_j c_{ij} \cdot P(\text{Napovedano}_i | \text{Dejansko}_j) \cdot P(\text{Dejansko}_j) \end{aligned} \quad (3.17),$$

kjer c_{ij} , $i, j = 0, 1, \dots, n$, predstavlja stroške pravilne, ko je $i = j$, in napačne klasifikacije, ko $i \neq j$, in $\bar{C}_0$ predstavlja stalne stroške (angl. *fixed overhead costs*) procesa odločanja⁵⁴.

⁵⁴ Pri izračunu stroškov se implicitno predpostavlja, da je funkcijska oblika enačbe stroškov enostavna in da lahko povprečno vrednost stroškov izračunamo s pomočjo seštevanja posameznih stroškov.

Če označimo $Napovedano_i$ in $Dejansko_j$ s kombinacijo oznak i in j , kjer velja $i, j = 0$ in 1 , potem lahko za kontingenčno matriko 2×2 ⁵⁵, zapišemo zgornjo enačbo kot

$$\overline{C} = \overline{C}_0 + c_{00} \cdot P_{00} \cdot P_0 + c_{10} \cdot P_{10} \cdot P_0 + c_{01} \cdot P_{01} \cdot P_1 + c_{11} \cdot P_{11} \cdot P_1 \quad (3.18).$$

Koordinati ROC krivulje sta TPR in FPR , ki sta dva neodvisna faktorja, ki vplivata na izračun celotnih povprečnih stroškov. Ker sta TPR in FPR odvisna od odločitvene meje, bo tudi sprememba te meje vplivala na spremembo celotnih povprečnih stroškov. Najboljša stroškovna učinkovitost je dosežena v točki/intervalu, kjer so celotni povprečni stroški minimalni – tj. v točki, kjer je prvi odvod stroškovne funkcije enak 0. Če stroškovno funkcijo odvajamo po FPR in enačimo z 0 dobimo

$$\frac{dP_{00}}{dP_{10}} = \frac{P_1 \cdot (c_{10} - c_{11})}{P_0 \cdot (c_{01} - c_{00})} \quad (3.19).$$

V primeru, da predpostavimo, da so stroški pravilno opravljenih klasifikacij razvrščeni pod stalne stroške, ker se bodo ti stroški pojavili v vsakem primeru pri uporabi klasifikacijskega modela in so neizogibni, potem velja, da je c_{11} in c_{00} enak 0. Stroškovno funkcijo lahko v tem primeru zapišemo kot funkcijo stroškov napačnih klasifikacij (Fawcett 2003, 18; Sinha in May 2005, 266; Webb 2002, 260), tj.

$$\overline{C}_c = c_{01} \cdot P_{01} \cdot P_0 + c_{10} \cdot P_{10} \cdot P_1 \quad (3.20a)$$

oziroma

$$\overline{C}_c = c_{01} \cdot (1 - \text{Sensitivity}) \cdot P_0 + c_{10} \cdot (1 - \text{Specificity}) \cdot P_1 \quad (3.20b)$$

za katerokoli točko (FPR_i, TPR_i) , $i = 1, \dots, n$, na krivulji ROC in posledično so stroški minimalni, kjer je

$$\frac{dP_{00}}{dP_{10}} = \frac{P_1 \cdot c_{10}}{P_0 \cdot c_{01}} \quad (3.21)$$

enako 0. Zadnji izraz pa v ROC ravnini prikazuje naklon linije enake uspešnosti (enakih stroškov), in sicer v točki, kjer je linija enake uspešnosti enaka tangenti na ROC krivuljo v isti točki – tj. točka, kjer so stroški minimalni. Ne obstaja nobenega drugega stičišča med ROC krivuljo in funkcijo stroškov napačnih klasifikacij, kjer bi povprečni stroški napačnih klasifikacij bili nižji pri dani odločitveni meji (Webb 2002, 260).

Za linijo enake uspešnosti za dve izbrani točki (FPR_i, TPR_i) , $i = 1, \dots, n$, ki ležita na ROC krivulji, velja

$$\frac{P_1 \cdot c_{10}}{P_0 \cdot c_{01}} = \frac{TP_i - TP_j}{FP_i - FP_j} = m \quad (3.22),$$

⁵⁵ Za pomen posameznih oznak v primeru kontingenčne tabele dimenzije 2×2 glej Seznam okrajšav in oznak (stran 83).

kjer $i \neq j$ za $i, j = 1, \dots, n$ in m je enak naklonu linije enake uspešnosti. Vsi klasifikacijski modeli, ki pripadajo vsaj eni točki na liniji enake uspešnosti imajo enake pričakovane stroške napačnih klasifikacij. Sprememba porazdelitve razredov ali sprememba stroškov je dejavnik, ki spremeni naklon linij enakih uspešnosti in s tem tudi definira novo odločitveno mejo, kjer so stroški napačnih klasifikacij minimalni.

Analiza komponent naklona linij enake učinkovitosti pokaže, da so linije, ki se nahajajo čim bolj desno zgoraj v ravnini ROC boljše, saj predstavljajo klasifikacijski model z nižjimi pričakovanimi stroški napačnih klasifikacij (Webb 2002, 260). Vrednost povprečnih stroškov napačnih klasifikacij namreč konstantno narašča od levo zgoraj proti desno spodaj v ravnini ROC. Tako npr., kjer je zelo nizka verjetnost P_0 in/ali je kazalnik

razmerja stroškov $\frac{c_{10}}{c_{01}}$ (angl. *cost ratio*) veliko večji od 1, je naklon linije enake uspešnosti

zelo visok, kar nakaže, da je potrebna višja odločitvena meja, da bi zagotovili odločanje z minimalnimi stroški. Obratno velja v primeru, da je verjetnost P_0 visoka in da so stroški skoraj enaki (kazalnik razmerja stroškov je enak 1), kjer je potrebna določitev nižje odločitvene meje. Slednje predstavlja manj natančno odločanje zaradi visoke tolerance odločitev, ki so napačne pozitivne (*FPR*)⁵⁶.

3.2.3 Občutljivost in zmožnost generalizacije klasifikacijskega modela

Pri občutljivosti klasifikacijskega modela ugotavljamo, kakšna je občutljivost modela na spremembe operativnih pogojev, kot so npr. spremembe predpostavk glede klasifikacijske razredne porazdelitve. S pomočjo analize občutljivosti (angl. *sensitivity analysis*) modela determiniramo, ali majhna sprememba v porazdelitvi med razredi vpliva na spremembo končnih izidov, da te spremembe postanejo signifikantne. Podobno velja tudi za drugi dejavnik, tj. spremembe v višini stroškov napačnih klasifikacij. Če so pričakovani stroški napačnih klasifikacij modela občutljivi na majhne spremembe v predpostavkah (npr. spremembe relativne višine stroškov, op.p.), potem je model občutljiv in je možno model uporabljati, le če so predpostavke striktno izpolnjene.

Cilj razvoja klasifikacijskega modela je v njegovi aplikativni uporabnosti v različnih situacijah. Kriterij generalizacije oz. zmožnosti posplošitve modela na različne situacije zagotovi, ali je model zmožen doseči enake ugotovitve, kot jih je dosegel na razvojnih podatkih tudi na podatkih, ki jih do tedaj še ni procesiral oz. videl (tj. testnih podatkih).

3.2.4 Prilagoditev parametrov klasifikacijskega modela

Prilagoditev parametrov (kalibracija) konstruiranega klasifikacijskega modela (angl. *tuning*) omogoči odločitvena analiza, saj so klasifikatorji lahko občutljivi na stroške napačnih klasifikacij in predhodne verjetnosti pripadnosti posameznemu razredu (Sinha in May 2005, 263). Prilagoditev parametrov modela je pomembna zaradi dejstva, ker lahko

⁵⁶ V primeru, da velja $\frac{c_{10}}{c_{01}} = \frac{P_{01}}{P_{10}}$, potem so celotni pričakovani stroški enaki $\bar{C}_c = ((1 - \text{Sensitivity}) + (1 - \text{Specificity})) \cdot c_{01} \cdot P_1$ in

velja, da je 1 % napačnih klasifikacij podjetij iz razreda podjetij s pozitivnimi mnenji enaka 1 % napačnih klasifikacij podjetij iz razreda podjetij z modificiranimi mnenji.

npr. dva revizorja z enako dobrim izobraževanjem, pregledom enakih kazalnikov in pridobitvi ostalih identičnih informacij odločata različno. Vzrok je v različnih kriterijih, ki jih postavita kot sprejemljive.

Prilagoditev posameznega modela je odvisna od odločitve posameznika, njegovih zahtev in nenazadnje tudi od posameznikovih zmožnosti. Ločimo tri možne scenarije prilagoditve modela klasifikacije, in sicer: (1) po prvem scenariju se na konstruiranem modelu ne prilagodi ničesar – torej ostane v prvotni obliki, kjer je predpostavljena odločitvena meja/pravilo postavljena pri vrednosti 0,5; (2) po drugem scenariju se model prilagodi tako, da minimizira število možnih napak tipa 1 ali/ in 2, in sicer s spreminjanjem odločitvene meje/pravila. Temelj za prilagoditev modela so vrednosti, ki se pridobijo s pomočjo ROC krivulje. (3) Po tretjem scenariju se model prilagodi tako, da ta minimizira celotne stroške napačnih klasifikacij. Tudi slednje temelji na spremembi odločitvene meje/pravila v kombinaciji z izračunom stroškov napačnih klasifikacij pri posamezni odločitveni meji⁵⁷.

3.3 Sklepna misel k poglavju o metodologiji

Problem klasifikacije/identifikacije v kontekstu razvoja modela za identifikacijo (napoved) vrste revizijskega mnenja zahteva ločitev podjetij na podlagi vhodnih podatkov na skupino podjetij, ki prejmejo modificirana mnenja, in skupino podjetij, ki prejmejo pozitivna (nemodificirana) mnenja. V prvem delu pričujočega poglavja naloge je predstavljen problem in osnovne lastnosti takšne bivariantne klasifikacije. Metod oz. tehnik, ki omogočijo razrešitev takšnih klasifikacijskih/identifikacijskih problemov, je več vrst od enostavnih tehnik do visoko kompleksnih. Logistična regresija je ena izmed enostavnejših tehnik (temelji na nekaterih restriktivnih predpostavkah), vendar je zato relativno enostavna za uporabo in pogosto lahko omogoča zadostno oz. primerno rešitev pri problemu klasifikacije/identifikacije.

Pri konstruiranem modelu pa je seveda najpomembnejše vprašanje, kolikšna je njegova uspešnost (tj. identifikacijska moč) oz. kako zanesljiv je model. V idealnih pogojih, ko so stroški napačnih klasifikacij enaki in ko je populacija/skupina podjetij uravnotežena (v razmerju 1:1), podajo/prikažejo klasični kriteriji realno sliko/zmožnost klasifikacijskega modela. V primeru, ko predhodno navedeni pogoji niso izpolnjeni, so potrebni alternativni kriteriji, ki pokažejo realnejšo sliko/zmožnost klasifikacijskega modela. Kot možnost sta predstavljena krivulja operativne karakteristike modela oz. ROC krivulja, ki pokaže zmožnost klasifikacijskega modela preko celotnega spektra možnih odločitvenih mej/pravil neodvisno od stroškov napačnih klasifikacij, in z njo povezan kriterij AUC (gre za površino področja pod ROC krivuljo), ki predstavlja povprečno uspešnost klasifikacijskega modela preko celotnega spektra odločitvenih mej.

Dejstvo pa je, da so pri pojavu napačnih klasifikacij pomembni predvsem stroški napačnih odločitev/klasifikacij/identifikacij, ki so le izjemoma enaki. Pogosto (ne pa vedno) gredo želje/zahteve racionalnega uporabnika modela (tj. revizorja) v smer, ki zahteva, da je model čim bolj racionalen, kar pomeni, da se ob že nastalih stalnih stroških, ki nastanejo pri uporabi modela, minimizirajo stroški napačnih klasifikacij. Slednje ob nekaterih poznanih pogojih (tudi predpostavkah, op.p.) omogoči enačba za izračun stroškov, ki se pojavijo ob

⁵⁷ Sam postopek prilagoditve identifikacijskega/klasifikacijskega modela prikazujemo v poglavju 5.3 Prilagoditev modelov klasifikacije.

napačnih klasifikacijah. Na podlagi poznanih stroškov napačnih klasifikacij pri posamezni odločitveni meji/pravilu je v zadnjem delu poglavja predstavljena tudi možnost prilagoditve modela, da bo le-ta optimalen s stroškovnega vidika.

V tem delu naloge predstavljena statistična metodologija in predstavljeni kriteriji sledijo ugotovitvam Trigueiros in Taffler-ja (1996, 347), ki sta trdila, da »[...] statistika igra pomembno vlogo v računovodstvu ter reviziji.« Predstavljena metodologija v povezavi s predhodnim delom naloge o reviziji omogoči oz. predstavlja izhodišče za empirični del naloge – tj. za konstrukcijo modela za identifikacijo (napoved) vrste revizijskega mnenja in njegovo oceno na podlagi predstavljenih kriterijev.

(Ta stran je namerno ostala prazna.)

4 SESTAVA MODELA ZA IDENTIFIKACIJO VRSTE MNENJA

Empirični del naloge obsega konstrukcijo modela za identifikacijo (napoved) vrste revizijskega mnenja in njegovo validacijo glede na postavljene kriterije. Na končno uspešnost (angl. *performance*) modela vpliva tudi izbrana metodologija vzorčenja ter izbranih spremenljivk, kot je bilo prikazano v okviru pregleda preteklih modelov v drugem poglavju. Vendar raziskovalci nimajo enotnega mnenja glede uporabe posamezne metodologije/tehnike. Pregled možnih tehnik vzorčenja in končno oblikovanje izhodiščne baze podatkov za razvoj modela je predstavljen v prvem delu poglavja. Druga občutljiva tematika, tj. izbor spremenljivk, sledi oblikovanju izhodiščne baze podatkov o podjetjih. V zadnjem delu poglavja pa so predstavljene nekatere lastnosti konstruiranih modelov klasifikacije/identifikacije.

4.1 Vzorec in njegove (statistične) značilnosti

Model za identifikacijo vrste revizijskega mnenja konstruiramo na podlagi podatkov podjetij v letnih računovodskih izkazih. Pri zbiranju in obdelavi podatkov se pojavijo različni problemi, ki vplivajo na sam potek razvoja modela, vendar moramo vedeti, da »[...] noben model ne more biti boljši od podatkov (njihove kvalitete, op.p.), na katerih je osnovan« (Shahian in drugi 2004, 1869; Gujarati 2003, 30). Skrbno izbrana metodologija in tehnike na področju vzorčenja pred obdelavo/procesiranjem podatkov so zato ključnega pomena in slednjemu je v nadaljevanju poglavja podan poudarek pred samim procesom izbora vzorca podatkov in analizo in imputacijo manjkajočih vrednosti podatkov. Statistika nekaterih lastnosti podjetij iz izbranega vzorca podatkov, namenjenega za razvoj modela, je podana na koncu poglavja.

4.1.1 Metodologija pri vzorčenju

Vzorec podatkov, ki so uporabljeni v raziskavi, vpliva na razvoj modela in posledično na njegovo uspešnost. Najpreprostejša je uporaba celotnih razpoložljivih podatkov ne glede na pogostost pojavljanja posameznega pojava in ne glede na dejavnike, ki vplivajo na pojav, ki je v interesu pri razvoju modela. Uporaba celotnih podatkov pa ni najprimernejša in večkrat ne pripomore k pričakovani uspešnosti modela. Za primer bivariantne klasifikacijskega problema je populacija v večini primerov sestavljena iz neenakih deležev dveh lastnosti, ki so v interesu raziskovalca in različni avtorji (Zmijewski 1984, 59; Palepu 1986, povzeto po Sen in drugi 2004, 227; Jain in Nag 1997, 208) opozorjajo na ta problem (ekstremno) nizkih frekvenc opazovanega pojava, ki je v interesu pri razvoju modela (tj. podjetij z modificiranimi mnenji) ter na problem pomanjkljivosti ter nedosegljivosti podatkov za pojav, ki je v interesu raziskovalca.

Zaradi slednjih problemov so se razvijalci modelov namesto uporabe celotnega razpoložljivega vzorca podatkov poslužili uporabe prilagojenih vzorcev (angl. *choice based sample*), ki imajo prilagojeno kompozicijo in večkrat ta ni enaka pogostosti posameznega pojava v dejanski populaciji. Tako je npr. delež podjetij z modificiranimi mnenji večji v prilagojenem vzorcu, kot je v dejanski populaciji. Na področju revizije so različni avtorji (glej npr. Dupoch in drugi (1987, 433), Tam in Kiang (1992, 942)) v svojih raziskavah uporabili uravnotežen (prilagojen) vzorec ciljnih podjetij, ki vsebujejo opazovan pojav, in neciljnih podjetij, ki opazovanega pojava ne vsebujejo. Z

organizacijskega vidika je prednost uporabe prilagojenega vzorca v zreduciranih stroških zbiranja podatkov; s statističnega vidika pa bi uporaba dejanskih populacijskih deležev pri ocenjevanju parametrov modela lahko/najverjetneje povzročila nenatančno oceno parametrov modela (Zmijewski 1984, 62).

Pogosto se avtorji raziskav odločijo za razmerje 1:1 – tj. uravnoteženi vzorec podatkov (O'Leary 1998, 189; Altman in drugi 1993, 508; Slachenberger in drugi 1992, povzeto po Jain in Nag 1997, 202), da s tem zagotovijo nepristranskost pri razvoju modela klasifikacije. Dejstvo je namreč, da če se uporabi vzorec, ki odraža dejansko populacijsko sestavo, kjer je pogostost opazovanega pojava zelo nizka (nizka frekventnost), ima razvit model klasifikacije slabo klasifikacijsko zmožnost/spособnost, saj bi na testnem vzorcu, ki odraža dejansko populacijo, klasificirali vsa podjetja kot podjetja, ki ne pripadajo razredu z nizko frekvenco (Jain in Nag 1997, 202; Koh 2004, 475; Sen in drugi 2004, 227). Z uporabo uravnoteženega vzorca, kjer je vključitev v vzorec odvisna od vrednosti odvisne spremenljivke, se poskuša pri razvoju modela izolirati ključne dejavnike, ki razlikujejo drugače enaka podjetja (Morris 1997; povzeto po Charitou in drugi 2004, 474). Model namreč potrebuje zadostno izpostavitve nefrekventnemu stanju/lastnosti, da lahko oblikuje svoj polni potencial za zaznavanje nefrekventne lastnosti/stanja. S tem se zmanjšuje učinek nezaželenih dejavnikov, ki niso v interesu raziskovanja, kot so npr. industrijski sektor, velikost podjetja, sredstev ipd. Kot predlaga O'Leary (1998, 196) naj bo pri razvoju modela delež podjetij, ki pripadajo razredu z nizko frekvenco, večji ali vsaj enak tistemu deležu v testnem vzorcu.

Slabost uravnoteženega vzorčenja je, da sestava vzorca vpliva na uspešnost uporabljene statistične tehnike. Boritz in drugi (1995, povzeto po O'Leary 1998, 195; Etheridge in drugi 2000, 541-542; Anandarajan in drugi 2001, 70-71) dodajajo, da obstajajo signifikantne variacije pri uporabi posamezne metodologije v vzorcu, ko se spreminja delež podjetij, ki pripadajo razredu z nizko frekvenco. Uravnotežen vzorec namreč ne odraža dejanskega razmerja ciljnih in neciljnih podjetij v populaciji in model, ki je razvit pri nizkem deležu podjetij z nizko razredno frekvenco, ni tako uspešen pri vzorcu podatkov, kjer je ta frekvenca podjetij višja (McKee in Greenstein 2000, 221).

Več avtorjev (npr. Altman in drugi (1994), Tam in Kiang (1992) itd.) tudi za testiranje modela uporabijo uravnoteženi vzorec podatkov. Jain in Nag (1997, 209) izpostavita dejstvo, da uporaba uravnoteženih vzorcev za ocenitev uspešnosti modela, ki bo namenjen kasnejši klasifikaciji/predikciji, ni primerna. Testiranje uspešnosti modela z velikim deležem nefrekventnega pojava/lastnosti podjetij lahko pogosto privede do nerazumljivih in kompleksnih realnih odločitvenih problemov. Da lahko ocenimo prednost (dodano vrednost, op.p.) modela, je pomembno, da ga testiramo pod realnimi pogoji namesto pod zavajajočimi situacijami, ki niso realne – tj. na ločenem testnem vzorcu, ki predstavlja populacijsko kompozicijo. Jain in Nag (1997, 213-214) sta v svoji raziskavi pokazala, da se uspešnost konstruiranega modela z uporabo logistične regresije dejansko izboljšuje, ko se oddaljimo od neenakih deležev v vzorcu proti deležem, ki predstavljajo populacijsko kompozicijo, vendar kljub temu generalizacija še ni možna, ker še ni opravljenih zadostnih raziskav.

Pomemben dejavnik, ki tudi lahko močno vpliva na potek in pristop pri razvoju in ocenjevanju uspešnosti modela klasifikacije, je velikost vzorca, ki je uporabljen pri konstruiranju in testiranju modela (Ehrenfeucht in drugi 1989, Tsai in Koehler 1992;

povzeto po Hansen in drugi 1992, 718). Zadostna velikost zmanjša možnost večjih napak in pristranskosti pri ocenjenih parametrih statističnega modela.

4.1.2 Izbrani vzorec podatkov

V raziskavi uporabljeni podatki so iz podatkovne baze F.A.M.E., v katero so vključena podjetja iz Velike Britanije in Irske. Izbor podjetij iz Velike Britanije in Irske lahko utemeljimo z dejstvom, da se Velika Britanija pojmuje kot del svetovnega ekonomskega prostora. Tako ima npr. Londonska borza vrednostnih papirjev visok dnevni volumen transakcij, ki je primerljiv z drugimi velikimi svetovnimi borzami, kot so New York, NASDAQ, Tokio in Toronto Stock Exchange. Kot navaja Taffler (1984, povzeto po Charitou in drugi 2004, 467) raziskovalci pojmujejo, da Velika Britanija »omogoči finančno okolje, ki je idealno za uspešen razvoj statističnih modelov.«


Zagotovitev relativno homogenega vzorca je možna s tem, da se v vzorec ne vključijo podjetja finančnega sektorja zaradi specializirane narave računovodskih standardov (Spathis in drugi 2003, 273; Pompe in Bilderbeek 2005, 850; Raghunandan in Rama 1995, 56). Slednje je utemeljeno tudi z dejstvom, da se enaki računovodski kazalniki podjetij iz finančnega sektorja v primerjavi s podjetji iz drugih industrijskih sektorjev bistveno razlikujejo in bi njihovo upoštevanje pri razvoju modela vplivalo na slabšo uspešnost klasifikacijskega modela.

V uravnotežen vzorec vključimo vsa podjetja iz vseh sektorjev razen finančnega, ki prejmejo modificirano mnenje v obdobju od leta 1997 do 2002⁵⁸. Število in nabor kriterijev, ki se pri sestavi uravnoteženega vzorca uporabijo za izbor posameznih kontrolnih podjetij, ki prejmejo pozitivno (nemodificirano) mnenje, v različnih raziskavah variirajo. Podobno kot nekateri avtorji (Charitou in drugi 2004, 474; Lee in drugi 2005, 63; Dupoch in drugi 1987, 434 itd.) arbitrarno izberemo najpogostejše uporabljene kriterije, kot so industrijska kategorizacija, velikost sredstev podjetja itd., ki so tudi po vsebinskem pomenu primerni.

Kriteriji, na podlagi katerih so podjetja vključena v vzorec, so: (1) da je poznana vrsta revizijskega mnenja (ali podjetje prejme modificirano ali nemodificirano mnenje); (2) da podjetje kotira na Londonski borzi vrednostnih papirjev in (3) da podjetje ni kategorizirano v finančni sektor. Za izbor kontrolnih podjetij oz. podjetij, ki prejmejo nemodificirano mnenje in so vključena v vzorec, uporabimo naslednje kriterije: (4) podjetje je kategorizirano v enak sektor kot podjetje, ki prejme modificirano mnenje; (5) podjetje, ki prejme nemodificirano mnenje, ima enak ali približno enak delež stalnih sredstev v vseh sredstvih kot podjetje, ki prejme modificirano mnenje in (6) podjetje, ki prejme nemodificirano mnenje, ima približno enako vrednost vseh sredstev kot podjetje, ki prejme modificirano mnenje.

⁵⁸ Prvotno predviden vzorec bi vključeval obdobje od leta 1995 do 2002, vendar glede na postavljene kriterije v podatkovni bazi ni bilo podjetij, ki bi prejela modificirano mnenje v letih 1995 in 1996.

Slika 11: Shema sestave vzorca podatkov



Vir: Lastni prikaz.

Pri razvoju modela za identifikacijo vrste revizijskega mnenja je uporabljen uravnotežen vzorec podatkov (podatki skupine C1 na Sliki 11 zgoraj), ki obsega skupaj 530 podjetij v razmerju 1:1, tj. 265 podjetij, ki prejmejo modificirano mnenje in 265 podjetij, ki prejmejo nemodificirano mnenje⁵⁹. Validacija modela je opravljena na testnem vzorcu podatkov (podatki skupine C2 na Sliki 11 zgoraj), ki za razliko od razvojnega vzorca podatkov ni uravnotežen vzorec podatkov, ampak odseva testni vzorec realno populacijsko sestavo. Testni vzorec tako obsega 2734 podjetij, od katerih je modificirano vrsto mnenja prejelo 176 podjetij (6,4 % validacijskega vzorca)⁶⁰.

4.1.3 Analiza manjkajočih podatkov in imputacija manjkajočih vrednosti

Manjkajoče vrednosti v posameznih podatkovnih nizih lahko predstavljajo s teoretičnega kot tudi praktičnega vidika problem pri obdelavi podatkov. Statistične tehnike namreč večkrat ne dopuščajo manjkajočih vrednosti. 5 do 20 % manjkajočih vrednosti pri posameznih spremenljivkah lahko signifikantno zmanjša celoten izbrani vzorec podatkov ob opustitvi nepopolnih podatkovnih nizov. Končni vzorec popolnih podatkovnih nizov ni več reprezentativen za populacijo; z opuščanjem podatkovnih nizov pa se izgubijo tudi informacije in posledično boljša statistična moč/uspešnost konstruiranega modela⁶¹ (Truxillo 2005, povzeto po Gerber 2005, 26; Schafer 1999b). Problem predstavljajo posamezne vrednosti v podatkovnih nizih, ki niso manjkajoče slučajno/stohastično, ampak so povezane z drugimi manjkajočimi vrednostmi⁶² ali celo s spremenljivko, ki je v interesu raziskovalca (Rässler 2004, 2).

⁵⁹ Pogostost pojava modificiranega mnenja po letih za obdobje od 1997 do 2002 variira. V letu 1997 le 1 podjetje prejme modificirano mnenje, 1998 26, 1999 20, 2000 50, 2001 69 in 2002 99. V nalogi predpostavljamo, da lahko podatke po različnih letih uporabimo v enem vzorcu in da ni problemov, ki bi jih npr. povzročala nestacionarnost podatkov (tj. kazalnikov) iz obdobja v obdobje.

⁶⁰ Za leto 2003 obsega validacijski vzorec 1302 podjetij, od tega jih je prejelo modificirano vrsto mnenja 85, in za leto 2004 obsega validacijski vzorec 1432 podjetij, od katerih jih je prejelo modificirano vrsto mnenja 91.

⁶¹ Npr. 1 % verjetnost, da je vrednost manjkajoča pri stotih spremenljivkah, vodi le do 37 % možnih popolnih podatkovnih nizov, ki so razpoložljivi za analizo ob predpostavki, da so lahko uporabljeni le popolni podatkovni nizi. Če mejo verjetnosti povečamo na 5 %, je manj kot 1 % možnosti, da so podatki razpoložljivi za analizo s stotimi spremenljivkami (Truxillo 2005, povzeto po Gerber 2005, 26).

⁶² Analiza manjkajočih vrednosti podatkov razreši vprašanje, kako so podatki povezani z ostalimi manjkajočimi in prisotnimi podatki. Manjkajoče vrednosti v podatkovnem nizu se pojavijo ali (1) popolnoma slučajno (MCAR – missing

Običajno splošno sprejeta metoda za ravnanje z manjkajočimi vrednostmi je vstavitvev oz. imputacija (angl. *impute*), tj. umestitev ene ali več možnih vrednosti na mesto manjkajočih podatkov v podatkovnem nizu. Enostavnejše enkratne umestitvene tehnike kot npr. umestitev povprečnih vrednosti (angl. *mean imputation*), linearna interpolacija (angl. *linear interpolation*) ali regresijska imputacija (angl. *regression imputation*) imajo običajno za posledico intervale zaupanja in *p*-vrednosti, ki se ne menijo za negotovost glede manjkajočih podatkov, kajti umeščeni podatki so bili obravnavani pod predpostavko, kot da so bili fiksno znane vrednosti (Schafer 1999b; Rässler 2004, 2). Kompleksnejše umestitvene tehnike kot je multipla imputacija (angl. *multiple imputation*) omogoča ocenitev negotovosti pri umestitvi novih podatkovnih vrednosti na mesto manjkajočih, kar ima za posledico širše ocenjene intervale zaupanja in *p*-vrednosti, ki sugerirajo manjšo signifikantnost, kot je to v primeru enkratne umestitve (Rässler 2004, 3; Gerber 2005, 35).

Multipla imputacija je tehnika, ki temelji na metodi Monte Carlo. Manjkajoče vrednosti v podatkovnih nizih so nadomeščene na podlagi verjetnostne porazdelitve z upoštevanjem kovarianc prisotnih podatkov⁶³. Po izračunu nepristranskih ocen in intervalov zaupanja, ki odražajo negotovost zaradi manjkajočih vrednosti, lahko nadaljujemo analizo pod predpostavko, da so vsi podatki resnični in prisotni (Purdon, Raab in Buckner 2005). Imputacija podatkov je samo način, ki omogoči, da lahko izvedemo statistično analizo in jo prilagodimo zaradi manjkajočih vrednosti.

Deskriptivna statistična analiza prilagojenega vzorca za razvoj modela za identifikacijo vrste revizijskega mnenja pokaže, da niso prisotni vsi podatki v podatkovnih nizih. Tabela 15 je podana v Prilogi 1. Pri 15 spremenljivkah manjka več kot 5 % vrednosti. Analiza manjkajočih vrednosti⁶⁴ pokaže, da če bi upoštevali le popolne podatkovne nize pri analizi, bi popoln vzorec bil signifikantno manjši, in sicer bi se zmanjšal na 233 podjetij s prvotnih 530 (44 % prvotnega prilagojenega vzorca; glej Tabelo 16 v Prilogi 2).

Zaradi prevelikega zmanjšanja vzorca in s tem pričakovane prevelike izgube informacij, če upoštevamo le popolne podatkovne nize pri raziskavi, uporabimo program NORM 2.03⁶⁵, ki omogoča multiplo imputacijo podatkov. Opravljenih je 5 podatkovnih augmentacij (simulacij) s 6.000 cikli in shranjevanjem vrednosti na vsakem 1.200-tem ciklu. Na podlagi rezultatov smo umestili predvidene vrednosti namesto manjkajočih vrednosti in s tem oblikovali popoln prilagojen vzorec, ki ga uporabimo za konstrukcijo modela⁶⁶. Razlika, ki nastane med vzorcem z umeščenimi nadomestnimi vrednostmi in vzorcem z manjkajočimi podatki, je zanemarljiva, kar prikazujemo v Tabeli 17 v Prilogi 3, utemeljeno pa s pomočjo Kruskal-Wallis statističnega *H*-testa⁶⁷.

completely at random) ali (2) slučajno (MAR – *missing at random*), kjer vrednosti v podatkovnem nizu manjkajo zaradi dejavnikov, ki niso vključeni v drugih spremenljivkah in (3) neslučajno (MNAR – *missing not at random*).

⁶³ Imputacija manjkajočih vrednosti podatkovnih nizov temelji na izvedenih simulacijah. Vsaka umeščena vrednost v posamezni simulaciji je analizirana na podlagi standardnih statističnih metod in rezultati se nato kombinirajo, da se pridobijo ocene in intervali zaupanja, ki odražajo negotovost zaradi manjkajočih vrednosti (Schafer 1999b).

⁶⁴ Analizo manjkajočih vrednosti opravimo s pomočjo funkcije Missing Value Analysis statističnega programa SPSS, verzije 13.0. Imputacija podatkov ni priporočljiva s programom SPSS, kajti kot navaja Hippel von (2004, 160-164), program ne poda primernih vstavljenih vrednosti.

⁶⁵ Program NORM 2.03 (avtor Joe Schafer) je dosegljiv na naslovu <http://www.stat.psu.edu/~jls/misoftwa.html> [16.6.2006].

⁶⁶ Pogojev oz. predpostavka, ki jo pri tem postavljamo, je, da ne obstaja pristranskost pri izboru podjetij v izbrani vzorec podatkov – tj. podjetja, ki nimajo znanih vseh vrednosti kazalnikov, se pojavljajo le stohastično/naključno.

⁶⁷ Podrobnejša razlaga Kruskal-Wallisovega testa je podana pod opombo številka 69.

4.1.4 Deskriptivna statistika izbranega vzorca

Nekatere osnovne statistične značilnosti skupin podjetij, ki prejmejo modificirano in nemodificirano mnenje, prikazujemo v Tabeli 5 spodaj. Na podlagi deskriptivne statistike ni možno sklepati, ali so podjetja, ki prejmejo nemodificirano mnenje, pogosto večja od podjetij, ki prejmejo modificirano mnenje. Podobno velja tudi za gibliva sredstva podjetij in kar je posebej zanimivo za vrednost, ki jo podjetja namenijo revizijskih hišam za opravljeno storitev revizije ($\chi^2=1,859$, $p=0,173$). Za podjetja, ki prejmejo nemodificirano mnenje, velja tudi, da je njihova donosnost, učinkovitost, likvidnost in aktivnost večinoma boljša od podjetij, ki prejmejo modificirano mnenje (glej Tabelo 20 v Prilogi 6).

Tabela 5: Deskriptivna statistika nekaterih značilnosti podjetij za izbrani vzorec

		Podjetja, ki prejmejo nemodificirano mnenje		Podjetja, ki prejmejo modificirano mnenje		Kruskal-Wallis test	
		Povprečje	Standardni odklon	Povprečje	Standardni odklon	χ^2	Signifikantnost
		1a	1b	2a	2b	3a	3b
1	Vsa sredstva podjetja	81.054,33	650.667,24	79.292,85	620.096,80	0,372	0,542
2	Gibljiva sredstva podjetja	35.032,09	290.988,71	36.959,51	317.328,00	1,983	0,159
3	Osnovni kapital delničarjev	34.419,42	256.239,85	30.593,20	259.147,90	7,919	0,005
4	Prihodki v obdobju	80.657,56	403.732,35	100.246,90	752.378,50	5,138	0,023
5	Dobiček ali izguba v obdobju	1.050,12	19.743,54	-17.200,17	113.455,80	86,625	0,000
6	Vrednost odhodkov za revizijske storitve	71,49	148,02	99,56	302,81	1,859	0,173

Vir podatkov: Lastni izračun.

4.2 Izbor spremenljivk

4.2.1 Nabor spremenljivk

Osnovno in pogosto kompleksno, tudi kontraverzno, vprašanje je število in vrsta spremenljivk, ki naj se vključijo v model za identifikacijo vrste revizijskega mnenja. Večkrat se namreč lahko zgodi, da so nekatere spremenljivke statistično signifikantne, torej imajo v modelu veliko težo, vendar nimajo vsebinske pomembnosti. Neprimeren izbor spremenljivk lahko povzroči preveliko prilagajanje statističnega modela obstoječim podatkom (angl. *overfitting*), nestabilnost modela pri podatkih izven vzorca, povečane stroške in težave pri zbiranju podatkov (Harrell 2001; Harrell 1996, Hosmer 1989; Tu in drugi 1997; povzeto po Shahian in drugi 2004, 1868).

Splošno sprejetega pravila, katere spremenljivke naj bi bile vključene v model za identifikacijo vrste revizijskega mnenja, ni. Potreba po modificiranem revizijskem mnenju v podjetju naj bi se odsevala v eni ali večih komponentah/faktorjih, ki predstavljajo finančno stanje in uspešnost podjetja. Ker sta že Beaver (1966) in Altman (1968) v svojih pionirskih raziskavah pokazala, da je finančno stanje in uspeh podjetja lahko prikazan z računovodskimi in/ali finančnimi kazalniki, so jih v preteklosti pogosto uporabljali raziskovalci (glej npr. Dupoch in drugi 1987, Hansen in drugi 1992, Krishnan in Krishnan 1996; Mutcher in drugi 1997 itd.) pri konstruiranju različnih modelov na področju revizije.

Nabor možnih spremenljivk se z leti in nenehno inovativnostjo avtorjev raziskav na področju računovodstva in financ povečuje.

V Tabeli 6 spodaj podajamo seznam, podrobnejši opis/definicijo in način izračuna možnih spremenljivk pa v Prilogi 4, ki je bil oblikovan pri pregledu nekaterih relevantnih del s področja računovodstva in financ, kot so (dela so razvrščena po abecednem zaporedju, op.p.) Altman (1968); Beaver (1966); Boynton, Johnson in Kell (2003); Brigham in Ehrhardt (2005); Dupoch in drugi (1987); Koletnik (2006); Krishnan in Krishnan (1996); Lee in drugi (2005); Mutchter in drugi (1997); SIR (2005); Spathis in drugi (2003) ter Wild, Subramanyam in Halsey (2003). Kriteriji pri oblikovanju seznama so bili pogostost uporabe posameznega kazalnika, vsebinski pomen posameznega kazalnika in pa javna dostopnost podatkov za izračun kazalnika. Kazalnike so razvrščeni na 4 vsebinska področja, tj. (I) kazalnike dobičkonosnosti, (II) kazalnike uporabe sredstev in učinkovitosti, (III) kazalnike likvidnosti in (IV) kazalnike kapitalske strukture in solventnosti, ki skupaj predstavljajo neko sliko stanja, uspešnosti in učinkovitosti podjetja.

Tabela 6: Kazalniki po vsebinskih sklopih

I.	II.	III.	IV.
Kazalniki dobičkonosnosti	Kazalniki uporabe sredstev in učinkovitosti	Kazalniki likvidnosti	Kazalniki kapitalske strukture in solventnosti
X₁ ► Koefficient čiste donosnosti sredstev X₂ ► Koefficient čiste donosnosti kapitala X₃ ► Koefficient donosnosti razpoložljivega kapitala X₄ ► Stopnja rasti kapitala X₅ ► Kazalnik (kosmate) donosnosti prodaje X₆ ► Kazalnik donosnosti poslovne dejavnosti X₇ ► Kazalnik čiste donosnosti poslovanja X₈ ► Kazalnik donosnosti poslovanja pred plačilom davkov X₉ ► Kazalnik donosnosti poslovanja pred plačilom davkov in obresti X₁₀ ► Kazalnik razmerja med denarnim tokom iz poslovanja in poslovnim izidom X₁₁ ► Kazalnik dobičkonosnostnega vzvodja X₁₂ ► Koefficient obračanja kapitala podjetja	X₁₃ ► Basic earnings power X₁₄ ► Koefficient obračanja sredstev X₁₅ ► Koefficient obračanja stalnih sredstev X₁₆ ► Koefficient obračanja denarja X₁₇ ► Čista obratna sredstva/kapital X₁₈ ► Koefficient obračanja čistih obratnih sredstev X₁₉ ► Koefficient obračanja kratkoročnih obveznosti do virov sredstev	X₂₀ ► Kratkoročni koefficient X₂₁ ► Koefficient neposredne pokritosti kratkoročnih obveznosti – Hitri koefficient X₂₂ ► Koefficient pospešene pokritosti kratkoročnih sredstev – Pospešeni koefficient X₂₃ ► Koefficient obračanja zalog X₂₄ ► Čas držanja zalog X₂₅ ► Koefficient obračanja terjatev X₂₆ ► Čas do poplčila terjatev X₂₇ ► Trajanje ciklusa proizvodnje X₂₈ ► Koefficient obračanja kratkoročnih obveznosti do dobaviteljev X₂₉ ► Čas do plačila kratkoročnih obveznosti do dobaviteljev X₃₀ ► Čas obračanja denarja X₃₁ ► Koefficient denarnega toka glede na kratkoročne obveznosti do virov sredstev	X₃₂ ► Stopnja zadolženosti X₃₃ ► Stopnja dolgoročne zadolženosti X₃₄ ► Kazalnik dolgovno-kapitalskega razmerja X₃₅ ► Kazalnik dolgoročno dolgovno-kapitalskega razmerja X₃₆ ► Kazalnik finančnega vzvodja X₃₇ ► Indeks finančnega vzvodja X₃₈ ► Koefficient pokrivanja odhodkov obresti s poslovnim izidom iz rednega delovanja X₃₉ ► Kazalnik Z po Altmanu

Vir podatkov: Lastni prikaz.

Problem, ki se pri uporabi velikega števila spremenljivk lahko pojavi, je korelacija ene ali več spremenljivk z eno ali več spremenljivkami in/ali multikolinearnost. V prvem primeru gre za korelacijo neodvisne spremenljivke z drugo spremenljivko oz. več spremenljivkami v primeru multiple korelacije. V primeru multikolinearnosti je neodvisna spremenljivka enaka ali skoraj enaka linearni kombinaciji ene spremenljivke in/ali več neodvisnih

spremenljivk. Prisotnost obeh problemov med spremenljivkami lahko zmanjšuje statistično pomembnost posameznih neodvisnih spremenljivk, povzroča napačne predznake in moč/velikost ocenjenih regresijskih koeficientov in posledica je lahko tudi v napačni oceni razmerja med neodvisnimi spremenljivkami in odvisno spremenljivko (SSTARS 2005).

4.2.2 Proces izbora (redukcije števila) spremenljivk

S praktičnega vidika je razvoj modela za identifikacijo vrste revizijskega mnenja, ki bo vključeval preveliko število spremenljivk težko uporabljen s strani uporabnika. Zbiranje velikega števila podatkov pomeni za revizorja uporabo različnih resursov (čas, management itd.) kot tudi povzroča dodatne stroške. Dodatni razlog za redukcijo števila spremenljivk je že predstavljen problem multikolinearnosti, ki lahko signifikantno vpliva na razvoj modela. Zato nekateri avtorji predlagajo (Harell 2001, Harell 1996, povzeto po Shahian in drugi 2004, 1868), da naj bo zreducirano število spremenljivk, ki so vključene v model, manjše od ene desetine opazovanih predvidenih spremenljivk. Slednje večkrat zahteva tehniko za reduciranje podatkov, da se zmanjša število potencialnih neodvisnih spremenljivk.

Obstaja več različnih tehnik za redukcijo podatkov in s tem števila možnih spremenljivk. Kompleksnejše tehnike (npr. analiza glavnih komponent, klasterška analiza, gensko programiranje itd.) so v primerjavi z enostavnimi z vidika praktičnosti manj uporabljive, saj so matematično kompleksne in zahtevajo proučitev dodatnih statističnih parametrov, pri čemer pa ni zagotovljeno, da bo končni izid (izpeljane komponente, op.p.) bistveno izboljšal uspešnost končnega modela. Pod enostavne tehnike pojmujejo enostaven pregled potencialnih spremenljivk s pomočjo standardnih univariantnih statističnih tehnik.

V raziskavi izvedemo *ad hoc* selekcijski proces izbora (redukcije) neodvisnih spremenljivk, kjer proučimo korelacijo med neodvisnimi spremenljivkami in njihovo statistično pomembnost s pomočjo enostavnih statističnih metod. S tem poskušamo maksimalno zmanjšati število spremenljivk in vpliv multikolinearnosti.

V Tabeli 19 v Prilogi 5 prikazujemo korake/faze pri redukciji števila spremenljivk. V prvem koraku izbora na podlagi deskriptivne statistike zaradi preveč manjkajočih vrednosti izločimo spremenljivke (imena spremenljivk/kazalnikov je možno razbrati iz Tabele 6 in/ali 7, op.p.): X_{24} , X_{26} , X_{27} , X_{29} , X_{30} , X_{33} in X_{35} . V drugem koraku se s pomočjo korelacijske analize izločijo spremenljivke, ki na podlagi Spearmanovega koeficienta korelacije rangov (angl. *Spearman's rho*) močno/zmerno korelirajo (tj. koeficient je večji ali enak 0,5)⁶⁸. Izločimo X_3 , X_4 , X_6 , X_8 , X_9 , X_{13} , X_{15} , X_{16} , X_{17} , X_{19} , X_{21} , X_{22} , X_{36} in X_{37} ; zaradi vsebinskega pomena kljub indicem korelacije ne izločimo spremenljivk X_5 in X_7 . V tretjem koraku se s pomočjo Kruskal-Wallis H -testa⁶⁹ ugotavlja statistična signifikantnost posamezne spremenljivke iz pripadajočega razreda podjetij (glej Tabelo 22 v Prilogi 8). V kolikor spremenljivka ni signifikantna in ne omogoča razlikovanja med podjetji, ki prejmejo modificirano mnenje in podjetji, ki prejmejo nemodificirano mnenje, je izločena iz nabora možnih spremenljivk. Na podlagi testa izločimo le še spremenljivko X_{28} . Končni

⁶⁸ Za vrednosti korelacijskega koeficienta glej Tabelo 21 v Prilogi 7.

⁶⁹ Kruskal-Wallis test/preizkus (tudi H -test, H -statistika) je razširitev Mann-Whitney U -testa (tudi Wilcoxonovega testa) več različnih vzorcev in je neparametrična (tj. ni predpostavk glede parametrov pri porazdelitvi in predpostavk o prilaganju podatkov katerikoli porazdelitvi) alternativa analizi variance (SPSS 2004, Garson 2006). Z njim testiramo domnevo (hipotezo nič), da je več neodvisnih vzorcev izbranih iz iste populacije. Test ne pokaže, kje se neodvisni vzorci razlikujejo, ampak le da je razlika prisotna (SPSS 2004).

nabor potencialnih spremenljivk za razvoj modela za identifikacijo vrste revizijskega mnenja je podan v Tabeli 7 spodaj.

Tabela 7: Izbrane spremenljivke po vsebinskih sklopih

I.	II.	III.	IV.
Kazalniki dobičkonosnosti	Kazalniki uporabe sredstev in učinkovitosti	Kazalniki likvidnosti	Kazalniki kapitalske strukture in solventnosti
X₁ ► Koefficient čiste donosnosti sredstev X₂ ► Koefficient čiste donosnosti kapitala X₅ ► Kazalnik (kosmate) donosnosti prodaje X₇ ► Kazalnik čiste donosnosti poslovanja X₁₀ ► Kazalnik razmerja med denarnim tokom iz poslovanja in poslovnim izidom X₁₁ ► Kazalnik dobičkonosnostnega vzvodja X₁₂ ► Koefficient obračanja kapitala podjetja	X₁₄ ► Koefficient obračanja sredstev X₁₈ ► Koefficient obračanja čistih obratnih sredstev	X₂₀ ► Kratkoročni koefficient X₂₃ ► Koefficient obračanja zalog X₃₁ ► Koefficient denarnega toka glede na kratkoročne obveznosti do virov sredstev	X₃₂ ► Stopnja zadolženosti X₃₄ ► Kazalnik dolgovno-kapitalskega razmerja X₃₈ ► Koefficient pokrivanja odhodkov obresti s poslovnim izidom iz rednega delovanja X₃₉ ► Kazalnik Z po Altmanu

Vir podatkov: Lastni prikaz.

4.3 Konstruiranje modela

Pri konstrukciji klasifikacijskega modela za identifikacijo vrste revizijskega mnenja se uporabi tehnika logistične regresije. Skupina potencialnih računovodskih kazalnikov, ki so možne spremenljivke modela, bi na podlagi računovodsko-finančne teorije lahko omogočale identifikacijo vrste revizijskega mnenja za izbrano podjetje. S tem bi model bil matematično popoln in ne-bi bilo napak tipa 1 in/ali 2. Vendar jasne situacije v realnih primerih niso pogoste, zato so predvidene tudi nepredvidljive napake (tj. napake tipa 1 in 2) v samem modelu.

Konstruirani modeli vključujejo posamezne kazalnike (spremenljivke) na podlagi njihove statistične pomembnosti. Upravičenost vključitve posamezne spremenljivke je poleg njihove statistične pomembnosti (signifikantnosti) pri identifikaciji vrste revizijskega mnenja posebej preverjena tudi z Akaikejevim informacijskim kriterijem (angl. *Akaike information criterion*)⁷⁰, kajti preveliko število spremenljivk bi s praktične uporabljivosti modela pomenilo omejitvev. 5 konstruiranih modelov in model *Intercept*, ki bi vseboval le konstantni člen, prikazujemo v Tabeli 8 spodaj⁷¹. Prvi model *Allmodel* vsebuje vse kazalnike ožjega izbora; ostali modeli vsebujejo čim manjše število spremenljivk, pri čemer modela *Model_1* in *Model_2* ne vsebujeta agregatne Altmanove Z spremenljivke za napoved bankrota, modela *Model_3* in *Model_4* pa jo vsebujeta.

⁷⁰ Akaike-jev informacijski kriterij (angl. *Akaike information criterion*) se uporablja kot kriterij za ocenjevanje primernosti modelov ob hkratni vpeljavi dodatnega faktorja za preveliko število prediktorjev. Več o tem glej Gujerati (2003, 537-538).

⁷¹ V nalogi prikazujemo 5 najboljših konstruiranih modelov, ki so bili izbrani na podlagi iterativnega procesa z upoštevanjem v nadaljevanju naloge podanih kriterijev.

Tabela 8: Konstruirani modeli klasifikacije

Model ^a	Število spremenljivi vk	Stopnja natančnosti	Skladnost ^b						
			Nagelkerke R _N ² ^c	Akaike-jev informacijski kriterij	-2 log likelihood	χ ²	Stopnja prostosti	Signifikant nost	
1	2	3	4	5	6a	6b	6c	6d	
0	Intercept	0	50,0 %	-	736,74	734,74	-	-	-
1	Allmodel	16	74,2 %	0,299	634,27	600,27	134,470	16	0,000
2	Model_1	6	73,0 %	0,283	622,40	608,40	126,338	6	0,000
3	Model_2	3	72,1 %	0,267	624,24	616,22	118,512	3	0,000
4	Model_3	7	72,3 %	0,292	619,64	603,64	131,096	7	0,000
5	Model_4	4	71,5 %	0,272	624,06	614,06	120,676	4	0,000

Opombe:

^a Spremenljivke in pripadajoči koeficienti posameznega modela so predstavljeni v poglavju 5.1 Analiza parametrov modela klasifikacije, kjer je opravljena analiza spremenljivk.

^b Skladnost (angl. *goodness-of-fit*) – gre za ujemanje opazovanih vrednosti s teoretičnimi vrednostmi, dobljenih z izbranim modelom.

^c Nagelkerke-jev determinacijski koeficient je prilagoditev Cox-Snell-ovega determinacijskega koeficienta in v primerjavi s Cox-Snell-ovim determinacijskim koeficientom omogoča doseganje maksimalne vrednosti 1. Nagelkerke-jev determinacijski koeficient tako kot Cox-Snell-ov determinacijski koeficient upošteva pri izračunu velikost vzorca. Več o tem in načinu izračuna determinacijskih koeficientov glej Tabachnick in Fidell (2001, 545-546).

Vir podatkov:

Lastni izračuni.

Relevanten pokazatelj skladnosti modela (angl. *goodness-of-fit*), ki pokaže, v kolikšni meri so z v posamezen model logistične regresije vključenimi spremenljivkami pojasnjene variacije v posameznem modelu, je Nagelkerke-jev determinacijski koeficient (R_N^2 ; angl. *coefficient of determination*). Možen razpon vrednosti R_N^2 je od 0 do 1, vendar glede na naravo raziskave visoke vrednosti determinacijskega koeficienta niso pričakovane (Tabachnick in Fidell 2001, 545-546; Gujarati 2003, 604-607), kar pomeni, da se lahko pojmujejo že nizke vrednosti determinacijskega koeficienta kot zadovoljive. Najboljši model med opazovanimi je tisti, ki ima najvišjo vrednost determinacijskega koeficienta.

Glede na vrednosti R_N^2 (glej stolpec 4 v Tabeli 8) je med opazovanimi modeli najboljši *Allmodel* z vrednostjo 0,299, kar pomeni, da je 29,9 % variabilnosti odvisne spremenljivke (tj. outputa modela) pojasnjeno z vsemi 16. spremenljivkami vključenimi v model. Modelu *Allmodel* sledijo *Model_3* (0,292), *Model_1* (0,283), *Model_4* (0,272) in *Model_2* (0,267). Takšna razvrstitev modelov, kjer je najboljši po R_N^2 model z največ spremenljivkami in najslabši model z najmanj spremenljivkami, je pričakovana, saj se determinacijski koeficient povečuje z večanjem števila spremenljivk, ki so vključene v posamezen model.

Eden izmed kriterijev pri konstruiranju modela je njegova praktičnost pri uporabi. Slednje se odraža v zahtevi po čim manjšem številu kazalnikov (prediktorjev), ki jih bo moral zbrati (tj. iskati, prilagoditi in/ali izračunati itd.) revizor, da bo lahko uporabil model. Praktičnost je seveda pogojena tudi z uspešnostjo klasifikacijskega modela. Akaikejev informacijski kriterij (odslej AIC) omogoča primerjavo različnih modelov ob hkratnem upoštevanju uspešnosti modela in njegove kompleksnosti (če je ta merjena s številom spremenljivk). V množici konstruiranih/opazovanih modelov je najprimernejši, ki ni nujno najboljši model po uspešnosti, tisti model, ki minimizira vrednost AIC.

Po vrednosti AIC (glej stolpec 5 v Tabeli 8) izstopa izmed opazovanih modelov le *Allmodel* z najvišjo vrednostjo AIC (634,3). Ostali modeli imajo vsi nižje vrednosti AIC, tj. *Model_4* (624,1), *Model_2* (624,2) in *Model_1* (622,4). *Model_3* (619,7) ima najnižjo vrednost in je z vidika praktičnosti najprimernejši konstruiran model.

Drugo merilo, ki je uporabljeno za primerjavo različnih modelov z vidika uspešnosti ob hkratnem upoštevanju števila prediktorjev/spremenljivk, je statistični χ^2 -test (hi-kvadrat preizkus, angl. *chi-square test*). Z zmanjšanjem števila prediktorjev se vrednost funkcije logaritmiranega verjetja (angl. *log-likelihood*) namreč poveča (Tabachnick in Fidell 2001, 526-527). V kolikor je povečanje vrednosti funkcije logaritmiranega verjetja signifikantno, potem zmanjšanje števila prediktorjev/spremenljivk pomeni glede na novo število spremenljivk boljšo ustreznost modela z vidika dosežene uspešnosti. Podobno kot pri AIC med opazovano množico modelov ni velikih razlik (glej stolpce 6a do 6d v Tabeli 8) in glede na izračunane vrednosti nobeno zmanjšanje oz. povečanje števila spremenljivk ni signifikantno, torej takšno, ki bi izboljšalo uspešnost modela z več vključenimi spremenljivkami.

4.4 Sklepna misel k poglavju o konstrukciji modela

Proces konstrukcije klasifikacijskega/identifikacijskega modela, ki klasificira (kadar gre za razvojne podatke) oz. napoveduje/identificira (kadar gre za testne podatke – tj. podatke, ki niso uporabljeni pri razvoju modela) vrsto revizijskega mnenja je prikazan v pričujočem poglavju. Sam proces poteka v treh stopnjah/fazah: (1) prvo stopnjo raziskave (po predprocesiranju podatkov⁷²) predstavlja vzorčenje; (2) drugo stopnjo predstavlja izbor kazalnikov oz. spremenljivk in (3) tretjo stopnjo raziskave predstavlja konstrukcija modela klasifikacije/identifikacije.

Od izbora primerne metodologije in tehnike vzorčenja je odvisen razvit model. Na podlagi v nalogi predstavljenih prednosti in slabosti je bila izbrana tehnika uravnoteženega vzorčenja pri razvoju modela za identifikacijo vrste revizijskega mnenja, kar se v glavnem utemeljuje z dejstvom, da morata proučevana pojava biti enako izpostavljena oz. v enakem položaju pri razvoju modela. S tem se zagotovi optimalne pogoje za oblikovanje polnega potenciala modela za zaznavanje želenega, v realni/dejanski situaciji pogosto, nefrekventnega pojava/lastnosti.

Širok nabor možnih kazalnikov (spremenljivk) je oblikovan na podlagi relevantnih del s področja računovodstva in financ. Ožji izbor kazalnikov oz. določitev izhodiščnega nabora spremenljivk je izbran na podlagi *ad hoc* selektivne redukcije števila spremenljivk s pomočjo enostavnih statističnih tehnik na podlagi manjkajočih vrednosti, korelacije med neodvisnimi spremenljivkami in njihove statistične pomembnosti/značilnosti. Namen *ad hoc* selektivnega procesa je bil odpraviti (ali vsaj zmanjšati na minimum) učinke multikolinearnosti.

Konstrukcija modela predstavlja prvi del empiričnega dela naloge in izhodišče za ocenjevanje uspešnosti (tj. validacijo) konstruiranega modela za identifikacijo vrste revizijskega mnenja glede na izbrane kriterije. S teoretičnega vidika so kriteriji predstavljeni v drugem delu tretjega poglavja in na podlagi slednjih je možna proučitev klasifikacijske oz. identifikacijske sposobnosti (tj. zmožnosti, moči) posameznega modela, ki poda odgovor na enega zadnjih odprtih (in večkrat tudi najpomembnejših) vprašanj – tj. ali je model primeren za vsesplošno rabo (uporabo, op.p.).

⁷² Pri procesu predprocesiranja podatkov in formiranju izhodiščne podatkovne baze podatkov so bile na podatkih opravljene transformacije podatkov v primerno obliko, njihovo preurejanje oz. ureditev in uvedba novih podatkov na podlagi že obstoječih (tj. izračun kazalnikov).

(Ta stran je namerno ostala prazna.)

5 ANALIZA REZULTATOV

Druga polovica empiričnega dela naloge predstavlja analitičen pregled končne uspešnosti posameznega klasifikacijskega/identifikacijskega modela in tvori skupaj s predhodnim poglavjem koherentno celoto. Poleg analize parametrov posameznega klasifikacijskega modela je opravljena ocena uspešnosti posameznega modela po izbranih kriterijih v skladu z v tretjem in četrtem poglavju predstavljeno metodologijo ter prilagoditev modelov.

5.1 Analiza parametrov modela klasifikacije

Vsaka konstrukcija modela zahteva oceno/analizo parametrov modela, če je takšno oceno mogoče podati. V Tabeli 9 na naslednji strani, ki je skrajšana verzija Tabele 23 v Prilogi 9, so podani ocenjeni parametri posameznega modela, ki se izrazijo kot linearna kombinacija neodvisnih spremenljivk. Ocenjeni parametri (glej stolpce s končno oznako 'a') nimajo globlje vsebinske vrednosti. Vsebinski pomen, ki ga je možno razumljivo interpretirati, ima razmerje obetov (angl. *odds ratio*), ki predstavlja razmerje obetov za i -to spremenljivko X_i ob upoštevanju $X_j, j = 1, \dots, n, j \neq i$, ki so v modelu. Drugače povedano, če se vrednosti vseh spremenljivk v modelu ne spremenijo (tj. ostanejo iste), je razmerje obetov za i -to spremenljivko enako izračunanemu razmerju obetov.

Npr. za *Allmodel* in spremenljivko X_1 (koeficient čiste donosnosti sredstev) je interpretacija naslednja: za podjetja, ki imajo vse kazalnike (tj. kazalnike, ki so vključeni v model) enake, velja, da imajo podjetja, katerih vrednost koeficienta čiste donosnosti sredstev (X_1) se poveča za eno enoto 0,99–krat večje obete za prejem modificirane vrste mnenja kot podjetja, ki prejmejo nemodificirano vrsto mnenja. Ostala razmerja obetov interpretiramo na identičen način, vendar kot pokažejo izidi so vsa razmerja obetov tveganj enaka 1,0 ali v bližini te vrednosti. Le koeficient obračanja sredstev (X_{14}) odstopa od te vrednosti in npr. pri *Allmodel*-u pove, da imajo podjetja, ki povečajo vrednost koeficienta obračanja sredstev za eno enoto in imajo vse ostale kazalnike, ki so vključeni v model, enake, 0,817-krat večje (dejansko 0,183-krat manjše) obete za prejem modificirane vrste mnenja v primerjavi s podjetji, ki prejmejo nemodificirano vrsto mnenja. Slednji kazalnik ima zaradi največje variacije tudi najvišjo razlagalno moč med vsemi kazalniki, ki so vključeni v katerikoli konstruiran model.

Na podlagi izidov primerjave obeh razredov podjetij (glej Tabelo 9 spodaj in Tabelo 23 v Prilogi 9), ugotovimo, da je v modelu *Allmodel* močno statistično značilen (tj. statistično signifikanten) vpliv spremenljivk X_1 (koeficient čiste donosnosti sredstev; $p=0'000$) in X_5 (kazalnik (kosmate) donosnosti prodaje; $p=0'002$) pri $\alpha=0'01$, X_{18} (koeficient obračanja čistih obratnih sredstev; $p=0'018$) pri $\alpha=0'05$, X_2 (koeficient čiste donosnosti kapitala; $p=0'053$), X_{14} (koeficient obračanja sredstev; $p=0'094$), X_{32} (stopnja zadolženosti; $p=0'052$) in X_{39} (kazalnik Z_{Altman} ; $p=0'082$) pri $\alpha=0'10$. Primerjava modelov *Model_1* in *Model_3* z referenčnim modelom *Allmodel* ne pokaže bistvenih razlik. Vse spremenljivke vključene v model *Model_1* imajo statistično značilen vpliv; enako velja za model *Model_3*, kjer so poleg slednjega dejstva signifikantne enake spremenljivke kot v modelu *Allmodel*. Proučitev statistične značilnosti spremenljivk v modelih *Model_2* in *Model_4* pokaže, da imajo v obeh modelih statistično značilen vpliv enake spremenljivke in vse, ki so vključene v posamezen model (kar je tudi pričakovano glede na število spremenljivk, op.p.), razen v modelu *Model_4* ni signifikantna X_{39} . Posebnost in slabost modelov *Model_2* in *Model_4* v primerjavi z ostalimi modeli je, da ima signifikanten vpliv tudi konstantni člen.

Tabela 9: Enačbe logistične regresije za posamezen model

Kazalniki		ALLMODEL		MODEL_1		MODEL_2		MODEL_3		MODEL_4	
▼		Ocena parametra ^a	Razmerje obetov ^b	Ocena parametra ^a	Razmerje obetov ^b	Ocena parametra ^a	Razmerje obetov ^b	Ocena parametra ^a	Razmerje obetov ^b	Ocena parametra ^a	Razmerje obetov ^b
		1a	1b	2a	2b	3a	3b	4a	4b	5a	5b
X ₁	Koeficient čiste donosnosti sredstev	- 0,012 *	0,988	- 0,014 *	0,986	- 0,017 *	0,983	- 0,013 *	0,987	- 0,017 *	0,983
X ₂	Koeficient čiste donosnosti kapitala	- 0,001 ***	0,999	- 0,001 **	0,999			- 0,002 **	0,998		
X ₅	Kazalnik (kosmate) donosnosti prodaje	- 0,007 *	0,993	- 0,007 *	0,993	- 0,006 *	0,994	- 0,007 *	0,993	- 0,006 *	0,994
X ₇	Kazalnik čiste donosnosti poslovanja	- 0,001	0,999								
X ₁₀	Kazalnik razmerja med denarnim tokom iz poslovanja in poslovnim izidom	0,000	1,000								
X ₁₁	Kazalnik dobičkonosnostnega vzvodja	- 0,030	0,970								
X ₁₂	Koeficient obračanja kapitala podjetja	0,002	1,002								
X ₁₄	Koeficient obračanja sredstev	- 0,202 ***	0,817	- 0,168 ***	0,845			- 0,236 **	0,790		
X ₁₈	Koeficient obračanja čistih obratnih sredstev	- 0,006 **	0,994	- 0,004 **	0,996	- 0,005 **	0,995	- 0,006 **	0,994	- 0,006 **	0,994
X ₂₀	Kratkoročni koeficient	0,002	1,002								
X ₂₃	Koeficient obračanja zalog	0,000	1,000								
X ₃₁	Koeficient denarnega toka glede na kratkoročne obveznosti do virov sredstev	- 0,055	0,947								
X ₃₂	Stopnja zadolženosti	0,004 ***	1,004	0,004 ***	1,004			0,004 *	1,004		
X ₃₄	Kazalnik dolgovno-kapitalskega razmerja	0,000	1,000								
X ₃₈	Koeficient pokrivanja odhodkov za obresti s poslovnim izidom iz rednega delovanja	0,001	1,001								
X ₃₉	Kazalnik Z _{Altman}	- 0,006 ***	0,994					- 0,005 **	0,995	- 0,003	0,997
a	Konstantni člen	- 0,281	0,755	- 0,307	0,736	- 0,316 **	0,729	- 0,257	0,773	- 0,315 **	0,730

Opombe:

^a S številom zvezdic desno od izračunanega koeficienta je podana signifikantnost (tj. statistična značilnost) posameznega koeficienta. Izračun je opravljen na osnovi Wald statistike, ki se izraža kot razmerje med ocenjenim parametrom in standardno napako (Tabachnick in Fidell 2001,524-525). Če je vrednost Wald statistike signifikantna (npr. vrednost je manjša od 0,005), potem je ocenjen parameter signifikanten v modelu.

^b Razmerje obetov je izračunano kot e^{β_i} , kjer je β_i izračunan ocenjen parameter/koeficient.

* Signifikantno pri 0,01.

** Signifikantno pri 0,05.

*** Signifikantno pri 0,10.

Vir podatkov:

Lastni izračun.

5.2 Primerjalna analiza modelov

Osnovno vprašanje, ki je v interesu raziskovalca pri proučevanju različnih modelov pri enakem problemu, je, kateri izmed modelov je boljši glede na zahteve oz. izbrane kriterije pod različnimi problemskimi situacijami/pogoji. Kot je v nalogi prikazano, se avtorji različnih modelov pogosto odločijo za uporabo klasičnih meril uspešnosti, kot so npr. stopnja natančnosti, stopnja pravilnih pozitivnih, stopnja pravilnih negativnih itd., za prikaz in utemeljitev/dokaz zadostne identifikacijske zmožnosti/moči modela. Vendar, kot je prikazano v poglavju 3.2 Kriteriji (merila) za oceno uspešnosti modela, klasična merila uspešnosti niso edina možna in zaradi spreminjajočih se pogojev in zahtev/želja po prilagoditvi posameznega modela, da bo le-ta optimalen z izbranega vidika klasifikacije/identifikacije, je po analizi klasičnih kriterijev prikazana tudi analiza s pomočjo razsevnih grafikonov, ROC krivulj posameznega modela in kriterija AUC.

5.2.1 Klasična merila uspešnosti

Klasična merila uspešnosti so pogosto uporabljana v literaturi in praksi, vendar se pogosto zamolči dejstvo, da so reprezentativni pokazatelj uspešnosti le pri restriktivno izpolnjenih pogojih, in sicer, da so stroški napačnih klasifikacij enaki ter da je populacija, na kateri je model razvit, uravnotežena (tj. v razmerju 1:1). V kolikor ti pogoji niso izpolnjeni, klasični kriteriji uspešnosti modelov ne prikazujejo realne zmožnosti klasifikacijskih modelov.

Ker različna dela s področja revizije in računovodstva (glej npr. Dupoch in drugi (1987), Tam in Kiang (1992), Hansen in drugi (1992), Mutcher in drugi (2001), Spathis in drugi (2003), Lee in drugi (2005) itd.) pogosto navajajo kot relevantna merila prav klasične kriterije uspešnosti, jih predstavljamo v Tabeli 10 spodaj, in sicer v sekciji A za uravnotežen vzorec podatkov, ki so bili uporabljeni pri razvoju modelov in v sekciji B za neuravnotežen vzorec testnih podatkov, s pomočjo katerih ocenjujemo uspešnost modela. Vrednosti klasičnih kriterijev v sekciji B bistveno odstopajo od vrednosti klasičnih kriterijev izračunanih v sekciji A, kar potrjuje trditev o neprimernosti klasičnih kriterijev uspešnosti. Tako je npr. pri modelu *Allmodel* celotna klasifikacijska zmožnosti 74,15 % na razvojnih podatkih, medtem ko je 88,36 % na testnih podatkih. Slednje je le posledica dejstva višje stopnje pravilne identifikacije visoko frekventnih nemodificiranih podjetij, ki je več kot 97 odstotna, medtem ko je zmožnost pravilne klasifikacije nemodificiranih podjetij le 23 odstotna. Podobno velja tudi za ostale modele.

Tabela 10: Klasični klasifikacijski kriteriji

					Stopnja dejansko pravih napovedi nemodificirane vrste mnenj	Stopnja dejansko pravih napovedi modificirane vrste mnenj	Stopnja natančnosti				
					1	2	3	4	5	6	7
A RAZVOJNI PODATKI											
1	AllModel	219	46	174	91	82,64	65,66	74,15			
2	Model_1	218	47	169	96	82,26	63,77	73,02			
3	Model_2	219	46	163	102	82,64	61,51	72,08			
4	Model_3	217	48	166	99	81,89	62,64	72,26			
5	Model_4	216	49	163	102	81,51	61,51	71,51			
B TESTNI PODATKI											
1	AllModel	1441	39	47	157	97,36	23,04	88,36			
2	Model_1	1952	59	79	193	97,07	29,04	88,96			
3	Model_2	1964	67	71	182	96,70	28,06	89,10			
4	Model_3	1947	56	82	198	97,20	29,29	88,87			
5	Model_4	1961	66	72	184	96,74	28,13	89,05			

Opomba:^a Napovedano in dejansko nemodificirano mnenje (resnični pozitivni, *TP*).^b Napovedano nemodificirano, vendar dejansko modificirano mnenje (napačni pozitivni, *FP*). Imenujemo tudi napaka tipa 1, lažni alarm.^c Napovedano in dejansko modificirano mnenje (resnični negativni, *TN*).^d Napovedano modificirano, vendar dejansko nemodificirano mnenje (napačni negativni, *FN*). Imenujemo tudi napaka tipa 2, napačna napoved.**Vir podatkov:**

Lastni izračun.

5.2.2 Grafični prikaz klasifikacije in analiza s pomočjo ROC krivulj

Vizualen prikaz razpršenosti podjetij z modificiranimi in nemodificiranimi mnenji v ravnini prikažemo s pomočjo razsevnih grafikonov za razvojne in testne podatke – glej Grafikon 1 in 2 na naslednjih straneh. Pri tem predstavlja trikotnik [Δ] podjetje, ki ji model pripiše/napove nemodificirano mnenje in krog [$\circ$] podjetje, ki ji model pripiše modificirano mnenje. Navpična črtkana črta predstavlja ločitveno mejo⁷³ med podjetji in deli ravnino na dva dela: levi del, kjer se nahajajo podjetja z nemodificiranimi mnenji (pravilna klasifikacija pozitivnih, *TP*) in desni del, kjer se nahajajo podjetja z modificiranimi mnenji (pravilna klasifikacija negativnih, *TN*). Pojav krogov, tj. podjetij z dejansko modificiranimi mnenji, na levi strani ločitvene meje, tj. območju predvidenem za podjetja, ki prejmejo nemodificirano mnenje, pomeni napačno klasifikacijo negativnih (*FN*, napaka tipa 2). In obratno, pojav trikotnikov, tj. podjetij z dejansko nemodificiranimi mnenji, na desni strani ločitvene meje, tj. območju predvidenem za podjetja, ki prejmejo modificirano mnenje, pomeni napačno klasifikacijo pozitivnih (*FP*, napaka tipa 1)⁷⁴.

Na razsevnih grafikonih za konstruirane klasifikacijske modele, ki temeljijo na razvojnih podatkih (Grafikon 1), se vidno oblikujeta dve skupini oz. dva razreda podjetij, ki imata

⁷³ Ločitvena meja (angl. *cutoff point*) je pri razvoju modelov in ocenjevanju parametrov modelov predpostavljena pri vrednosti 0,5. Sprememba ločitvene meje in s tem zmožnosti klasifikacijskega modela je možna. Več o tem v poglavju 5.3 Prilagoditev modelov klasifikacije.

⁷⁴ Vsebinski pomen je identičen razlagi s pomočjo Venovih diagramov podano v poglavju 3.2.1.2 Napaka tipa 1 in 2 in stroški napravljenih napak.

različne lastnosti, in sta ločena z ločitveno mejo/pravidom. Glede napačnih klasifikacij je možno razbrati, da se pojavi več napačnih klasifikacij podjetij z modificiranimi mnenji med podjetja z nemodificirani mnenji (*FP*, napaka tipa 2), kar se vidi tudi pri nižjih vrednostih stopenj pravih negativnih – glej Tabelo 10 zgoraj.


Izrazitejše oblikovanje dveh skupin/razredov podjetij je še posebej vidno pri razsevnih grafikonih za klasifikacijske modele, ki temeljijo na testnih podatkih (glej Grafikon 2). Slednje je posledica zelo visoke frekvence podjetij z nemodificiranimi mnenji (nizka stopnja disperzije) v primerjavi s frekvencami podjetij z modificiranimi mnenji (visoka stopnja disperzije) v populacijskem testnem vzorcu.

Pod razsevnim grafikonom posameznega modela je prikazana pripadajoča ROC krivulja posameznega modela, ki prikazuje zmožnost klasifikacijskega modela preko celotnega spektra možnih odločitvenih mej. Referenčna krivulja je krivulja *Allmodel*-a, ki je na vseh grafikonih desno od ROC krivulje *Allmodel*-a prikazana v sivi barvi. Sečišče črtkanih črt na grafikonih ROC krivulj predstavlja odločitveno mejo/pravilo pri vrednosti 0'5. Za barvno legendo, ki velja za vse grafikone vključene v nalogo, velja, da

- [] rdeča barva predstavlja *Allmodel*,
- [] oranžna predstavlja *Model_1*,
- [] rumena predstavlja *Model_2*,
- [] zelena predstavlja *Model_3* in
- [] modra predstavlja *Model_4*.

Glede na grafikone ROC krivulj ne moremo reči, da kateri izmed modelov dominira nad drugim tako na primeru razvojnih podatkov kot tudi pri testnih podatkih.


Grafikon 1: Razsevní grafikon in ROC krivulje klasifikacijskih modelov na razvojnih podatkih



Legenda:
Vir podatkov:

Glej poglavje 5.2.2 Grafični prikaz klasifikacije in analiza s pomočjo ROC krivulj na strani 58.
Lastni prikaz.

Grafikon 2: Razsevni grafikon in ROC krivulje klasifikacijskih modelov na testnih podatkih



Legenda:
Vir podatkov:

Glej poglavje 5.2.2 Grafični prikaz klasifikacije in analiza s pomočjo ROC krivulj na strani 58.
Lastni prikaz.

5.2.3 Primerjava modelov s pomočjo kriterija AUC

Glede na grafikone ROC krivulj za vseh 5 klasifikacijskih modelov za identifikacijo vrste revizijskega mnenja sklepamo, da nobeden klasifikacijski model ne dominira nad drugim preko celotnega odločitvenega spektra. S kriterijem AUC dobimo številčno vrednost, ki povzame povprečno uspešnost modela preko celotnega spektra in omogoči medsebojno primerjavo modelov na podlagi izračunane vrednosti. Na razvojnem vzorcu podatkov imata najvišjo vrednost AUC (0,797) modela *Allmodel*, ki vključuje vseh 16 kazalnikov, in *Model_3*, ki vključuje 7 kazalnikov, kateremu blizu sledijo *Model_1* (0,794; 6 kazalnikov), nato *Model_4* (0,781; 4. kazalniki) in *Model_2* (0,779; 3 kazalniki). Drug vrstni red podajo vrednosti AUC na testnem vzorcu, kjer ima najvišjo vrednost AUC *Model_1* (0,814), in nato sledijo *Model_3* (0,809), *Allmodel* (0,798), *Model_2* (0,780) in *Model_4* (0,775). Enako razvrstitev pokaže tudi Ginijev koeficient.

Tabela 11: Primerjava modelov na podlagi AUC

RAZVOJNI PODATKI				TESTNI PODATKI					
		AUC (c-index)	Standardna napaka AUC	Ginijev koeficient			AUC (c-index)	Standardna napaka AUC	Ginijev koeficient
		1	2	3			4	5	6
1	Allmodel	0,797	0,019	0,595			0,798	0,027	0,597
2	Model_1	0,794	0,020	0,588			0,814	0,025	0,628
3	Model_2	0,779	0,020	0,558			0,780	0,028	0,559
4	Model_3	0,797	0,019	0,594			0,809	0,025	0,617
5	Model_4	0,781	0,020	0,562			0,775	0,029	0,551

Vir podatkov: Lastni izračun.

Glede na 5-stopenjsko klasifikacijsko lestvico predstavljeno v poglavju 3.2.2.1 Kriterij AUC (Področje pod krivuljo ROC), ki glede na vrednost AUC posamezen model klasifikacije/identifikacije ordinalno razvrsti v posamezen razred, lahko rečemo, da so predstavljeni modeli na meji med dobrimi in zadovoljivimi modeli (torej med razredom B in C).

Analiza posameznih modelov⁷⁵ v primerjavi z *Allmodel*-om, ki je referenčni model, v Tabeli 12 spodaj pokaže, da nobeden izmed modelov nima signifikantno nižje (višje) vrednosti AUC v primerjavi z *Allmodel*-om tako na razvojnih kot na testnih podatkih, kar pomeni, da v povprečju ni signifikantno velikih razlik med posameznimi klasifikacijskimi modeli in *Allmodel*-om. Sklepamo lahko, da ker ni signifikantne razlike med *Allmodel*-om in drugim izbranim klasifikacijskim modelom, da tudi ni signifikantnih razlik med posameznimi izbranimi modeli – tj. glede na vrednosti prikazane v Tabeli 12 spodaj, nobeden izmed konstruiranih modelov ne dominira nad drugim preko celotnega spektra možnih odločitvenih mej.

⁷⁵ Teoretična podlaga in enačbe, ki omogočijo primerjavo, so podane v poglavju 3.2.2.1 Kriterij AUC (Področje pod krivuljo ROC).

Tabela 12: Primerjava modelov na podlagi kriterija AUC

	Povprečje AUC ^a	Korelacijski koeficient			Vrednost r_{ij} ^b	Vrednost z ^c	Signifikantnost
		za podjetja z nemodificiranim mnenjem	za podjetja z modificiranim mnenjem	Povprečna vrednost ^a			
	1	2	3	4	5	6	7
A RAZVOJNI PODATKI							
1 Allmodel – Model_1	0,80	0,8359	0,9022	0,869	0,83	0,2919	0,386
2 Allmodel – Model_2	0,79	0,7213	0,7885	0,755	0,72	1,2321	0,109
3 Allmodel – Model_3	0,80	0,8451	0,9281	0,887	0,85	0,0362	0,486
4 Allmodel – Model_4	0,79	0,7232	0,8035	0,763	0,72	1,1115	0,134
B TESTNI PODATKI							
1 Allmodel – Model_1	0,81	0,7273	0,7554	0,7413	0,69	-0,7654	0,221
2 Allmodel – Model_2	0,79	0,5900	0,6312	0,6106	0,56	0,7354	0,230
3 Allmodel – Model_3	0,80	0,7209	0,7614	0,7412	0,69	-0,4985	0,309
4 Allmodel – Model_4	0,79	0,6013	0,6339	0,6176	0,57	0,9019	0,184

Opomba:

^a Aritmetično povprečje.^b Vrednost r_{ij} je pridobljena na podlagi povprečnih vrednosti AUC in korelacijskih koeficientov iz tabele vrednosti r_{ij} v Hanley in McNeil (1983).^c Vrednost z je izračunana iz enačbe (3.13) podane v poglavju 3.2.2.1 Kriterij AUC (Področje pod krivuljo ROC).

Vir podatkov:

Lastni izračun.

5.3 Prilagoditev modelov klasifikacije

Eden izmed kriterijev pri izboru optimalnega modela poleg uspešnosti modela je tudi smotrnost (gospodarnost). Razloge in možne poti, kako prilagoditi posamezen model klasifikacije, so nakazane v okviru poglavja 3.2.4 Prilagoditev parametrov klasifikacijskega modela, pri čemer po do sedaj prikazanih izsledkih raziskave, ni možno izvesti le prilagoditve modela po tretjem scenariju – tj. optimirati model, da minimizira celotne stroške napačnih klasifikacij. Pomen stroškov pravičnih in napačnih klasifikacij v reviziji je predstavljen v 3. poglavju in podana je tudi enačba (3.20a) oz. (3.20b) za njihov možni izračun. Ker so stroški in razmerje med stroški napak tipa 1 in 2 večkrat neznani oz. nemerljivi, predpostavljamo podobno kot ostali avtorji, da je relativno razmerje med napakami enako 1:1, 1:2, 1:3, 1:4, 1:5, 1:10, 1:25, 1:50, 1:75 in 1:100, pri čemer je vrednost 1 pripisana stroškom napak tipa 1 (stroški napačnega pozitivnega (FP) oz. lažnega alarma). Ker tudi pogoji za zmožnost zaznavanja napačnega pozitivnega primera variirajo in so dejansko v populaciji večkrat redkeje identificirani kot napačni negativni, predpostavljamo pet različnih vrednosti verjetnosti (P_1) za identifikacijo napačnega pozitivnega primera, in sicer 0'1, 0'2, 0'3, 0'4 in 0'5.

Kombinacija predpostavljenih pogojev in poznane koordinate ROC krivulj (FPR_i , TPR_i) pri posamezni odločitveni meji omogoči izračun predvidenih stroškov napačnih klasifikacij pri posamezni odločitveni meji s pomočjo funkcije za izračun stroškov napačnih klasifikacij (glej enačbo 3.20a). Tabela izračunanih minimalnih stroškov na razvojnih podatkih predstavljamo v Prilogi 10 (glej Tabela 24). Odločitvene meje/točke za razvojne podatke, pri katerih so ti stroški minimalni, prikazujemo v Tabeli 13 na naslednji strani. S pomočjo poznanih optimalnih odločitvenih mej pri razvojnih podatkih je možen izračun pričakovanih stroškov pri enakih odločitvenih mejah za testne podatke, saj so koordinate točk za ROC krivulje, ki temeljijo na testnih podatkih, znane. Pričakujemo, da če se pri

uporabi modela uporabi odločitvena meja, ki optimalno minimizira stroške pri razvojnih podatkih, da so izračunani stroški pri testnih podatkih prav tako relativno nizki in se ne razlikujejo veliko od izračunanih stroškov pri razvojnih podatkih (glej Tabela 24 v Prilogi 10).

Tabela 13: Optimalne odločitvene meje/točke modelov

C ₀₁	P ₁	ALLMODEL		MODEL_1		MODEL_2		MODEL_3		MODEL_4	
		Razvojni podatki	Testni podatki	Razvojni podatki	Testni podatki	Razvojni podatki	Testni podatki	Razvojni podatki	Testni podatki	Razvojni podatki	Testni podatki
1	2	3a	3b	4a	4b	5a	5b	6a	6b	7a	7b
1	0,1	0,1679	0,0005	0,0637	0,2711	0,1842	0,1958	0,1106	0,2733	0,1843	0,1631
1	0,2	0,3000	0,3325	0,2908	0,2711	0,2121	0,2607	0,3021	0,2733	0,2637	0,2587
1	0,3	0,3843	0,3325	0,3601	0,3413	0,3539	0,3671	0,3728	0,3223	0,3491	0,3635
1	0,4	0,4144	0,3641	0,4084	0,3863	0,4040	0,3671	0,4144	0,3983	0,4070	0,3635
1	0,5	0,4900	0,3641	0,4319	0,4069	0,4869	0,3671	0,4255	0,3983	0,4912	0,3728
2	0,1	0,2653	0,2829	0,2908	0,2711	0,2121	0,1958	0,2795	0,2733	0,2045	0,2587
2	0,2	0,4144	0,3325	0,4053	0,3413	0,4040	0,3671	0,4046	0,3223	0,3982	0,3635
2	0,3	0,4144	0,3641	0,4279	0,4069	0,4040	0,3671	0,4144	0,3983	0,4172	0,3728
2	0,4	0,4900	0,4412	0,4789	0,4069	0,4869	0,4053	0,4704	0,4184	0,4912	0,4060
2	0,5	0,5019	0,4994	0,4928	0,4069	0,5408	0,4282	0,5498	0,4987	0,5509	0,4060
3	0,1	0,3209	0,3325	0,3446	0,3413	0,3280	0,3124	0,3021	0,3223	0,3350	0,2963
3	0,2	0,4144	0,3641	0,4279	0,4069	0,4040	0,3671	0,4144	0,3983	0,4070	0,3635
3	0,3	0,4900	0,4412	0,4789	0,4069	0,4869	0,4053	0,4704	0,4184	0,4912	0,4060
3	0,4	0,5019	0,4994	0,4928	0,4069	0,5408	0,4282	0,5498	0,4987	0,5509	0,4060
3	0,5	0,5539	0,5080	0,6545	0,4888	0,6338	0,4716	0,6469	0,4987	0,6443	0,4754
4	0,1	0,3843	0,3325	0,3601	0,3413	0,3539	0,3671	0,4046	0,3223	0,3491	0,3635
4	0,2	0,4900	0,3641	0,4319	0,4069	0,4869	0,3671	0,4255	0,3983	0,4912	0,3728
4	0,3	0,4900	0,4994	0,4928	0,4069	0,4998	0,4053	0,4762	0,4283	0,4912	0,4060
4	0,4	0,5539	0,5080	0,6545	0,4888	0,6338	0,4716	0,6469	0,4987	0,6443	0,4754
4	0,5	0,7528	0,5325	0,7516	0,4912	0,6709	0,6132	0,7460	0,4987	0,6443	0,6123
5	0,1	0,4144	0,3325	0,4053	0,3413	0,4040	0,3671	0,4046	0,3223	0,3982	0,3635
5	0,2	0,4900	0,4412	0,4410	0,4069	0,4869	0,4053	0,4704	0,4184	0,4912	0,4060
5	0,3	0,5539	0,4994	0,4928	0,4069	0,5408	0,4282	0,5597	0,4987	0,5900	0,4306
5	0,4	0,7001	0,5080	0,6545	0,4888	0,6338	0,6132	0,6469	0,4987	0,6443	0,6123
5	0,5	0,8713	0,6602	0,7516	0,6552	0,8554	0,6132	0,7460	0,4987	0,8703	0,6123
10	0,1	0,4900	0,3641	0,4319	0,4069	0,4869	0,4053	0,4255	0,4184	0,4912	0,4060
10	0,2	0,5539	0,5080	0,6408	0,4888	0,6010	0,4716	0,6469	0,4987	0,6443	0,4754
10	0,3	0,7715	0,6205	0,7516	0,4912	0,8554	0,6132	0,7460	0,4987	0,6443	0,6123
10	0,4	0,8860	0,9220	0,9926	0,6552	0,9788	0,6132	0,8740	0,6914	0,9789	0,7655
10	0,5	0,9933	0,9220	0,9926	0,9099	0,9947	0,7230	0,9938	0,9219	0,9946	0,7655
25	0,1	0,8860	0,9220	0,9926	0,6552	0,9788	0,6132	0,8740	0,6914	0,9789	0,6123
25	0,2	0,8860	0,9220	0,9926	0,6552	0,9788	0,6132	0,8740	0,6914	0,9789	0,6123
25	0,3	0,9933	1,0000	0,9926	0,9099	0,9947	0,9861	0,9938	1,0000	0,9946	0,9860
25	0,4	0,9933	1,0000	0,9926	1,0000	0,9947	1,0000	0,9938	1,0000	0,9946	1,0000
25	0,5	0,9933	1,0000	0,9926	1,0000	0,9947	1,0000	0,9938	1,0000	0,9946	1,0000
50	0,1	0,8713	0,9220	0,8693	0,6552	0,9788	0,6132	0,8740	0,6914	0,8703	0,6123
50	0,2	0,9933	1,0000	0,9926	0,9099	0,9947	1,0000	0,9938	1,0000	0,9946	1,0000
50	0,3	0,9933	1,0000	0,9926	1,0000	0,9947	1,0000	0,9938	1,0000	0,9946	1,0000
50	0,4	0,9933	1,0000	0,9926	1,0000	0,9947	1,0000	0,9938	1,0000	0,9946	1,0000
50	0,5	0,9933	1,0000	0,9926	1,0000	0,9947	1,0000	0,9938	1,0000	0,9946	1,0000

(Nadaljevanje na naslednji strani.) ▼

1	2	3a	3b	4a	4b	5a	5b	6a	6b	7a	7b
---	---	----	----	----	----	----	----	----	----	----	----

75	0,1	0,9933	0,9220	0,9926	0,9099	0,9788	0,7230	0,9938	0,9091	0,9789	0,7655
75	0,2	0,9933	1,0000	0,9926	1,0000	0,9947	1,0000	0,9938	1,0000	0,9946	1,0000
75	0,3	0,9933	1,0000	0,9926	1,0000	0,9947	1,0000	0,9938	1,0000	0,9946	1,0000
75	0,4	0,9933	1,0000	0,9926	1,0000	0,9947	1,0000	0,9938	1,0000	0,9946	1,0000
75	0,5	0,9933	1,0000	0,9926	1,0000	0,9947	1,0000	0,9938	1,0000	0,9946	1,0000
100	0,1	0,9933	1,0000	0,9926	0,9099	0,9947	0,9861	0,9938	1,0000	0,9946	0,9860
100	0,2	0,9933	1,0000	0,9926	1,0000	0,9947	1,0000	0,9938	1,0000	0,9946	1,0000
100	0,3	0,9933	1,0000	0,9926	1,0000	0,9947	1,0000	0,9938	1,0000	0,9946	1,0000
100	0,4	0,9933	1,0000	0,9926	1,0000	0,9947	1,0000	0,9938	1,0000	0,9946	1,0000
100	0,5	0,9933	1,0000	0,9926	1,0000	0,9947	1,0000	0,9938	1,0000	0,9946	1,0000


Vir podatkov: Lastni izračun.

Če predpostavljamo enake stroške napačnih klasifikacij, tj. $c_{01}=1$ in $P_1=0,5$, ki je predpostavljena pri razvoju modelov, se optimalna odločitvena meja, ki minimizira pričakovane stroške pri razvojnih podatkih, kot je razvidno iz Tabele 13 zgoraj, nahaja za *Allmodel* (0,49), *Model_2* (0,49) in *Model_4* (0,49) blizu vrednosti 0,5, medtem ko sta vrednosti za *Model_1* (0,43) in *Model_3* (0,43) že nekoliko nižji. Slednje potrjuje tudi ugotovitev Sinha in May-a (2005, 268), da tudi če stroški napačnih klasifikacij niso pomembni, je potrebno, da bi izboljšali uspešnost modelov klasifikacije, njihova prilagoditev.

Odločitvena meja je bila izbrana tako, da je minimizirala pričakovane stroške na podatkih za razvoj modela. Vendar dejstvo je, da izbrana odločitvena meja ne zagotavlja, da bodo pričakovani stroški minimalni tudi pri testnih podatkih, vendar pričakujemo, da bodo stroški blizu minimalnih. Za vsak model je določena odločitvena meja, da se minimizirajo stroški na testnih podatkih. Zadostna bližina minimalnih stroškov napačnih klasifikacij razvojnih in testnih določenih odločitvenih mej podpre ugotovitev glede eksterne ustreznosti modelov (tj. zmožnosti generalizacije) (glej Tabelo 24 v Prilogi 10).

Grafikoni spodaj (glej Grafikon 3) prikazujejo uspešnost modelov s stroškovnega vidika za razvojne in testne podatke in temeljijo na izračunih iz Tabele 24 v Prilogi 10. Primerjava logističnih modelov pri različnih razmerjih stroškov in predpostavljenih verjetnostih pokaže, da so modeli enaki po stroškovni uspešnosti in opazna je le relativno zelo majhna variabilnost v izračunanih stroških za razvojne podatke. Izračuni na testnih podatkih pokažejo, da sta modela *Allmodel* in *Model_4* s stroškovnega vidika manj uspešna, saj so njuni stroški napačnih klasifikacij višji kot pri razvojnih podatkih za večino kombinacij različnih stroškov in predpostavljenih verjetnosti. Delno velja slednje tudi za *Model_2*, predvsem pri višje predpostavljenih verjetnostih. Relativno majhne variacije v pričakovanih stroških med razvojnimi in testnimi podatki pri različnih pogojih imata *Model_1* in *Model_3* – tj. njuna generalizacijska sposobnost je zelo visoka; sledi *Model_2* in nato *Model_4* in *Allmodel*, ki ima najslabšo generalizacijsko sposobnost.

Grafikon 3: Grafikoni pričakovanih stroškov pri različnih razmerjih stroškov



Legenda:
Vir podatkov:

Glej poglavje 5.2.2 Grafični prikaz klasifikacije in analiza s pomočjo ROC krivulj na strani 58.
Lastni prikaz.

Ker optimalna odločitvena meja na razvojnih podatkih ne zagotavlja, da bodo tudi na testnih podatkih pričakovani stroški minimalni, preverimo tudi odločitvene meje, ki so pridobljene neodvisno od razvojnih podatkov za testne podatke in ki minimirajo pričakovane stroške uporabe klasifikacijskega modela. Majhne razlike med optimalnimi odločitvenimi mejami za razvojne in testne podatke dodatno podprejo dobro generalizacijsko sposobnost posameznega modela.

Optimalne odločitvene meje za razvojne in testne podatke pri različnih pogojih so podane v Tabeli 13 na strani 64. V kolikor je korelacijski koeficient⁷⁶ med razvojnimi in testnimi odločitvenimi mejami za vsak posamezen klasifikacijski model visok, ima model dobro generalizacijsko sposobnost. Visok koeficient pomeni tudi, da je prilagoditev – tj. sprememba odločitvene meje, tako da so pričakovani stroški minimalni – posameznega modela uspešna/smiselna. *Allmodel* ima izmed vseh modelov najvišji korelacijski koeficient (0,977), sledi mu *Model_3* (0,955) in nato še *Model_4* (0,935), *Model_1* (0,931) in *Model_2* (0,917)⁷⁷. Najvišja možna vrednost korelacijskega koeficienta je 1 in pomeni popolno korelacijo. Ker imajo modeli odločitvene meje za razvojne in testne podatke v bližini popolne korelacije (idealni primer), je prilagoditev vsakega posameznega modela z uporabo optimalne odločitvene točke uspešna, saj se tako dosežejo najnižji pričakovani stroški napačnih klasifikacij.

5.4 Analiza občutljivosti


Pri razvoju modela je pomembno, da je model relativno neobčutljiv na spremembe v predpostavkah oz. pogojih glede porazdelitve razredov/skupin podjetij, kajti če zaradi majhne spremembe pogojev model posamezen primer napačno klasificira/identificira, je model zelo občutljiv na spremembe pogojev. Z vidika stroškov je torej klasifikacijski model občutljiv na spremembe pogojev, če so pričakovani stroški napačnih klasifikacij občutljivi na majhne spremembe v predpostavkah/pogojih.

Na grafikonih spodaj (glej Grafikon 4) prikazujemo spremembe pričakovanih stroškov (za razvojne podatke) uporabe klasifikacijskega modela pri različnih verjetnostih ob različnih predpostavljenih stroških napačnih pozitivnih (c_{01}). Večji kot je naklon krivulje v določenem delu grafikona, večja je občutljivost modela na spremembe v verjetnostih za zaznavanje modificiranega mnenja (P_1). Glede na prikazane grafike lahko sklepamo, da se modeli z vidika občutljivosti na spremembe predhodnih pogojev ne razlikujejo, saj nobeden izmed modelov po prikazanih karakteristikah pri posamezni predpostavljeni verjetnosti ne odstopa od drugih modelov (relativno gledano je najbolj robusten *Allmodel*, kateremu sledijo ostali).

⁷⁶ Gre za Pearsonov korelacijski koeficient.

⁷⁷ Vsi izračunani korelacijski koeficienti so signifikantni pri 0,01.

Grafikon 4: Analiza občutljivosti modelov klasifikacije



5.5 Sklepna misel k analizi rezultatov

Validacija oz. analiza klasifikacijskega modela na podlagi izbranih kriterijev, ki so bili predstavljeni v tretjem poglavju, poda odgovor na vprašanje, kakšna je identifikacijska/klasifikacijska moč/zmožnost modela. Analiza parametrov posameznega modela, ki pokaže, kateri kazalniki so statistično značilni v posameznem modelu, primerjalna analiza modelov na podlagi klasičnih kriterijev, ROC krivulj in kriterija AUC pokaže skoraj identično sposobnost vsakega posameznega modela, kajti nobeden izmed modelov, relativno gledano, ne izstopa po svoji zmožnosti/moči veliko od drugega.

Optimizacijski postopek prilagoditve posameznega modela pokaže, da je kalibracija modela potrebna tudi v primeru idealnih pogojev, ko bi stroški napačnih klasifikacij bili enaki in bi tudi verjetnost zaznavanja obeh pojavov bila enaka. Če je cilj uporabnika modela (tj. revizorja) minimizacija števila napačnih klasifikacij/identifikacij pri uporabi modela, je z Grafikonom 1 in 2 podana podatkovna podlaga, ki omogoča prilagoditev modela, tako da minimizira želeno število napačnih klasifikacij. V kolikor je cilj optimizacija/minimizacija celotnih stroškov napačnih klasifikacij, so v nalogi (glej Tabelo 13) podane najprimernejše odločitvene meje, ki bi izbran klasifikacijski/identifikacijski model optimirale. Odločitev, ali uporabiti odločitvene meje izračunane pri testnih ali razvojnih podatkih, je odvisna od odločitve uporabnika modela. Vsi predstavljeni modeli imajo namreč na podlagi izidov visoko generalizacijsko sposobnost (tj. na podatkih, ki jih do tedaj niso videli, bi bili relativno uspešni) in so relativno neobčutljivi na spremembe pogojev (npr. spremembo stroškov napačne klasifikacije).

(Ta stran je namerno ostala prazna.)

6 SKLEP

Namen pričujočega dela je (bil) predstaviti model, ki bi zainteresiranim uporabnikom, predvsem pa revizorjem, omogočil identifikacijo vrste revizijskega mnenja. S pomočjo takšnega modela, osnovanega na javno dostopnih podatkih, je možno identificirati podjetje, ki naj bi prejelo modificirano vrsto mnenja z določeno stopnjo/mero verjetnosti. Izhodišče naloge je bila vsebinska kot tudi praktična uporabljivost takšnega modela. Vsebinska z vidika možne identifikacije občutljivih področij zaradi katerih je podjetje prejelo modificirano vrsto mnenja; praktična z vidika uporabljivosti, tj. praktične uporabnosti, modela v dejanski/realni situaciji.

Zastavljen problem naloge je po svoji naravi interdisciplinaren in zahteva proučitev literature s področja revizije ter statistike. V preteklosti obstajajo poizkusi zasnove modelov, ki bi omogočali identifikacijo/napoved vrste revizijskega mnenja, vendar je njihova relativna (večkrat pa tudi absolutna) uspešnost na podatkih, ki niso bili uporabljeni pri razvoju modela, pogosto neznana. Vprašanje uspešnosti je dejansko relativen pojem, ki je odvisen od vsakega uporabnika modela in njegovih preferenc, kar je nazorno prikazano v nalogi z Venovimi diagrami. Model, ki omogoča identifikacijo vrste revizijskega mnenja, je zaradi pojava napačnih klasifikacij/identifikacij in pripadajočih stroškov potrebno prilagoditi značilnostim/lastnostim situacije/okolja in predvsem preferencam/videnju, ki ga ima revizor in/ali revizijsko podjetje. Ne glede na navedeno je možno konstruirati izhodiščni model, ki je vesplošno uporabljen, vendar pa z vidika števila napačnih klasifikacij in/ali vidika stroškov ni optimalen. Vprašanje je tudi, ali je identifikacija oz. napoved vrste revizijskega mnenja s pomočjo računovodskih kazalnikov, ki so predvsem pokazatelj trenutnega, nekoliko manj pa bodočega 'zdravja' podjetja, možno.

Z vidika možne uporabe računovodskih kazalnikov je posebna pozornost v nalogi namenjena izboru kazalnikov (spremenljivk), ki v primerjavi z nekaterimi v preteklosti predstavljenimi modeli, pokrivajo osnovna ključna vsebinska področja delovanja podjetja. Z *ad hoc* selekcijskim procesom je zreducirano število možnih kazalnikov, ki so uporabljeni v posameznem modelu za identifikacijo/napoved vrste revizijskega mnenja. Analiza ožjega nabora vseh kazalnikov, ki so uporabljeni v modelu logistične regresije, ne pokaže jasnih indecev, da bi obstajala močna povezava med posameznim (tj. individualno) uporabljenim računovodskim kazalnikom in posamezno vrsto revizijskega mnenja. Vendar statistična analiza posameznih kazalnikov pokaže obstoj razlike med kazalniki skupine podjetij, ki prejmejo modificirano vrsto menja, in skupine podjetij, ki prejmejo pozitivno mnenje. Tako naj bi podjetja, ki prejmejo pozitivno mnenje, imela boljše donosnost, učinkovitost in likvidnost od podjetij, ki prejmejo modificirano mnenje.

Vprašanje, ali lahko kombinacija različnih računovodskih kazalnikov pokaže obstoj povezave/razmerja med posamezno vrsto revizijskega mnenja in kombinacijo teh kazalnikov, je povezano s problemom merjenja uspešnosti modela. Prav tako kot kazalnikom je v nalogi posebna pozornost namenjena kriterijem uspešnosti in njihovi dejanski zmožnosti pokazati klasifikacijsko/identifikacijsko moč modela. Omejenost klasičnih kriterijev le na idealno situacijo, ko so stroški napačnih klasifikacij enaki in ko je verjetnost za identifikacijo prav tako enaka za oba pojava, ki sta v interesu raziskovanja, onemogoča prikaz dejanske/realne zmožnosti modela. Alternativna merila, kot so krivulja operativne karakteristike modela (ROC krivulja), kriterij AUC, ki predstavlja povprečno zmožnost modela preko celotnega spektra možnih uporabnikovih (revizorjevih) preferenc in krivulje enake zmožnosti modela, ki omogočajo izračun celotnih stroškov napačnih

klasifikacij posameznega modela ob željeni uporabnikovi preferenci, omogočijo prikaz dejanske uspešnosti posameznega modela. Nobeden izmed petih v nalogi razvitih modelov po omenjenih alternativnih kriterijih ne prevladuje nad drugim po uspešnosti in razlike med njimi, kljub različnim uporabljenim kazalnikom in njihovem različnem številu v posameznem modelu, so relativno (kot tudi absolutno, op.p.) majhne.

Uspešnost modelov po alternativnih (kot tudi po klasičnih) kriterijih in glede na razsevne grafikone pa je boljša kot v primeru naključnega ugibanja oz. modela (ti. naivni model), ki bi pripisal vsa podjetja le eni skupini podjetij. Identično pokaže tudi izračun Nagelkerkejevih determinacijskih koeficientov za posamezen model (tj. vrednosti koeficientov so blizu 0,3 za vseh pet modelov). Dejstvo, da ob uporabi posameznega modela tako na razvojnih kot testnih podatkih pride do (zaznanega) razlikovanja med podjetji, ki prejmejo pozitivno mnenje, in podjetji, ki prejmejo modificirano mnenje, potrjuje obstoj povezave med posamezno vrsto revizijskega mnenja in izbrano kombinacijo računovodskih kazalnikov. Z (skoraj) enako uspešnostjo in obstojem povezave oz. zmožnostjo diskriminacije tudi na testnih podatkih, ki niso uporabljeni pri razvoju modela, je pokazana tudi visoka generalizacijska sposobnost razvitih modelov.

Z vidika uporabnosti posameznega modela je poleg uspešnosti pomembno predvsem dvoje, in sicer, da ima model čim nižjo vrednost Akaike-jevega informacijskega kriterija (AIC), kar omogoči vključitev le zares relevantnih spremenljivk v model v čim nižjem številu, in da je model (relativno) neobčutljiv na spremembe v pogojih delovanja, kot so npr. stroški napačne klasifikacije. Ker kljub celotnemu 'portfelju' kriterijev med konstruiranimi modeli ni modela, ki bi izrazilo prevladoval nad drugimi, in imajo po izidih modeli enako generalizacijsko sposobnost, so vsi neobčutljivi na spremembe pogojev in imajo enako uspešnost glede na zbrane kriterije, je prevladujoč kriterij pri izboru optimalnega modela AIC. Najprimernejši model je *Model_1* ($AIC_{Model_1}=622,40$; 6 kazalnikov), ki ima skoraj enako vrednost AIC kot *Model_2* ($AIC_{Model_2}=624,24$; 3 kazalniki), vendar je njegova uspešnost (relativno gledano) nekoliko boljša. Drug razlog za izbor modela *Model_1* je, da vključuje v model kombinacijo kazalnikov s treh različnih vsebinskih področij⁷⁸. Modela *Model_3* ($AIC_{Model_3}=619,64$) in *Model_4* ($AIC_{Model_4}=624,06$) izpadeta iz možnega izbora, ker vključujeta v model tudi Altmanov Z_{Altman} kazalnik za napoved bankrota, ki je agregatni/sestavljene kazalnik in zahteva za izračun vrednosti kazalnika Z_{Altman} predhodni izračun petih različnih kazalnikov⁷⁹. Enačba izbranega modela (tj. modela *Model_1*) za identifikacijo/napoved vrste revizijskega mnenja je

$$f(x_i) = \frac{1}{1 + e^{-(0,014 \cdot x_1 - 0,001 \cdot x_2 - 0,007 \cdot x_3 - 0,168 \cdot x_4 - 0,004 \cdot x_5 + 0,004 \cdot x_6 - 0,307)}} \quad (6.1),$$

kjer so

- x_1 – koeficient čiste donosnosti sredstev,
- x_2 – koeficient čiste donosnosti kapitala,
- x_3 – kazalnik (kosmate) donosnosti prodaje,
- x_4 – koeficient obračanja sredstev,
- x_5 – koeficient obračanja čistih obratnih sredstev in
- x_6 – stopnja zadolženosti.

⁷⁸ Kazalniki x_1 , x_2 in x_3 so kazalniki s področja dobičkonosnosti; x_4 in x_5 s področja učinkovitosti in uporabe sredstev in x_6 s področja kapitalne strukture in solventnosti.

⁷⁹ Model *Allmodel* ($AIC_{Allmodel}=634,27$) v nalogi predstavlja izhodiščni/referenčni model, saj vključuje vseh 16 možnih spremenljivk iz zoženega nabora kazalnikov.

S statističnega vidika so vse spremenljivke, ki so vključene v zgoraj izbrani model, statistično značilne/signifikantne, kar pomeni, da ima izbrana kombinacija računovodskih kazalnikov močan vpliv v modelu. V nalogi je pri (predpostavljeni) odločitveni meji/pravilu 0'5 zmožnost identifikacije/klasifikacije izbranega modela izražena s stopnjo natančnosti, če so izpolnjeni restriktivni pogoji, enaka 73,0 % na razvojnih podatkih, medtem ko če restriktivni pogoji niso izpolnjeni, je stopnja natančnosti enaka 89,0 % na testnih podatkih.

Izid zgornje enačbe (6.1) predstavlja verjetnost, da podjetje prejme modificirano vrsto revizijskega mnenja. Model kot takšen je neposredno uporabljen, vendar kot je pokazano v nalogi, je glede na preference uporabnika (tj. revizorja in/ali revizijskega podjetja) možno model prilagoditi. Preference/videnja uporabnika se namreč razlikujejo pri pojmovanju stroškov posameznih napačnih klasifikacij in glede verjetnosti za identifikacijo/napoved modificirane vrste revizijskega mnenja. Odločitev, ali model prilagoditi ali ne, je odvisna od uporabnika modela. V Tabeli 14 spodaj so podani možni načini (scenariji) prilagoditve modela glede na zahteve/preference uporabnika modela.

Tabela 14: Možni načini uporabe modela in možnosti prilagoditve modela klasifikacije

		I.	II.	III.
		Uporaba modela brez prilagoditev	Uporaba modela s prilagoditvijo odločitvene meje 1.	Uporaba modela s prilagoditvijo odločitvene meje 2.
1.	Preference/zahteve uporabnikov	► Ni posebnih preferenc/želja glede števila napačnih klasifikacij in/ali stroškov napačnih klasifikacij.	► Zahteva po najmanjšem možnem številu napak tipa 1 in/ali 2.	► Zahteva po najnižjih možnih (optimalnih) celotnih povprečnih stroških napačnih klasifikacij.
2.	Potrebna prilagoditev modela	► Ni prilagoditev.	► Prilagoditev modela z določitvijo nove odločitvene meje.	► Prilagoditev modela z določitvijo nove odločitvene meje.
3.	Potrebni dodatni podatki za prilagoditev modela	► Niso potrebni dodatni podatki.	► ROC krivulja modela (tj. poznane koordinate).	► Poznani/definirani pogoji (tj. višina stroškov, verjetnosti). ► Vrednosti odločitvenih mej pri različnih možnih scenarijih/pogojih – podane v Tabeli 13 v poglavju 5.3 Prilagoditev modelov klasifikacije.

Vir podatkov: Lastni prikaz.

Z vidika preprostosti je najenostavnejši prvi način uporabe modela, medtem ko se pri drugem in tretjem načinu uporabe modela zahteva definiranje preferenc/zahtev uporabnika modela. Z vidika gospodarnosti je optimalen tretji način uporabe modela, saj minimizira celotne povprečne stroške napačnih klasifikacij, medtem ko drugi način uporabe minimizira število napak, ki jih napravi model, kar pa ni zagotovilo, da bodo celotni povprečni stroški napačnih klasifikacij najnižji pri izbrani odločitveni meji. Optimalne odločitvene meje/pravila, ki zagotovijo minimalne celotne povprečne stroške napačnih klasifikacij pri uporabi modela, so v nalogi podane v Tabeli 13 v poglavju 5.3 Prilagoditev modelov klasifikacije.

V kolikor bi se uporabnik odločil za prilagoditev zgornjega modela, predstavljenega z enačbo (6.1), ima ta po kriteriju AUC 79,4 % povprečno uspešnost preko celotnega spektra odločitvenih mej/pravil na razvojnih podatkih in 81,4 % povprečno uspešnost preko celotnega spektra odločitvenih mej/pravil na testnih podatkih. Glede na v nalogi predstavljeno splošno sprejeto ordinalno lestvico lahko izbrani model pojmuje kot dober identifikacijski/klasifikacijski model (tj. model klasificiramo v razred B, op.p.).

Končno odločitev glede uporabe oz. relevantnosti izidov, ki jih pridobi uporabnik modela za identifikacijo oz. napoved vrste revizijskega mnenja, sprejme uporabnik/revizor sam. Predstavljen model lahko predstavlja le pripomoček revizorju za pridobivanje analitičnih dokazov, predhodni pregled stranke ali verifikacijo opravljene odločitve in kot takšen lahko služi le kot osnova za sprejemanje potrebnih ukrepov/odločitev. Kot je že v uvodu naloge poudarjeno je revizija še vedno subjektiven proces, ki ga ni možno *ad hoc* brez obširnih predhodnih raziskav umestiti v en sam model. Glede na načelo dejanskosti je obstoj univerzalnega modela težko mogoč in revizor kot nepogrešljivi člen revizijskega procesa, ki se odloči glede na zbrane revizijske dokaze o vrsti revizijskega mnenja, sam presoja, kdaj in na kateri način bo uporabil model.

Ne glede na predstavljeno vsebino naloge pa ostajajo nekatera področja neraziskana oz. je potrebna njihova poglobitev. Smeri nadaljnjih raziskav je možno okvirno usmeriti v vsaj tri različne smeri. Z vsebinskega vidika so v nalogi bili v raziskavo vključeni le kvantitativni (tj. vrednostno izraženi) računovodski kazalniki in vprašanje vpliva kvalitativnih (tj. ne vrednostno izraženih) računovodskih in/ali finančnih kazalnikov na zmožnost modela za identifikacijo/predikcijo ni proučeno. Na področju vhodnih podatkov posameznega modela je prav tako odprta možnost uporabe kompleksnejših selektivnih procesov/tehnik in samega predprocesiranja podatkov, kar bi lahko omogočilo izboljšanje končne uspešnosti posameznega modela. Poleg slednjega je priporočljiva proučitev uporabe drugačnega metodološkega instrumentarija in/ali razvoj novih tehnik (npr. kombinacija dveh tehnik itd.), ki bi izboljšale končno uspešnost posameznega modela, in prav tako proučitev uporabe in/ali razvoja drugih primernejših/boljših kriterijev za ocenitev uspešnosti posameznega modela. Odprta ostaja tudi možnost razvoja prilagojenih modelov za posamezne specialne panoge, kot je npr. razvoj modelov za podjetja iz finančnega sektorja.

7 POVZETEK

7.1 Povzetek v slovenščini

Zunanji revizorji po opravljeni reviziji gospodarskih družb v revizijskem poročilu izrazijo mnenje o izkazih gospodarskih družb. V okviru analitičnih postopkov (po Mednarodnih standardih revidiranja) je dopuščen razvoj pripomočkov oz. orodij, ki omogočijo revizorjem pridobitev analitičnih dokazov, ki so potrebni pri odločitvi glede vrste podanega revizijskega mnenja. Poznana predvidena vrsta revizijskega mnenja pred končno odločitvijo revizorja je pomemben podatek revizorju, ki vpliva na njegovo odločitev. Identificirati oz. napovedati vrsto revizijskega mnenja je možno z uporabo kombinacije izbranih računovodskih kazalnikov, kot je pokazano v nalogi. Uspešnost modela, ki temelji na logistični regresiji, pa ni realno prikazana s klasičnimi kriteriji uspešnosti, kot je npr. stopnja natančnosti, ki so omejeni z restriktivnimi pogoji. Zaradi različnih potreb/preferenc revizorjev je potrebna prilagoditev modela, v kolikor je kriterij revizorja minimizacija števila napak ali minimizacija povprečnih stroškov napačnih klasifikacij. S pomočjo ROC krivulje modela in kriterija AUC je podana agregatna povprečna uspešnost modela preko celotnega spektra odločitvenih mej. Na podlagi ROC krivulje je možna prilagoditev modela v smer minimiziranja števila napak. V nalogi predstavljena funkcija za izračun povprečnih stroškov napačnih klasifikacij omogoči določitev optimalnih odločitvenih mej, ki omogočijo minimiziranje stroškov napačnih klasifikacij pri različnih pogojih. Razvit model ima na podlagi testnih podatkov visoko zmožnost generalizacije. Prav tako rezultati analize občutljivosti pokažejo neobčutljivost modela na spremembe predpostavljenih pogojev. Podatki so bila pridobljeni iz podatkovne baze F.A.M.E. Ključna ugotovitev raziskave je, da je možno uporabiti računovodske kazalnike pri identifikaciji oz. napovedi vrste revizijskega mnenja ter da je za doseg optimalne učinkovitosti modela glede na preference revizorja potrebna njegova prilagoditev.

Ključne besede: revizija // mnenje revizorja // analitični postopki // revizijski model // identifikacijski model // klasifikacijski model // predikcijski model // računovodski kazalniki // merjenje uspešnosti // krivulja ROC // kriterij AUC // krivulje enake uspešnosti // stroški napačnih klasifikacij // analiza občutljivosti // kalibracija modela

7.2 Abstract in English

After completed audit of a company external auditor expresses opinion on financial statements of a company in auditors report. Analytical procedures (as it is stated in International Standards on Auditing) allow development of auditing applications/tools that help auditors obtain analytical evidence that are necessary for an auditor to decide about a type of audit opinion. Type of audit opinion known in advance before auditors' final decision is made is an important information for auditors and it affects auditors' decision. As it is shown in this thesis, identification/prediction of opinion type is possible using chosen combination of accounting ratios. Model was developed and tested using logistic regression and company data from F.A.M.E. database. Model's performance is not adequately shown using traditional performance measures like for example accuracy rate because they are limited by strict conditions. Auditors' criterion for minimization of error identifications/predictions or minimization of average misclassification costs requires

model adjustment. ROC curve of classification model and AUC as performance measure show aggregate average performance of a model throughout the spectrum of decision thresholds. Models' minimization of error identifications/predictions is possible with model adjustment using ROC curve results. Calculating average misclassification costs enables the determination of optimal decision thresholds that minimize misclassification costs at different conditions. Based on test data set (unseen data) the developed model has a high generalization ability. Results of a sensitivity analysis also show that model is insensitive to changes in presumed conditions. First important finding of this research is that it is possible to use accounting ratios for audit opinion identification/prediction and second that for optimal performance proposed identification/prediction model needs to be adequately adjusted while considering auditors' criteria.

Key words: audit // audit opinion // analytical procedures // audit model // identification model // classification model // prediction model // accounting ratios // performance evaluation // ROC curve // area under the curve // iso-performance lines // misclassification costs // sensitivity analysis // model calibration

8 LITERATURA IN VIRI

8.1 Literatura

- Altman, Edward I. 1968. Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy. *The Journal of Finance* 4/23: 589-609.
- Altman, Edward I., Giancarlo Marco in Franco Varetto. 1994. Corporate Distress Diagnosis: Comparisons Using Linear Discriminant Analysis and Neural Networks (the Italian Experience). *Journal of Banking and Finance* 18/1994: 505-529.
- Anandarajan, Murugan in Anandarajan Asokan. 1999. A Comparison of Machine Learning Techniques with a Qualitative Response Model for Auditor's Going Concern Reporting. *Expert Systems with Applications* 16/1999: 385-392.
- Anandarajan, Murugan, Picheng Lee in Asokan Anandarajan. 2001. Bankruptcy Prediction of Financially Stressed Firms: An Examination of the Predictive Accuracy of Artificial Neural Networks. *International Journal of Intelligent Systems in Accounting, Finance and Management* 2/10: 69-81.
- Barnes, Paul. 2004. The Auditor's Going Concern Decision and Type I and II Errors: The Coase Theorem, Transaction Costs, Bargaining Power and Attempts to Mislead. *Journal of Accounting and Public Policy* 23/2004: 415-440.
- Bazerman, Max H., George Loewenstein in Don A. Moore. 2002. Why Good Accountants do Bad Audits. *Harvard Business Review* 11/2002: 91-102.
- Beaver, William H. 1966. Financial Ratios as Predictors of Failure. *Journal of Accounting Research – Empirical Research in Accounting: Selected Studies* 4/1966: 71-111.
- Bell, Timothy B. 1997. Neural Nets or the Logit Model? A Comparison of Each Model's Ability to Predict Commercial Bank Failures. *Intelligent Systems in Accounting, Finance & Management* 6/1997: 249-264.
- Bettinger, Ross. (2003). *Cost-Sensitive Classifier Selection Using the ROC Convex Hull Method* [online]. George Mason University – Statistics Department. Available: <http://neptune.galaxy.gmu.edu/interface/I03/I2003Proceedings/BettingerRoss/BettingerRoss.paper.pdf> [20.6.2006].
- Boynton, William C., Raymond N. Johnson in Walter G. Kell. 2001. *Modern Auditing – Seventh Edition*. New York: John Wiley & Sons, Inc.
- Brigham, Eugene F. in Michael C. Ehrhardt. 2005. *Financial Management: Theory and Practice – 11th Edition*. United States of America: Thomson South-Western.
- Calderon, Thomas G. in John J. Cheh. 2002. A Roadmap for Future Neural Networks Research in Auditing and Risk Assessment. *International Journal of Accounting Information Systems* 3/2002: 203-236.
- Charitou, Andreas, Evi Neophytou in Chris Charalambous. 2004. Predicting Corporate Failure: Empirical Evidence for the UK. *European Accounting Review* 3/13: 465-497.
- Dupoch, Nicholas, Robert W. Holthausen in Richard W. Leftwich. 1987. Predicting Audit Qualifications with Financial and Market Variables. *The Accounting Review* 3/58: 431-454.
- Dupoch, Nicholas, Robert W. Holthausen in Richard W. Leftwich. 1986. Abnormal Stock Returns Associated with Media Disclosures of 'Subject to' Qualified Audit Opinions. *Journal of Accounting and Economics* 8/1986: 93-117.

- EC – European Communities. (2003). *Uredba Komisije (ES) št. 1725/2003 – o sprejetju nekaterih mednarodnih računovodskih standardov v skladu z Uredbo (ES) št. 1606/2002* [online]. EURLex - Urad za uradne publikacije Evropskih skupnosti. Available: <http://europa.eu.int/eur-lex/sl/dd/docs/2003/32003R1725-SL.doc> [20.6.2006].
- Etheridge, Harlan L., Ram S. Sriram in H.Y. Kathy Hsu. 2000. A Comparison of Selected Artificial Neural Networks that Help Auditors Evaluate Client Financial Viability. *Decision Sciences* 2/31: 531-550.
- Fawcett, Tom. (2003). *ROC Graphs: Notes and Practical Considerations for Data Mining Researchers* [online]. Hewlett-Packard Company – HP Laboratories Palo Alto. Available: <http://www.hpl.hp.com/techreports/2003/HPL-2003-4.pdf> [15.6.2006].
- Flach, Peter A. (2004). *The Many Faces of ROC Analysis in Machine Learning* [online]. The 21st International Conference on Machine Learning – ICML 2004 Tutorial on ROC Analysis. Available: <http://www.cs.bris.ac.uk/~flach/ICML04tutorial/ROCTutorialPartI.pdf> [15.6.2006].
- Gaganis, Chrysovalantis, Fotios Pasiouras in Michael Doumpos. 2006. Probabilistic Neural Networks for the Identification of Qualified Audit Opinions. *Expert Systems with Applications*: [Article in Press].
- Garson, David. D. (2006). *Logistic Regression* [online]. North Carolina State University. Available: <http://www2.chass.ncsu.edu/garson/PA765/logistic.htm> [3.6.2006].
- Gerber, Kathy. (2005). *ITC Research Computing Support – Missing Values Analysis and Imputation* [online]. ITC Research Computing. Available: <http://www.itc.virginia.edu/research/talks/missing.ppt#1> [15.6.2006].
- Gujarati, Damodar N. 2003. *Basic Econometrics – 4th Edition*. New York: McGraw-Hill, Inc.
- Hanley, James A. in Barbara J. McNeil. 1983. A Method of Comparing the Areas under Receiver Operating Characteristic Curves Derived from the Same Cases. *Radiology* 3/148: 839-843.
- Hansen, James V., James B. McDonald in James D. Stice. 1992. Artificial intelligence and Generalized Qualitative-Response Models: An Empirical Test on Two Audit Decision-Making Domains. *Decision Sciences* 3/23: 708-723.
- Hippel von, Paul T. 2004. Biases in SPSS 12.0 Missing Value Analysis. *The American Statistician* 2/58: 160-164.
- Hopwood, William, James McKeown in Jane Mutcher. 1989. A Test of the Incremental Explanatory Power of Opinions Qualified for Consistency and Uncertainty. *The Accounting Review* 1/64: 28-48.
- Hunter, A., L. Kennedy, J. Henry in I. Ferguson. 2000. Application of Neural Networks and Sensitivity Analysis to Improved Prediction of Trauma Survival. *Computer Methods and Programs in Biomedicine* 62/2000: 11-19.
- IFAC – International Federation of Accountants. (2005). *Handbook of International Auditing, Assurance, and Ethics Pronouncements – 2005 Edition* [online]. IAASB – International Auditing and Assurance Standards Board. Dosegljivo: <http://www.ifac.org/IAASB/Pronouncements.php#Standards> [3.3.2006].
- Ireland, Jennifer C. 2003. An Empirical Investigation of Determinants of Audit Reports in the UK. *Journal of Business Finance & Accounting* 7-8/30: 975-1015.
- Jain, Bharat A. in Barin N. Nag. 1997. Performance Evaluation of Neural Network Decision Models. *Journal of Management Information Systems* 2/14: 201-216.

- Kocbek, Marijan in Saša Prelič. 2006. *Zakon o gospodarskih družbah (ZGD-1) – Uvodna pojasnila*. Ljubljana: GV Založba.
- Koh, Hian Chye in Larry N. Killough. 1990. The Use of Multiple Discriminant Analysis in the Assessment of the Going-Concern Status of an Audit Client. *Journal of Business, Finance & Accounting* 2/17: 179-192.
- Koh, Hian Chye. 1991. Model Predictions and Auditor Assessments of Going Concern Status. *Accounting and Business Research* 21/84: 331-338.
- Koh, Hian Chye. 1992. The Sensitivity of Optimal Cutoff Points to Misclassification Costs of Type I and Type II Errors in the Going-Concern Prediction Context. *Journal of Business, Finance & Accounting* 2/19: 187-197.
- Koh, Hian Chye. 2004. Going Concern Prediction using Data Mining Techniques. *Managerial Auditing Journal* 3/19: 462-476.
- Koletnik, Franc. 2005. *Revidiranje*. Maribor: Ekonomsko-poslovna fakulteta, Katedra za računovodstvo in revizijo.
- Koletnik, Franc. 2006. *Proučevanje (analiziranje) računovodskih izkazov – Tretja dopolnjena izdaja*. Maribor: Ekonomsko-poslovna fakulteta.
- Koskivaara, Eija. 2000. Artificial Neural Network Models for Predicting Patterns in Auditing Monthly Balances. *Journal of the Operational Research Society* 51/2000: 1060-1069.
- Koskivaara, Eija. 2004. Artificial Neural Networks in Analytical Review Procedures. *Managerial Auditing Journal* 2/19: 191-223.
- Krishnan, Jagan in Jayanthi Krishnan. 1996. The Role of Economic Trade-Offs in the Audit Opinion Decision: An Empirical Analysis. *Journal of Accounting, Auditing and Finance* 4/11: 565-586.
- Lacher, R.C., Pamela K. Coats, Shanker C. Sharma in L. Franklin Fant. 1995. A Neural Network for Classifying the Financial Health of a Firm. *European Journal of Operational Research* 85/1995: 53-65.
- LaSalle, Randall E., Asokan Anandarajan in Allie F. Miller. 1996. Going Concern Uncertainties: Disclaimer of Opinion versus Unqualified Opinion with Modified Wording. *Auditing: A Journal of Practice & Theory* 2/15: 30-48.
- Lee, Picheng, Wei Jiang in Asokan Anandarajan. 2005. Going Concern Report Modeling: A Study of Factors Influencing the Auditor's Decision. *Journal of Forensic Accounting* 1/6: 55-76.
- Lenard, Mary Jane, Pervaiz Alam in David Booth. 2000. An Analysis of Fuzzy clustering and a Hybrid Model for the Auditor's Going Concern Assessment. *Decision Sciences* 4/31: 861-884.
- Lensberg, Terje, Aasmund Eilifsen in Thomas E. McKee. 2006. Bankruptcy Theory Development and Classification via Genetic Programming. *European Journal of Operational Research* 169/2006: 677-697.
- Luther, Raminder K. 1998. An Artificial Neural Network Approach to Predicting the Outcome of Chapter 11 Bankruptcy. *The Journal of Business and Economic Studies* 1/4: 57-73.
- McKee, Thomas E. in Marilyn Greenstein. 2000. Predicting Bankruptcy Using Recursive Partitioning and a Realistically Proportioned Data Set. *Journal of Forecasting* 19/2000: 219-230.
- Menon, Krishnagopal in Kenneth B. Schwartz. 1986. An Empirical Investigation of Audit Qualification Decisions in the Presence of Going Concern Uncertainties. *Contemporary Accounting Research* 2/3: 302-315.

- Metaxiotis, Kostas in John Psarras. 2004. The Contribution of Neural Networks and Genetic Algorithms to Business Decision Support – Academic Myth or Practical Solution? *Management Decision* 1-2/42: 229-242.
- Mutcher, Jane F., William Hopwood in James M. McKeown. 1997. The Influence of Contrary Information and Mitigating Factors on Audit Opinion Decisions on Bankrupt Companies. *Journal of Accounting Research* 2/35: 295-310.
- Nanda, Sudhir in Parag Pendharkar. 2001. Linear Models for Minimizing Costs in Bankruptcy Prediction. *International Journal of Intelligent Systems in Accounting, Finance and Management* 3/10: 155-168.
- O'Leary, Daniel E. 1998. Using Neural Networks to Predict Corporate Failure. *International Journal of Intelligent Systems in Accounting, Finance and Management* 7: 187-197.
- Pompe, Paul P.M. in Jan Bilderbeek. 2005. The Prediction of Bankruptcy of Small- and Medium-Sized Industrial Firms. *Journal of Business Venturing* 20: 847-868.
- Purdon, Susan, Gillian Raab in Kathy Buckner. (2005). *Using Imputation for Missing Values* [online]. PEAS – Practical Exemplars and Survey Analysis. Available: <http://www.napier.ac.uk/depts/fhls/peas/imputation.asp> [16.6.2006].
- Raghunandan, K. in D.V. Rama. 1995. Audit Reports for Companies in Financial Distress: Before and After SAS No. 59. *Auditing: A Journal of Practice & Theory* 1/14: 50-63.
- Rässler, Susanne. (2004). *The Impact of Multiple Imputation for DACSEIS* [online]. DACSEIS Research Paper Series – No. 5. Available: <http://w210.ub.uni-tuebingen.de/dbt/volltexte/2004/1135/pdf/DRPS5.pdf> [15.6.2006].
- Schafer, Joe. (1999a). *NORM: Multiple imputation of incomplete multivariate data, version 2.03* [online]. Department of Statistics, The Pennsylvania State University. Available: <http://www.stat.psu.edu/~jls/misoftwa.html> [15.6.2006].
- Schafer, Joe. (1999b). *The multiple imputation – Frequently Asked Questions* [online]. Joe Schafer. Available: <http://www.stat.psu.edu/~jls/mifaq.html> [15.6.2006].
- Schalkwyk, Lara in Jo Schalkwyk. (2003). *The Magnificent ROC (Receiver Operating Characteristic Curve)* [online]. Anaesthetist.com. Available: <http://www.anaesthetist.com/mnm/stats/roc/> [20.6.2006].
- Sen, Tarun K., Parviz Ghandforoush in Charles T. Stivason. 2004. Improving Prediction of Neural Networks: A Study of Two Financial Prediction Tasks. *Journal of Applied Mathematics and Decision Sciences* 4/8: 219-233.
- Shahian, D.M., E.H. Blackstone, F.H. Edwards, F.L. Grover, G.L. Grunkemeier, D.C. Naftel, S.A.M. Nashef, W.C. Nugent in E.D. Peterson. 2004. Cardiac Surgery Risk Models: A Position Article. *The Annals of Thoracic Surgery* 78/2004: 1868-1877.
- Sinha, Atish P. in Jerrold H. May. 2005. Evaluating and Tuning Predictive Data Mining Models Using Receiver Operating Characteristic Curves. *Journal of Management Information Systems* 3/21: 249-280.
- SIR – Slovenski inštitut za revizijo. 2005. *Slovenski računovodski standardi 2006*. Ljubljana: Slovenski inštitut za revizijo.
- Spathis, Charalambos, Michael Doumpos in Constantin Zopounidis. 2003. Using Client Performance Measures to Identify Pre-engagement Factors Associated with Qualified Audit Reports in Greece. *The International Journal of Accounting* 2003/38: 267-284.
- SPSS – SPSS, Inc. 2004. Help Topics – Tests of Several Independent Samples. *SPSS, Inc.* Available in SPSS 13.0 Release for Windows.

- SSTARS – Social Sciences Teaching and Research Statistics. (2005). Multicollinearity in Logistic Regression. *SSTARS – Center for Statistical Computing Support* [online]. Available: <http://www.uky.edu/ComputingCenter/SSTARS/MulticollinearityinLogisticRegression.htm> [10.6.2006].
- Tabachnick, Barbara G. in Linda S. Fidell. 2001. *Using Multivariate Statistics – 4th Edition*. Boston: Pearson Education – Allyn & Bacon, Corp.
- Tam, Kar Yan in Melody Y. Kiang. 1992. Managerial Applications of Neural Networks: The Case of Bank Failure Predictions. *Management Science* 7/38: 926-947.
- Trigueiros, Duarte in Richard Taffler. 1996. Neural Networks and Empirical Research in Accounting. *Accounting and Business Research* 4/26: 347-355.
- Turk, Ivan. 2002. *Pojmovnik računovodstva, financ in revizije*. Ljubljana: Slovenski inštitut za revizijo.
- Webb, Andrew R. 2002. *Statistical Pattern Recognition – 2nd Edition*. Chichester: John Wiley & Sons, Ltd.
- Wild, John J., K.R. Subramanyam in Robert F. Halsey. 2003. *Financial Statement Analysis – 8th Edition*. Singapore: McGraw-Hill.
- Zmijewski, Mark E. 1984. Methodological Issues Related to the Estimation of Financial Distress Prediction Models. *Journal of Accounting Research* 22: 59-82.

8.2 Viri

- Bureau van Dijk. 2006. “F.A.M.E. – Financial Analysis Made Easy. UK and Irish Company Information in an Instant.” F.A.M.E. [database online]. Available: <https://fame.bvdep.com/cgi/template.dll?product=1> [8.4.2006].

(Ta stran je namerno ostala prazna.)

9 SEZNAM OKRAJŠAV IN OZNAK

Oznaka / okrajšava	Definicija oz. pomen
MSRev	► Mednarodni standardi revidiranja (angl. <i>ISA – International Standards on Auditing</i>).
MSRP	► Mednarodni standardi računovodskega poročanja (angl. <i>IFRS – International Financial Reporting Standards</i>).
N	► Število spremenljivk.
C	► Število razredov.
x_i	► Vektor podatkovnega niza kazalnikov i -tega podjetja.
X_i	► i -ta spremenljivka.
ω_j	► Oznaka razreda j .
β_i	► Koeficient spremenljivke X_i .
b	► Vektor koeficientov.
b^T	► Transponiran vektor koeficientov b .
a	► Mejna vrednost (angl. <i>threshold</i>).
y_i	► Izhodni vektor za i -to podjetje po transformaciji f .
$E(Y X)$	► Pričakovana vrednost Y pri podani vrednosti X .
$p(x \omega_j)$	► Pričakovana verjetnost (angl. <i>prior probability</i>), da podatkovni niz x pripada razredu ω_j .
$\frac{p(x \omega_j)}{p(x \omega_i)}$	► Razmerje obetov (angl. <i>odds ratio</i>) med pričakovanima verjetnostima, da podatkovni niz x pripada razredu ω_j in razredu ω_i .
TP	► Dejansko pozitivno klasificirani/identificirani primeri (angl. <i>True positive</i>).
FP	► Napačno pozitivno klasificirani/identificirani primeri (angl. <i>False positive</i>).
FN	► Napačno negativno klasificirani/identificirani primeri (angl. <i>False negative</i>).
TN	► Dejansko negativno klasificirani/identificirani primeri (angl. <i>True negative</i>).
$TPR, Sensitivity$	► Stopnja resnično/dejansko pozitivno klasificiranih/identificiranih primerov (angl. <i>True positive rate, Recall, Sensitivity</i>); tudi senzitivnost.
$TNR, Specificity$	► Stopnja resnično/dejansko negativno klasificiranih/identificiranih primerov (angl. <i>True negative rate, Specificity</i>); tudi specifičnost.
FPR	► Stopnja napačnih negativno klasificiranih/identificiranih primerov (angl. <i>False positive rate</i>).
$Precision$	► Stopnja resnično/dejansko pozitivno klasificiranih/identificiranih primerov glede na vse pozitivno klasificirane/identificirane primere (angl. <i>Precision</i>); tudi natančnost.
Acc	► Stopnja natančnosti (angl. <i>Accuracy</i>).
ROC	► Krivulja operativne karakteristike (angl. <i>Receiver operating characteristic curve</i>).
AUC	► Področje/površina pod krivuljo ROC (angl. <i>Area under the curve, c-index, c-statistics</i>); tudi c -indeks, c -statistika.
n_p	► Število podjetij s prejetim pozitivnim mnenjem.
n_m	► Število podjetij s prejetim modificiranim mnenjem.
S_0	► Vsota rangov razreda podjetij s pozitivnim mnenjem za izbrani vzorec podatkov.
z	► Izračunana vrednost po Hanley in McNeil (1983) za primerjavo dveh različnih ROC krivulj.
SE_i	► Standardna napaka pri izračunu AUC_i .
r_{ij}	► Ocenjen korelacijski koeficient med AUC_i in AUC_j .
$Gini coefficient$	► Ginijev koeficient, ki je izračunan na podlagi AUC_i .
$\bar{C}$	► Povprečni stroški klasifikacijskega/identifikacijskega modela.
$\bar{C}_0$	► Stalni povprečni stroški klasifikacijskega/identifikacijskega modela.

(Nadaljevanje na naslednji strani.) ▼

Oznaka / okrajšava	Definicija oz. pomen
C_{ij}	► Stroški klasifikacij/identifikacij, in sicer ko je $i = j$ pravilne klasifikacije in ko je $i \neq j$ napačne klasifikacije.
C_{00}	► Stroški pravih klasifikacij/identifikacij resničnih/dejanskih pozitivnih primerov (tj. podjetij s pozitivnimi mnenji med podjetja s pozitivnimi mnenji).
C_{11}	► Stroški pravih klasifikacij/identifikacij resničnih/dejanskih negativnih primerov (tj. podjetij z modificiranimi mnenji med podjetja z modificiranimi mnenji).
C_{10}	► Stroški napačnih klasifikacij/identifikacij resničnih/dejanskih pozitivnih primerov (tj. podjetij s pozitivnimi mnenjem med podjetja z modificiranimi mnenji); tudi napaka tipa 1 (angl. <i>type 1 error</i>).
C_{01}	► Stroški napačnih klasifikacij/identifikacij resničnih/dejanskih negativnih primerov (tj. podjetij z modificiranimi mnenjem med podjetja s pozitivnimi mnenji); tudi napaka tipa 2 (angl. <i>type 2 error</i>).
P_{ij}	► Pričakovana verjetnost, da podjetje, ki je klasificirano/identificirano v razred ω_i , resnično pripada razredu ω_j ; če je $i = j$, je to verjetnost pravilne klasifikacije in če je $i \neq j$, je to verjetnost napačne klasifikacije.
P_i	► Pričakovana verjetnost klasifikacije/identifikacije podjetij, ki dejansko pripadajo razredu ω_i (tj. ko je $i = 0$, je to razred podjetij, ki prejmejo pozitivno mnenje in ko je $i = 1$, je to razred podjetij, ki prejmejo modificirano mnenje).
$\bar{C}_c$	► Povprečni stroški napačnih klasifikacij/identifikacij klasifikacijskega modela.
m	► Naklon linije enake uspešnosti (angl. <i>iso-performance line</i>).
AIC	► Akaike-jev informacijski kriterij (angl. <i>Akaike Information Criterion</i>).
R_N^2	► Nagelkerke-jev determinacijski koeficient (angl. <i>Nagelkerkes' coefficient of determination</i>).

10 KAZALO SEZNAMOV

10.1 Seznam tabel

TABELA 1: OBLIKE POROČIL IN VRSTE REVIZIJSKIH MNENJ	7
TABELA 2: DEJAVNIKI, KI VPLIVAJO NA REVIZORJA	14
TABELA 3: KONTINGENČNA TABELA	26
TABELA 4: KLASIČNI KRITERIJI ZA OCENJEVANJE USPEŠNOSTI MODELA KLASIFIKACIJE	27
TABELA 5: DESKRIPTIVNA STATISTIKA NEKATERIH ZNAČILNOSTI PODJETIJ ZA IZBRANI VZOREC	48
TABELA 6: KAZALNIKI PO VSEBINSKIH SKLOPIH	49
TABELA 7: IZBRANE SPREMENLJIVKE PO VSEBINSKIH SKLOPIH	51
TABELA 8: KONSTRUIRANI MODELI KLASIFIKACIJE	52
TABELA 9: ENAČBE LOGISTIČNE REGRESIJE ZA POSAMEZEN MODEL	56
TABELA 10: KLASIČNI KLASIFIKACIJSKI KRITERIJI	58
TABELA 11: PRIMERJAVA MODELOV NA PODLAGI AUC	62
TABELA 12: PRIMERJAVA MODELOV NA PODLAGI KRITERIJA AUC	63
TABELA 13: OPTIMALNE ODLOČITVENE MEJE/TOČKE MODELOV	64
TABELA 14: MOŽNI NAČINI UPORABE MODELA IN MOŽNOSTI PRILAGODITVE MODELA KLASIFIKACIJE	73
TABELA 15: DESKRIPTIVNA STATISTIKA PRILAGOJENEGA RAZVOJNEGA VZORCA	87
TABELA 16: ANALIZA MANJKAJOČIH PODATKOV PRI POSAMEZNIH SPREMENLJIVKAH	88
TABELA 17: RAZLIKA MED IMPUTIRANIM IN NEIMPOTIRANIM VZORCEM PODATKOV	89
TABELA 18: RAČUNOVODSKI KAZALNIKI PO VSEBINSKIH SKLOPIH – DEFINICIJE IN NAČIN IZRAČUNA	90
TABELA 19: PROCES REDUKCIJE ŠTEVILA SPREMENLJIVK	94
TABELA 20: DESKRIPTIVNA STATISTIKA ZA IZBRANI VZOREC	95
TABELA 21: KORELACIJSKA ANALIZA	96
TABELA 22: DESKRIPTIVNA STATISTIKA ZA IZBRANI VZOREC IN KRUSKAL-WALLIS PREIZKUS	98
TABELA 23: ANALIZA SPREMENLJIVK MODELA	99
TABELA 24: MINIMALNI STROŠKI PRI UPORABI MODELOV ZA RAZVOJNE PODATKE IN STROŠKI PRI ENAKI ODLOČITVENI TOČKI NA TESTNIH PODATKIH	101

10.2 Seznam slik

SLIKA 1: DIAGRAM POTEKA ANALITIČNIH POSTOPKOV	11
SLIKA 2: LINEARNO LOČLJIV PROBLEM	20
SLIKA 3: SHEMATIČEN PRIKAZ ZAPISA PREPROSTEGA MODELA	21
SLIKA 4: LINEARNO NEREŠLJIVI PROBLEMI	22
SLIKA 5: SHEMATIČEN PRIKAZ ZAPISA LOGISTIČNEGA MODELA	23
SLIKA 6: VENOV DIAGRAM	27
SLIKA 7: PRIMERI VENOVIH DIAGRAMOV	28
SLIKA 8: GRAFIKON ROC KRIVULJE IN VENOV DIAGRAMI	32
SLIKA 9: PODROČJE POD KRIVULJO ROC	35
SLIKA 10: LINIJE ENAKE USPEŠNOSTI	37
SLIKA 11: SHEMA SESTAVE VZORCA PODATKOV	46

10.3 Seznam grafikonov

GRAFIKON 1: RAZSEVNI GRAFIKONI IN ROC KRIVULJE KLASIFIKACIJSKIH MODELOV NA RAZVOJNIH PODATKIH	60
GRAFIKON 2: RAZSEVNI GRAFIKONI IN ROC KRIVULJE KLASIFIKACIJSKIH MODELOV NA TESTNIH PODATKIH	61
GRAFIKON 3: GRAFIKONI PRIČAKOVANIH STROŠKOV PRI RAZLIČNIH RAZMERJIH STROŠKOV	66
GRAFIKON 4: ANALIZA OBČUTLJIVOSTI MODELOV KLASIFIKACIJE	68

(Ta stran je namerno ostala prazna.)

11 PRILOGE

11.1 Priloge k 4. poglavju

11.1.1 Priloga 1: Deskriptivna statistika prilagojenega vzorca

Tabela 15: Deskriptivna statistika prilagojenega razvojnega vzorca

	Oznaka kazalnika	Število	Povprečje	St. odklon	Manjkajoče vrednosti		Število ekstremov ^a	
					Število	V odstotkih (%)	Spodnja meja	Zgornja meja
	1	2	3	4	5a	5b	6a	6b
X ₁	ROA	528	-105,72	975,30	2	,4	39	0
X ₂	ROE	530	-51,95	691,23	0	,0	45	42
X ₃	ROCE	530	-137,55	2.019,62	0	,0	65	40
X ₄	EquityGrowthRate	530	-53,47	691,03	0	,0	45	43
X ₅	GrossPM	437	8,45	390,04	93	17,5	21	0
X ₆	OperatingPM	437	-582,27	3.115,12	93	17,5	66	0
X ₇	NetPM	437	-628,07	3.229,40	93	17,5	70	3
X ₈	EBITPM	437	-617,85	3.247,59	93	17,5	71	3
X ₉	PretaxPM	437	-632,95	3.242,84	93	17,5	70	2
X ₁₀	OperatingCFtoIncome	516	230,47	2.179,94	14	2,6	23	47
X ₁₁	EarningsLeverage	516	1,13	4,38	14	2,6	110	82
X ₁₂	CapitalEmployedTurnover	530	3,51	20,96	0	,0	23	54
X ₁₃	BasicEarningsPower	528	-161,94	1.045,71	2	,4	58	0
X ₁₄	AssetsTurnover	528	,85	,97	2	,4	0	14
X ₁₅	FixedAssetsTurnover	518	2,99	7,30	12	2,3	0	61
X ₁₆	CashTurnover	514	140,45	855,06	16	3,0	0	70
X ₁₇	WorkingCapital	530	8.993,89	126.532,01	0	,0	37	81
X ₁₈	WorkingCapitalTurnover	476	4,83	74,38	54	10,2	47	59
X ₁₉	CurrentLiabTurnover	527	2,51	7,02	3	,6	0	9
X ₂₀	CurrentRatio	527	3,01	13,24	3	,6	0	54
X ₂₁	QuickRatio	527	2,21	6,12	3	,6	0	65
X ₂₂	LiquidityRatio	527	1,87	6,13	3	,6	0	58
X ₂₃	InventoryTurnover	319	65,80	290,81	211	39,8	0	54
X ₂₄	DaysInventoryHeld	296	222,26	1.331,28	234	44,2	0	24
X ₂₅	DebtorsTurnover	411	29,94	163,98	119	22,5	0	54
X ₂₆	DebtorsCollectionPeriod	401	71,97	78,71	129	24,3	0	26
X ₂₇	GrossOperatingCycle	283	289,14	1.378,15	247	46,6	0	20
X ₂₈	AccountsPayableTurnover	444	6,61	21,86	86	16,2	1	31
X ₂₉	DaysPurchasesAccountsPayable	378	7.624,41	100.803,55	152	28,7	13	69
X ₃₀	NetOperatingCycle	264	-1.215,77	10.165,97	266	50,2	39	12
X ₃₁	CFtoCurrentLiabilities	527	-1,01	2,64	3	,6	62	6
X ₃₂	DebtRatio	528	130,96	757,33	2	,4	0	41
X ₃₃	LTDebtToAssets	528	32,97	361,37	2	,4	0	35
X ₃₄	DebtToEquityRatio	530	149,25	1.102,29	0	,0	42	55
X ₃₅	LTDebttoEquity	530	17,56	165,04	0	,0	36	62
X ₃₆	FinLeverageRatio	530	2,49	11,02	0	,0	42	55
X ₃₇	FinLeverageIndex	515	2,05	11,50	15	2,8	63	64
X ₃₈	InterestCoverageRatio	402	-270,80	2.554,14	128	24,2	63	8
X ₃₉	AltmanZ	528	-5,53	47,15	2	,4	56	1

Opomba: ^a Število primerov izven intervala ($Q1 - 1,5 \cdot IQR$, $Q3 + 1,5 \cdot IQR$).
Vir podatkov: Lastni izračun.

11.1.2 Priloga 2: Analiza manjkajočih podatkov pri posameznih spremenljivkah

Tabela 16: Analiza manjkajočih podatkov pri posameznih spremenljivkah

		Število primerov podjetij	
Manjkajoči vzorci podatkov ^a		233	63
X ₁	ROA		
X ₂	ROE		
X ₃	ROCE		
X ₄	EquityGrowthRate		
X ₅	GrossPM		
X ₆	OperatingPM		
X ₇	NetPM		
X ₈	PretaxPM		
X ₉	EBITPM		
X ₁₀	OperatingCFtoIncome		
X ₁₁	EarningsLeverage		
X ₁₂	CapitalEmployedTurnover		
X ₁₃	BasicEarningsPower		
X ₁₄	AssetsTurnover		
X ₁₅	FixedAssetsTurnover		
X ₁₆	CashTurnover		
X ₁₇	WorkingCapital		
X ₁₈	WorkingCapitalTurnover		
X ₁₉	CurrentLiabTurnover		
X ₂₀	CurrentRatio		
X ₂₁	QuickRatio		
X ₂₂	LiquidityRatio		
X ₂₃	InventoryTurnover		X
X ₂₄	DaysInventoryHeld		X
X ₂₆	DebtorsCollectionPeriod		
X ₂₅	DebtorsTurnover		
X ₂₇	GrossOperatingCycle		X
X ₂₈	AccountsPayableTurnover		
X ₂₉	DaysPurchasesAccountsPayable		
X ₃₀	NetOperatingCycle		X
X ₃₁	CFtoCurrentLiabilities		
X ₃₂	DebtRatio		
X ₃₃	LTDebtToAssets		
X ₃₄	DebtToEquityRatio		
X ₃₅	LTDebttoEquity		
X ₃₆	FinLeverageRatio		
X ₃₇	FinLeverageIndex		
X ₃₈	InterestCoverageRatio		
X ₃₉	AltmanZ		
Popolni vzorec, če... ^b		233	306

Opombe:

^a Vzorci, ki imajo manj kot 5 % manjkajočih vrednosti (27 podjetij ali manj), niso prikazani.

^b Število popolnih primerov, če spremenljivka, ki manjka v vzorcu podatkov (označena z X), ni vključena v vzorec.

Vir podatkov:

Lastni izračun.

11.1.3 Priloga 3: Kruskal-Wallis H-test za imputiran in neimputiran vzorec

Tabela 17: Razlika med imputiranim in neimputiranim vzorcem podatkov

		Število podjetij		Povprečje rangov		Kruskal-Wallis test		
		Neimputiran vzorec	Imputiran vzorec	Neimputiran vzorec	Imputiran vzorec	χ^2	Stopnja prostosti	Signifikantnost
		1a	1b	2a	2b	3a	3b	3c
X ₁	ROA	528	530	529,97	529,03	0,003	1	0,960
X ₂	ROE	530	530	530,03	530,97	0,002	1	0,960
X ₃	ROCE	530	530	526,97	534,03	0,141	1	0,707
X ₄	EquityGrowthRate	530	530	529,99	531,01	0,003	1	0,957
X ₅	GrossPM	437	530	485,97	482,38	0,040	1	0,842
X ₆	OperatingPM	437	530	459,35	504,33	6,212	1	0,013 **
X ₇	NetPM	437	530	456,22	506,91	7,889	1	0,005 *
X ₈	EBITPM	437	530	458,39	505,12	6,706	1	0,010 *
X ₉	PretaxPM	437	530	456,68	506,53	7,631	1	0,006 *
X ₁₀	OperatingCFtoIncome	516	530	526,87	520,22	0,127	1	0,722
X ₁₁	EarningsLeverage	516	530	534,08	513,20	1,282	1	0,258
X ₁₂	CapitalEmployedTurnover	530	530	511,09	549,91	4,265	1	0,039 **
X ₁₃	BasicEarningsPower	528	530	523,07	535,91	0,467	1	0,495
X ₁₄	AssetsTurnover	528	530	489,62	569,23	17,966	1	0,000 *
X ₁₅	FixedAssetsTurnover	518	530	488,33	559,85	14,636	1	0,000 *
X ₁₆	CashTurnover	514	530	493,01	551,10	9,689	1	0,002 *
X ₁₇	WorkingCapital	530	530	583,39	477,61	31,640	1	0,000 *
X ₁₈	WorkingCapitalTurnover	476	530	487,35	518,00	2,792	1	0,095 ***
X ₁₉	CurrentLiabTurnover	527	530	484,25	573,49	22,595	1	0,000 *
X ₂₀	CurrentRatio	527	530	527,59	530,40	0,022	1	0,881
X ₂₁	QuickRatio	527	530	526,65	531,33	0,062	1	0,803
X ₂₂	LiquidityRatio	527	530	526,51	531,48	0,070	1	0,791
X ₂₃	InventoryTurnover	319	530	417,01	429,81	0,542	1	0,461
X ₂₄	DaysInventoryHeld	296	530	409,19	415,91	0,151	1	0,698
X ₂₅	DebtorsTurnover	411	530	444,93	491,21	6,712	1	0,010 *
X ₂₆	DebtorsCollectionPeriod	401	530	466,94	465,29	0,009	1	0,926
X ₂₇	GrossOperatingCycle	283	530	417,29	401,51	0,833	1	0,361
X ₂₈	AccountsPayableTurnover	444	530	469,09	502,92	3,496	1	0,062 ***
X ₂₉	DaysPurchasesAccountsPayable	378	530	508,29	416,14	27,240	1	0,000 *
X ₃₀	NetOperatingCycle	264	530	415,22	388,68	2,360	1	0,125
X ₃₁	CFtoCurrentLiabilities	527	530	534,41	523,62	0,330	1	0,566
X ₃₂	DebtRatio	528	530	533,90	525,12	0,218	1	0,640
X ₃₃	LTDebtToAssets	528	530	480,35	578,47	27,388	1	0,000 *
X ₃₄	DebtToEquityRatio	530	530	548,83	512,17	3,798	1	0,051 ***
X ₃₅	LTDebttoEquity	530	530	498,04	562,96	11,959	1	0,001 *
X ₃₆	FinLeverageRatio	530	530	528,92	532,08	0,028	1	0,867
X ₃₇	FinLeverageIndex	515	530	521,97	524,00	0,012	1	0,913
X ₃₈	InterestCoverageRatio	402	530	468,01	465,35	0,022	1	0,881
X ₃₉	AltmanZ	528	530	529,41	529,58	0,000	1	0,993

Opombe: * Signifikantno pri 0,01.
 ** Signifikantno pri 0,05.
 *** Signifikantno pri 0,10.

Vir podatkov: Lastni izračun.

11.1.4 Priloga 4: Računovodski kazalniki

Tabela 18: Računovodski kazalniki po vsebinskih sklopih – Definicije in način izračuna

Kazalnik	Oznaka kazalnika v nalogi	Običajna oznaka	Enota mere	Izračun	Pomen kazalnika
1	2	3	4	5	6
I. KAZALNIKI DOBIČKONOSNOSTI					
1. Koeficient čiste donosnosti sredstev (<i>Return on assets</i>)	X ₁	ROA	%	$\frac{\text{Čisti poslovni izid} + \text{Dane obresti v obračunskem letu}}{\text{Povprečna sredstva v obdobju}}$	Koeficient čiste donosnosti sredstev je merilo dobičkonosnosti v povezavi s strukturo sredstev v podjetju. Je dobro merilo za primerjavo uspešnosti podjetij, ker je neodvisno od finančnih odločitev. Višji kot je koeficient, višja je stopnja čiste donosnosti sredstev, ki jih ima podjetje.
2. Koeficient čiste donosnosti kapitala (<i>Return on equity</i>)	X ₂	ROE	%	$\frac{\text{Čisti poslovni izid iz rednega delovanja}}{\text{Povprečna vrednost kapitala v proučevanem obdobju}}$	Koeficient čiste donosnosti kapitala pokaže učinkovitost podjetja pri uporabi vloženega kapitala delničarjev ali družbenikov. Je merilo, ki pokaže, kaj je za delničarje donosnejše in višji kot je koeficient, boljša je donosnost kapitala.
3. Koeficient donosnosti razpoložljivega kapitala (<i>Return on capital employed</i>)	X ₃	ROCE	%	$\frac{\text{Poslovni izid pred plačilom obresti in davkov (EBIT)}}{\text{Celotna sredstva - Kratkoročne obveznosti od virov sredstev}}$ $\frac{\text{Poslovni izid pred plačilom obresti in davkov (EBIT)}}{\text{Kapital + Dolgoročne obveznosti do virov sredstev}}$	Koeficient donosnosti razpoložljivega kapitala pokaže učinkovitost podjetja pri uporabi razpoložljivih virov ne glede na vir financiranja. Razpoložljivi kapital je obseg kapitala uporabljenega za poslovanje* in sestava virov financiranja ne vpliva na koeficient. Višji kot je koeficient, boljša je donosnost razpoložljivega kapitala.
4. Stopnja rasti kapitala (<i>Equity growth rate</i>)	X ₄	Equity Growth Rate	%	$\frac{\text{Čisti poslovni izid} - \text{Izplačilo dividend}}{\text{Povprečna vrednost kapitala v obdobju}}$	Stopnja rasti kapitala podjetja je merilo, ki pokaže zmožnost rasti kapitala podjetja brez zunanjega financiranja poslovanja. Pri tem se predpostavlja, da se zadržijo dobički podjetja in da je izplačilo dividend konstantno v celotnem obdobju. Višja kot je stopnja rasti kapitala, večja je zmožnost podjetja rasti brez zunanjih virov financiranja.
5. Kazalnik (kosmate) donosnosti prodaje (<i>Gross profit margin</i>)	X ₅	Gross PM	%	$\frac{\text{Kosmati poslovni izid}}{\text{Prihodki v obdobju}}$	Kazalnik (kosmate) donosnosti prodaje je merilo, ki pokaže, kolikšna je zmožnost podjetja ustvarjati prihodke od prodaje proizvodov. Višji kot je kazalnik, boljša je uspešnost podjetja pri ustvarjanju zadostnega kosmatega poslovnega izida.
6. Kazalnik donosnosti poslovne dejavnosti (<i>Operating profit margin</i>)	X ₆	Operating PM	%	$\frac{\text{Poslovni izid iz rednega delovanja}}{\text{Prihodki v obdobju}}$	Kazalnik donosnosti iz poslovne dejavnosti pokaže donosnost prodaje dosežene z ustvarjanjem in prodajanjem outputov v okviru redne poslovne dejavnosti. Višji kot je kazalnik donosnosti poslovne dejavnosti, boljše je podjetje v svoji poslovni dejavnosti.
7. Kazalnik čiste donosnosti poslovanja (<i>Net profit margin</i>)	X ₇	Net PM	%	$\frac{\text{Čisti poslovni izid obdobja}}{\text{Prihodki v obdobju}}$	Kazalnik čiste donosnosti poslovanja meri dobičkonosnost prodaje v odstotkih prihodkov, neodvisno od stroškov financiranja. Višji kot je kazalnik, višja je podjetniška stopnja dobičkovnosti neodvisno od stroškov financiranja.
8. Kazalnik donosnosti poslovanja pred plačilom davkov (<i>Pretax profit margin</i>)	X ₈	Pretax PM	%	$\frac{\text{Poslovni izid pred plačilom davkov}}{\text{Prihodki v obdobju}}$	Kazalnik donosnosti poslovanja pred plačilom davkov meri dobičkonosnost prodaje pred plačilom davkov. Višji kot je kazalnik, višja je podjetniška stopnja dobičkovnosti pred plačilom davkov.
9. Kazalnik donosnosti poslovanja pred plačilom davkov in obresti (<i>EBIT profit margin</i>)	X ₉	EBIT PM	%	$\frac{\text{Poslovni izid pred plačilom davkov in obresti}}{\text{Prihodki v obdobju}}$	Kazalnik čiste donosnosti poslovanja meri dobičkonosnost prodaje pred plačilom davkov in obresti za sposojeni kapital. Višji kot je kazalnik, višja je dobičkovnost podjetja pri ustvarjanju dobička pred plačilom davkov in obresti.
10. Kazalnik razmerja med denarnim tokom iz poslovanja in poslovnim izidom (<i>Operating cash flow to income</i>)	X ₁₀	Operating CF To Income	%	$\frac{\text{Denarni tok iz rednega poslovanja}}{\text{Čisti poslovni izid v obdobju}}$	Kazalnik razmerja med denarnim tokom iz rednega poslovanja in poslovnim izidom v obdobju pokaže, kakšno je razmerje med omenjenima kategorijama. Če je kazalnik enak 1, je denarni tok iz rednega poslovanja enak čistemu poslovnemu izidu v obdobju, kar pomeni, da je razlika med prilivi in odlivi denarnih sredstev enaka razliki med prihodki in odhodki. Če je kazalnik večji od 1, je v podjetje bilo več prilivov kot je prihodkov in če je kazalnik manjši od 1, je v podjetju več odlivov denarnih sredstev, kot je odhodkov.

(Nadaljevanje na naslednji strani.) ▼

1	2	3	4	5	6
---	---	---	---	---	---

11.	Kazalnik dobičkonosnostnega vzvodja (<i>Common earnings leverage</i>)	X ₁₁	Earnings Leverage	$\frac{\text{Čisti poslovni izid v obračunskem obdobju}}{\text{Čisti poslovni izid} + \text{Obresti pred plačilom davka v obdobju}}$	Dobičkonosnostni vzvod omogoča meritev vpliva finančnih odločitev na dobiček podjetja. Primerjamo čisti dobiček delničarjem po plačilu stroškov financiranja kot odstotek dobička pred financiranjem. Vzvodje je večinoma manjše od 1. Bolj kot je število blizu 1, manj čistega dobička je porabljenih za stroške financiranja.**
12.	Koeficient obračanja kapitala podjetja (<i>Capital employed turnover</i>)	X ₁₂	Capital Employed Turnover	$\frac{\text{Prihodek}}{\text{Kapital}}$	Koeficient obračanja kapitala podjetja pokaže razmerje med kapitalom delničarjev in prihodkom, ki ga je podjetje ustvarilo s pomočjo kapitala delničarjev. Višji kot je kazalnik (priporočljiva je vsaj vrednost 1), višji prihodek na enoto delničarskega kapitala je ustvarilo podjetje.
II. KAZALNIKI UPORABE SREDSTEV IN UČINKOVITOSTI					
13.	Basic earnings power (<i>Basic earnings power</i>)	X ₁₃	Basic Earnings Power	% $\frac{\text{Poslovni izid pred plačilom davkov in obresti}}{\text{Sredstva}}$	Kazalnik osnovne zmožnosti zaslужka je uporaben pri primerjavi podjetij v različnih davčnih okvirih in različnih stopnjah finančnega vzvodja. Kazalnik se uporablja kot merilo za uspešnost aktivnosti podjetja. Z njim merimo osnovno dobičkonosnost sredstev, ker izključuje obresti in davke. Če ga uporabimo v kombinaciji s kazalniki obračanja, lahko s njegovo pomočjo razkrijemo kritična področja podjetja pri upravljanju s sredstvi podjetja. Višja kot je vrednost kazalnika, boljša je zmožnost podjetja pri upravljanju sredstev in ustvarjanju dobička pred plačilom obresti in davkov.
14.	Koeficient obračanja sredstev (<i>Total assets turnover</i>)	X ₁₄	Assets Turnover	$\frac{\text{Prihodki}}{\text{Povprečna sredstva v obdobju}}$	S koeficientom obračanja sredstev se meri intenzivnost, s katero podjetje uporablja vsa sredstva. Višji kot je koeficient, bolj je podjetje sposobno ustvariti prihodke z uporabo lastnih sredstev.
15.	Koeficient obračanja stalnih sredstev (<i>Fixed assets turnover</i>)	X ₁₅	Fixed Assets Turnover	$\frac{\text{Prihodki}}{\text{Povprečna stalna sredstva v obdobju}}$	Koeficient obračanja stalnih sredstev je podoben koeficientu obračanja sredstev, le da merimo, kolikšna je sposobnost podjetja za ustvarjanje prihodkov z uporabo lastnih stalnih sredstev (npr. proizvodne hale, opreme itd.). Višji kot je koeficient obračanja stalnih sredstev, bolj uspešno je podjetje pri upravljanju s stalnimi sredstvi.
16.	Koeficient obračanja denarja (<i>Cash turnover</i>)	X ₁₆	Cash Turnover	$\frac{\text{Prihodki}}{\text{Povprečna denarna sredstva in njegovi ustrezniki v obdobju}}$	Koeficient obračanja denarja nakaže število obratov, kolikokrat se denar preoblikuje v opazovanem obdobju. Višji koeficient pomeni hitrejši obrat denarja.
17.	Čista obratna sredstva ali čisti obratni kapital (<i>Working capital</i>)	X ₁₇	Working Capital	Kratkoročna sredstva – Kratkoročne obveznosti	Čista obratna sredstva oz. čisti obratni kapital je kategorija, ki pokaže presežek kratkoročnih sredstev nad kratkoročnimi obveznostmi. Čista obratna sredstva povedo, koliko je likvidnih sredstev, ki so na voljo za aktivnosti podjetja. Odvisno od dolga podjetja so lahko čista obratna sredstva pozitivna ali negativna. Na splošno bodo podjetja, ki imajo veliko čistih obratnih sredstev bolj uspešna, ker lahko razširijo in izboljšajo svoje operacije s pomočjo čistih obratnih sredstev, medtem ko podjetja z negativnimi čistimi obratnimi sredstvi večkrat ne bodo imela dovolj kapitalskih sredstev za rast.
18.	Koeficient obračanja čistih obratnih sredstev (<i>Working capital turnover</i>)	X ₁₈	Working Capital Turnover	$\frac{\text{Prihodki}}{\text{Povprečna čista obratna sredstva v obdobju}}$	Koeficient obračanja čistih obratnih sredstev pokaže uspešnost uporabe čistih obratnih sredstev pri ustvarjanju prihodkov v obračunskem obdobju. S koeficientom analiziramo razmerje med uporabljenimi sredstvi za aktivnosti podjetja in ustvarjenimi prodajami s temi aktivnostmi. Višji kot je koeficient, boljše je podjetje pri ustvarjanju prihodkov.
19.	Koeficient obračanja kratkoročnih obveznosti do virov sredstev (<i>Current liabilities turnover</i>)	X ₁₉	Current Liab Turnover	$\frac{\text{Prihodki}}{\text{Povprečne kratkoročne obveznosti do virov sredstev v obdobju}}$	Koeficient obračanja kratkoročnih obveznosti do virov sredstev pokaže, kolikokrat bi podjetje lahko z ustvarjenimi prihodki pokrilo kratkoročne obveznosti do virov sredstev v obdobju. Če je koeficient nižji od 1, podjetje z lastnimi prihodki ni sposobno pokriti niti kratkoročnih obveznosti do virov sredstev in obratno, če je koeficient večji od 1, podjetje lahko z lastnimi prihodki pokrije kratkoročne obveznosti do virov sredstev.

(Nadaljevanje na naslednji strani.) ▼

1	2	3	4	5	6
---	---	---	---	---	---

III. KAZALNIKI LIKVIDNOSTI					
20.	Kratkoročni koeficient (<i>Current ratio</i>)	X ₂₀	Current Ratio	$\frac{\text{Kratkoročna sredstva}}{\text{Kratkoročne obveznosti}}$	Kratkoročni koeficient nakaže zmožnost podjetja, da poravna kratkoročne obveznosti oz. meri stopnjo, do katere so kratkoročne obveznosti pokrite s kratkoročnimi sredstvi (v običajnem poslovnem ciklu). Višji kot je kazalnik, bolj je podjetje likvidno oz. boljša je likvidnost. Če ima podjetje dvakrat več kratkoročnih sredstev kot kratkoročnih obveznosti, potem se podjetje lahko pojmuje kot podjetje z dobro kratkoročno finančno močjo. Če so kratkoročne obveznosti večje od kratkoročnih sredstev, potem ima podjetje večkrat težave pri poravnavanju kratkoročnih obveznosti.
21.	Koeficient neposredne pokritosti kratkoročnih obveznosti – Hitri koeficient (<i>Quick ratio, Acid test</i>)	X ₂₁	Quick Ratio	$\frac{\text{Likvidna sredstva}}{\text{Kratkoročne obveznosti}}$	Koeficient neposredne pokritosti kratkoročnih obveznosti je merilo likvidnosti podjetja in njegove zmožnosti, da poravna svoje obveznosti. Je kazalec podjetniške finančne moči oz. likvidnosti (visoka vrednost kazalnika) ali slabosti oz. slabše likvidnosti (nizka vrednost kazalnika). Likvidna sredstva predstavljajo kratkoročna sredstva zmanjšana za zaloge.
22.	Koeficient pospešene pokritosti kratkoročnih sredstev – Pospešeni koeficient (<i>Cash ratio, Liquidity ratio</i>)	X ₂₂	Liquidity Ratio	$\frac{\text{Denarna sredstva} + \text{Kratkoročne terjatve}}{\text{Kratkoročne obveznosti}}$	Koeficient pospešene likvidnosti nakaže zmožnost podjetja, kako hitro lahko podjetje preoblikuje sredstva v denar in pokrije kratkoročne obveznosti. Višji kot je kazalnik, večja je zmožnost podjetja za hitro preoblikovanje sredstev v denar.
23.	Koeficient obračanja zalog (<i>Inventory turnover ratio</i>)	X ₂₃	Inventory Turnover	$\frac{\text{Stroški prodaje zalog}}{\text{Povprečno stanje zalog v obdobju}}$	Koeficient obračanja zalog meri, kolikšno je število obratov zalog v podjetju v obračunskem obdobju. Višji kazalnik nakazuje, da podjetje proizvaja in prodaja proizvod in/ali storitev zelo hitro.
24.	Čas držanja zalog (<i>Days inventory held</i>)	X ₂₄	Days Inventory Held	dni $\frac{365}{\text{Koeficient obračanja zalog}}$	Število dni držanja zalog pove povprečen čas držanja zalog od njihove nabave do prodaje. Manjše število dni, pomeni krajše obdobje oz. višjo hitrost obračanja zalog.
25.	Koeficient obračanja terjatev (<i>Debtors turnover</i>)	X ₂₅	Debtors Turnover	$\frac{\text{Prihodki}}{\text{Povprečne terjatve v obdobju}}$	Koeficient obračanja terjatev meri, kolikšno je število obratov terjatev v obračunskem obdobju. Višji kazalnik nakazuje hitro obračanje terjatev.
26.	Čas do poplčila terjatev (<i>Collection period; Days sales outstanding</i>)	X ₂₆	Debtors Collection Period	dni $\frac{365}{\text{Koeficient obračanja terjatev}}$	Kazalnik pokaže število dni vezave denarnih sredstev v obliki terjatev. Pove nam povprečno dolžino časa, ko mora podjetje čakati na denarna sredstva po opravljeni prodaji. Krajši kot je čas čakanja, hitreje podjetje pridobi denarna sredstva.
27.	Trajanje ciklusa proizvodnje (<i>Gross operating cycle</i>)	X ₂₇	Gross Operating Cycle	dni Čas držanja zalog + Čas do poplčila terjatev	Pokaže povprečno dolžino poslovnega cikla podjetja od nabave zalog do končnega prejema sredstev od prodaje zalog oz. do poravnanih terjatev. Krajše obdobje pomeni hitrejšo obračanje operativnih sredstev.
28.	Koeficient obračanja kratkoročnih obveznosti do dobaviteljev (<i>Accounts payable turnover</i>)	X ₂₈	Accounts Payable Turnover	$\frac{\text{Stroški nabave in proizvodnje proizvodov in/ali storitev}}{\text{Povprečno stanje kratkoročnih obveznosti do dobaviteljev}}$	Koeficient obračanja kratkoročnih obveznosti do dobaviteljev nakazuje povprečno hitrost, s katero podjetje poravnava kratkoročne obveznosti do virov sredstev. Stroški nabave in proizvodnje proizvodov in/ali storitev so enaki stroškom nabave proizvodov in/ali storitev povečanim za razliko med končnim in začetnim stanjem zalog podjetja.
29.	Čas do plačila kratkoročnih obveznosti do dobaviteljev (<i>Days' purchases in accounts payable</i>)	X ₂₉	Days Purchases Accounts Payable	dni $\frac{365}{\text{Koeficient obračanja kratkoročnih obveznosti do dobaviteljev}}$	Čas do plačila kratkoročnih obveznosti do dobaviteljev pokaže povprečno dolžino obdobja, katerega podjetje potrebuje, da poplača vse svoje kratkoročne obveznosti do virov sredstev. Višji kazalnik predstavlja počasnejše plačilo obveznosti podjetja do virov sredstev.
30.	Čas obračanja denarja (<i>Net operating cycle</i>)	X ₃₀	Net Operating Cycle	dni Trajanje ciklusa proizvodnje – Čas do poplčila kratkoročnih obveznosti do dobaviteljev	Kazalnik čas obračanja denarja nam pokaže razliko v dnevih med upravljanjem denarja na aktivni in pasivi. Pove nam, ali lahko podjetje uporabi kapital kratkoročnih obveznosti za financiranje nabave zalog ipd. Negativna vrednost kazalnika je za podjetje boljše, saj je s tem trajanje ciklusa proizvodnje krajše od časa za poplačilo kratkoročnih obveznosti.
31.	Koeficient denarnega toka glede na kratkoročne obveznosti do virov sredstev (<i>Cash flow to current liabilities ratio</i>)	X ₃₁	CF To Current Liabilities	$\frac{\text{Denarni tok iz redne dejavnosti}}{\text{Kratkoročne obveznosti do virov sredstev}}$	Koeficient razmerja denarnega toka iz redne dejavnosti in kratkoročnih obveznosti do virov sredstev pokaže delež potrebnih denarnih sredstev podjetja (po opravljenih aktivnostih nabave blaga in/ali storitev itd.) glede na kratkoročne obveznosti podjetja do virov sredstev oz. kako dobro so kratkoročne obveznosti podjetja pokrite z ustvarjenim denarnim tokom, ki ga ima podjetje. Če je koeficient višji od 1, ima podjetje dejansko razpoložljiva denarna sredstva in obratno, če je koeficient manjši od 1, ima podjetje več kratkoročnih obveznosti kot ima razpoložljivih denarnih sredstev.

(Nadaljevanje na naslednji strani.) ▼

1	2	3	4	5	6
---	---	---	---	---	---

IV. KAZALNIKI KAPITALSKE STRUKTURE IN SOLVENTNOSTI						
32.	Stopnja zadolženosti (<i>Total debt ratio</i>)	X ₃₂	Debt Ratio	%	<u>Celotne obveznosti do virov sredstev (brez kapitala)</u> Celotna sredstva	Kazalnik stopnja zadolženosti pokaže delež sredstev podjetja, ki so financirana s pomočjo dolgovnega kapitala podjetja. Če je kazalnik manjši od 1, je večina sredstev podjetja financirana s pomočjo kapitala podjetja. Če je kazalnik večji od 1, je večina sredstev podjetja financirana s pomočjo dolgovnega kapitala oz. dolgov. Podjetja z visokim kazalnikom se pojmujejo kot višje tvegana, kajti lahko so v nevarnosti, če posojilodajalci zahtevajo poplačilo dolgov.
33.	Stopnja dolgoročne zadolženosti (<i>Long-term debt to assets</i>)	X ₃₃	LT Debt To Assets	%	<u>Dolgoročne obveznosti do virov sredstev</u> Celotna sredstva	Kazalnik stopnje dolgoročne zadolženosti je zelo podoben kazalniku dolgovnega financiranja sredstev. Pokaže delež sredstev podjetja, ki so financirana s pomočjo dolgoročnih dolgov podjetja. Če je kazalnik večji od 1, je večina sredstev podjetja financirana s pomočjo dolgoročnih dolgov podjetja in obratno.
34.	Kazalnik dolgovno-kapitalskega razmerja (<i>Total debt to equity ratio</i>)	X ₃₄	Debt To Equity Ratio	%	<u>Celotne obveznosti do virov sredstev (brez kapitala)</u> Kapital	Kazalnik razmerja dolgov in trajnega kapitala podjetja nam pokaže razmerje med dolgovnim kapitalom podjetja in trajnim (delniškim) kapitalom podjetja. Če je kazalnik večji od 1, je v podjetju več dolgovnega kapitala (sredstva večinoma financirana z njim) in obratno, če je kazalnik manjši od 1, je v podjetju več delniškega kapitala (sredstva pretežno financirana z njim). Kazalnik naj ne bi bil večji od 1, saj bi v tem primeru dolgovni kapital postal bolj tvegan od lastniškega. Podobno velja v času visokih obrestnih mer, kajti takrat mora podjetje plačati dodatno višje obresti pri dolgovnem kapitalu.
35.	Kazalnik dolgoročno dolgovno-kapitalskega razmerja (<i>Long-term debt to equity ratio</i>)	X ₃₅	LT Debt To Equity	%	<u>Dolgoročne obveznosti do virov sredstev</u> Kapital	Koeficient dolgovno-kapitalskega razmerja podobno kot finančno vzvodje pokaže zmožnost podjetja, kakšno je financiranje podjetja z dolgoročnim dolgovnim kapitalom. Če je kazalnik manjši od 1, je večina sredstev podjetja financirana z lastniškim kapitalom. Če je kazalnik večji od 1, je večina sredstev podjetja financiranih z dolgoročnimi dolgovi.
36.	Kazalnik finančnega vzvodja (<i>Financial leverage ratio</i>)	X ₃₆	Fin Leverage Ratio		<u>Celotna sredstva</u> Kapital	S kazalnikom finančnega vzvodja merimo razmerje med celotnimi sredstvi podjetja in delniškim kapitalom, ki financira sredstva. Večji kot je delež sredstev financiranih z delniškim kapitalom, nižji je kazalnik finančnega vzvodja. Za podjetje, ki uspešno izrablja vzvodje, se višji kazalnik pokaže tudi v višji donosnosti kapitala.
37.	Indeks finančnega vzvodja (<i>Financial leverage index</i>)	X ₃₇	Fin Leverage Index		ROE ROA	Indeks finančnega vzvodja se navezuje na dolgovni kapital podjetja. Če je kazalnik donosnosti sredstev podjetja (ROA) višji, kot so obresti posojila, potem je kazalnik donosnosti kapitala (ROE) višji, kot če si podjetje ne-bi izposojalo sredstev. Na drugi strani, če bi kazalnik donosnosti sredstev bil nižji od obrestne mere, potem bi kazalnik donosnosti kapitala bil nižji, kot če si podjetje ne-bi izposojalo sredstev.
38.	Koeficient pokrivanja odhodkov za obresti s poslovnim izidom iz rednega delovanja (<i>Times interest earned; Interests coverage ratio</i>)	X ₃₈	Interest Coverage Ratio		<u>Poslovni izid pred plačilom obresti in davkov (EBIT)</u> Odhodki za obresti v obdobju	Predhodni kazalniki kapitalske strukture in solventnosti ne povedo ničesar o zmožnosti podjetja glede ustvarjanja zadostnega priliva sredstev za poplačilo obresti. Koeficient pokrivanja odhodkov za obresti s poslovnim izidom iz rednega delovanja pokaže zmožnost podjetja, da poravnava obresti glede na trenutno stanje dolgov. Ali drugače: kazalnik meri razpon, do katerega se lahko zniža EBIT, preden bo podjetje nezmožno poravnati letne obveznosti za obresti. Nižji kot je kazalnik, večje je breme dolga na podjetju.
39.	Kazalnik Z _{Altman} (<i>Altman Z-score</i>)	X ₃₉	Altman Z		$0,717 \times \frac{\text{Čista obratna sredstva}}{\text{Sredstva}} + 0,847 \times \frac{\text{Zadržani dobički}}{\text{Sredstva}} + 3,107 \times \frac{\text{Poslovni izid pred plačilom obresti in davkov}}{\text{Sredstva}} + 0,420 \times \frac{\text{Kapital}}{\text{Celotne obveznosti do virov sredstev}} + 0,998 \times \frac{\text{Prihodki}}{\text{Sredstva}}$	Kazalnik Z _{Altman} , ki se imenuje po Altmanu (1968), se uporablja pri ugotavljanju finančnega neravnovesja v podjetju in nevarnosti finančnega zloma podjetja. Kazalec je agregatno sestavljen kazalnik in vključuje področja: (1) likvidnosti, (2) starosti podjetja in kumulativne dobičkonosnosti, (3) dobičkonosnosti, (4) finančne strukture podjetja in (5) stopnje obračanja kapitala. Velikost kazalnika pod 1,20 nakazuje veliko verjetnost bankrota podjetja, medtem ko vrednost nad 2,90 nakazuje majhno verjetnost finančnega zloma podjetja.

Opomba:

* Komponente razpoložljivega kapitala se razlikujejo glede na definicijo, ki jo posameznik uporabi za razpoložljivi kapital. Nekateri vključujejo delniški kapital, medtem ko drugi vključujejo tudi dolgoročne dolgove in možne kratkoročne zadolžitve, ki jih podjetje lahko uporabi za ustvarjanje dobička.

Vir podatkov:

** Izračun kazalnika zahteva predpostavko glede višine obdavčitve dobička.

Altman (1968), Beaver (1966), Boynton in drugi (2001), Brigham in Ehrhardt (2005), Dupoch in drugi (1987), Koletnik (2006), Krishnan in Krishnan (1996), Lee in drugi (2005), Mutcher in drugi (1997), SIR (2005), Spathis in drugi (2003) in Wild in drugi (2003).

11.1.5 Priloga 5: Proces izbora spremenljivk

Tabela 19: Proces redukcije števila spremenljivk

		Redukcija števila spremenljivk ^a			Končni nabor spremenljivk
		1. korak	2. korak	3. korak	
		1	2	3	
X ₁	ROA				► X ₁
X ₂	ROE				► X ₂
X ₃	ROCE		X		
X ₄	EquityGrowthRate		X		
X ₅	GrossPM				► X ₅
X ₆	OperatingPM		X		
X ₇	NetPM				► X ₇
X ₈	EBITPM		X		
X ₉	PretaxPM		X		
X ₁₀	OperatingCFtoIncome				► X ₁₀
X ₁₁	EarningsLeverage				► X ₁₁
X ₁₂	CapitalEmployedTurnover				► X ₁₂
X ₁₃	BasicEarningsPower		X		
X ₁₄	AssetsTurnover				► X ₁₄
X ₁₅	FixedAssetsTurnover		X		
X ₁₆	CashTurnover		X		
X ₁₇	WorkingCapital		X		
X ₁₈	WorkingCapitalTurnover				► X ₁₈
X ₁₉	CurrentLiabTurnover		X		
X ₂₀	CurrentRatio				► X ₂₀
X ₂₁	QuickRatio		X		
X ₂₂	LiquidityRatio		X		
X ₂₃	InventoryTurnover				► X ₂₃
X ₂₄	DaysInventoryHeld	X			
X ₂₅	DebtorsTurnover				► X ₂₅
X ₂₆	DebtorsCollectionPeriod	X			
X ₂₇	GrossOperatingCycle	X			
X ₂₈	AccountsPayableTurnover			X	
X ₂₉	DaysPurchasesAccountsPayable	X			
X ₃₀	NetOperatingCycle	X			
X ₃₁	CFtoCurrentLiabilities				► X ₃₁
X ₃₂	DebtRatio				► X ₃₂
X ₃₃	LTDebtToAssets	X			
X ₃₄	DebtToEquityRatio				► X ₃₄
X ₃₅	LTDebttoEquity	X			
X ₃₆	FinLeverageRatio		X		
X ₃₇	FinLeverageIndex		X		
X ₃₈	InterestCoverageRatio				► X ₃₈
X ₃₉	AltmanZ				► X ₃₉

Opomba:

^a Izločitev spremenljivke v posameznem koraku/fazi izbora je označena z X.

Vir podatkov:

Lastni prikaz.

11.1.6 Priloga 6: Deskriptivna statistika izbranih spremenljivk

Tabela 20: Deskriptivna statistika za izbrani vzorec

		Povprečje		Kruskal-Wallis test	
		Podjetja z nemodificiranimi mnenji	Podjetja z modificiranimi mnenji	χ^2	Signifikantnost
		1	2	3	4
X ₁	ROA	-14,787	-77,790	102,667	0,000 *
X ₂	ROE	-7,645	-60,212	38,462	0,000 *
X ₃	ROCE	-17,856	-50,782	24,017	0,000 *
X ₄	EquityGrowthRate	-9,943	-61,015	37,574	0,000 *
X ₅	GrossPM	46,992	22,138	18,858	0,000 *
X ₆	OperatingPM	-36,245	-112,360	47,583	0,000 *
X ₇	NetPM	-33,030	-123,382	45,520	0,000 *
X ₈	EBITPM	-32,641	-120,388	41,104	0,000 *
X ₉	PretaxPM	-32,476	-124,085	44,375	0,000 *
X ₁₀	OperatingCFtoIncome	92,313	64,089	6,543	0,011 **
X ₁₁	EarningsLeverage	1,348	1,013	26,315	0,000 *
X ₁₂	CapitalEmployedTurnover	3,807	3,051	8,397	0,004 *
X ₁₃	BasicEarningsPower	-20,388	-90,630	87,485	0,000 *
X ₁₄	AssetsTurnover	1,127	0,838	19,212	0,000 *
X ₁₅	FixedAssetsTurnover	3,768	4,340	0,120	0,729
X ₁₆	CashTurnover	29,375	31,945	5,700	0,017 **
X ₁₇	WorkingCapital	78,441	-36,914	28,525	0,000 *
X ₁₈	WorkingCapitalTurnover	12,672	-2,247	23,721	0,000 *
X ₁₉	CurrentLiabTurnover	3,426	2,617	67,628	0,000 *
X ₂₀	CurrentRatio	3,333	2,817	37,100	0,000 *
X ₂₁	QuickRatio	2,639	1,870	33,063	0,000 *
X ₂₂	LiquidityRatio	2,173	1,658	12,829	0,000 *
X ₂₃	InventoryTurnover	34,248	34,360	0,637	0,425
X ₂₄	DaysInventoryHeld	74,658	105,459	2,823	0,093 ***
X ₂₅	DebtorsTurnover	25,564	26,390	0,231	0,631
X ₂₆	DebtorsCollectionPeriod	61,708	70,806	0,271	0,603
X ₂₇	GrossOperatingCycle	138,014	137,034	0,092	0,762
X ₂₈	AccountsPayableTurnover	6,061	11,563	1,097	0,295
X ₂₉	DaysPurchasesAccountsPayable	124,652	77,507	3,057	0,080 ***
X ₃₀	NetOperatingCycle	-17,415	19,465	0,039	0,843
X ₃₁	CFtoCurrentLiabilities	-0,670	-1,564	26,603	0,000 *
X ₃₂	DebtRatio	51,846	88,924	21,344	0,000 *
X ₃₃	LTDebtToAssets	17,038	30,123	7,307	0,007 *
X ₃₄	DebtToEquityRatio	72,932	42,467	2,155	0,142
X ₃₅	LTDebttoEquity	22,555	25,682	0,004	0,948
X ₃₆	FinLeverageRatio	2,491	2,559	0,294	0,587
X ₃₇	FinLeverageIndex	2,333	1,934	0,889	0,346
X ₃₈	InterestCoverageRatio	-49,577	-113,471	32,740	0,000 *
X ₃₉	AltmanZ	-1,800	-9,433	90,169	0,000 *

Opombe:

* Signifikantno pri 0,01.

** Signifikantno pri 0,05.

*** Signifikantno pri 0,10.

Vir podatkov:

Lastni izračun.

11.1.7 Priloga 7: Korelacijska analiza

Tabela 21: Korelacijska analiza

	1	X ₂	X ₃	X ₄	X ₅	X ₆	X ₇	X ₈	X ₉	X ₁₀	X ₁₁	X ₁₂	X ₁₃	X ₁₄	X ₁₅	X ₁₆	X ₁₇	X ₁₈	X ₁₉	X ₂₀	X ₂₁	X ₂₂	X ₂₃	X ₂₄	X ₂₅	X ₂₆	X ₂₇	X ₂₈	X ₂₉	X ₃₀	X ₃₁	X ₃₂	X ₃₃	X ₃₄	X ₃₅	X ₃₆	X ₃₇	X ₃₈	X ₃₉
X ₁	1,00	0,53	0,51	0,53	0,07	0,66	0,68	0,68	0,68	0,24	-0,40	0,24	0,94	0,29	0,12	0,26	0,21	0,19	0,42	0,18	0,14	-0,01	0,02	-0,12	0,07	-0,12	-0,07	0,23	-0,04	0,20	0,59	-0,13	0,02	0,27	0,19	0,22	0,12	0,65	0,86
X ₂	0,53	1,00	0,74	1,00	0,05	0,34	0,37	0,37	0,37	0,18	-0,30	-0,03	0,56	0,26	0,17	0,15	-0,01	0,10	0,19	-0,05	-0,07	-0,16	-0,09	-0,07	0,10	-0,06	-0,04	0,17	-0,01	0,11	0,42	0,09	0,19	-0,11	-0,13	-0,18	-0,34	0,46	0,43
X ₃	0,51	0,74	1,00	0,74	0,07	0,36	0,39	0,39	0,39	0,18	-0,35	-0,01	0,57	0,28	0,22	0,16	-0,06	0,04	0,19	-0,13	-0,15	-0,23	-0,11	-0,07	0,07	-0,08	-0,04	0,16	-0,01	0,10	0,43	0,17	0,17	-0,15	-0,11	-0,16	-0,13	0,42	0,41
X ₄	0,53	1,00	0,74	1,00	0,05	0,34	0,37	0,37	0,37	0,18	-0,30	-0,04	0,55	0,25	0,17	0,15	-0,01	0,09	0,19	-0,06	-0,07	-0,15	-0,09	-0,07	0,10	-0,06	-0,04	0,16	0,00	0,10	0,41	0,10	0,19	-0,12	-0,14	-0,19	-0,35	0,45	0,42
X ₅	0,07	0,05	0,07	0,05	1,00	0,06	0,08	0,07	0,07	0,06	-0,12	-0,11	0,04	-0,12	-0,07	-0,14	0,04	-0,04	-0,02	0,19	0,19	0,19	-0,21	0,16	-0,10	0,13	0,15	-0,33	0,00	-0,13	-0,02	-0,14	-0,01	-0,15	-0,10	-0,17	-0,14	0,07	0,03
X ₆	0,66	0,34	0,36	0,34	0,06	1,00	0,86	0,87	0,86	0,16	-0,35	0,21	0,64	0,28	0,14	0,25	0,16	0,10	0,35	0,15	0,13	0,01	0,05	-0,11	0,07	-0,09	-0,09	0,19	-0,08	0,07	0,50	-0,06	0,02	0,22	0,14	0,19	0,11	0,53	0,59
X ₇	0,68	0,37	0,39	0,37	0,08	0,86	1,00	0,99	1,00	0,22	-0,41	0,19	0,66	0,24	0,09	0,19	0,21	0,14	0,33	0,21	0,21	0,11	0,09	-0,12	0,06	-0,06	-0,10	0,19	-0,05	0,03	0,44	-0,14	-0,05	0,16	0,12	0,12	0,05	0,50	0,61
X ₈	0,68	0,37	0,39	0,37	0,07	0,87	0,99	1,00	0,99	0,20	-0,40	0,17	0,66	0,24	0,10	0,19	0,20	0,12	0,32	0,19	0,19	0,08	0,09	-0,11	0,06	-0,07	-0,10	0,20	-0,04	0,03	0,44	-0,13	-0,03	0,17	0,14	0,13	0,04	0,52	0,61
X ₉	0,68	0,37	0,39	0,37	0,07	0,86	1,00	0,99	1,00	0,22	-0,41	0,19	0,66	0,25	0,10	0,20	0,21	0,14	0,33	0,20	0,20	0,10	0,09	-0,12	0,06	-0,07	-0,10	0,19	-0,05	0,04	0,44	-0,14	-0,05	0,17	0,13	0,12	0,05	0,51	0,61
X ₁₀	0,24	0,18	0,18	0,18	0,06	0,16	0,22	0,20	0,22	1,00	-0,36	0,07	0,25	0,06	0,04	0,01	0,13	0,03	0,12	0,18	0,18	0,14	0,07	-0,05	0,03	-0,01	-0,05	0,05	-0,02	0,06	-0,08	-0,13	-0,07	0,05	0,08	0,04	-0,02	0,16	0,21
X ₁₁	-0,40	-0,30	-0,35	-0,30	-0,12	-0,35	-0,41	-0,40	-0,41	-0,36	1,00	-0,08	-0,41	-0,01	-0,09	-0,02	-0,15	-0,07	-0,11	-0,16	-0,14	-0,06	0,04	-0,02	-0,03	0,01	-0,03	-0,06	-0,04	-0,05	-0,19	0,10	-0,02	-0,07	-0,09	-0,04	0,21	-0,26	-0,33
X ₁₂	0,24	-0,03	-0,01	-0,04	-0,11	0,21	0,19	0,17	0,19	0,07	-0,08	1,00	0,22	0,38	0,29	0,35	0,12	0,18	0,27	0,04	0,00	-0,11	0,06	-0,10	-0,03	-0,09	-0,08	0,17	-0,05	0,15	0,28	0,16	-0,01	0,55	0,43	0,73	0,46	0,23	0,37
X ₁₃	0,94	0,56	0,57	0,55	0,04	0,64	0,66	0,66	0,66	0,25	-0,41	0,22	1,00	0,32	0,14	0,24	0,18	0,18	0,41	0,14	0,10	-0,04	0,05	-0,15	0,09	-0,17	-0,09	0,25	-0,02	0,21	0,59	-0,11	0,06	0,24	0,18	0,18	0,11	0,64	0,82
X ₁₄	0,29	0,26	0,28	0,25	-0,12	0,28	0,24	0,24	0,25	0,06	-0,01	0,38	0,32	1,00	0,57	0,58	-0,01	0,09	0,56	-0,21	-0,23	-0,37	-0,04	-0,15	0,16	-0,24	-0,14	0,28	-0,08	0,21	0,40	0,38	0,07	0,13	-0,01	0,20	0,17	0,31	0,48
X ₁₅	0,12	0,17	0,22	0,17	-0,07	0,14	0,09	0,10	0,10	0,04	-0,09	0,29	0,14	0,57	1,00	0,29	-0,01	0,08	0,23	-0,08	-0,12	-0,22	-0,11	-0,02	-0,06	-0,04	0,04	0,29	0,00	0,23	0,23	0,26	0,07	0,09	-0,03	0,15	0,16	0,09	0,25
X ₁₆	0,26	0,15	0,16	0,15	-0,14	0,25	0,19	0,19	0,20	0,01	-0,02	0,35	0,24	0,58	0,29	1,00	-0,03	0,08	0,39	-0,20	-0,25	-0,37	0,07	-0,17	0,17	-0,18	-0,17	0,29	-0,06	0,15	0,35	0,23	0,09	0,22	0,08	0,22	0,17	0,28	0,34
X ₁₇	0,21	-0,01	-0,06	-0,01	0,04	0,16	0,21	0,20	0,21	0,13	-0,15	0,12	0,18	-0,01	-0,01	-0,03	1,00	0,35	0,26	0,66	0,60	0,47	0,01	0,02	0,00	0,06	0,06	0,08	0,05	0,08	-0,04	-0,36	-0,11	0,12	0,08	0,03	0,02	0,08	0,26
X ₁₈	0,19	0,10	0,04	0,09	-0,04	0,10	0,14	0,12	0,14	0,03	-0,07	0,18	0,18	0,09	0,08	0,08	0,35	1,00	0,27	0,25	0,22	0,12	-0,05	0,04	-0,01	0,08	0,03	0,08	-0,02	0,09	0,07	-0,15	-0,07	0,14	0,02	0,12	0,06	0,08	0,21
X ₁₉	0,42	0,19	0,19	0,19	-0,02	0,35	0,33	0,32	0,33	0,12	-0,11	0,27	0,41	0,56	0,23	0,39	0,26	0,27	1,00	0,25	0,22	0,07	0,11	-0,22	0,26	-0,25	-0,21	0,48	-0,12	0,16	0,33	-0,13	0,01	0,14	0,04	0,08	0,05	0,32	0,54
X ₂₀	0,18	-0,05	-0,13	-0,06	0,19	0,15	0,21	0,19	0,20	0,18	-0,16	0,04	0,14	-0,21	-0,08	-0,20	0,66	0,25	0,25	1,00	0,91	0,78	0,01	0,14	-0,12	0,15	0,21	0,02	0,07	0,08	-0,21	-0,57	-0,16	-0,01	0,01	-0,10	-0,09	0,03	0,26
X ₂₁	0,14	-0,07	-0,15	-0,07	0,19	0,13	0,21	0,19	0,20	0,18	-0,14	0,00	0,10	-0,23	-0,12	-0,25	0,60	0,22	0,22	0,91	1,00	0,88	0,07	0,05	-0,14	0,18	0,13	0,00	0,06	-0,03	-0,24	-0,58	-0,17	-0,05	-0,01	-0,14	-0,10	-0,03	0,19
X ₂₂	-0,01	-0,16	-0,23	-0,15	0,19	0,01	0,11	0,08	0,10	0,14	-0,06	-0,11	-0,04	-0,37	-0,22	-0,37	0,47	0,12	0,07	0,78	0,88	1,00	0,09	0,03	0,03	0,03	0,05	-0,05	0,03	-0,11	-0,34	-0,57	-0,17	-0,14	-0,04	-0,20	-0,15	-0,14	-0,02
X ₂₃	0,02	-0,09	-0,11	-0,09	-0,21	0,05	0,09	0,09	0,09	0,07	0,04	0,06	0,05	-0,04	-0,11	0,07	0,01	-0,05	0,11	0,01	0,07	0,09	1,00	-0,39	0,18	-0,10	-0,36	0,26	-0,02	-0,17	-0,05	-0,05	0,06	0,17	0,25	0,16	0,08	-0,01	0,00
X ₂₄	-0,12	-0,07	-0,07	-0,07	0,16	-0,11	-0,12	-0,11	-0,12	-0,05	-0,02	-0,10	-0,15	-0,15	-0,02	-0,17	0,02	0,04	-0,22	0,14	0,05	0,03	-0,39	1,00	-0,24	0,34	0,82	-0,24	-0,04	0,22	-0,10	0,02	0,01	-0,13	-0,03	-0,06	-0,03	-0,10	-0,06
X ₂₅	0,07	0,10	0,07	0,10	-0,10	0,07	0,06	0,06	0,06	0,03	-0,03	-0,03	0,09	0,16	-0,06	0,17	0,00	-0,01	0,26	-0,12	-0,14	0,03	0,18	-0,24	1,00	-0,64	-0,39	0,18	-0,11	-0,07	0,06	-0,04	0,04	-0,03	-0,02	-0,08	-0,16	0,11	0,03
X ₂₆	-0,12	-0,06	-0,08	-0,06	0,13	-0,09	-0,06	-0,07	-0,07	-0,01	0,01	-0,09	-0,17	-0,24	-0,04	-0,18	0,06	0,08	-0,25	0,15	0,18	0,03	-0,10	0,34	-0,64	1,00	0,39	-0,16	0,04	-0,03	-0,13	0,02	-0,09	-0,04	-0,02	-0,03	0,05	-0,10	-0,10
X ₂₇	-0,07	-0,04	-0,04	-0,04	0,15	-0,09	-0,10	-0,10	-0,10	-0,05	-0,03	-0,08	-0,09	-0,14	0,04	-0,17	0,06	0,03	-0,21	0,21	0,13	0,05	-0,36	0,82	-0,39	0,39	1,00	-0,19	0,18	0,23	-0,09	0,00	0,02	-0,13	-0,05	-0,05	0,00	-0,08	0,01
X ₂₈	0,23	0,17	0,16	0,16	-0,33	0,19	0,19	0,20	0,19	0,05	-0,06	0,17	0,25	0,28	0,29	0,29	0,08	0,08	0,48	0,02	0,00	-0,05	0,26	-0,24	0,18	-0,16	-0,19	1,00	-0,14	0,28	0,29	0,06	0,08	0,17	0,04	0,11	0,04	0,24	0,27

(Nadaljevanje na naslednji strani.) ▼

1	X ₂	X ₃	X ₄	X ₅	X ₆	X ₇	X ₈	X ₉	X ₁₀	X ₁₁	X ₁₂	X ₁₃	X ₁₄	X ₁₅	X ₁₆	X ₁₇	X ₁₈	X ₁₉	X ₂₀	X ₂₁	X ₂₂	X ₂₃	X ₂₄	X ₂₅	X ₂₆	X ₂₇	X ₂₈	X ₂₉	X ₃₀	X ₃₁	X ₃₂	X ₃₃	X ₃₄	X ₃₅	X ₃₆	X ₃₇	X ₃₈	X ₃₉
---	----------------	----------------	----------------	----------------	----------------	----------------	----------------	----------------	-----------------	-----------------	-----------------	-----------------	-----------------	-----------------	-----------------	-----------------	-----------------	-----------------	-----------------	-----------------	-----------------	-----------------	-----------------	-----------------	-----------------	-----------------	-----------------	-----------------	-----------------	-----------------	-----------------	-----------------	-----------------	-----------------	-----------------	-----------------	-----------------	-----------------

X ₂₉	-0,04	-0,01	-0,01	0,00	0,00	-0,08	-0,05	-0,04	-0,05	-0,02	-0,04	-0,05	-0,02	-0,08	0,00	-0,06	0,05	-0,02	-0,12	0,07	0,06	0,03	-0,02	-0,04	-0,11	0,04	0,18	-0,14	1,00	-0,42	-0,07	-0,03	-0,02	-0,07	-0,11	-0,07	-0,06	-0,12	-0,02
X ₃₀	0,20	0,11	0,10	0,10	-0,13	0,07	0,03	0,03	0,04	0,06	-0,05	0,15	0,21	0,21	0,23	0,15	0,08	0,09	0,16	0,08	-0,03	-0,11	-0,17	0,22	-0,07	-0,03	0,23	0,28	-0,42	1,00	0,17	0,09	0,07	0,14	0,11	0,13	0,11	0,15	0,27
X ₃₁	0,59	0,42	0,43	0,41	-0,02	0,50	0,44	0,44	0,44	-0,08	-0,19	0,28	0,59	0,40	0,23	0,35	-0,04	0,07	0,33	-0,21	-0,24	-0,34	-0,05	-0,10	0,06	-0,13	-0,09	0,29	-0,07	0,17	1,00	0,27	0,16	0,27	0,15	0,26	0,16	0,58	0,58
X ₃₂	-0,13	0,09	0,17	0,10	-0,14	-0,06	-0,14	-0,13	-0,14	-0,13	0,10	0,16	-0,11	0,38	0,26	0,23	-0,36	-0,15	-0,13	-0,57	-0,58	-0,57	-0,05	0,02	-0,04	0,02	0,00	0,06	-0,03	0,09	0,27	1,00	0,50	0,07	0,05	0,26	0,23	0,11	-0,04
X ₃₃	0,02	0,19	0,17	0,19	-0,01	0,02	-0,05	-0,03	-0,05	-0,07	-0,02	-0,01	0,06	0,07	0,07	0,09	-0,11	-0,07	0,01	-0,16	-0,17	-0,17	0,06	0,01	0,04	-0,09	0,02	0,08	-0,02	0,07	0,16	0,50	1,00	0,03	0,19	0,08	-0,01	0,14	0,05
X ₃₄	0,27	-0,11	-0,15	-0,12	-0,15	0,22	0,16	0,17	0,17	0,05	-0,07	0,55	0,24	0,13	0,09	0,22	0,12	0,14	0,14	-0,01	-0,05	-0,14	0,17	-0,13	-0,03	-0,04	-0,13	0,17	-0,07	0,14	0,27	0,07	0,03	1,00	0,59	0,79	0,53	0,20	0,28
X ₃₅	0,19	-0,13	-0,11	-0,14	-0,10	0,14	0,12	0,14	0,13	0,08	-0,09	0,43	0,18	-0,01	-0,03	0,08	0,08	0,02	0,04	0,01	-0,01	-0,04	0,25	-0,03	-0,02	-0,02	-0,05	0,04	-0,11	0,11	0,15	0,05	0,19	0,59	1,00	0,67	0,39	0,16	0,18
X ₃₆	0,22	-0,18	-0,16	-0,19	-0,17	0,19	0,12	0,13	0,12	0,04	-0,04	0,73	0,18	0,20	0,15	0,22	0,03	0,12	0,08	-0,10	-0,14	-0,20	0,16	-0,06	-0,08	-0,03	-0,05	0,11	-0,07	0,13	0,26	0,26	0,08	0,79	0,67	1,00	0,64	0,19	0,27
X ₃₇	0,12	-0,34	-0,13	-0,35	-0,14	0,11	0,05	0,04	0,05	-0,02	0,21	0,46	0,11	0,17	0,16	0,17	0,02	0,06	0,05	-0,09	-0,10	-0,15	0,08	-0,03	-0,16	0,05	0,00	0,04	-0,06	0,11	0,16	0,23	-0,01	0,53	0,39	0,64	1,00	0,10	0,19
X ₃₈	0,65	0,46	0,42	0,45	0,07	0,53	0,50	0,52	0,51	0,16	-0,26	0,23	0,64	0,31	0,09	0,28	0,08	0,08	0,32	0,03	-0,03	-0,14	-0,01	-0,10	0,11	-0,10	-0,08	0,24	-0,12	0,15	0,58	0,11	0,14	0,20	0,16	0,19	0,10	1,00	0,61
X ₃₉	0,86	0,43	0,41	0,42	0,03	0,59	0,61	0,61	0,61	0,21	-0,33	0,37	0,82	0,48	0,25	0,34	0,26	0,21	0,54	0,26	0,19	-0,02	0,00	-0,06	0,03	-0,10	0,01	0,27	-0,02	0,27	0,58	-0,04	0,05	0,28	0,18	0,27	0,19	0,61	1,00

Opomba: Poimenovanje spremenljivk X_i je možno razbrati iz Tabele 6 v poglavju 4.2.1 Nabor spremenljivk na strani 49.
Vir podatkov: Lastni izračun.

11.1.8 Priloga 8: Deskriptivna statistika izbranega vzorca in Kruskal-Wallis test

Tabela 22: Deskriptivna statistika za izbrani vzorec in Kruskal-Wallis preizkus

		Skupaj število		Povprečje rangov		Kruskal-Wallis test		
		Podjetja z nemodificiranim mnenjem	Podjetja z modificiranim mnenjem	Podjetja z nemodificiranim mnenjem	Podjetja z modificiranim mnenjem	χ^2	Stopnja prostosti	Signifikantnost
		1a	1b	2a	3b	3a	3b	3c
X ₁	ROA	265	265	332,90	198,10	102,667	1	0,000 *
X ₂	ROE	265	265	306,75	224,25	38,462	1	0,000 *
X ₃	ROCE	265	265	298,10	232,90	24,017	1	0,000 *
X ₄	EquityGrowthRate	265	265	306,28	224,72	37,574	1	0,000 *
X ₅	GrossPM	265	265	294,38	236,62	18,858	1	0,000 *
X ₆	OperatingPM	265	265	311,38	219,62	47,583	1	0,000 *
X ₇	NetPM	265	265	310,38	220,62	45,520	1	0,000 *
X ₈	EBITPM	265	265	308,15	222,85	41,104	1	0,000 *
X ₉	PretaxPM	265	265	309,81	221,19	44,375	1	0,000 *
X ₁₀	OperatingCFtoIncome	265	265	282,52	248,48	6,543	1	0,011 **
X ₁₁	EarningsLeverage	265	265	232,24	298,76	26,315	1	0,000 *
X ₁₂	CapitalEmployedTurnover	265	265	284,78	246,22	8,397	1	0,004 *
X ₁₃	BasicEarningsPower	265	265	327,72	203,28	87,485	1	0,000 *
X ₁₄	AssetsTurnover	265	265	294,66	236,34	19,212	1	0,000 *
X ₁₅	FixedAssetsTurnover	265	265	263,19	267,81	0,120	1	0,729
X ₁₆	CashTurnover	265	265	281,38	249,62	5,700	1	0,017 **
X ₁₇	WorkingCapital	265	265	301,00	230,00	28,525	1	0,000 *
X ₁₈	WorkingCapitalTurnover	265	265	297,90	233,10	23,721	1	0,000 *
X ₁₉	CurrentLiabTurnover	265	265	320,20	210,80	67,628	1	0,000 *
X ₂₀	CurrentRatio	265	265	306,02	224,98	37,100	1	0,000 *
X ₂₁	QuickRatio	265	265	303,75	227,25	33,063	1	0,000 *
X ₂₂	LiquidityRatio	265	265	289,32	241,68	12,829	1	0,000 *
X ₂₃	InventoryTurnover	265	265	260,19	270,81	0,637	1	0,425
X ₂₄	DaysInventoryHeld	265	265	254,32	276,68	2,823	1	0,093
X ₂₅	DebtorsTurnover	265	265	268,70	262,30	0,231	1	0,631
X ₂₆	DebtorsCollectionPeriod	265	265	262,04	268,96	0,271	1	0,603
X ₂₇	GrossOperatingCycle	265	265	267,52	263,48	0,092	1	0,762
X ₂₈	AccountsPayableTurnover	265	265	258,53	272,47	1,097	1	0,295
X ₂₉	DaysPurchasesAccountsPayable	265	265	277,13	253,87	3,057	1	0,080
X ₃₀	NetOperatingCycle	265	265	266,82	264,18	0,039	1	0,843
X ₃₁	CFtoCurrentLiabilities	265	265	299,81	231,19	26,603	1	0,000 *
X ₃₂	DebtRatio	265	265	234,77	296,23	21,344	1	0,000 *
X ₃₃	LTDebtToAssets	265	265	247,52	283,48	7,307	1	0,007 *
X ₃₄	DebtToEquityRatio	265	265	275,26	255,74	2,155	1	0,142
X ₃₅	LTDebttoEquity	265	265	265,07	265,93	0,004	1	0,948
X ₃₆	FinLeverageRatio	265	265	269,11	261,89	0,294	1	0,587
X ₃₇	FinLeverageIndex	265	265	259,23	271,77	0,889	1	0,346
X ₃₈	InterestCoverageRatio	265	265	303,56	227,44	32,740	1	0,000 *
X ₃₉	AltmanZ	265	265	328,67	202,33	90,169	1	0,000 *

Opombe:

* Signifikantno pri 0,01.

** Signifikantno pri 0,05.

*** Signifikantno pri 0,10.

Vir podatkov:

Lastni izračun.

11.2 Priloge k 5. poglavju

11.2.1 Priloga 9: Analiza spremenljivk posameznega modela

Tabela 23: Analiza spremenljivk modela

Kazalnik ▼		Koeficient	St. napaka	Wald ^a	p-vrednost	Razmerje obetov ^b	95 % interval zaupanja za razmerje obetov	
		1	2	3	4	5	Spodnja meja	Zgornja meja
							6a	6b
ALLMODEL								
X ₁	Koeficient čiste donosnosti sredstev	- 0,012	0,003	18,453	0,000 *	0,988	0,982	0,993
X ₂	Koeficient čiste donosnosti kapitala	- 0,001	0,001	3,760	0,053 ***	0,999	0,997	1,000
X ₅	Kazalnik (kosmate) donosnosti prodaje	- 0,007	0,002	9,868	0,002 *	0,993	0,989	0,997
X ₇	Kazalnik čiste donosnosti poslovanja	- 0,001	0,001	0,649	0,420	0,999	0,998	1,001
X ₁₀	Kazalnik razmerja med denarnim tokom iz poslovanja in poslovnim izidom	0,000	0,001	0,156	0,693	1,000	0,999	1,001
X ₁₁	Kazalnik dobičkonosnostnega vzvodja	- 0,030	0,051	0,351	0,554	0,970	0,878	1,072
X ₁₂	Koeficient obračanja kapitala podjetja	0,002	0,004	0,118	0,731	1,002	0,993	1,010
X ₁₄	Koeficient obračanja sredstev	- 0,202	0,121	2,808	0,094 ***	0,817	0,645	1,035
X ₁₈	Koeficient obračanja čistih obratnih sredstev	- 0,006	0,002	5,592	0,018 **	0,994	0,989	0,999
X ₂₀	Kratkoročni koeficient	0,002	0,008	0,043	0,837	1,002	0,986	1,017
X ₂₃	Koeficient obračanja zalog	0,000	0,001	0,011	0,782	1,000	0,997	1,002
X ₃₁	Koeficient denarnega toka glede na kratkoročne obveznosti do virov sredstev	- 0,055	0,048	1,284	0,257	0,947	0,862	1,041
X ₃₂	Stopnja zadolženosti	0,004	0,002	3,774	0,052 ***	1,004	1,000	1,009
X ₃₄	Kazalnik dolgovno-kapitalskega razmerja	0,000	0,001	0,175	0,676	1,000	0,999	1,001
X ₃₈	Koeficient pokrivanja odhodkov za obresti s poslovnim izidom iz rednega delovanja	0,001	0,001	0,703	0,402	1,001	0,999	1,002
X ₃₉	Kazalnik Z _{Altman}	- 0,006	0,003	3,020	0,082 ***	0,994	0,988	1,001
a	Konstantni člen	- 0,281	0,243	1,331	0,249	0,755		
MODEL 1								
X ₁	Koeficient čiste donosnosti sredstev	- 0,014	0,003	31,712	0,000 *	0,986	0,981	0,991
X ₂	Koeficient čiste donosnosti kapitala	- 0,001	0,001	4,068	0,044 **	0,999	0,997	1,000
X ₅	Kazalnik (kosmate) donosnosti prodaje	- 0,007	0,002	9,307	0,002 *	0,993	0,989	0,998
X ₁₄	Koeficient obračanja sredstev	- 0,168	0,109	2,380	0,123	0,845	0,682	1,047
X ₁₈	Koeficient obračanja čistih obratnih sredstev	- 0,004	0,002	3,909	0,048 **	0,996	0,991	1,000
X ₃₂	Stopnja zadolženosti	0,004	0,002	3,029	0,082 ***	1,004	1,000	1,008
a	Konstantni člen	- 0,307	0,203	2,277	0,131	0,736		
MODEL 2								
X ₁	Koeficient čiste donosnosti sredstev	- 0,017	0,002	53,146	0,000 *	0,983	0,979	0,988
X ₅	Kazalnik (kosmate) donosnosti prodaje	- 0,006	0,002	9,107	0,003 *	0,994	0,990	0,998
X ₁₈	Koeficient obračanja čistih obratnih sredstev	- 0,005	0,002	5,075	0,024 **	0,995	0,991	0,999
a	Konstantni člen	- 0,316	0,143	4,840	0,028 **	0,729		

(Nadaljevanje na naslednji strani.) ▼

1	2	3	4	5	6a	6b
---	---	---	---	---	----	----

MODEL_3	
X ₁	Koeficient čiste donosnosti sredstev
X ₂	Koeficient čiste donosnosti kapitala
X ₅	Kazalnik (kosmate) donosnosti prodaje
X ₁₄	Koeficient obračanja sredstev
X ₁₈	Koeficient obračanja čistih obratnih sredstev
X ₃₂	Stopnja zadolženosti
X ₃₉	Kazalnik Z _{Altman}
a	Konstantni člen

- 0,013	0,003	27,478	0,000 *	0,987	0,982	0,992	
- 0,002	0,001	4,536	0,033 **	0,998	0,997	1,000	
- 0,007	0,002	9,511	0,002 *	0,993	0,989	0,998	
- 0,236	0,113	4,383	0,036 **	0,790	0,633	0,985	
- 0,006	0,002	5,545	0,019 **	0,994	0,989	0,999	
0,004	0,002	3,739	0,053 ***	1,004	1,000	1,008	
- 0,005	0,003	3,965	0,046 **	0,995	0,989	1,000	
- 0,257	0,206	1,557	0,212	0,773			

MODEL_4	
X ₁	Koeficient čiste donosnosti sredstev
X ₅	Kazalnik (kosmate) donosnosti prodaje
X ₁₈	Koeficient obračanja čistih obratnih sredstev
X ₃₉	Kazalnik Z _{Altman}
a	Konstantni člen

- 0,017	0,002	51,048	0,000 *	0,983	0,979	0,988	
- 0,006	0,002	9,199	0,002 *	0,994	0,990	0,998	
- 0,006	0,002	6,272	0,012 **	0,994	0,989	0,999	
- 0,003	0,002	1,844	0,174	0,997	0,992	1,001	
- 0,315	0,144	4,814	0,028 **	0,730			

Opombe:

^a Wald statistika je izražena kot razmerje med ocenjenim parametrom in standardno napako (Tabachnick in Fidell 2001,524-525). Če je vrednost Wald statistike signifikantna (npr. vrednost je manjša od 0,005), potem je ocenjen parameter signifikanten v modelu.

^b Razmerje obetov je izračunano kot e^{β_i} , kjer je β_i izračunan ocenjen parameter/koefficient.

* Signifikantno pri 0,01.

** Signifikantno pri 0,05.

*** Signifikantno pri 0,10.

Vir podatkov:

Lastni izračun.

11.2.2 Priloga 10: Stroški pri uporabi modela

Tabela 24: Minimalni stroški pri uporabi modelov za razvojne podatke in stroški pri enaki odločitveni točki na testnih podatkih

C ₀₁	P ₁	ALLMODEL		MODEL_1		MODEL_2		MODEL_3		MODEL_4	
		Razvojni podatki	Testni podatki	Razvojni podatki	Testni podatki	Razvojni podatki	Testni podatki	Razvojni podatki	Testni podatki	Razvojni podatki	Testni podatki
1	2	3a	3b	4a	4b	5a	5b	6a	6b	7a	7b
1	0,1	0,0977	0,1052	0,0992	0,0991	0,0955	0,0977	0,0989	0,0979	0,0955	0,1077
1	0,2	0,1842	0,1540	0,1872	0,1908	0,1887	0,2112	0,1789	0,1837	0,1894	0,1977
1	0,3	0,2321	0,2975	0,2313	0,2515	0,2434	0,2516	0,2336	0,2677	0,2464	0,2553
1	0,4	0,2460	0,3325	0,2498	0,2530	0,2642	0,2856	0,2460	0,2644	0,2649	0,2966
1	0,5	0,2528	0,4188	0,2547	0,2604	0,2736	0,3496	0,2547	0,2520	0,2736	0,3473
2	0,1	0,1894	0,2010	0,1921	0,1966	0,1891	0,2135	0,1842	0,2003	0,1906	0,2139
2	0,2	0,2868	0,3534	0,2883	0,2878	0,3064	0,3577	0,2868	0,3388	0,3064	0,3612
2	0,3	0,3283	0,3557	0,3294	0,3476	0,3540	0,3563	0,3268	0,3315	0,3543	0,4002
2	0,4	0,3396	0,3572	0,3555	0,3591	0,3675	0,4174	0,3540	0,3507	0,3653	0,4323
2	0,5	0,3415	0,3296	0,3566	0,3347	0,3623	0,3968	0,3585	0,3655	0,3604	0,4014
3	0,1	0,2547	0,2550	0,2547	0,2645	0,2660	0,3080	0,2513	0,2547	0,2683	0,3165
3	0,2	0,3487	0,3906	0,3532	0,3848	0,3751	0,3924	0,3479	0,3641	0,3758	0,4065
3	0,3	0,3902	0,4132	0,4083	0,4165	0,4223	0,4844	0,4060	0,4059	0,4200	0,5018
3	0,4	0,4098	0,3955	0,4279	0,4016	0,4347	0,4762	0,4302	0,4386	0,4325	0,4817
3	0,5	0,4019	0,3936	0,4057	0,4074	0,4094	0,4250	0,4019	0,4130	0,4038	0,4385
4	0,1	0,3038	0,3737	0,3042	0,3283	0,3200	0,3288	0,3064	0,3714	0,3242	0,3339
4	0,2	0,4045	0,4479	0,4075	0,4166	0,4377	0,5360	0,4075	0,4032	0,4377	0,5556
4	0,3	0,4445	0,4451	0,4638	0,4528	0,4777	0,5214	0,4672	0,4331	0,4755	0,5253
4	0,4	0,4581	0,4570	0,4725	0,4826	0,4755	0,5045	0,4672	0,4886	0,4694	0,5205
4	0,5	0,4321	0,4447	0,4358	0,4425	0,4472	0,4520	0,4302	0,4475	0,4415	0,4529
5	0,1	0,3381	0,4069	0,3411	0,3330	0,3619	0,4111	0,3389	0,3910	0,3623	0,4155
5	0,2	0,4408	0,4692	0,4604	0,4588	0,4770	0,5514	0,4581	0,4573	0,4747	0,5712
5	0,3	0,4902	0,5052	0,5170	0,4692	0,5208	0,5610	0,5136	0,5730	0,5170	0,5585
5	0,4	0,4989	0,5139	0,5011	0,4951	0,5072	0,5155	0,4974	0,5572	0,4996	0,5320
5	0,5	0,4509	0,4696	0,4585	0,4528	0,4642	0,4901	0,4528	0,5277	0,4604	0,4886
10	0,1	0,4732	0,5145	0,4849	0,4824	0,5121	0,6107	0,4868	0,4691	0,5109	0,6329
10	0,2	0,5947	0,5992	0,6204	0,6443	0,6234	0,6456	0,6128	0,6468	0,6158	0,6901
10	0,3	0,6140	0,6323	0,6192	0,6236	0,6385	0,6812	0,6113	0,6311	0,6332	0,6398
10	0,4	0,5585	0,5735	0,5638	0,5996	0,5653	0,5936	0,5623	0,5853	0,5653	0,5961
10	0,5	0,4755	0,5058	0,4698	0,5112	0,4755	0,5036	0,4755	0,5040	0,4755	0,5036
25	0,1	0,7396	0,7638	0,7517	0,8002	0,7525	0,7908	0,7434	0,7758	0,7525	0,7939
25	0,2	0,7396	0,7638	0,7517	0,8002	0,7525	0,7939	0,7434	0,7758	0,7525	0,7939
25	0,3	0,6657	0,7122	0,6577	0,7119	0,6657	0,7059	0,6657	0,7166	0,6657	0,7059
25	0,4	0,5706	0,6395	0,5638	0,7119	0,5706	0,6118	0,5706	0,6299	0,5706	0,6118
25	0,5	0,4755	0,5668	0,4698	0,5353	0,4755	0,5177	0,4755	0,5431	0,4755	0,5177
50	0,1	0,8211	0,8577	0,8347	0,8579	0,8442	0,8916	0,8245	0,8642	0,8381	0,8841
50	0,2	0,7608	0,8255	0,7517	0,8189	0,7608	0,8095	0,7608	0,8252	0,7608	0,8095
50	0,3	0,6657	0,7732	0,6577	0,7400	0,6577	0,7200	0,6657	0,7494	0,6657	0,7200
50	0,4	0,5706	0,7208	0,5638	0,6611	0,5706	0,6306	0,5706	0,6737	0,5706	0,6306
50	0,5	0,4755	0,6685	0,4698	0,5822	0,4755	0,5411	0,4755	0,5979	0,4755	0,5411
75	0,1	0,8558	0,8982	0,8457	0,9166	0,8536	0,8978	0,8558	0,9119	0,8536	0,8978
75	0,2	0,7608	0,8662	0,6577	0,8377	0,7608	0,8189	0,7608	0,7823	0,7608	0,8189
75	0,3	0,6657	0,8342	0,6577	0,7682	0,6657	0,7341	0,6657	0,7823	0,6657	0,7341
75	0,4	0,5706	0,8092	0,5638	0,6987	0,5706	0,6493	0,5706	0,7175	0,5706	0,6493
75	0,5	0,4755	0,7702	0,4698	0,6292	0,4755	0,5646	0,4755	0,6526	0,4755	0,5646
100	0,1	0,8558	0,9186	0,8457	0,9166	0,8558	0,9083	0,8558	0,9229	0,8558	0,9083
100	0,2	0,7608	0,9069	0,7517	0,8565	0,7608	0,8282	0,7608	0,8690	0,7608	0,7482
100	0,3	0,6657	0,8952	0,6577	0,7964	0,6657	0,7482	0,6657	0,8151	0,6657	0,7482
100	0,4	0,5706	0,8835	0,5638	0,7362	0,5706	0,6681	0,5706	0,7613	0,5706	0,6681
100	0,5	0,4755	0,8719	0,4698	0,6761	0,4755	0,5881	0,4755	0,7074	0,4755	0,5881

Vir podatkov: Lastni izračun.