

UNIVERZA V LJUBLJANI
EKONOMSKA FAKULTETA

MAGISTRSKO DELO

**NAPOVEDOVANJE DENARNEGA TOKA S POMOČJO PODATKOV
IZ POSLOVNO INFORMACIJSKEGA SISTEMA MICROSOFT
DYNAMICS AX**

Ljubljana, julij 2016

MAJA GOLOB

IZJAVA O AVTORSTVU

Podpisana Maja Golob, študentka Ekonomske fakultete Univerze v Ljubljani, avtorica predloženega dela z naslovom Napovedovanje denarnega toka s pomočjo podatkov iz poslovno informacijskega sistema Microsoft Dynamics AX, pripravljenega v sodelovanju s svetovalcem prof. dr. Aleš Skok Berk-om in sosvetovalko prof. dr. Mojco Indihar Štemberger

IZJAVLJAM

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

V Ljubljani, dne 12.7.2016

Podpis študentke: _____

KAZALO

UVOD.....	1
1 NAPOVEDOVANJE DENARNEGA TOKA	2
1.1 Razlogi za napovedovanje denarnega toka.....	2
1.2 Časovni horizonti napovedovanja denarnega toka	3
1.3 Pristopi pri napovedovanju denarnega toka.....	4
2 TEHNIKE UPRAVLJANJA Z DENARNIMI SREDSTVI.....	6
2.1 Nadzor nad prilivi iz naslova terjatev	9
2.1.1 Upravljanje s terjatvami do kupcev	9
2.1.2 Učinkovitost v procesu fakturiranja, eRačuni in direktne obremenitve	10
2.1.3 Izterjava	11
2.2 Nadzor nad plačili iz naslova obveznosti	11
2.3 Nadzor nad zalogami	12
2.4 Kratkoročno investiranje presežkov in financiranje primanjkljajev.....	13
2.4.1 Kratkoročno investiranje presežkov	13
2.4.2 Financiranje primanjkljajev	14
2.5 Združevanje denarnih sredstev (»Cash pooling«)	15
3 PREGLED METOD ZA NAPOVEDOVANJE DENARNEGA TOKA.....	17
3.1 Prvi modeli za izračun optimalnega stanja denarnih sredstev	17
3.1.1 Baumol-ov in Beranek-ov model	17
3.1.2 Miller-Orr-ov model	19
3.1.3 Stone-ov model.....	20
3.1.4 Drugi modeli.....	21
3.2 Napovedovanje denarnega toka.....	22
3.2.1 Metoda prejemkov in izdatkov	22
3.2.2 Enostavno drseče povprečje	23
3.2.3 Eksponentno glajenje.....	24
3.2.4 Regresijska analiza	25
3.2.5 Metoda porazdelitve	26
3.3 Napovedovanje denarnega toka iz naslova terjatev.....	27
3.3.1 Tradicionalni kazalniki za napovedovanje denarnega toka iz naslova terjatev in upravljanje s terjatvami	27
3.3.2 Regresija na časovnih vrstah	28
3.3.3 Markovske matrike	29
3.3.4 Moderni pristopi pri napovedovanju denarnega toka	30
3.4 Napovedovanje denarnega toka iz naslova obveznosti	30
4 MICROSOFT DYNAMICS AX 2012 R2	31
4.1 Viri za napovedovanje denarnega toka v Microsoft Dynamics AX 2012.....	33

4.1.1	Terjatve do kupcev	33
4.1.2	Obveznosti do dobaviteljev	34
4.1.3	Nabavna naročila	34
4.1.4	Prodajna naročila	35
4.1.5	Neknjižene finančne fakture	35
4.1.6	Transakcije iz glavne knjige	36
4.1.7	Plani nabave in prodaje ter predračuni	36
4.1.8	Neknjiženi prejeti računi	36
4.1.9	Potrjeni obračuni potnih stroškov	37
4.1.10	Zakladništvo	37
4.1.11	DDV	37
4.1.12	Banka	37
4.2	Funkcionalnost za napovedovanje denarnega toka v Microsoft Dynamics AX 2012	38
5	STROJNO UČENJE	40
5.1	Kaj je strojno učenje	40
5.2	Pregled metod strojnega učenja	42
5.2.1	Metode nadzorovanega strojnega učenja	42
5.2.1.1	Linearna regresija	42
5.2.1.2	Logistična regresija	43
5.2.1.3	Odločitvena drevesa	44
5.2.1.4	Nevronske mreže	45
5.2.1.5	Druge metode	46
5.2.2	Metode nenadzorovanega strojnega učenja	47
5.2.3	Metode okrepitvenega učenja	47
5.3	Uporaba strojnega učenja v praksi	47
5.4	Strojno učenje z »Microsoft Azure machine learning«	48
5.5	Izbor metode in parametrov za napovedovanje denarnega toka s strojnim učenjem	49
6	NAPOVEDOVANJE DENARNEGA TOKA V IZBRANEM PODJETJU	55
6.1	Načrtovanje denarnega toka in upravljanje z denarnimi sredstvi v izbranem podjetju	55
6.1.1	Uporabljeni postopki in viri za napovedovanje denarnega toka	56
6.1.2	Viri, za napovedovanje denarnega toka, ki jih je mogoče nadomestiti z Microsoft Dynamics AX	57
6.1.2.1	Terjatve do kupcev	57
6.1.2.2	Nabavna naročila in obveznosti do dobaviteljev	58
6.1.2.3	Stanje na bančnih računih	59
6.1.2.4	Zakladništvo	60
6.1.2.5	Obračuni potnih stroškov	60

6.1.2.6 DDV	60
6.2 Napovedovanje denarnega toka iz naslova terjatev z uporabo metod strojnega učenja.....	61
6.2.1 Priprava podatkov.....	61
6.2.2 Uporabljene metode izračuna pričakovanega denarnega toka iz izdanih računov	63
6.2.2.1 Uporabljene metode napovedi.....	63
6.2.2.2 Struktura delovnega toka za preračun napovedi denarnega toka s strojnim učenjem	65
6.2.3 Rezultati napovedi denarnega toka s pomočjo različnih modelov	68
6.2.3.1 Primerjava rezultatov algoritmov strojnega učenja za napoved denarnega toka pri poslovanju s podjetji	68
6.2.3.2 Vizualizacija napovedi z odločitvenim gozdom.....	69
6.2.3.3 Primerjava napovedi z odločitvenim gozdom in drugimi metodami za podjetja.....	69
6.2.3.4 Primerjava napovedi z odločitvenim gozdom in drugimi metodami za fizične osebe.....	76
6.2.4 Primerjava rezultatov napovedi denarnega toka za podjetja in fizične osebe .	81
6.3 Postopki za uporabo napovedi denarnega toka na podlagi strojnega učenja v praksi	83
6.4 Nadaljnji koraki pri napovedi denarnega toka v izbranem podjetju na podlagi ugotovitev pri izračunih.....	87
SKLEP	88
LITERATURA IN VIRI.....	91

KAZALO TABEL

Tabela 1: Metoda prejemkov in izdatkov	22
Tabela 2: Primer izračuna enostavnega drsečega povprečja (v EUR).....	24
Tabela 3: Primer izračuna eksponentnega glajenja (v EUR).....	25
Tabela 4: Podatki iz AX, uporabljeni pri napovedovanju denarnega toka iz izdanih računov	62
Tabela 5: Podatki, izračunani iz podatkov v AX, uporabljeni za napoved denarnega toka iz izdanih računov.....	65
Tabela 6: Primerjava rezultatov pri napovedi denarnega toka iz računov za podjetja z algoritmi strojnega učenja	68
Tabela 7: Prikaz glavnih kazalnikov za napoved denarnega toka na dnevnem nivoju	70
Tabela 8: Prikaz glavnih kazalnikov za napoved denarnega toka na tedenskem nivoju.....	73

Tabela 9: Prikaz glavnih kazalnikov za napoved denarnega toka za fizične osebe na dnevnem nivoju	76
Tabela 10: Prikaz glavnih kazalnikov za napoved denarnega toka za fizične osebe na tedenskem nivoju.....	79

KAZALO SLIK

Slika 1: Dnevi vezave denarnih (obratnih) sredstev.....	8
Slika 2: Stanje denarnih sredstev pri Baumol-ovem modelu	18
Slika 3: Stanje denarnih sredstev pri Miller-Orr modelu	20
Slika 4: Stanje denarnih sredstev pri Stone modelu	21
Slika 5: Standardni prikaz neto potreb po likvidnostnih sredstvih v Microsoft Dynamics AX 2012	39
Slika 6: Prikaz napovedi denarnega toka z dodelavo	40
Slika 7: Linearna regresija.....	43
Slika 8: Logistična regresija.....	43
Slika 9: Odločitveno drevo.....	44
Slika 10: Nevronska mreža	46
Slika 11: Koraki pri napovedi denarnega toka z algoritmi strojnega učenja	67
Slika 12: Primerjava povprečne absolutne napake za napovedi denarnega toka za podjetja na dnevnem nivoju (od 1.1.2015 do datuma) v EUR.....	71
Slika 13: Primerjava povprečne absolutne skalirane napake za napovedi denarnega toka za podjetja na dnevnem nivoju (od 1.1.2015 do datuma)	72
Slika 14: Primerjava povprečne absolutne skalirane napake za napovedi denarnega toka za podjetja na dnevnem nivoju (30-dnevno drseče povprečje)	72
Slika 15: Primerjava povprečne absolutne napake za napovedi denarnega toka za podjetja na tedenskem nivoju (od 1.1.2015 do datuma) v EUR	74
Slika 16: Primerjava povprečne absolutne skalirane napake za napovedi denarnega toka za podjetja na tedenskem nivoju (od 1.1.2015 do datuma)	75
Slika 17: Primerjava povprečne absolutne skalirane napake za napovedi denarnega toka za podjetja na tedenskem nivoju (4-tedensko drseče povprečje)	75
Slika 18: Primerjava povprečne absolutne napake za napovedi denarnega toka za fizične osebe na dnevnem nivoju (od 1.1.2015 do datuma) v EUR.....	77
Slika 19: Primerjava povprečne absolutne skalirane napake za napovedi denarnega toka za fizične osebe na dnevnem nivoju (od 1.1.2015 do datuma)	78

Slika 20: Primerjava povprečne absolutne skalirane napake za napovedi denarnega toka za fizične osebe na dnevnem nivoju (30-dnevno drseče povprečje)	78
Slika 21: Primerjava povprečne absolutne napake za napovedi denarnega toka za fizične osebe na tedenskem nivoju (od 1.1.2015 do datuma) v EUR.....	79
Slika 22: Primerjava povprečne absolutne skalirane napake za napovedi denarnega toka za fizične osebe na tedenskem nivoju.....	80
Slika 23: Primerjava povprečne absolutne skalirane napake za napovedi denarnega toka za fizične osebe na tedenskem nivoju (4-tedensko drseče povprečje)	81
Slika 24: Prikaz porazdelitve velikosti računov za fizične osebe in podjetja ($\log_{10}$).....	82
Slika 25: Primerjava povprečne absolutne napake za napovedi denarnega toka za podjetja na tedenskem nivoju (od 1.10.2015 do datuma) v EUR.....	85
Slika 26: Primerjava povprečne absolutne skalirane napake za napovedi denarnega toka za podjetja na tedenskem nivoju (od 1.10.2015 do datuma)	86
Slika 27: Primerjava povprečne absolutne skalirane napake za napovedi denarnega toka za podjetja na tedenskem nivoju (4-tedensko drseče povprečje).....	86

UVOD

Načrtovanje denarnega toka lahko podjetju prinese veliko prednosti, če je izvedeno dovolj natančno, da se na njegovi osnovi da pravilno predvideti potrebe po virih financiranja ali morebitne presežke sredstev, ki jih podjetje lahko nameni investicijam. To pa zna biti pravi izziv, kadar gre za podjetje, ki posluje v več državah, v različnih valutah in ki poslovanje spremlja v različnih poslovno informacijskih sistemih. S takšnimi izzivi se sooča tudi izbrano podjetje.

Pri načrtovanju denarnega toka je veliko vprašanje, kdaj in v kolikšnem deležu bodo plačane odprte terjatve. Plačila obveznosti je lažje načrtovati, saj so odvisna od ravnanja podjetja. Napovedovanje prilivov pa je odvisno od ravnanja kupcev, na katerega podjetje ne more vedno vplivati. Določeni kupci plačujejo račune na datum zapadlosti, običajno pa je več tistih, ki račune plačajo prepozno ali prezgodaj. To pomeni, da se podjetju, ki prilive planira glede na zapadlosti računov, kaj lahko zgodi, da ima določen dan na računu premalo sredstev za pokrivanje svojih obveznosti, drug dan pa ima sredstev preveč. Takšne situacije podjetju povzročajo neželene stroške. Obstaja mnogo različnih metod za napovedovanje prilivov, ena od novejših pa je uporaba strojnega učenja, ki je za napovedovanje prilivov iz naslova izdanih računov uporabljena v tem delu. Pristop se zdi obetaven, kajti algoritmi strojnega učenja so zmožni iz velike množice podatkov o obstoječem obnašanju kupcev potegniti bistvene vzorce in jih uporabiti na napoved na novih primerih. To bi lahko izboljšalo napoved v primerjavi z napovedmi na podlagi enostavnejših pristopov, zastopanih v informacijskem sistemu in obravnavanih v tem delu, za namene primerjave rezultatov.

Namen magistrskega dela je raziskati možnosti, ki jih ima izbrano mednarodno storitveno podjetje na voljo za izboljšanje trenutno uporabljanega procesa napovedovanja denarnega toka. Temeljno raziskovalno vprašanje dela je, ali se lahko uporaba metod strojnega učenja na preteklih podatkih o plačilni disciplini kupcev, in na splošnih podatkih o kupcih, uporabi za kvalitetno napovedovanje denarnega toka iz naslova izdanih računov. Drugo raziskovalno vprašanje pa se nanaša na možnost uporabe podatkov iz ERP sistema Microsoft Dynamics AX 2012 R2 (v nadaljevanju AX) in posledično izboljšanje in pohitritev postopka napovedovanja denarnega toka v podjetju, in sicer tako, da se sistemsko nadomestijo določeni drugi viri, na podlagi katerih se denarni tok načrtuje trenutno.

Cilji magistrskega dela obsegajo pregled relevantne literature iz področja napovedovanja denarnega toka in strojnega učenja, analizo trenutno uporabljenih postopkov načrtovanja denarnega toka v izbranem podjetju, pregled možnosti za optimizacijo procesa s pomočjo podatkov iz AX ter aplikacijo pridobljenega znanja na napoved denarnega toka iz terjatev z algoritmi strojnega učenja ter analizo ugotovitev oz. predloge za izboljšavo procesa.

Prvi del magistrskega dela vsebuje pregled literature iz področja tehnik upravljanja z denarnimi sredstvi in načrtovanja denarnega toka, pri čemer je ločeno popisano

izračunavanje optimalnega stanja denarnih sredstev, napovedovanje denarnega toka za podjetja ter bolj specifično načrtovanje prilivov iz naslova terjatev ter načrtovanje odlivov iz naslova obveznosti.

V nadaljevanju je predstavljena rešitev za načrtovanje denarnega toka v poslovno informacijskem sistemu Microsoft Dynamics AX, ki ga za spremljanje poslovanja v Sloveniji uporablja izbrano podjetje. Sledi pregled najbolj znanih in najpogostejše uporabljenih algoritmov strojnega učenja ter metod za ugotavljanje točnosti napovedi oz. napake pri napovedih.

V zadnjem delu so predstavljene možnosti za izboljšanje procesa načrtovanja denarnega toka v podjetju z nadomestitvijo nekaterih ročno planiranih vrednosti s podatki, ki se spremljajo v AX, ter rezultati napovedovanja denarnega toka na podlagi podatkov o kupcih ter odprtih terjativah, ki se spremljajo v AX, s pomočjo metod strojnega učenja ter primerljivih, enostavnejših metod, v preglednicah. Za konec sledi analiza ugotovitev ter priporočila za spremembe pri načrtovanju denarnega toka v podjetju.

1 NAPOVEDOVANJE DENARNEGA TOKA

Kadar razmišljamo o uspešnosti poslovanja podjetja, se najpogosteje vprašamo, kakšen je njegov dobiček (Berry, 2016). Vendar pa podjetja, prav tako kot fizične osebe, trošijo denar in ne dobička, zato je kritičnega pomena, da planirajo denarni tok, ter aktivno upravljajo denarna sredstva, sicer se lahko tudi dobičkonosna podjetja znajdejo v težavah (Berry, 2016).

1.1 Razlogi za napovedovanje denarnega toka

Zgodovinsko gledano, se je oddelek zakladništva obravnavalo kot eno od podpornih funkcij podjetja, katerega bistvena naloga je bila zagotavljati dovolj sredstev za plačilo obveznosti, izplačilo plač ter informirati zainteresirane deležnike o stanjih na bančnih računih (Van Steenberghe, 2011). Globalna likvidnostna kriza ter fluktuacija pri gibanju obrestnih mer in valutnih tečajev pa je povzročila, da je oddelek zakladništva dobil precej bolj pomembno vlogo, saj je v takšnih razmerah na trgih dostop do likvidnostnih sredstev lahko za podjetje pomenil razliko med preživetjem in stečajem (Van Steenberghe, 2011).

Bragg (2012) aktivnosti upravljanja z denarnimi sredstvi v zakladništvu deli na:

- agregiranje informacij (sem uvršča tudi napovedovanje denarnega toka),
- uravnavanje likvidnosti,
- uravnavanje tveganja.

Napoved denarnega toka je orodje, ki pripomore k kvalitetnejši izvedbi drugih aktivnosti upravljanja z denarnimi sredstvi (Bragg, 2012). Napovedovanje denarnega toka lahko podjetju pomaga na mnogih področjih, če je napoved pripravljena kvalitetno ter pravilno uporabljena; v primeru, da temu ni tako, pa lahko za vse vpletene v proces napovedovanja pomeni zgolj veliko izgubo časa (De Caux, 2005).

Združenje finančnih strokovnjakov funkcije oz. prednosti napovedovanja denarnega toka loči na (Association for Financial Professionals, 2012):

- funkcije, ki se nanašajo na oddelek zakladništva:
 - omogoča zagotavljanje sredstev na pravem mestu, ob pravem času in v pravi valuti za plačilo obveznosti oz. zagotavljanje likvidnosti ter s tem normalno poslovanje podjetja;
 - omogoča minimiziranje stroškov zadolževanja na dva načina – s tem da, zmanjša potrebo po zadolževanju, saj omogoča pravočasno prerazporeditev sredstev, in s tem, da zniža stroške vsakršne potrebne zadolžitve s skupnim zadolževanjem podružnic oz. zadolževanjem tam, kjer je to najbolj ugodno;
 - omogoča maksimiranje obresti za naložena sredstva v primerih, ko ima podjetje presežek likvidnostnih sredstev;
 - omogoča zmanjšanje izpostavljenosti valutnemu tveganju (npr. z uporabo instrumentov zavarovanja) in pravočasne prenose sredstev v valutah, kar zmanjša potrebo po menjavah valut ali zadolževanju v valutah;
- funkcije, ki se nanašajo na vodenje podjetja:
 - omogoča boljši finančni nadzor nad poslovanjem podružnic podjetja, kar je še posebej pomembno za velika mednarodna podjetja, in je lahko uporaben tudi kot priprava na spremembe v tehnikah upravljanja denarnega toka – npr. pri vpeljavi združevanja denarnih sredstev;
 - omogoča boljšo kontrolo nad poslovanjem podjetja ter nad trendi plačevanja, s tem lahko opozori na morebitne probleme oz. da vodstvu informacije za hitro ukrepanje;
 - ima strateško vlogo, saj omogoča identifikacijo trendov v poslovnem ciklu podjetja in s tem identifikacijo potreb po investiranju ali presežkov sredstev.

1.2 Časovni horizonti napovedovanja denarnega toka

Denarni tok je mogoče napovedovati za različna časovna obdobja – kratkoročno, srednjeročno ali dolgoročno (De Caux, 2005). Kratkoročno napovedovanje denarnega toka se uporablja za napovedi do 30 dni v naprej, srednjeročno za napovedi znotraj enega leta in dolgoročno za napovedi nad enim letom (De Caux, 2005).

Cilj kratkoročnega napovedovanja denarnega toka je identificirati prilive in odlive dovolj natančno, da se zagotovi dnevno potrebna sredstva na bančnih računih ter investira

morebiten presežek sredstev (De Caux, 2005). Kratkoročne napovedi se običajno dela na dnevnem nivoju (Rappold, 2015).

Srednjeročne napovedi denarnega toka se najpogosteje delajo na mesečnem nivoju za največ dvanajst mesecev v naprej in se uporabljajo za ocenjevanje povprečnega stanja denarnih sredstev ter kot orodje za pridobivanje kreditov, oz. s strani bank kot orodje za nadzor nad posojilojemalci (De Caux, 2005). Uporablja se tudi kvartalno oz. 13-tedensko napovedovanje denarnega toka (angl. *TWCF*) na tedenskem nivoju, ki je pogosto v podjetjih, ki so v težavah ali stečaju (Snyder, 2013).

Dolgoročne napovedi denarnega toka upoštevajo dolgoročne plane prodaje, nabave in strategijo podjetja ter se npr. uporabljajo za planiranje večjih investicij (De Caux, 2005).

Časovni horizont in nivo napovedi (dnevna, tedenska, mesečna) morata biti izbrana glede na značilnosti podjetja (Rappold, 2015). Podjetja v določenih panogah, kjer je povpraševanje razmeroma enakomerno, lahko plane delajo za daljše obdobje, kot podjetja, kjer povpraševanje močno variira ali podjetja, ki delajo projektno (Rappold, 2015). V vsakem primeru pa velja, da bolj dolgoročna kot je napoved, manj točna je (De Caux, 2005).

1.3 Pristopi pri napovedovanju denarnega toka

Napovedovanje denarnega toka je pomembno tako za financiranje poslovanja, kot tudi za investiranje podjetja (Bank of America, Merrill Lynch, 2013). K napovedi denarnega toka lahko dandanes veliko pripomore tehnologija, vendar je še bolj kot tehnologija pomemben proces, ki ga pri napovedovanju uvedejo podjetja, saj mora ta omogočati pridobitev pomembnih in zanesljivih podatkov, s katerimi je mogoče narediti kvalitetno napoved (Bank of America, Merrill Lynch, 2013).

Proces napovedovanja denarnega toka vključuje (Association for Financial Professionals, 2012):

- identifikacijo podatkov, ki jih je potrebno zajeti v načrt denarnega toka;
- identifikacijo virov podatkov;
- oceno zanesljivosti in popolnosti podatkov;
- izbor časovnega horizonta za napoved denarnega toka;
- izbor metode za napoved denarnega toka;
- nadzor nad pridobljenimi podatki za planiranje na dnevni ravni;
- pregledovanje rezultatov napovedi denarnega toka.

Izbor in pridobitev vhodnih podatkov sta izrednega pomena za točnost napovedi denarnega toka (Matassi, 2011). Podatke je pogosto potrebno pridobiti iz veliko različnih virov, še

posebej kadar podjetje uporablja različne informacijske sisteme, ki sicer dandanes pogosto že vključujejo module za izračun načrta denarnega toka (Matassi, 2011). V primerih razdrobljenih virov podatkov je pomembno, da se vsi oddelki v podjetju zavedajo pomena načrta denarnega toka ter da prevzamejo svoj del odgovornosti za planiranje oz. za točnost podatkov, ki jih priskrbijo za planiranje (Matassi, 2011). Še boljši pristop k načrtovanju denarnega toka pa je integracija vseh virov v en, skupen vir podatkov, iz katerega lahko črpa oddelek zakladništva, ter se s tem izogne zahtevnemu premetavanju podatkov, čas pa koristneje porabi za njihovo analizo (Backlund, 2008).

Napovedovanje denarnega toka je možno z uporabo naslednjih pristopov (Higdon, 2011; De Caux, 2005):

- od spodaj navzgor (neposredna metoda oz. metoda prejemkov in izdatkov): gre za prevedbo podrobnih podatkov iz poslovanja, npr. podatkov o odprtih terjativah, odprtih obveznostih, stanjih na bančnih računih, transakcijah v zakladništvu, itd. v napoved denarnega toka;
- od zgoraj navzdol (posredna metoda): gre za napovedovanje denarnega toka s prerazporejanjem predračunov ali napovedi iz širših časovnih obdobij (leto, mesec) na krajša časovna obdobja (mesec, teden, dan) z uporabo enostavnih ali kompleksnih (npr. z upoštevanjem sezonskih vplivov, datumov plačil DDV) razporeditev;
- ali s pomočjo statističnih modelov, kjer s statističnimi metodami iz preteklih denarnih tokov napovedujemo bodoče denarne tokove (spadajo med pristop od spodaj navzgor in se lahko uporabijo v kombinaciji z drugimi pristopi).

Napovedovanje kratkoročnega denarnega toka se običajno izvaja z uporabo pristopa od spodaj navzgor, napovedovanje dolgoročnega denarnega toka z uporabo pristopa od zgoraj navzdol, napovedovanje srednjeročnega denarnega toka pa s kombiniranjem teh dveh pristopov (Bragg, 2012).

Za napovedovanje denarnega toka z metodo od zgoraj navzdol se lahko uporabi posredne metode (Rajendra, 2013):

- metoda prilagojenega čistega dobička (angl. *adjusted net income* oz. *ANI*), pri kateri se uporabi prihodke iz poslovanja ter se upošteva spremembe v bilanci stanja, kot npr. spremembe terjatev in obveznosti ter spremembe v stanju zalog;
- metoda odprave razmejitev (angl. *accrual reversing method* oz. *ARM*), ki je najbolj zahtevna in je hibrid metode prilagojenega čistega dobička in metode prejemkov in izdatkov (torej hibrid pristopov od spodaj navzgor in od zgoraj navzdol), temelji na pretvorbi dejanskih ali planiranih poslovnih dogodkov (prihodkov in odhodkov) v denarne posledice na podlagi algoritmov in statističnih distribucij;

- pro-forma bilanco stanja (angl. *pro-forma balance sheet* oz. *PBS*), pri kateri se uporabi planirano vrednost denarnih sredstev iz bilance stanja.

Za napovedovanje denarnega toka se lahko uporabijo tudi statistični modeli, ki na podlagi analize preteklih podatkov napovedujejo denarni tok v prihodnosti (Higdon, 2011). Modeli in njihov zgodovinski razvoj so predstavljeni v poglavju 3.

Kakršnakoli je že napoved denarnega toka, realnost nikoli ne bo povsem v skladu z njo (Association for Financial Professionals, 2012). Na dnevnem nivoju bo lahko prihajalo do precejšnjih odklonov med napovedjo in dejanskim denarnim tokom (Association for Financial Professionals, 2012). Iz procesa napovedovanja se je zato potrebno učiti, ga prilagajati specifičnemu podjetju in ga s tem konstantno izboljševati (Backlund, 2008). Napovedi je potrebno primerjati z dejanskim denarnimi tokovi za celo podjetje in posamezne podružnice ter odkriti vzroke za napake v planiranih zneskih, pri čemer pomembno vlogo igrajo tudi posamezne poročevalske enote, ne samo oddelek zakladništva (Backlund, 2008).

2 TEHNIKE UPRAVLJANJA Z DENARNIMI SREDSTVI

Tehnike upravljanja z denarnimi sredstvi so finančne strategije, ki jih uvedejo podjetja za zagotovitev ciljev upravljanja z denarnimi sredstvi (zagotavljanje likvidnosti, doseganje profita, minimiziranje stroškov) (Reider & Heyler, 2003).

Podjetja imajo običajno velik del sredstev vezanih v obratna sredstva, kar lahko privede do potrebe po večjem zadolževanju ali nižjem investiranju; zato je ta sredstva smiselno nadzorovati in sprejemati ukrepe, ki povzročijo znižanje potreb po denarnih sredstvih za financiranje obratnih sredstev (Bragg, 2012). Pri nadzorovanju obratnih sredstev si podjetja običajno pomagajo s preprostimi merili, kot so dnevi vezave denarnih sredstev oz. koeficienti obračanja posameznih komponent obratnega kapitala (Bragg, 2012; Slovenski računovodski standard 29 (2006): računovodsko proučevanje (računovodsko analiziranje), 2005).

Koeficient obračanja terjatev do kupcev se izračuna z naslednjo enačbo (Weygandt, Kimmel & Kieso, 2012):

$$\text{Koeficient obračanja terjatev do kupcev} = \frac{\text{Prihodki od prodaje v letu dni}}{\text{Povprečno stanje terjatev do kupcev}} \quad (1)$$

Koeficient obračanja terjatev do kupcev prikazuje kolikokrat se v letu dni obrnejo sredstva, ki so vezana v terjatvah do kupcev (Turk, 2016). Visok koeficient obračanja terjatev lahko

pomeni, da podjetje izvaja učinkovito politiko upravljanja s terjatvami, nizek koeficient pa lahko pomeni, da kupci podjetju ne plačujejo dovolj hitro.

Koeficient obračanja zalog se izračuna z naslednjo enačbo (Slovenski računovodski standard 29 (2006): računovodsko proučevanje (računovodsko analiziranje), 2005):

$$\text{Koeficient obračanja zalog materiala} = \frac{\text{Porabljeni material v letu dni (nabavna vrednost)}}{\text{Povprečna zaloga materiala (nabavna vrednost)}} \quad (2)$$

Koeficient obračanja zalog materiala prikazuje kolikokrat letno se obrnejo zaloge materiala (Turk, 2016).

Ločeno se lahko izračunajo še kazalniki obračanja zalog za proizvode, pri čemer se namesto porabljenega materiala upošteva prodane proizvode ter povprečno zalogo proizvodov, ali pa za trgovsko blago, kjer se upošteva prodano blago in stanje zalog blaga (Slovenski računovodski standard 29 (2006): računovodsko proučevanje (računovodsko analiziranje), 2005). Slovenski računovodski standard 29 (2006): računovodsko proučevanje (računovodsko analiziranje) (2005) poleg omenjenih, definira še druge koeficiente obračanja, kot npr. koeficient obračanja obratnih sredstev, koeficient obračanja osnovnih sredstev, ipd. Turk (2016) pa navaja tudi koeficient obračanja obveznosti do dobaviteljev, ipd.

Dneve vezave denarnih (obratnih) sredstev (angl. *cash conversion cycle* oz. *CCC*) se izračuna iz naslednjih kazalnikov (Brigham & Daves, 2004):

- dnevi vezave terjatev (angl. *days sales outstanding* oz. *DSO*): povprečno število dni, potrebnih za prevedbo terjatev v denar;

$$\text{Dnevi vezave terjatev} = \frac{\text{Povprečne terjatve do kupcev} \times 365}{\text{Prihodki od prodaje}} \quad (3)$$

- dnevi vezave obveznosti (angl. *payables deferral period*): povprečno število dni med nakupom in plačilom materiala in dela;

$$\text{Dnevi vezave obveznosti} = \frac{\text{Povprečne obveznosti do dobaviteljev} \times 365}{\text{Stroški prodanih proizvodov}} \quad (4)$$


- dnevi vezave zalog (angl. *inventory conversion period*): povprečno število dni, potrebnih za pretvorbo materialov v izdelke in prodajo teh izdelkov.

$$\text{Dnevi vezave zalog} = \frac{\text{Povprečno stanje zalog proizvodov} \times 365}{\text{Stroški prodanih proizvodov}} \quad (5)$$

Dnevi vezave denarnih sredstev se izračunajo kot (Brigham & Daves, 2004):

$$\text{Dnevi vezave denarnih sredstev} = \text{Dnevi vezave terjatev} + \text{Dnevi vezave zalog} - \text{Dnevi vezave obveznosti} \quad (6)$$

Slika 1: Dnevi vezave denarnih (obratnih) sredstev



Vir: E.F. Brigham & P.R. Daves, *Intermediate Financial Management*, 2004, str. 702, slika 20-1.

Nižji kazalnik dni vezave denarnih sredstev običajno kaže na to, da podjetje denar od kupcev pridobi hitro, medtem ko dobaviteljem plačuje pozno, kar pomeni, da ima ugodnejši cikel denarja kot podjetja z višjim kazalnikom (Gentry, Vaidyanathan, & Lee, 1990). Hitro pridobivanje denarja in pozno plačevanje je lahko posledica različnih faktorjev – kratkih plačilnih rokov ali predplačil na strani terjatev in dolgih plačilnih rokov na strani obveznosti, ali pa zaradi razlike v povprečni zamudi plačil na strani kupcev in podjetja.

Klasično izračunan kazalnik pa ne upošteva zneskov vezave, kar so upoštevali Gentry, Vaidyanathan in Lee (1990), ko so vpeljali koncept uteženih dni vezave denarnih sredstev (angl. WCCC) – ta je izračunan na podlagi končne vrednosti proizvodov in je lahko za podjetja s enakimi dni vezave denarnih sredstev različen, saj imajo nekatera podjetja precej višjo maržo na svoje proizvode kot druga podjetja. Kazalnik je običajno nižji za storitvena podjetja, kjer se pri izračunu ne upošteva dni vezave zalog (Bragg, 2012).

Izboljšanje kazalnika vezave denarnih sredstev je mogoče s pomočjo znižanja dni vezave terjatev, znižanja dni vezave zalog in zvišanjem dni vezave obveznosti do dobaviteljev.

Merila, s katerimi podjetje spremlja terjatve, so namenjena odločanju v zvezi s pogoji oz. metodami, ki jih bo podjetje uporabilo za nadzor nad terjatvami. Dneve vezave terjatev se lahko primerja s plačilnimi pogoji, ki jih ponuja podjetje, ter se s tem ugotavlja, ali kupci plačujejo v okviru določenih plačilnih rokov (Brigham & Daves, 2004). Prav tako je kazalnik mogoče primerjati s primerljivimi podjetji za ugotavljanje, kako kupci podjetju plačujejo v primerjavi z drugimi podjetji (Brigham & Daves, 2004).

Poleg kazalnika dnevi vezave terjatev se za spremljanje terjatev uporablja še npr. starostno strukturo terjatev (Brigham & Daves, 2004). Ta je zgrajena iz podatkov o posameznih terjatvah oz. iz podatkov o dnevih poplačil terjatev in bolje pokaže plačilne vzorce posamičnih kupcev, ki iz dni vezave terjatev niso razvidni, ker kazalnik kaže zgolj povprečne vrednosti za vse kupce (Brigham & Daves, 2004).

2.1 Nadzor nad prilivi iz naslova terjatev

Podjetja morajo svojim kupcem omogočiti plačilne pogoje, ki so konkurenčni ostalim podjetjem, da si s tem zagotovijo posel in preživetje, hkrati pa se morajo izogibati dolgim vezavam sredstev v terjatvah in slabim terjatvam (Credit and Collection Policies and Procedures Methods, 2016). Cilj nadzora nad terjatvami ne sme biti maksimiranje prodaje ali minimiziranje tveganja za nastanek slabega dolga, pač pa maksimiranje zneska povračila iz optimalnega zneska terjatev (Van Horne & Wachowicz, Jr., 2008). Optimalni znesek terjatev je določen s primerjavo prednosti (zaslužka) iz naslova dodatnih terjatev ter stroškov, ki nastanejo zaradi vezave sredstev v te terjatve ter zaradi neplačil s strani posameznih kupcev (Van Horne & Wachowicz, Jr., 2008).

Metode, ki jih lahko podjetje uporabi za nadzor nad terjatvami, lahko v grobem razdelimo v 3 skupine (Bragg, 2010; Bragg, 2012):

- upravljanje s terjatvami do kupcev,
- učinkovitost v procesu fakturiranja,
- izterjavo.

2.1.1 Upravljanje s terjatvami do kupcev

Upravljanje s terjatvami do kupcev obsega določitev kreditnega limita, plačilnih pogojev (določitev števila dni do zapadlosti računa, možnost plačil na obroke, predplačila, kasaskonto, ipd.) in potrebnih garancij ter obdobjno preverjanje ustreznosti limita oz. ponudbo zunanjega financiranja prodaje, v primeru da podjetje ni pripravljeno kupcu odobriti dovolj velikega kreditnega limita ali željene dolžine plačilnih pogojev (Bragg, 2010). Pri določanju kreditnega limita si podjetja pogosto pomagajo z bonitetnimi ocenami podjetij, ki podajo oceno tveganja poslovanja z določenim poslovnim partnerjem (Gospodarska zbornica Slovenije, 2016). Bonitetne ocene v Sloveniji ponujajo npr. podjetja Pro Kolekt d.o.o., Coface Slovenija d.o.o., I d.o.o., AJ PES in drugi.

Kako strogo politiko upravljanja s terjatvami do kupcev bo podjetje uporabilo, je odvisno od narave posla tega podjetja – storitvena podjetja, ki poskušajo pridobiti tržni delež in imajo visoke marže, si lažje privoščijo višjo prodajo ob nižji verjetnosti poplačila terjatev, saj ne morejo veliko izgubiti, kot pa podjetja, ki prodajajo proizvode z nizko maržo in nimajo

veliko prostora za rast (Bragg, 2010). Politika upravljanja s terjatvami bi morala biti vedno določena s strani uprave podjetja in bi morala vključevati standardne plačilne pogoje podjetja, kriterije za odobritve kreditnih limitov, definirati s katero bonitetno hišo bo podjetje sodelovalo, ipd. (Allott, Besson-Levine, & Young, 2009).

2.1.2 Učinkovitost v procesu fakturiranja, eRačuni in direktne obremenitve

Proces fakturiranja lahko pomembno vpliva na denarni tok podjetja (Driscoll, 2012). Hitro izdajanje računov brez napak lahko močno pohitri poplačilo terjatev ter s tem izboljša denarni tok podjetja ter vrednost kazalnika dnevi vezave terjatev (Driscoll, 2012). Učinkovitost v procesu fakturiranja je mogoče zagotoviti s spremembami v načinu pošiljanja računov (namesto papirnatih izpisov lahko podjetja uporabijo elektronske račune), z izogibanjem napakam pri fakturiranju in s hitrim reševanjem reklamacij (Driscoll, 2012). Bragg (2010) med možnostmi za izboljšanje procesa navaja tudi načine za sprejemanje plačil (v Sloveniji so plačila predvsem v elektronski obliki, uporabljajo pa se lahko tudi direktne obremenitve). Bryk, Lee, Thibault in Stewien (2016) pa navajajo še pomembnost pravočasnega knjiženja plačil in pravilnega zapiranja terjatev, ki posledično zagotavljajo spremljanje odprtih terjatev ter izterjavo.

Ena od možnosti, ki so se pojavile v zadnjih letih in močno vplivajo na hitrost dostave računov kupcem, zagotavljajo transparentnost poslovanja in izboljšujejo odnose s kupci, so eRačuni (Balasubramanian, 2009). Podjetja morajo v Sloveniji eRačune od 1.1.2015 obvezno pošiljati proračunskim uporabnikom, lahko pa jih pošiljajo tudi ostalim dolžnikom (Republika Slovenija, Ministrstvo za finance, 2016). eRačuni enakovredno zamenjujejo račune v papirnatih obliki in imajo kar nekaj prednosti – hitrost, varnost, natančnost pri prevzemu podatkov, nižje stroške zaradi manjše porabe papirja in poštnih storitev, itd. (eRačun – proračunski uporabniki, 2016). Pravne in fizične osebe lahko pošiljajo eRačune proračunskim uporabnikom preko portala UJP eRačun, vsem uporabnikom pa preko bank oz. drugih ponudnikov elektronskih poti (Republika Slovenija, Ministrstvo za finance, 2016).

Poleg eRačunov lahko podjetje na točnost napovedi denarnega toka iz naslova terjatev kupcev močno vpliva z uporabo SEPA direktnih obremenitev. SEPA direktne obremenitve podjetjem omogočajo, da poberejo plačila kupcev točno na datum zapadlosti računov, kar jim omogoča enostavno načrtovanje denarnega toka in enostavno pobotanje terjatev s plačili. (Westerhaus, 2009). SEPA direktne obremenitve se izvajajo tako, da prejemnik plačila na podlagi soglasja, ki mu ga predloži plačnik, pošlje plačilni nalog preko svojega ponudnika plačilnih storitev ponudniku plačilnih storitev plačnika (Direktne obremenitve, 2016). Direktne obremenitve podjetjem omogočajo, da poberejo plačila v celotnem SEPA območju, ki obsega 33 držav (članice EU in Islandijo, Lihtenštajn, Norveško, Švico in Monako), s pomočjo standardiziranega plačilnega instrumenta, kar omogoča znižanje stroškov vlaganja v informacijsko tehnologijo (Westerhaus, 2009). Osnovna SDD shema je namenjena

direktnim obremenitvam v breme plačilnih računov potrošnikov, B2B SDD shema pa izvajanju direktnih obremenitev med poslovnimi subjekti (Direktne obremenitve, 2016).

2.1.3 Izterjava

Obseg odprtih terjatev se lahko v podjetjih precej zmanjša z uporabo tehnik izterjave. Izterjava obsega (Bragg, 2012):

- vnaprejšnje poizvedovanje pri večjih kupcih glede datumov plačil, ko terjatve še niso zapadle;
- izdelavo in pošiljanje opominov pri manjših odprtih terjativah, ki so že zapadle;
- telefonsko izterjavo zamujenih plačil, pri kateri se podjetje s kupcem poskuša dogovoriti za datum poplčila dolga ali za vračilo izdelkov;
- pismo odvetnika (v Sloveniji se pošilja opomine pred tožbo s strani odvetnika tudi kupcem, ki se jih nato predlaga v eIzvršbo);
- izterjava preko sodišča (v Sloveniji eIzvršbe ali tožba);
- izterjava preko izterjevalske agencije (agencija lahko upniku zaračuna določen delež od izterjane terjatve ali pa odkupi dolg ter s tem postane lastnica dolga).

Telefonsko poizvedovanje in izterjava ter pošiljanje opominov veljajo za ustaljeno prakso ter ne pomenijo zaostritve odnosov med prodajalcem in kupcem, medtem ko izvedba ostalih akcij pomeni zaostritev odnosov oz. običajno tudi konec poslovanja med partnerji (Bragg, 2012).

2.2 Nadzor nad plačili iz naslova obveznosti

Podjetja imajo obveznosti do zaposlenih in obveznosti do dobaviteljev (Brigham & Daves, 2004). Izplačil obveznosti zaposlenim iz naslova plač in državi iz naslova prispevkov in davkov iz plač ni mogoče dobro nadzorovati, saj so vezana na zakonodajo, pogodbe in splošne tržne pogoje, medtem ko so možnosti pri izplačilih obveznosti dobaviteljem bolj odprte (Brigham & Daves, 2004).

Obveznosti do dobaviteljev pomenijo za podjetja vir financiranja, zato mora biti cilj podjetja, obveznosti plačati čim pozneje, ne da bi pri tem zamudili plačilne roke, dogovorjene z dobavitelji (Bragg, 2012). Podjetje si lahko poskuša izpogajati daljše plačilne roke, vendar to običajno zahteva določen vložek časa ter lahko povzroči, da dobavitelji podjetju zaradi tega dajo slabše pogoje drugje (npr. nižji popust) (Bragg, 2012).

Dobavitelji pogosto podjetjem nudijo tudi možnost izkoristiti kasaskonto oz. popust na plačilo zaradi predčasnega poplčila obveznosti (Brigham & Daves, 2004). Podjetje mora v takšnem primeru izračunati, ali se mu splača obveznost plačati prezgodaj oz. ali je popust

dovolj visok, da pokrije stroške dodatnega financiranja zaradi predčasnega poplčila obveznosti (Brigham & Daves, 2004). Če uporabimo enačbo, ki jo je npr. mogoče najti v Van Horne in Wachowicz, Jr. (2008), ugotovimo, da je pri plačilnih pogojih »2/10 neto 60« (2 odstotni kasaskonto pri plačilu v desetih dneh, sicer zapadlost 60 dni), približni ekvivalent letne obrestne mere za izkoriščenje popusta 14,9 odstotkov. Pri plačilnih pogojih »2/5 neto 30« približni ekvivalent letne obrestne mere za izkoriščenje popusta naraste na 29,8 odstotkov. Če je podjetje zmožno zadolževanja po ugodnejši obrestni meri, je izkoriščenje popusta smiselno oz. neizkoriščenje popusta pomeni njihov oportunitetni strošek.

Pri plačevanju obveznosti se je tudi smiselno izogibati plačevanju samo na določen dan v tednu, saj to običajno povzroči, da se obveznosti plačujejo prezgodaj, oz. da so odlivi denarnih sredstev hitrejši, kot bi bilo to potrebno glede na plačilne pogoje (Bragg, 2012).

V primeru, da imajo podjetja več podružnic, je smiselno za poslovanje med njimi kot metodo plačila uporabljati kompenzacije, saj se tako zmanjša obseg in stroške prenosa denarnih sredstev (Bragg, 2010).

Za boljši nadzor odlivov denarnih sredstev iz podjetja Bragg (2012) predlaga tudi vpeljavo in kontrolo predračunov, s katerimi se nadzoruje porabo oddelkov v podjetju ter vpeljavo nabavnih naročil, ki jih je pred izvedbo naročila potrebno avtorizirati, kar pomeni, da se s tem omeji nepotrebne izdatke.

2.3 Nadzor nad zalogami

V zalogah so denarna sredstva običajno vezana razmeroma dolgo časa, zato je smiselno, da se njihov obseg poskuša čim bolj omejiti, hkrati pa je potrebno zagotoviti, da ima podjetje dovolj zalog za normalno poslovanje (Bragg, 2010).

Nadzor nad zalogami vključuje (Bragg, 2010):

- naročanje zalog preko nabavnih nalogov za boljšo kontrolo nad naročili;
- planiranje nabave (angl. *MRP* oz. *material requirement planning*) in planiranje prodaje (npr. z odpoklici);
- določitev obsega proizvodnje produktov, pri čemer se lahko podjetje posluži tehnik, kot so npr. proizvodnja ravno ob pravem času (angl. *just-in-time*);
- določitev obsega produktov in variant produktov, ki jih bo podjetje hranilo na zalogi;
- obdobjno pregledovanje kosovnic in iskanje substitutov za materiale;
- skladiščenje zalog, kjer je potrebno preučiti tudi alternativne možnosti kot so npr. neposredne dobave od dobavitelja h kupcu;
- ipd.

Izbrano podjetje, ki je uporabljeno kot primer v tej magistrski nalogi, zalog nima, zato v nadaljevanju niso več izpostavljene.

2.4 Kratkoročno investiranje presežkov in financiranje primanjkljajev

2.4.1 Kratkoročno investiranje presežkov

Če ima podjetje vzpostavljeno dobro planiranje denarnega toka, ima tudi jasno sliko o lokaciji, valuti in znesku razpoložljivih denarnih sredstev ter o tem, do kdaj bodo sredstva razpoložljiva (HSBC Global Asset Management, 2014). Na podlagi teh informacij se lahko odloči za najbolj optimalno investiranje presežnih sredstev (HSBC Global Asset Management, 2014).

Pri investiranju denarnih sredstev je potrebno upoštevati 3 cilje (HSBC Global Asset Management, 2014):

- varnost naložbe,
- likvidnost,
- donosnost.

Vsako investiranje zahteva sklepanje kompromisov med tremi cilji – višji donos pomeni, da bo moral investitor sprejeti večje tveganje naložbe ali pa sredstva investirati za daljše obdobje (HSBC Global Asset Management, 2014).

Z vidika ročnosti finančni trg delimo na denarni trg, na katerem se trguje s kratkoročnimi finančnimi oblikami (do enega leta) in kapitalski trg, na katerem se trguje z dolgoročnimi finančnimi oblikami, ki dospejo v obdobju, daljšem od enega leta ali pa sploh ne dospejo (delnice, obveznice) (Blatnik, 2010). Poznamo pa še trge izvedenih finančnih instrumentov, ki so izvedeni iz osnovnih instrumentov (Blatnik, 2010).

Kratkoročne presežke denarja je potrebno investirati v oblike, kjer sta varnost naložbe in likvidnost visoki (HSBC Global Asset Management, 2014). Primerne instrumente za investiranje takšnega denarja torej najdemo predvsem na denarnem trgu. Kapitalski trg in trg izvedenih instrumentov imata manj ugodne lastnosti, predvsem s stališča varnosti naložb.

Finančne instrumente denarnega trga lahko izdajajo države, banke, podjetja in druge institucije (Instrumenti denarnega trga, 2016). Med finančne instrumente denarnega trga sodijo kratkoročna posojila in kratkoročni vrednostni papirji (Blatnik, 2010). Kratkoročna posojila so pogodbeno dogovorjena in z njimi ne trgujemo, s kratkoročnimi vrednostnimi papirji pa trgujemo na sekundarnem trgu vrednostnih papirjev (Blatnik, 2010). Pri izbiri kratkoročnega finančnega instrumenta, ki ga bo podjetje uporabilo, je vedno potrebno

upoštevati interna in eksterna pravila in omejitve (zakonodaja, davki) (HSBC Global Asset Management, 2014).

Med najpogostejše vrste instrumentov denarnega trga štejemo (Instrumenti denarnega trga, 2016):

- zakladne menice:
 - izdaja jih država oz. Ministrstvo za finance,
 - imetniku prinašajo v naprej določen donos v obliki obresti,
 - ročnost je običajno 3, 6 ali 12 mesecev;
- potrdila o denarnem depozitu (potrdila o vlogi):
 - so potrdila, da so bila na kreditni instituciji (banki) položena sredstva za določeno obdobje po določeni obrestni meri;
- komercialne zapise:
 - izdajajo jih podjetja z boljšo boniteto in imajo v naprej določen donos,
 - ročnost je običajno od nekaj mesecev do enega leta;
- blagajniške zapise:
 - izdajajo jih centralne ali poslovne banke,
 - imajo določen rok dospelosti in obrestno mero in so podobni obveznicam,
 - ročnost je od 30 do 360 dni;
- bančne akcepte:
 - služijo za financiranje uvozno-izvoznih poslov,
 - z njimi se banka zaveže, da bo ob zapadlosti nosilcu instrumenta poplačala obveznost;
- sklade denarnega trga:
 - gre za vzajemne sklade, ki sredstva nalagajo v instrumente denarnega trga in druge sklade denarnega trga;
- ipd.

2.4.2 Financiranje primanjkljajev

Izbira pravega vira financiranja podjetja je eden od ključnih izzivov podjetja in zahteva poglobljeno analizo vseh razpoložljivih virov (Sources of Finance, 2016). Vire financiranja lahko delimo glede na časovno obdobje, lastništvo ali glede na vir generiranja sredstev (Sources of Finance, 2016).

Glede na časovno obdobje delimo vire financiranja na dolgoročne, srednjeročne in kratkoročne (Sources of Finance – Explain the Types of Business Finance?, 2016). Dolgoročni viri financiranja so viri z dobo financiranja nad pet let, ki so namenjeni pretežno za financiranje osnovnih sredstev podjetja, srednjeročni viri financiranja so viri z dobo financiranja do 5 let in so običajno namenjeni popravilom in modernizaciji opreme, razvoju

novih proizvodnih postopkov in marketingu, kratkoročni viri financiranja pa so viri z dobo financiranja do enega leta, ki so namenjeni predvsem vsakodnevnemu financiranju poslovanja (Sources of Finance – Explain the Types of Business Finance?, 2016).

Glede na lastništvo delimo vire financiranja na dolg in kapital, glede na vir generiranja sredstev pa delimo vire financiranja na notranje in zunanje (Sources of Finance, 2016).

Med notranje vire financiranja spadajo (Rebernik & Repovž, 2000):

- nerazdeljeni dobiček;
- amortizacija;
- prestrukturiranje premoženja;
- davčne olajšave;
- ipd.

Med zunanje vire financiranja pa spadajo (Rebernik & Repovž, 2000; Glas, 2001):

- javna prodaja podjetja, ki kotira na borzi (izdaja delnic);
- zaprta prodaja podjetja, ki ne kotira na borzi;
- obveznice;
- bančna posojila;
- druga posojila;
- skladi tveganega kapitala;
- poslovni angeli;
- subvencije;
- lizing;
- faktoring;
- forfeitiranje.

Odločitev za pravi vir financiranja je za podjetja bistvenega pomena, saj lahko napačna odločitev pomeni višje stroške ali ponovno iskanje virov financiranja zaradi neusklajenosti denarnega toka, ki ga lahko povzroči financiranje poslovanja z napačno ročnostjo (npr. financiranje dolgoročnih projektov s kratkoročnim kreditom) (Sources of Finance, 2016).

2.5 Združevanje denarnih sredstev (»Cash pooling«)

V primeru, da ima podjetje več podružnic ali večje število bančnih računov, se lahko namesto upravljanja vsake denarne pozicije posebej (po vsaki podružnici oz. bančnem računu) posluži združevanja denarnih sredstev (angl. *cash pooling*) in upravljanju samo skupne denarne pozicije (Treasury Alliance Group, 2012).

Združevanje denarnih sredstev se lahko izvaja na dva načina (Treasury Alliance Group, 2012):

- fizično združevanje denarnih sredstev pomeni avtomatizirane dnevne prenose denarnih sredstev (stanja) iz transakcijskih računov skupine podjetij na izbrani transakcijski račun. Presežek sredstev na določenem računu pokriva primanjkljaj sredstev na drugih transakcijskih računih, združevanje sredstev pa lahko poteka v različnih državah, vendar vedno v eni valuti.
- fiktivno združevanje denarnih sredstev pomeni navidezno združevanje bančnih računov in skupen izračun obresti, denarja pa se v resnici ne prenaša. Fiktivno združevanje lahko poteka v različnih državah in v različnih valutah, vendar je pogosto omejeno z zakonodajo in precej kompleksno zaradi več-ih valut.

Obstajajo tudi različne hibridne možnosti, ki jih ponujajo banke (Treasury Alliance Group, 2012).

Prednosti, ki jih podjetjem prinaša združevanje denarnih sredstev so (Unicredit Bank, 2016):

- lažji dostop do potrebnih informacij o likvidnosti celotne skupine podjetij;
- avtomatična koncentracija preseženih denarnih sredstev;
- učinkovito upravljanje sredstev (optimizacija obresti in internega financiranja);
- transparentnost;
- znižanje stroškov;
- prihranek časa zaradi avtomatizacije združevanja sredstev;
- razbremenitev zaposlenih v operativnih financah;
- povečanje konkurenčnosti skupine.

Vendar pa lahko združevanje denarnih sredstev podjetjem povzroči tudi določene stroške (stroški implementacije združevanja, stroški vzdrževanja skupnega računa in tehnoloških rešitev, transakcijski stroški, oportunitetni stroški zaradi nezmožnosti aktivnega upravljanja denarnih sredstev), zaradi česar morajo ta preveriti, ali se jim takšno združevanje res splača, ali pa je bolje uporabiti katerega od alternativnih pristopov (Treasury Alliance Group, 2012). Rebel (2007) kot alternativne možnosti združevanju denarnih sredstev ponuja možnost uporabe avtomatičnih prenosov sredstev v primeru, da na določenem transakcijskem računu stanje denarnih sredstev ni več znotraj v naprej definiranih limitov; možnost poenostavitve strukture transakcijskih računov, ki povzroči bolj stabilen in predvidljiv denarni tok na posamičnem od teh računov; in pa zmanjšanje volatilnosti denarnega toka na transakcijskih računih preko uporabe kompenzacij v skupini, plačevanja v imenu drugega v skupini in preko proaktivnega upravljanja z obveznostmi.

3 PREGLED METOD ZA NAPOVEDOVANJE DENARNEGA TOKA

Modele za upravljanje z denarnimi sredstvi lahko ločujemo v 4 različne kategorije (Gitman, Moses, & White, 1979):

- modeli za izračun optimalnega stanja denarnih sredstev;
- modeli za načrtovanje denarnega toka;
- modeli za načrtovanje prilivov iz naslova terjatev;
- modeli za načrtovanje odlivov iz naslova obveznosti.

3.1 Prvi modeli za izračun optimalnega stanja denarnih sredstev

Medtem, ko je danes cilj podjetij minimizirati količino denarnih sredstev na računih na takšno, ki hkrati še omogoča normalno poslovanje podjetja, so podjetja včasih na računih morala imeti veliko večjo količino denarja zaradi težav pri prenosih in težav pri načrtovanju denarnega toka (Brigham & Daves, 2004). Razvoj informacijske tehnologije je omogočil večjo preglednost stanja denarnih sredstev na računih, lažje prenose sredstev in lažje načrtovanje denarnega toka (Brigham & Daves, 2004). Prvi matematični modeli, ki so se pričeli pojavljati v drugi polovici dvajsetega stoletja, so se zato veliko ukvarjali z optimiziranjem stanja denarnih sredstev, ki jih mora podjetje imeti za normalno poslovanje oz. z minimiziranjem stroškov držanja denarnih sredstev (Gitman, Moses, & White, 1979). Najbolj znani modeli tega tipa so Baumol-ov model, Beranek-ov model, Miller-Orr-ov model in Stone-ov model (Michalski, 2009).

Baumol-ov model je uporaben, kadar podjetje ve kakšni bodo prilivi in odlivi in pričakuje, da bodo odlivi denarja presegali prilive (Michalski, 2009). Beranek-ov model je uporaben, kadar podjetje ve, kakšni bodo prilivi in odlivi in pričakuje, da bodo prilivi denarja presegali odlive (Michalski, 2009). Kadar je denarni tok mogoče napovedati samo za kratkoročno obdobje (približno 14 dni), podjetje lahko uporabi Stone-ov model, kadar pa denarnega toka sploh ni mogoče napovedati, lahko uporabi Miller-Orr-ov model (Michalski, 2009).

3.1.1 Baumol-ov in Beranek-ov model

Prvi znan model za določitev optimalnega stanja denarnih sredstev za normalno poslovanje podjetja je razvil William J. Baumol leta 1952 (Brigham & Daves, 2004). Model temelji na modelu za optimizacijo naročanja zalog (angl. *economic ordering quantity model* oz. *EOQ model*) (Brigham & Daves, 2004).

Predpostavke modela so, da podjetje potrebuje denarna sredstva v konstantnem obsegu (enak znesek vsak teden) in da so prilivi podjetja konstantni (enak znesek vsak teden), posledično pa je enaka tudi potreba podjetja po denarnih sredstvih (Brigham & Daves, 2004).

Model poskuša minimizirati stroške držanja denarnih sredstev na bančnem računu in transakcijske stroške (Baumol, 1952). Stroški držanja denarnih sredstev na bančnem računu so oportunitetni stroški zaradi neinvestiranja sredstev, transakcijski stroški pa so stroški pridobitve novih denarnih sredstev (s prodajo vrednostnih papirjev) in so fiksni za transakcijo (Baumol, 1952).

Optimalno stanje denarnih sredstev je po Baumolu (1952) mogoče izračunati z uporabo naslednjih enačb:


$$\text{Stroški} = \frac{b \times T}{C} + \frac{i \times C}{2} \quad (7)$$

$$C^* = \sqrt{\frac{2 \times b \times T}{i}} \quad (8)$$

pri čemer velja:

- b je konstantni transakcijski strošek za izposojno konstantnega obsega denarja;
- T je celotni znesek denarnih sredstev, ki ga podjetje potrebuje v obdobju;
- C je obseg denarja, ki si ga podjetje izposodi naenkrat;
- i je oportunitetni strošek denarja;
- C^* je optimalni obseg denarja, ki bi si ga podjetje moralo izposoditi.

Slika 2: Stanje denarnih sredstev pri Baumol-ovem modelu



Vir: E.F. Brigham & P.R. Daves, *Intermediate Financial Management*, 2004, str. 779, slika 22-1.

Prvi del enačbe stroškov ($b \times T / C$) predstavlja transakcijske stroške v obdobju, drugi del enačbe ($i \times C / 2$) pa stroške držanja denarja na računu (Baumol, 1952). Optimalen obseg

denarja za izposojno je višji, kadar so višji transakcijski stroški izposoje in celotni znesek denarnih sredstev, ki jih podjetje potrebuje in nižji, kadar je višja obrestna mera oz. oportunitetni strošek denarja (Baumol, 1952).

Glavni problemi modela so predpostavke o stabilnem denarnem toku ter neupoštevanje sezonskih in cikličnih trendov (Brigham & Daves, 2004).

Slika 2 prikazuje stanje denarnih sredstev na računu podjetja skozi čas po Baumol-ovem modelu.

Beranek je izpeljal model, ki je pravzaprav samo obrnjeni Baumol-ov model. Predpostavke modela so enake kot pri Baumol-ovem modelu, le da so prilivi podjetja večji kot odlivi in da mora podjetje, ko doseže zgornjo mejo, sredstva investirati (Michalski, 2009).

3.1.2 Miller-Orr-ov model

Miller-Orr-ov model nadgrajuje Baumol-ov model, tako da sprosti predpostavko Baumol-ovega modela o konstantnih prilivih in odlivih denarja (Miller & Orr, 1966). Predpostavke modela so (Miller & Orr, 1966):

- da podjetje vzdržuje dva tipa sredstev, denarna sredstva in vrednostne papirje s konstantnim donosom, med katerimi so prenosi mogoči kadarkoli v zelo kratkem času s konstantnimi stroški, neodvisnimi od velikosti prenosa;
- da obstaja minimalni znesek, pod katerega denarna sredstva ne smejo pasti (v modelu je predpostavljen znesek 0);
- da je gibanje denarnega toka stohastično;
- in da želi podjetje minimizirati povprečne stroške upravljanja z denarnimi sredstvi na dolgi rok.

Model definira zgornjo mejo denarnih sredstev ter optimalno stanje denarnih sredstev podjetja. Če denarna sredstva dosežejo zgornjo mejo, podjetje kupi vrednostne papirje ter se s tem premakne v normalno območje stanja denarnih sredstev. Če denarna sredstva dosežejo spodnjo mejo, podjetje proda vrednostne papirje.

Zgornjo mejo ter optimalno stanje denarnih sredstev Miller in Orr (1966) opredelita z naslednjimi enačbami:


$$Z^* = \left(\frac{3\gamma\sigma^2}{4v} \right)^{\frac{1}{3}} \quad (9)$$

$$h^* = 3Z \quad (10)$$

$$\bar{M}^* = \frac{4}{3}z \quad (11)$$

pri čemer velja:

- Z^* je optimalno stanje denarnih sredstev;
- γ so transakcijski stroški;
- σ^2 je varianca preteklih denarnih tokov;
- v so oportunitetni stroški;
- h^* je optimalna zgornja meja;
- $\bar{M}^*$ je optimalno povprečno stanje denarnih sredstev.



Vir: M.H. Miller & D. Orr, *A Model of the Demand for Money by Firms*, 1966, str. 420, slika II.

Slika 3 prikazuje gibanje denarnih sredstev po Miller-Orr modelu. V točki h podjetje kupi vrednostne papirje, pri točki 0 pa jih proda, tako da doseže optimalno točko z (Miller & Orr, 1966).


3.1.3 Stone-ov model

Stone-ov model temelji na Miller-Orr-ovem modelu, le da predpostavlja, da podjetje lahko planira denarni tok za nekaj dni v naprej (Michalski, 2009). Enako kot Miller in Orr postavi spodnjo in zgornjo mejo za denarna sredstva, vendar pa ločuje zunanjo in interno mejo (Stone, 1972). Preseganje meje pa pri Stonu ne pomeni takojšnjega popravka s pomočjo prodaje ali nakupa vrednostnih papirjev, saj pravi, da to običajno ni optimalna rešitev, ampak se popravek na optimalno stanje denarnih sredstev naredi samo v primeru, da je denarni tok presegel zunanjo mejo ter je po določenem obdobju še vedno izven interne meje.

Predpostavke modela so (Stone, 1972):

- podjetje ima dva tipa sredstev – denar in vrednostne papirje;
- obstaja več ročnosti vrednostnih papirjev z različnimi obrestnimi merami;
- zapadli vrednostni papirji niso investirani avtomatično, pač pa so del denarnega toka podjetja;
- obstaja načrt denarnega toka za N dni, ki se posodobi, kadarkoli podjetje dobi nove informacije ali kadar kupi ali proda vrednostne papirje;
- podjetje teži k vzdrževanju določenega nivoja denarnih sredstev, ki zagotavlja izpolnitev povprečnih zahtev po denarju v skladu s planiranimi krediti in bančnimi potrebami.

Slika 4: Stanje denarnih sredstev pri Stone modelu



Vir: B.K. Stone, *The use of Forecasts and Smoothing in Control-Limited Models for Cash Management*, 1972, str. 79, slika 4.

Slika 4 prikazuje stanje denarnih sredstev po Stone-ovem modelu. Transakcija nakupa vrednostnih papirjev se zgodi samo, ko denar preseže zunanjo zgornjo mejo in podjetje ve, da bo stanje denarnega toka v naslednjih dneh naraščalo (Stone, 1972).

3.1.4 Drugi modeli

Avtorjev, ki so se prav tako ukvarjali z modeli za optimiziranjem denarnih sredstev, je bilo veliko, večinoma pa so njihove izpeljave temeljile na predpostavki stohastičnosti denarnih tokov zaradi nezmožnosti dobrega planiranja prejemkov iz izdatkov (da Costa Moraes, Nagano, & Sobreiro, 2015). Veliko teh avtorjev je svoje modele zgradilo z dopolnitvami že obstoječih modelov, npr. z dodatnim upoštevanjem minimalnega zneska denarnih sredstev, ki ga mora podjetje imeti na računih (Michalski, 2009). Da Costa Moraes, Nagano in Sobreiro (2015) v svojem delu navajajo večino avtorjev s pomembnejšimi prispevki na tem področju od 80-ih let prejšnjega stoletja do danes.

3.2 Napovedovanje denarnega toka

Podjetja morajo za doseganje optimalnega stanja denarnih sredstev, poznati ne samo trenutno stanje sredstev in obveznosti, pač pa tudi bodoče prilive in odlive, ki jih je mogoče predvideti z upoštevanjem različnih napovedi (Michalski, 2009).

3.2.1 Metoda prejemkov in izdatkov

Metoda prejemkov in izdatkov oz. neposredna metoda napovedovanja denarnega toka (angl. *scheduling*) je metoda sestavljanja denarnega toka iz podatkov o poslovanju podjetja (Stone & Wood, 1977). Izdatke je mogoče napovedati na podlagi prejetih računov, naročil, načrta proizvodnje, stroškov plač, ipd., prejemke pa na podlagi terjatev (Bragg, 2012). Napovedovanje denarnega toka z uporabo podrobnih podatkov iz poslovanja oz. metode prejemkov in izdatkov prikazuje Tabela 1.

Tabela 1: Metoda prejemkov in izdatkov

Predznak	Postavka	Opis
+	Začetno stanje	Stanje na bančnih računih na začetni dan napovedi ali končno planirano stanje v predhodni napovedi denarnih tokov.
+	Terjatve (odprte postavke) kupcev	Običajno se večje odprte terjatve napoveduje ločeno, manjše pa agregirano.
+	Ostali prejemki	Navede se npr. pričakovane avanse kupcev.
-	Plače	Običajno se strošek plač oceni na podlagi preteklega meseca, pri čemer je potrebno upoštevati morebitne spremembe (npr. izplačilo regresa).
-	Prispevki in davki iz naslova plač	Navede se stroške dohodnine ter prispevkov (pokojninsko in invalidsko zavarovanje, starševsko varstvo, zdravstveno zavarovanje).
-	Plačila podizvajalcem	V kolikor podjetje posluje s podizvajalci, lahko ta plačila predstavljajo velik del vseh izplačil, in se jih zato navede ločeno.
-	Obveznosti (odprte postavke) do dobaviteljev	Običajno se večje odprte obveznosti, ki zapadejo v obdobju napovedi, navede ločeno, ostale pa agregirano. Datume plačil se lahko prilagodi glede na napovedano stanje denarnih sredstev.
-	Ponavljajoča plačila	Navede se večja obdobjna plačila – npr. najemnino.
-	Odlivi iz naslova posojil	Navede se npr. večja plačila obresti.
-	Dividende	Navede se morebitna izplačila dividend.
-	Potni stroški	Navede se pričakovane potne stroške v obdobju.

(se nadaljuje)

(nadaljevanje)

=	Neto pozicija	Neto pozicija predstavlja seštevek začetnega stanja ter prilivov in odlivov v obdobju (seštevek vseh zgornjih postavk).
+/-	Financiranje	Navede se morebitna povečanja in zmanjšanja posojil.
=	Končno stanje	Končno stanje je seštevek neto pozicije in aktivnosti financiranja.
-	Varnostna zaloga	Navede se varnostno zalogo oz. željeno stanje.
=	Razpoložljivo stanje	Razpoložljivo stanje je razlika med končnim stanjem in varnostno zalogo oz. razpoložljivi znesek za investiranje.

Vir: Povzeto po S. M. Bragg, *Corporate Cash Management: A Treasurer's Guide*, 2012, str. 17-19.

Struktura prejemkov in izdatkov je lahko predstavljena na različne načine, vsebinsko pa vedno vključuje vse predvidene prejeme in izdatke v podjetju, začetno stanje denarnih sredstev in včasih še varnostno zalogo denarnih sredstev, ki jo želi imeti podjetje.

Metoda je primerna za kratkoročno načrtovanje denarnega toka, še posebej za napovedovanje odlivov, manj pa za napovedovanje prilivov (Stone & Wood, 1977). Običajno jo podjetja kombinirajo z uporabo statističnih metod (Association for Financial Professionals, 2012). Pregled napovedi denarnega toka mora biti ob uporabi te metode dovolj razdrobljen, da zagotavlja natančnost, ne pa tako razdrobljen, da bi zahteval ogromno dela za posodabljanje, ki mora biti dokaj pogosto (Bragg, 2012). Če se metodo uporablja za napovedovanje denarnega toka v daljšem časovnem obdobju, izgubi na natančnosti, saj so zneski in datumi plačil bolj negotovi (Association for Financial Professionals, 2012).

3.2.2 Enostavno drseče povprečje

Metoda enostavnega drsečega povprečja je statistična metoda, ki temelji na izračunu povprečnih vrednosti denarnih tokov v obdobju za napoved bodočih denarnih tokov (De Caux, 2005). Na rezultat lahko močno vpliva količina podatkov, ki so upoštevani v izračunu – večja količina podatkov pomeni manjšo varianco v rezultatih, lahko pa prikrije spremembe v denarnem toku (Association for Financial Professionals, 2012). Metoda je lahka za uporabo, vendar pa napoved denarnega toka, ki je narejena na podlagi te metode, vedno kaže trende iz preteklosti, ne pa trenutnih trendov, zato je najbolj primerna za podjetja s stabilnim vzorcem prodaje (De Caux, 2005).

Tabela 2 prikazuje primer izračuna načrta denarnega toka za dan z uporabo enostavnega drsečega povprečja na podlagi prejšnjih treh dni.

Tabela 2: Primer izračuna enostavnega drsečega povprečja (v EUR)

Dan	Dejanski denarni tok	Dnevno drseče povprečje	Napaka
Torek, 1. teden	1.050		
Sreda, 1. teden	1.170		
Četrtek, 1. teden	1.270		
Petek, 1. teden	1.365	1.163	202
Ponedeljek, 2. teden	965	1.268	(303)
Torek, 2. teden	1.480	1.200	280

Vir: Association for Financial Professionals, 2012, str. 10.

3.2.3 Eksponentno glajenje

Eksponentno glajenje je statistična metoda, ki uporabi podatke, izračunane s pomočjo enostavnega drsečega povprečja, in jih uteži s pomočjo napake iz prejšnjega obdobja napovedi (Association for Financial Professionals, 2012). Enačba je opredeljena kot (De Caux, 2005):

$$F_{t+1} = F_t + a(x_t - F_t) \quad (12)$$

pri čemer velja:

- F_{t+1} je napoved denarnega toka za obdobje $t+1$;
- F_t je napoved denarnega toka za obdobje t ;
- a je utež;
- x_t je dejanski denarni tok v obdobju t .

Kadar se uporabi utež z vrednostjo 1, pomeni, da je napoved za obdobje $t+1$ enaka, kot je bil dejanski denarni tok v obdobju t (De Caux, 2005).

Tabela 3 prikazuje primerjavo med metodo enostavnega drsečega povprečja in eksponentnim glajenjem. Uporabljena je utež -0,5.

Stone in Miller (1987) sta opozorila, da tako enostavno drseče povprečje kot eksponentno glajenje običajno ne prinašata dobrih rezultatov, saj pogosto obstaja problem sezonske prodaje ter učinka dneva v mesecu in dneva v tednu na dejanski denarni tok. Namesto uporabe teh metod, sta za načrtovanje denarnega toka predlagala uporabo metode porazdelitve (Stone & Miller, 1987).

Tabela 3: Primer izračuna eksponentnega glajenja (v EUR)

Dan	Dejanski denarni tok	Dnevno drseče povprečje	Napaka	Eksponentno glajenje	Napaka pri eksponentnem glajenju
Torek, 1. teden	1.050				
Sreda, 1. teden	1.170				
Četrtek, 1. teden	1.270				
Petek, 1. teden	1.365	1.163,33	201,67		
Ponedeljek, 2. teden	965	1.268,33	(302,67)	1.062,5	(97,5)
Torek, 2. teden	1.480	1.200	280	1.419,67	60,33

Vir: povzeto po Association for Financial Professionals, 2012, str. 10.

3.2.4 Regresijska analiza

Regresijska analiza spada med statistične metode (De Caux, 2005). Poznamo različne tipe regresijske analize (Wang & Jain, 2003):

- enostavno regresijsko analizo in multiplo regresijsko analizo;
- linearno in nelinearno regresijsko analizo;
- regresijsko analizo na časovnih vrstah in presečno regresijsko analizo;
- probit in logit modele.

Enostavna regresijska analiza pomeni, da je v modelu samo ena neodvisna spremenljivka, s katero pojasnujemo obnašanje neodvisne spremenljivke. Če je v modelu več neodvisnih spremenljivk, gre za multiplo regresijo (Dougherty, 2007).

Model linearne regresijske analize predpostavlja, da je odvisna spremenljivka linearna funkcija neodvisne spremenljivke, medtem ko model nelinearne regresijske analize predpostavlja nelinearno funkcijo (Wang & Jain, 2003).

Kadar je model izražen s pomočjo zgodovinskih podatkov, gre za regresijsko analizo na časovnih vrstah, kadar pa je model izražen s pomočjo podatkov na nek presečni datum, govorimo o presečni regresijski analizi (Wang & Jain, 2003). Poseben primer regresijske analize je tudi panelna regresijska analiza, kjer se za pojasnitev odvisne spremenljivke uporabi tako časovno vrsto kot tudi podatke na presečni datum (Wang & Jain, 2003).

Probit in logit modeli se uporabljajo, kadar je cilj ugotoviti verjetnost nekega dogodka (npr. bankrota podjetja) oz. je odvisna spremenljivka kvalitativna (Wang & Jain, 2003; Dougherty, 2007). Kadar se uporabi funkcijo, ki predpostavlja normalno porazdelitev, govorimo o probit modelu, kadar pa se uporabi funkcijo, ki predpostavlja logaritemsko porazdelitev, govorimo o logit modelu (Dougherty, 2007).

Linearna regresija je ena najpogostejših metod, ki jo uporabljajo različne rešitve za napovedovanje denarnega toka in se običajno uporablja za napoved prilivov (Association for Financial Professionals, 2012). Če rezultat kombiniramo z odlivi, dobljenimi z metodo prejemkov in izdatkov, dobimo napoved neto denarnih tokov (Association for Financial Professionals, 2012).

Regresija je uporabljena tudi pri metodi porazdelitve, ki je opisana v nadaljevanju. Regresija se uporablja tudi v novejših, računalniško podprtih metodah, kot so npr. odločitvena drevesa ali nevronske mreže. Te metode so opisane v poglavju 5.2, kjer so predstavljene metode strojnega učenja.

3.2.5 Metoda porazdelitve

Metoda porazdelitve (angl. *distribution*) se pogosto uporablja za napovedovanje prilivov (lahko tudi odlivov) iz večjega števila manjših terjatev, za katere je prilive težko napovedati z dovolj visoko gotovostjo in ki posamično tudi nimajo velikega vpliva na neto denarni tok podjetja, lahko pa napovemo njihov skupni znesek (Horcher, 2006).

Metoda porazdelitve spada med statistične modele in pomeni uporabo preteklih podatkov o denarnem toku podjetja za napoved in razporejanje napovedanih denarnih tokov v prihodnosti (Stone & Wood, 1977; Miller & Stone, 1985). Pretekle podatke uporabimo za to, da za določeno kategorijo denarnih tokov najprej zgradimo porazdelitev v nekem časovnem obdobju (običajno mesecu), nato pa to porazdelitev uporabimo da predvideni skupni znesek teh tokov v bodočem obdobju porazdelimo po tednih ali dnevih (Stone & Wood, 1977). Temelji na regresiji z umetnimi spremenljivkami (angl. *dummy-variable regression*) (Stone & Wood, 1977). Metoda obsega pripravo podatkov, določitev parametrov, oceno vrednosti na mesečnem nivoju, distribucijo tokov in združitve napovedi z večjimi pričakovanimi denarnimi tokovi (Stone & Wood, 1977).

Priprava podatkov pomeni, da se na podlagi bančnega izpiska najprej izloči vse glavne denarne tokove, nato se vse manjše tokove razdeli v kategorije. Za posamično kategorijo se nato izračuna neto dnevni priliv oz. odliv in izrazi kot delež mesečnega zneska (Stone & Wood, 1977).

Parametra, ki jih Stone in Wood (1977) upoštevata v regresiji z umetnimi spremenljivkami sta vpliv dneva v mesecu in vpliv dneva v tednu na denarni tok. Medtem ko sta Stone in

Wood sprva predvidela model, kjer sta se ta vpliva seštevata v skupen vpliv (linearna regresija), sta Stone in Miller (1987; 1985) kasneje predlagala multiplikativen model, kjer vpliva dneva v mesecu in dneva v tednu nista neodvisna, pač pa je možen mesečni cikel s tedensko motnjo, tedenski cikel z mesečno motnjo ali pa kombinacija obojega. Problem nelinearnosti enačb sta reševala z uporabo logaritemske funkcije, ki jima je omogočila izvedbo regresije z umetnimi spremenljivkami (Stone & Miller, 1987). Poleg tega sta v splošni izpeljavi multiplikativnega modela poskušala odpraviti tudi druge probleme, in sicer problem kolinearnosti, motnjo zaradi praznikov, motnjo zaradi sprememb v dolžini meseca in variiranje kombinacije dneva v tednu in dneva v mesecu (Miller & Stone, 1985).

Ocena vrednosti na mesečnem nivoju obsega razdelitev obstoječega plana na večje denarne tokove ter manjše denarne tokove (Stone & Wood, 1977). Večji predvideni denarni tokovi se izločijo iz izračuna (Stone & Wood, 1977).

Distribucija tokov obsega uporabo regresijskih koeficientov za razporeditev seštevka manjših denarnih tokov znotraj delovnih dni v obdobju (mesecu) (Stone & Wood, 1977).

Združitev napovedi z večjimi pričakovanimi denarnimi tokovi pa pomeni, da se k distribuiranim denarnim tokovom prišteje še večje planirane odlive in prilive, ki so bili izvezeti iz modeliranja, s čimer dobimo napoved neto denarnih tokov po dnevih (Stone & Wood, 1977).

De Caux (2005) vidi uporabo metode porazdelitve predvsem v planiranju odlivov pri plačilih s čeki, kjer do odlivov ne pride takoj, kar pa v Sloveniji ne pride v poštev, saj poslovanja s čeki ni.

Problem napovedi z metodo porazdelitve je predvsem v tem, da je uporaba preteklih podatkov za napovedovanje denarnega toka v primeru večjih sprememb v podjetju manj uporabna (Horcher, 2006).

3.3 Napovedovanje denarnega toka iz naslova terjatev

3.3.1 Tradicionalni kazalniki za napovedovanje denarnega toka iz naslova terjatev in upravljanje s terjatvami

Najenostavnejša napoved denarnega toka iz terjatev je pričakovati prilive na dan zapadlosti terjatev. Takoj za tem pa je napovedovanje z uporabo nekaj že dolgo znanih kazalnikov, ki merijo učinkovitost pretvorbe terjatev v denar s katero se popravi predpostavka o ničelni zamudi pri plačilu.

Med tradicionalne kazalnike za napovedovanje in upravljanje z denarnim tokom iz naslova terjatev, spadajo (Stone, 1976):

- dnevi vezave terjatev, ki so podrobneje opisani v poglavju 2;
- starostna struktura terjatev kot delež terjatev v različnih starostnih razredih (običajno mesecih);
- povprečna starost terjatev (uteženo povprečje mediane dni v vsakem starostnem razredu).

Problem večine tradicionalnih kazalnikov je, da je njihov rezultat odvisen od velikosti prodaje podjetja v obdobju in zato ne kažejo pravilno sprememb v vzorcu plačevanja, kar pomeni, da je težko primerjati vrednosti kazalnikov v različnih obdobjih, kadar gre za podjetje s sezonsko pogojeno prodajo (Stone, 1976). Podjetja s sezonsko pogojeno prodajo so zato poizkušala vrednosti kazalnikov primerjati z vrednostmi izpred enega leta, ali s planiranimi vrednostmi, ali pa namesto letne prodaje za izračune uporabila npr. kvartalno prodajo (Stone, 1976). Stone (1976) je predlagal, da se namesto teh kazalnikov uporabi pristop, ki upošteva vzorce plačevanja kupcev (angl. *payment-pattern approach*), in sicer povprečje ali regresijo na časovnih vrstah.

Carpenter in Miller (1979) sta predlagala, da se namesto kazalnika dnevi vezave terjatev uporabi kazalnik uteženi dnevi vezave terjatev, kjer se dni izračuna na podlagi utežitve dni z odstotkom odprtih terjatev iz posameznih preteklih mesecev. To naj bi podjetjem omogočilo, da izločijo vplive neenakomernega obsega prodaje in identificirajo trende v izterjavi ter posledično sprejmejo ustrezne ukrepe (npr. spremenijo plačilne pogoje ali zagotovijo dodatno financiranje). Njuno delo sta kasneje nadgradila Gentry in De La Garza (1985), ki sta poleg učinka prodaje in učinka izterjave prepoznala še skupni učinek, ki je odvisen tako od sprememb v obsegu prodaje, kot tudi od sprememb v izterjavi.

Gallinger in Ifflander (1986) pa sta namesto uporabe kazalnika dnevi vezave terjatev predlagala, da podjetja uporabijo njun model analize odmikov, kjer sta odmik definirala kot razliko med dejanskimi in planiranimi zneski. Uporaba planskih podatkov naj bi, ob skrbnem planiranju, omogočala, da se poleg zgodovine uporabi tudi predpostavke o obnašanju prodaje v preučevanem obdobju (Gallinger & Ifflander, 1986). Razčlenitev odmikov na posamezne faktorje (odmik zaradi izterjave, odmik zaradi vzorcev prodaje, odmik zaradi obsega prodaje) pa omogoča boljše spremljanje pretvorbe prodaje v denar (Gallinger & Ifflander, 1986).

3.3.2 Regresija na časovnih vrstah

Uporabo regresije na časovnih vrstah sta predlagala Stone (1976) in Shim (1981) namesto uporabe nekaterih, bolj tradicionalnih kazalnikov, ki so se uporabljali za napovedovanje terjatev oz. denarnega toka iz naslova terjatev.

Pri regresiji na časovnih vrstah se pri napovedi terjatev oz. denarnega toka upošteva prodajo iz preteklih mesecev ter se na podlagi izračunanih koeficientov izterjanih sredstev za

posamezno obdobje določi pričakovani denarni tok (Shim, 1981). Za določitev slabih terjatev pa se lahko uporabi npr. metodo markovskih matrik (Shim, 1981).

3.3.3 Markovske matrike

Markovska veriga je tranzicija iz enega v drugo stanje, ki je odvisna samo od stanja, v katerem se zapis trenutno nahaja, ne pa tudi od zgodovinskih stanj takšnega zapisa (Greenwell, Ritchey, & Lial, 2003). Markovska oz. tranzicijska matrika se uporablja za vizualno reprezentacijo tranzicij markovske verige (možne so tudi druge reprezentacije, kot npr. tranzicijski diagram ali odločitveno drevo) (Greenwell, Ritchey, & Lial, 2003). Tranzicijska matrika je kvadratna, z vrednostmi med 0 in 1, seštevek vrednosti v vrsticah pa mora biti 1 (Greenwell, Ritchey, & Lial, 2003).

Za obravnavo terjatev so primerna stanja nezapadlo, zapadlo do 30 dni, zapadlo do 60 dni, zapadlo do 90 dni, zapadlo nad 90 dni in pa plačano. Možni prehodi terjatev po poteku enega meseca so ali prehod v višje stanje zapadlosti ali pa med plačane terjatve. Verjetnosti za prehode med stanji (izračunane na podlagi zgodovinskih podatkov) lahko zapišemo v obliko matrike. Če s tako matriko delujemo nad vektorjem zneskov terjatev v posameznem stanju, dobimo vektor pričakovanih novih zneskov. Za planiranje denarnega toka so seveda najpomembnejše verjetnosti za prehod v stanje plačano.

Markovske matrike za napovedovanje verjetnosti neplačila odprtih terjatev so leta 1962 prvič uporabili Cyert, Davidson in Thompson (Kallberg & Saunders, 1983). Njihova matrika je omogočala izračun verjetnosti, da zneski v določenem statusu končajo kot slaba terjatev (Cyert, Davidson, & Thompson, 1962). Prednost matrike pred klasičnimi kazalniki je bila v njeni relativni neodvisnosti od gibanja prodaje, glavna slabost pa v odsotnosti časovne komponente, s tem pa ni omogočila nadzora nad gibanjem terjatev in napovedovanja denarnih tokov (Corcoran, 1978; Kallberg & Saunders, 1983). Kasneje so metodo nadgrajevali v smeri boljšega spremljanja vzorcev plačevanja, gl. Corcoran (1981), Kulen, Spronk in Corcoran (1981) in Kallberg in Saunders (1983).

V zadnjem času sta se napovedovanja denarnega toka z razvojem novega modela, ki temelji na markovskih matrikah lotila tudi Tangsucheeva in Prabhu (2014). Na podlagi verjetnosti iz markovske verige in verjetnosti plačila na podlagi obnašanja posameznih kupcev sta generirala markovsko matriko in jo prilagodila z eksponentnim glajenjem ter jo nato uporabita za napovedovanje denarnega toka. (Tangsucheeva & Prabhu, 2014) Model je mogoče implementirati v Excelu, gradi pa na delih Corcoran-a ter Pate-Cornell-a, Tagaras-a in Eisenhardt-a (Tangsucheeva & Prabhu, 2014).

3.3.4 Moderni pristopi pri napovedovanju denarnega toka

Večina podjetij za napovedovanje denarnega toka še vedno uporablja preglednice, npr. v Excelu, saj so lahke za uporabo, enostavno dostopne in jih je možno prilagajati glede na potrebe podjetja (Association for Financial Professionals, 2012). Problem preglednic je velika možnost napak ter oteženo spremljanje spreminjanja podatkov (Fuchs, 2011). Nekatera podjetja za napovedovanje denarnega toka uporabljajo poslovno informacijske sisteme, druga pa specializirane rešitve (Association for Financial Professionals, 2012). Takšna podjetja so v manjšini zaradi različnih razlogov – poslovno informacijski sistemi npr. niso v uporabi v vseh podružnicah podjetja, ali pa je modul za napovedovanje denarnega toka preveč kompliciran za uporabo (Fuchs, 2011).

Ena od najpogostejših metod, ki se uporablja za napovedovanje prilivov podjetja je linearna regresija, ki se za celovito napoved denarnega toka običajno kombinira še z drugimi pristopi, kot so metoda prejemkov in izdatkov (Association for Financial Professionals, 2012).

Specializirane rešitve za napovedovanje denarnega toka uporabljajo tudi druge metode. Eno od takšnih rešitev je izdelalo podjetje Eka, ki prilive napoveduje na podlagi analize vzorcev plačevanja s strojnim učenjem, specifično z odločitvenim drevesom oz. algoritmom PART (Mungurwadi, 2015). Rezultat napovedi so pričakovana plačila po starostnih razredih (npr. plačano do roka, v 15 dneh po zapadlosti, med 15 in 45 dni po zapadlosti, itd.) (Mungurwadi, 2015).

Napovedi s strojnim učenjem se je lotilo tudi podjetje IBM, ki je izvedlo napovedovanje denarnega toka iz naslova terjatev s petimi različnimi metodami (Zeng et al., 2008):

- algoritmom PART (odločitveno drevo);
- algoritmom C4.5 (odločitveno drevo);
- *boosting* enonivojskimi odločitvenimi drevesi (angl. *boosting decision stumps*);
- logistično regresijo;
- naivnim bayesovim klasifikatorjem.

Pri tem so upoštevali podatke o kupcih ter podatke o zgodovini plačevanja posameznega kupca (Zeng et al., 2008). Predvidene zneske (odstotke) plačil so razporedili v starostne razrede (Zeng et al., 2008). Najboljše rezultate so dobili z uporabo odločitvenih dreves z algoritmom C4.5 (Zeng et al., 2008).

3.4 Napovedovanje denarnega toka iz naslova obveznosti

Modeli, ki se ukvarjajo z napovedovanjem denarnega toka iz naslova obveznosti, se ukvarjajo predvsem s tem, kdaj bodo unovčena plačila, ki jih podjetje izvede s čeki, ter

poskušajo maksimirati čas med izdajo čeka ter dejanskim unovčenjem – takšna sta npr. modela, ki so ju izpeljali Maier, Robinson in Vander Weide (1981) ter Gitman, Forrester in Forrester (1976). Takšni modeli za podjetja, ki poslujejo v Sloveniji, ne pridejo v poštev, saj poslovanja s čeki ni.

4 MICROSOFT DYNAMICS AX 2012 R2

Program Microsoft Dynamics AX (prej Axapta) se uporablja že več kot 25 let in izvira iz Danske, kjer ga je podjetje Microsoft Corporation leta 2002 odkupilo od podjetja Navision A/S (Microsoft, 2012). Razvoj AX je danes organiziran v treh večjih ekipah – v Fargu in Redmondu v ZDA in v Kopenhagenu na Danskem (Microsoft, 2012).

Microsoft Dynamics AX 2012 (v nadaljevanju AX) predstavlja novo generacijo poslovno informacijskih sistemov (angl. *enterprise resource planning* oz. *ERP*), ki ponuja globalne rešitve za podjetja v mnogih panogah (proizvodnja, distribucija, storitve, maloprodaja, javni sektor) (The Microsoft Dynamics AX Team, 2012). Gre za sistem, ki je dovolj enostaven, da nudi informacijsko podporo podjetju z eno poslovno enoto v eni državi in dovolj robusten, da lahko hkrati podpira informacijske zahteve 36-ih držav, za katere Microsoft pripravlja lokalizacijo (The Microsoft Dynamics AX Team, 2012). Lokalizacija je proces prilagoditve programskih rešitev na način, ki zagotavlja skladnost teh z zahtevami davčne zakonodaje in računovodskih predpisov ter poročanjem (Microsoft, 2012). Lokalizacija in prevodi za Slovenijo s strani Microsofta niso podprti, zato podjetje Adacta, programska oprema d.o.o. (v nadaljevanju Adacta) sama zagotavlja podporo zakonskim zahtevam ter prevod programa v slovenščino.

AX je zaradi širokega nabora funkcionalnosti in možnosti uporabe ene baze za spremljanje poslovanja podjetja v več državah, primeren predvsem za srednja in velika, lahko tudi mednarodna, podjetja.

Funkcionalnosti programa Microsoft Dynamics AX 2012 so organizirane po modulih. Vsak od modulov v AX zagotavlja določen, vsebinsko smiseln, nabor funkcionalnosti, ki so integrirane z glavno knjigo. To omogoča, da se transakcije knjiži samo enkrat, posledično pa se te odražajo v modulu, s katerim je transakcija povezana, pa tudi v glavni knjigi (npr. prejeti račun se zapiše kot odprta postavka v saldakonte dobaviteljev in v glavno knjigo). Moduli, po katerih je organiziran AX 2012 R2, so:

- Glavna knjiga: modul vsebuje pravila za knjiženje (kontni načrt, druge dimenzije, davek, ipd.) ter omogoča spremljanje transakcij glavne knjige ter poročanje;
- Saldakonti kupcev: modul vsebuje šifrant kupcev ter omogoča vnos prodajnih pogodb, knjiženje izdanih računov ter spremljanje terjatev (odprte terjatev, staranje, ipd.);

- Saldakonti dobaviteljev: modul vsebuje šifrant dobaviteljev, ter omogoča spremljanje nabavnih pogodb, vnose nabavnih naročil (nabavni nalogi), vnose in knjiženje prejetih računov, spremljanje odprtih obveznosti in pripravo plačil dobaviteljem;
- Proračun: modul vsebuje plane in proračune podjetij, ki se lahko uporabljajo za kontrolo stroškov pri knjiženju;
- Stroškovno računovodstvo: modul omogoča izdelavo poročil na podlagi stroškov, povezanih s produkti, aktivnostmi ali organizacijo;
- Osnovna sredstva: modul vsebuje šifrant osnovnih sredstev z njihovimi tehničnimi podatki ter omogoča knjiženje različnih transakcij na sredstva (pridobitve, amortizacija, izločitve, ipd.);
- Denarno in bančno poslovanje: modul vsebuje šifrant bančnih računov podjetja, ter omogoča obdelavo bančnih izpiskov ter knjiženje blagajne;
- Zakladništvo (modul v celoti razvit s strani podjetja Adacta): modul omogoča spremljanje kreditov in depozitov podjetja;
- Potni nalogi in stroški: modul omogoča knjiženje potnih stroškov zaposlenih;
- Skladnost in interne kontrole: modul omogoča spremljanje okoljskega odtisa podjetja in predstavlja orodje za spremljanje izpolnjevanja internih pravil podjetja;
- Človeški viri: modul vsebuje šifrant zaposlenih ter omogoča spremljanje delovnih mest, pozicij ter ostalih kadrovskih podatkov o zaposlenih;
- Plače: modul se uporablja za obračun plač v ZDA;
- Nabava: modul omogoča spremljanje nabavnih pogodb, vnose zahtevkov za nabavo, povpraševanj, nabavnih naročil ter vnos nastavitev za nabavo;
- Produkti: modul vsebuje šifrant produktov ter nastavitve za spremljanje produktov (artiklov);
- Glavno planiranje: modul se uporablja za planiranje potreb po artiklih (angl. *material requirements planning* oz. *MRP*);
- Nadzor proizvodnje: modul omogoča knjiženje proizvodnje – porabo materialov ter drugih stroškov ter izdelavo polizdelkov in izdelkov;
- Upravljanje zaloge: modul omogoča spremljanje zaloge količinsko in vrednostno ter vsebuje nastavitve za vrednotenje zaloge;
- Prodaja in trženje: modul omogoča spremljanje podajnih pogodb, kampanj, potencialnih strank, vnos prodajnih naročil ter fakturiranje le-teh;
- Maloprodaja: modul ponuja rešitev za prodajna mest (angl. *point of sale* oz. *POS*) ter zaledni sistem za spremljanje prodaje;
- Projektno vodenje in računovodstvo: modul omogoča spremljanje projektov tipov čas in material in fiksna cena, ki se jih fakturira strankam, ter tipov investicijski, stroškovni in interni, ki se jih uporablja za spremljanje investicij ali internih stroškov;
- Servis: modul se uporablja za spremljanje storitvenih dogovorov in naročnin ter za spremljanje poizvedb kupcev ter analizo opravljenih storitev;
- Ogrodje za uvoze in izvoze podatkov: modul se uporablja za migracijo podatkov, predvsem pri prehodu iz drugih sistemov v AX;

- Organizacijska administracija: modul se uporablja za spremljanje organizacijskih hierarhij ter druge nastavitve (naslovi, številčne serije, ipd.);
- Sistemska administracija: modul se uporablja za nastavitve uporabnikov programa ter za sistemske nastavitve.

Iz širokega nabora modulov, ki jih pozna AX, pridejo v poštev za napovedovanje denarnega toka Glavna knjiga, Saldakonti dobaviteljev, Saldakonti kupcev, Nabava, Prodaja in trženje, Potni nalogi in stroški, Zakladništvo, Proračun in Denarno in bančno poslovanje.

4.1 Viri za napovedovanje denarnega toka v Microsoft Dynamics AX 2012

AX standardno omogoča izračun likvidnostnih zahtev po valuti. In sicer so viri za izračun načrta denarnega toka naslednji:

- odprte postavke kupcev (terjatve);
- odprte postavke dobaviteljev (obveznosti);
- nabavni nalogi;
- prodajni nalogi;
- neknjižene finančne fakture;
- transakcije iz GK;
- postavke iz proračuna.

S strani podjetja Adacta je bila narejena dodelava funkcionalnosti, in sicer so v plan denarnega toka dodani viri:

- neknjiženi prejeti računi;
- potrjeni obračuni potnih stroškov;
- zakladništvo (kredit, depoziti);
- neknjižene postavke davka – davek na dodano vrednost (v nadaljevanju DDV);
- knjižene postavke davka (DDV).

V nadaljevanju je podrobneje predstavljen način uporabe vsakega izmed virov v načrtovanju denarnega toka.

4.1.1 Terjatve do kupcev

Terjatve do kupcev se vodijo v modulu saldakonti kupcev. Odprte terjatve do kupcev se v načrtu denarnega toka v AX upoštevajo glede na datum zapadlosti in obdobje do plačila, ki je nastavljeno v nastavitvah saldakontov kupcev. Vsaka odprta terjatev ima lahko več datumov zapadlosti, kar omogoča funkcionalnost vodenja obrokov. Datum zapadlosti in

obroke za posamično terjatev je mogoče spreminjati, glede na dogovore s kupci. Obdobje do plačila pa predstavlja oceno podjetja, v kolikšnem času po zapadlosti postavke bodo kupci terjatev res plačali oz. bo denar res pritekel na bančni račun podjetja. Nastavitev velja za vse kupce.

Podatki o datumu zapadlosti so sicer dober približek za napovedovanje denarnega toka iz naslova odprtih terjatev, ne upoštevajo pa specifik posamičnih kupcev oz. skupin kupcev. Nekateri kupci imajo navado plačevati na določen dan v mesecu ali tednu, določeni kupci imajo poslovne težave, ki jim onemogočajo račune plačevati na rok, ipd. Ti vzorci so za posamičnega kupca razvidni iz zgodovine transakcij s podjetjem, vendar pa se pri izračunavanju denarnega toka ne upoštevajo.

4.1.2 Obveznosti do dobaviteljev

Obveznosti do dobaviteljev se vodijo v modulu saldakonti dobaviteljev. Odprte obveznosti do dobaviteljev se upoštevajo v načrtu denarnega toka glede na datum zapadlosti in obdobje do plačila, nastavljeno v nastavitvah saldakontov dobaviteljev. Vsaka odprta obveznost ima lahko več datumov zapadlosti, kar omogoča funkcionalnost vodenja obrokov. Datum zapadlosti in obroke za posamično obveznost je mogoče spreminjati, glede na dogovore z dobavitelji. Obdobje do plačila pa predstavlja oceno podjetja, v kolikšnem času po zapadlosti postavke bo res plačalo račun. Nastavitev velja za vse dobavitelje.

Pri saldakontih dobaviteljev lahko podjetje z večjo zanesljivostjo presodi, kdaj bo obveznosti plačalo. Večina podjetij obveznosti plačuje na rok, v primeru likvidnostnih težav pa lahko podjetje te rešuje tudi s pomočjo zamika pri plačevanju računov.

4.1.3 Nabavna naročila

Nabavni nalogi oz. nabavna naročila se vodijo v modulih nabava in saldakonti dobaviteljev. V načrtu denarnega toka se upoštevajo, dokler ni za nabavni nalog odprt račun, in sicer glede na plačilne pogoje na nalogu in glede na nekatera predvidena obdobja, ki so nastavljena v saldakontih dobaviteljev. Obdobja, ki vplivajo na izračun načrta denarnega toka, in se upoštevajo za vse dobavitelje oz. nabavne naloge, so:

- obdobje med dostavo in fakturiranjem: je obdobje, za katerega podjetje meni, da bo minilo med dostavo blaga in izdajo fakture s strani dobavitelja in se uporablja pri načrtovanju denarnega toka za že dobavljene nabavne naloge (na katerih ni navedenega datuma zapadlosti);
- obdobje fakturiranja: je obdobje, za katerega podjetje meni, da bo minilo med dostavo blaga in izdajo fakture s strani dobavitelja in se uporablja pri načrtovanju denarnega toka za še nedobavljene nabavne naloge (na katerih ni navedenega datuma zapadlosti) ter za plane nabave.

- plačilni pogoji: se uporabijo za izračun datuma zapadlosti glede na predvideni datum fakturiranja v primeru, da na nabavnem nalogu ni zabeleženih drugačnih plačilnih pogojev ali datuma zapadlosti.

4.1.4 Prodajna naročila

Prodajni nalogi oz. prodajna naročila se vodijo v modulih prodaja in trženje ter saldakonti kupcev. V načrtu denarnega toka se upoštevajo, dokler ni knjiženi izdani račun, in sicer glede na plačilne pogoje na nalogu in glede na nekatera predvidena obdobja, ki so nastavljena v saldakontih kupcev. Obdobja, ki vplivajo na izračun načrta denarnega toka, in se upoštevajo za vse kupce oz. prodajne naloge, so:

- obdobje med dostavo in fakturiranjem: je obdobje, za katerega podjetje meni, da bo minilo med dostavo blaga in izdajo fakture kupcu in se uporablja pri načrtovanju denarnega toka za že dobavljene prodajne naloge (na katerih ni navedenega datuma zapadlosti);
- obdobje fakturiranja: je obdobje, za katerega podjetje meni, da bo minilo med dostavo blaga in izdajo fakture kupcu in se uporablja pri načrtovanju denarnega toka za še ne dobavljene prodajne naloge (na katerih ni navedenega datuma zapadlosti) ter za plane prodaje;
- plačilni pogoji: se uporabijo za izračun datuma zapadlosti glede na predvideni datum fakturiranja v primeru, da na prodajnem nalogu ni zabeleženih drugačnih plačilnih pogojev ali datuma zapadlosti.

4.1.5 Neknjižene finančne fakture

Finančne fakture se knjižijo v modulu saldakonti kupcev. Gre za fakture, ki omogočajo zgolj knjiženje storitev ter so neodvisni od prodajnih nalogov, navedenih pod točko 4.1.4. V načrtu denarnega toka se upoštevajo, dokler ni knjižena izdana faktura, in sicer glede na plačilne pogoje na fakturi in glede na nekatera predvidena obdobja, ki so nastavljena v saldakontih kupcev:

- obdobje fakturiranja: je obdobje, za katerega podjetje meni, da bo minilo med datumom opravljene storitve in izdajo fakture.
- plačilni pogoji: se uporabijo za izračun datuma zapadlosti glede na predvideni datum fakturiranja v primeru, da na finančni fakturi ni zabeleženih drugačnih plačilnih pogojev oz. datuma zapadlosti.

4.1.6 Transakcije iz glavne knjige

Na kontih glavne knjige je mogoče narediti nastavitve za upoštevanje določenih transakcij v načrtu denarnega toka. Na kontu se navede odstotek transakcij za upoštevanje v načrtu, plačilne pogoje, ki se uporabijo za izračun datuma zapadlosti transakcij, ter konto likvidnosti (konto banke, na katerem pričakujemo priliv ali odliv). Originalno se je takšen način načrtovanja uporabilo npr. za načrtovanje plačila DDV-ja, kar pa je podjetje Adacta za dodelalo zaradi slovenske specifičnosti pri knjiženju DDV-ja (datum za DDV se razlikuje od datuma knjiženja), tako da funkcionalnost načrtovanja v glavni knjigi običajno ne pride v poštev.

4.1.7 Plani nabave in prodaje ter predračuni

Podjetja lahko v AX pripravijo plan prodaje in nabave po artiklih, predvidenih datumih nabave oz. prodaje, s količinami in cenami ter po dobaviteljih oz. kupcih. Takšen plan se lahko označi za upoštevanje v načrtu denarnega toka. Pri upoštevanju v načrtu denarnega toka se upoštevajo plačilni pogoji in obdobje do plačila.

Predračune se vnaša v modulu proračun. V načrtu denarnega toka je mogoče upoštevati postavke iz proračuna, ki je označen, da se v načrtu upošteva, za konte, na katerih je prav tako označeno, da se upoštevajo v načrtu denarnega toka. Enako kot pri nastavitvah za upoštevanje transakcij iz glavne knjige v načrtovanju denarnega toka, se tudi v tem primeru nastavi odstotek proračuna za upoštevanje v načrtu, plačilne pogoje, ki se uporabijo za izračun datuma zapadlosti transakcij, ter konto likvidnosti (konto banke, na katerem pričakujemo priliv ali odliv). Uporabi se lahko npr. za predvidljive večje odlive ali prilive – npr. za odliv zaradi izplačila plač zaposlenim.

4.1.8 Neknjiženi prejeti računi

Prejete račune se vnaša v modul saldakonti dobaviteljev. V načrtu denarnega toka se upoštevajo, dokler niso knjiženi. Če se prejeti račun poveže z nabavnim nalogom oz. nabavnim naročilom, se vrstice tega naloga prenesejo na tak račun, kar pomeni, da se v načrtu denarnega toka ne upošteva več nalog, pač pa prejeti račun. Predpostavlja se namreč, da račun vsebuje bolj pravilne podatke glede roka plačila oz. datuma zapadlosti.

Funkcionalnost je bila dodana s strani podjetja Adacta, saj v večjih slovenskih podjetjih potrjevanje računov (likvidacija) pogosto traja tako dolgo, da se račun knjiži šele tik preden zapade v plačilo, včasih pa celo kasneje. Načrtovanje denarnega toka bi bilo v takšnih primerih zelo nenatančno, še posebej takrat, kadar v ozadju računa ni nabavnega naloga, ki bi se upošteval v načrtu denarnega toka.

4.1.9 Potrjeni obračuni potnih stroškov

Potrjeni obračuni potnih stroškov se nahajajo v modulu potni nalogi in stroški. Funkcionalnost za upoštevanje potrjenih potnih stroškov v načrtu denarnega toka je bila dodana s strani podjetja Adacta. Potrjeni potni nalogi se v planu upoštevajo dokler niso knjiženi. S knjiženjem nastane obveznost do dobavitelja (zaposlenega), ki se že standardno upošteva v načrtu denarnega toka.

4.1.10 Zakladništvo

V načrtu denarnega toka se upoštevajo amortizacijski načrti prejetih in danih kreditov ter depozitov, ki se nahajajo v modulu zakladništvo, ki je bil v celoti narejen s strani podjetja Adacta. Običajno se postavke zakladništva knjiži preko kupcev in dobaviteljev, zato se v načrtu denarnega toka upoštevajo, dokler niso knjižene. Po tem se v načrtu denarnega toka upoštevajo preko standardne funkcionalnosti, ki upošteva terjatve do kupcev in obveznosti do dobaviteljev.

4.1.11 DDV

Postavke davka (DDV-ja) se standardno ne upoštevajo v načrtu denarnega toka. Standardno je mogoče nastavitve za upoštevanje davka narediti zgolj na kontih glavne knjige, kar pa je v Sloveniji problem, saj je datum za DDV različen od datuma knjiženja dokumentov – datum za DDV pa se ne spremlja v glavni knjigi. To pomeni, da je načrtovanje denarnega toka s pomočjo funkcionalnosti v glavni knjigi, opisane pod točko 4.1.6, zelo nenatančno. S strani podjetja Adacta je bila zato narejena prilagoditev funkcionalnosti, ki omogoča upoštevanje neknjiženega in knjiženega DDV glede na datum za DDV.

Postavke davka se knjižijo preko različnih dokumentov (in modulov) v modul glavna knjiga. Nekonjižene postavke davka se upoštevajo v načrtu denarnega toka kot plačilo oz. vračilo, izračunajo pa se iz posamičnih neknjiženih dokumentov (nabavni nalog, prejeti račun, finančna faktura, prodajni nalog). Ko so ti dokumenti knjiženi, se v načrtu denarnega toka upoštevajo na podlagi knjiženih postavk davka.

4.1.12 Banka

V modulu denarno in bančno poslovanje se spremljajo vsi bančni računi podjetja. Stanje na vseh bančnih računih skupaj predstavlja podatek o začetnem stanju denarnih sredstev pri metodi prejemkov in izdatkov. Pri izračunu denarnega toka v AX se standardni podatek o stanju na bančnem računu ne uporablja, saj se izračunavajo zgolj zahteve po valuti – torej kolikšen je neto znesek prilivov ali odlivov v določenem obdobju. V lokalizaciji je bilo upoštevanje stanja na denarnih računih podjetja dodano na pregled načrta denarnega toka,

kar omogoča tudi pregled dejanskega stanja denarnih sredstev oz. dejanskih potreb po financiranju.

Problem pri upoštevanju stanja na bančnih računih se pojavi v primeru dnevnega oz. zelo kratkoročnega planiranja denarnega toka, kjer začetno stanje na bančnih računih v AX običajno še ne ustreza dejanskemu stanju na bančnih računih. Bančni izpiski se namreč običajno knjižijo z enodnevnim zamikom, kar pomeni, da je stanje v AX aktualno šele dopoldne naslednjega dne, plan denarnega toka pa je narejen že pred tem (zjutraj ali celo prejšnji dan popoldan). V praksi to pomeni, da podjetja namesto stanja iz AX, upoštevajo stanje iz plačilnih sistemov, od koder morajo podatke pridobiti ročno, ali pa v začetnem stanju poleg stanja na bančnih računih v AX upoštevajo tudi plan prilivov in odlivov za prejšnji dan. Najaktualnejše stanje v AX je mogoče dobiti iz bančnih izpiskov, še preden so ti obdelani in knjiženi (to namreč lahko vzame nekaj časa, predvsem v primeru, da ima podjetje velik obseg plačil). Zaradi tega je bilo omogočeno tudi pridobivanje podatkov o začetnih stanjih na bančnih računih iz uvoženih bančnih izpiskov.

4.2 Funkcionalnost za napovedovanje denarnega toka v Microsoft Dynamics AX 2012

Funkcionalnost za napovedovanje denarnega toka v AX temelji na izračunu datumov zapadlosti ter upoštevanju nekaterih dodatnih obdobij za vse predhodno opisane vire podatkov. Prikaz načrta denarnega toka oz. neto potreb po likvidnostnih sredstvih je mogoč za posamezno valuto po dneh. Ob ponovnem zagonu izračuna likvidnostnih zahtev se stanje prepiše z novim izračunanim stanjem. Takšen prikaz ni uporabniku prijazen, saj ne omogoča nikakršnega spreminjanja podatkov - npr. dodajanja podatkov, ki jih sistem ne vsebuje, upoštevanja stanj na bančnih računih ali prilagajanja datumov za plačilo glede na stanje denarnih sredstev. Prav tako ni mogoče zgodovinsko spremljanje načrtovanih denarnih tokov.

Slika 5 prikazuje standardni prikaz neto potreb po likvidnostnih sredstvih v Microsoft Dynamics AX 2012, iz katerega je razvidno kolikšna so sredstva, ki jih podjetje potrebuje na določen dan oz. kolikšen je presežek sredstev na dan, in kolikšna je kumulativna neto potreba po denarnih sredstvih do vsakega izmed planiranih datumov. Z vrtanjem v globino je mogoče priti do posamičnih podatkov oz. zneskov (brez detajlov o izvoru) iz katerih je znesek za nek dan sestavljen. Podatkov o denarnih stanjih na bančnih računih tu ni mogoče videti, ampak jih je potrebno preveriti ločeno, v modulu Denarno in bančno poslovanje.

V okviru slovenske lokalizacije s strani podjetja Adacta je bila izdelana forma, ki omogoča dodajanje podatkov, brisanje določenih podatkov, spreminjanje datumov predvidenih plačil in upoštevanje stanja iz bančnih računov na podlagi knjiženega stanja na bančnih računih ali stanja na neknjiženih bančnih izpiskih. Uporabniki si prav tako lahko izberejo terminski obseg za napoved denarnega toka, valuto, v kateri bodo denarni tok napovedovali ter

pogostost napovedi. Stare napovedi se zaklenejo za spremembe, vnašajo pa se nove napovedi oz. nove verzije napovedi, kar omogoča tudi pregledovanje zgodovine napovedi. Napovedi je mogoče delati za več časovnih obdobj (npr. teden, mesec, kvartal, leto).

Slika 5: Standardni prikaz neto potreb po likvidnostnih sredstvih v Microsoft Dynamics AX 2012

Datum	V dobro/V breme	Kumulativno
30.4.2016	11.506,85	11.506,85
8.5.2016	12,33	11.519,18
31.5.2016	12.739,73	24.258,91
8.6.2016	12,77	24.271,68
15.6.2016	5.006.164,38	5.030.436,06
8.7.2016	12,39	5.030.448,45
8.8.2016	12,84	5.030.461,29
8.9.2016	12,87	5.030.474,16
8.10.2016	12,48	5.030.486,64
31.10.2...	12,52	5.030.499,16
18.11.2...	19,86	5.030.519,02
10.1.2017	-2.400,00	5.028.119,02
16.2.2017	30,92	5.028.149,94
5.4.2017	-2.824,30	5.025.325,64
8.7.2017	-1.500,00	5.023.825,64
9.7.2017	100.000,00	5.123.825,64
8.8.2017	-12.000,00	5.111.825,64
9.8.2017	1.000,00	5.112.825,64
16.8.2017	-169,14	5.112.656,50
8.9.2017	-332,78	5.112.323,72

Slika 6 prikazuje primer napovedi za valuto EUR za mesec april (zaradi pregledosti je prikazanih samo 10 dni). Iz zgornjega dela forme so razvidne neto potrebe po denarnih sredstvih na dan, razbite glede na vir nastanka stroška (prikaz po virih stroškov se lahko prilagodi z nastavitvami). Podatek o stanju na bančnih računih se lahko pripelje v formo ter se ga prikaže v polju Začetni saldo iz knjiženega stanja na bančnih računov, iz prejšnje napovedi likvidnosti ali pa iz stanja v še neknjiženih bančnih izpiskih. V spodnjem delu napovedi so prikazane posamezne postavke napovedi (računi, naročila, predvidene transakcije iz zakladništva, ipd.), ki jih je mogoče urejati, ter s tem prilagajati napoved.

Slika 6: Prikaz napovedi denarnega toka z dodelavo

Napoved likvidnosti (1 - gesi) - Valuta: EUR, GESI-000010

Pregled

Opis	Dan 1.4.2016	Dan 2.4.2016	Dan 3.4.2016	Dan 4.4.2016	Dan 5.4.2016	Dan 6.4.2016	Dan 7.4.2016	Dan 8.4.2016	Dan 9.4.2016	Dan 10.4.2016
Začetni saldo	0,00	0,00	-5.001.220,00	-5.003.320,00	-10.002.120,00	-10.004.140,00	-10.006.379,29	-10.019.485,22	-10.034.216,55	-10.022.216,55
Zakladništvo	0,00	-5.000.000,00	0,00	-5.000.000,00	0,00	0,00	0,00	0,00	0,00	0,00
Potni stroški	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
Odpрте postavke dobaviteljev	0,00	-610,00	-2.100,00	1.200,00	-2.020,00	-2.239,29	-12.617,93	-15.000,00	0,00	0,00
Odpрте postavke kupcev	0,00	0,00	0,00	0,00	0,00	0,00	0,00	268,67	12.000,00	0,00
Nalogi	0,00	-610,00	0,00	0,00	0,00	0,00	-488,00	0,00	0,00	0,00
Davek	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
Ostalo	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
Končni saldo	0,00	-5.001.220,00	-5.003.320,00	-10.002.120,00	-10.004.140,00	-10.006.379,29	-10.019.485,22	-10.034.216,55	-10.022.216,55	-10.022.216,55

Vrstice napovedi

Datum	Planski nivo	Vrsta stroška	Glavni konto	Forecast amount	Popravek	Tip konta vira	Vir konta	Št. vira	Datum vira	Valuta	Izvorni znesek
2.4.2016	NR		1100	-610,00		Dobavitelj	000007		2.4.2016	EUR	-610,00
4.4.2016	ZKL		1100	-5.000.000,00		Glavna knjiga			4.4.2016	EUR	-5.000.000,00
7.4.2016	NR		1100	-488,00		Dobavitelj	000007	PR333	7.4.2016	EUR	-488,00
16.4.2016	DAVEK		1100	25,00		Kupec	GESI-000003		16.4.2016	EUR	25,00
16.4.2016	NR		1100	-200,00		Dobavitelj	000055	3333	16.4.2016	EUR	-200,00
30.4.2016	ZKL		1100	-350,00		Glavna knjiga			30.4.2016	EUR	-350,00
30.4.2016	ZKL		1100	7.000.000,00		Glavna knjiga			30.4.2016	EUR	7.000.000,00
2.4.2016	ZKL		500000	-5.000.000,00		Glavna knjiga			2.4.2016	EUR	-5.000.000,00
30.4.2016	ZKL		500000	11.506,85		Glavna knjiga			30.4.2016	EUR	11.506,85

5 STROJNO UČENJE

Strojno učenje je eden od novejših pristopov k napovedovanju vrednosti spremenljivk na podlagi izbranih parametrov. V magistrskem delu je po zgledu pristopov, opisanih v točki 3.3.4, uporabljeno za napoved denarnega toka iz naslova izdanih računov oz. terjatev do kupcev. V nadaljevanju so predstavljene najpogostejše uporabljane metode strojnega učenja ter izbor metod, ki so bile uporabljene v tem magistrskem delu.

5.1 Kaj je strojno učenje

Strojno učenje se uporablja na področju podatkovne znanosti (angl. *data science*), skupaj z matematiko, statistiko, programiranjem, jezikoslovjem, ipd. (Barga, Fontama, & Tok, 2015). Cilj podatkovne znanosti je pridobiti uporabna spoznanja iz podatkov, še posebej kadar imamo opravka z veliko količino strukturiranih ali nestrukturiranih podatkov (angl. *big data*), npr. za namene poslovnega obveščanja (Barga et al., 2015).

Podatkovna znanost je izraz, ki se uporablja pretežno v zadnjem času, in se v literaturi pogosto omenja tudi kot podatkovno rudarjenje (Provost & Fawcett, 2013). Razlika med tema dvema je majhna, in sicer je podatkovna znanost nabor pravil, s pomočjo katerih se

pridobiva informacije iz podatkov, podatkovno rudarjenje pa pomeni uporabo tehnologij za pridobitev informacij iz podatkov na osnovi pravil podatkovne znanosti (Provost & Fawcett, 2013).

McKinsey Global Institute je kot prednosti, ki jih lahko podjetje pridobi s pomočjo podatkovne znanosti, prepoznal (Manyika et al., 2011):

- večjo transparentnost oz., hitrejši prenos podatkov med oddelki;
- izboljšanje izvedbe s pomočjo analize variabilnosti in kontroliranimi poizkusi, ki omogočijo razumevanje variabilnosti;
- možnost segmentacije populacije, npr. z namenom oglaševanja;
- podporo pri odločanju z avtomatiziranimi algoritmi, ki minimizirajo tveganje, npr. pri določevanju cenovne politike, zaloge;
- podporo pri inovacijah novih produktov, storitev in poslovnih modelov.

Naloge podatkovne znanosti razvrščamo v naslednje kategorije (razvrščene po naraščajoči kompleksnosti) (Barga et al., 2015):

- opisna: se uporablja za opise in razlage podatkov;
- diagnostična: se uporablja za raziskovanje vzrokov za dogodke s pomočjo statističnih metod, metod podatkovnega rudarjenja in s pomočjo metod strojnega učenja;
- napovedna: omogoča napovedovanje dogodkov v prihodnosti s pomočjo statističnih metod in metod strojnega učenja;
- predpisujoča: predlaga najboljše ukrepe za optimizacijo poslovnih rezultatov s pomočjo kombiniranja napovedne analitike in upoštevanja poslovnih pravil.

Proces podatkovnega rudarjenja poteka v 5-ih korakih (Barga et al., 2015). Prvi korak je kritičen za nadaljnji proces in rezultate, in obsega definicijo poslovnega problema, ki ga je potrebno rešiti (Barga et al., 2015). V drugem koraku je potrebno pridobiti podatke iz različnih podatkovnih virov ter jih organizirati na način, ki omogoča nadaljnje analize ter določiti lastnosti ter spremenljivke, ki bodo v modelu uporabljene (Barga et al., 2015). Tretji korak obsega izbor algoritma in izgradnjo modela, četrti korak pa implementacijo modela (Barga et al., 2015). Zadnji korak obsega nadzor nad točnostjo modela in spremljanje morebitnih sprememb, ki jih je potrebno vključiti v model (Barga et al., 2015).

Strojno učenje je tehnična osnova podatkovne znanosti oz. rudarjenja (Pangeršič, 2015). Razcvetelo se je v 90-ih letih prejšnjega stoletja kot stranska panoga pri raziskovanju umetne inteligence (Russel & Norvig, 2009). Cilj strojnega učenja je postaviti algoritme za avtomatizirano učenje oz. t.i. programiranje s primeri (Schapire, 2008). Namesto, da bi razvili program za rešitev specifičnega problema, se razvijajo metode, s pomočjo katerih

lahko računalnik sam razvije program za rešitev specifičnega problema na podlagi testnih oz. vzorčnih primerov (Schapire, 2008).

5.2 Pregled metod strojnega učenja

Strojno učenje delimo v 3 skupine metod (Rohrer, 2016):

- nadzorovano učenje (angl. *supervised learning*);
- nenadzorovano učenje (angl. *unsupervised learning*);
- okrepitveno učenje (angl. *reinforcement learning*).

5.2.1 Metode nadzorovanega strojnega učenja

Algoritmi nadzorovanega strojnega učenja se učijo na podlagi testnih podatkov ter njihovih rezultatov, s ciljem naučiti se splošnega pravila, ki omogoča razvrščanje podatkov (Rohrer, 2016).

Algoritme nadzorovanega strojnega učenja lahko glede na pričakovane rezultate razvrstimo na (Rohrer, 2016; Pangeršič, 2015):

- klasifikacijo (angl. *classification*): podatke se razvršča v kategorije (dve ali več);
- regresijo (angl. *regression*): algoritme se uporablja za napovedovanje vrednosti zvezne spremenljivke;
- odkrivanje anomalij (angl. *anomaly detection*): odkriva se primere, ki ne spadajo v skupine normalnih vzorcev.

V nadaljevanju so predstavljeni najpogosteje uporabljeni algoritmi strojnega učenja – linearna regresija, logistična regresija, odločitvena drevesa, nevronske mreže, bayesovske metode, na kratko pa so predstavljene še nekatere druge metode.


5.2.1.1 Linearna regresija

Linearna regresija spada med algoritme tipa regresija (Rohrer, 2016). Uporablja se za napovedovanje vrednosti odvisne spremenljivke na podlagi neodvisnih spremenljivk, ob minimalni napaki (Wang & Jain, 2003). V primeru uporabe ene neodvisne spremenljivke govorimo o enostavni linearni regresiji, v primeru uporabe več-ih neodvisnih spremenljivk pa o multipli linearni regresiji (Wang & Jain, 2003).

Enostavno linearno regresijo lahko prikažemo kot premico, ki ponazarja razmerje med neodvisno in odvisno spremenljivko – premica je določena tako, da je razdalja med točkami

in premico minimalna (Berson, Smith & Thearling, 2016). Slika 7 predstavlja vizualno predstavitev enostavne linearne regresije.

Slika 7: Linearna regresija




5.2.1.2 Logistična regresija

Kljub svojemu imenu spada logistična regresija med klasifikacijske algoritme, s katerimi lahko podatke razporedimo v skupine (Rohrer, 2016). Logistična regresija se uporabi kadar ne želimo zveznega ampak diskreten rezultat odvisne spremenljivke (Hastie, Tibshirani, & Friedman, 2009). Rezultat je izražen v verjetnosti določenega izida in se zato giba med vrednostjo 0 in 1 (Hastie et al., 2009).

Slika 8 prikazuje vizualno predstavitev logistične regresije, pri kateri so bili podatki razvrščeni v dve skupini na osnovi ene neodvisne spremenljivke. Meja med skupinama se nahaja pri verjetnosti 0,5 oz. pri vrednosti neodvisne spremenljivke 40.

Slika 8: Logistična regresija




5.2.1.3 Odločitvena drevesa

Odločitvena drevesa lahko spadajo med klasifikacijske algoritme ali regresijske algoritme, odvisno od načina uporabe (Rohrer, 2016). Med odločitvena drevesa sodijo tudi algoritmi odločitveni gozd, odločitvena džungla in *boosting* odločitvena drevesa (Rohrer, 2016).

Odločitveno drevo je struktura, podobna hierarhičnim diagramom poteka, sestavljena iz vej, notranjih in zunanjih vozlišč (Pohorec, 2014). Zapis vstopi v odločitveno drevo pri izvornem vozlišču, kjer se glede na vrednost določenega atributa izbere veja, po kateri nadaljuje pot (skozi notranja vozlišča) (Pohorec, 2014). Atributi za delitev množice podatkov so lahko diskretni, pri čemer je izhodov iz vozlišča toliko, kot je različnih vrednosti, ali pa zvezni, kjer se z regresijo izbere mejna točka (izpelje se več linearnih regresijskih funkcij za podatke), na podlagi katere se izoblikujeta običajno dve veji oz. dva izhoda (Pohorec, 2014). Ta proces se ponavlja, dokler zapis ne pride do zunanjega vozlišča (Pohorec, 2014; Microsoft, 2016). Zunanja vozlišča imajo točno en vhod in nobenega izhoda ter predstavljajo rezultat klasifikacije – vsi zapisi, ki pot končajo v istem zunanjem vozlišču, spadajo v isti razred (Pohorec, 2014).

Slika 9 prikazuje primer odločitvenega drevesa, kjer se ocenjuje ali se bo potencialna stranka odzvala na mail na podlagi starosti, spola in tega, ali se je v preteklosti že odzvala.

Slika 9: Odločitveno drevo



Vir: L. Rokach & O. Maimon, *Data Mining and Knowledge Discovery Book*, 2005, str.166, slika 9.1.

Ena od pomembnih lastnosti odločitvenih dreves je, da je posameznim kriterijem klasifikacije enostavno slediti, kar omogoča jasn vpogled v delovanje, ki je pri določenih problemih nujen (npr. pri medicinski uporabi) (Pohorec, 2014).

Najbolj znani algoritmi odločitvenih dreves so ID3, C4.5, C5.0, AID, CART in CHAID (Barga et al., 2015).

Odločitveni gozd je sestavljen iz velikega števila odločitvenih dreves, ki med sabo niso korelirana (Rohrer, 2016). Končni rezultat je drevo, ki je povprečje teh dreves (Rohrer, 2016). Odločitveni gozd (in tudi odločitvena džungla, ki deluje na podobnem principu) rešuje problem preveč natančnega določevanja razredov, ki bi v končni fazi lahko privedlo do tega, da bi vsak posamezen zapis spadal v svoj razred (Rohrer, 2016). *Boosting* odločitvena drevesa pa ta problem rešujejo tako, da omejijo število vozlišč in minimalno število zapisov v posameznem zunanjem vozlišču (Rohrer, 2016).

5.2.1.4 Nevronske mreže

Nevronske mreže so se originalno pričele uporabljati v psihologiji in nevrobiologiji, s ciljem ugotoviti kako delujejo nevroni (Han, Kamber, & Pei, 2012). Nevronska mreža je set povezanih vhodnih in izhodnih spremenljivk, pri katerih ima vsaka povezava dodeljeno utež (Han et al., 2012).

Nevronske mreže potrebujejo veliko časa za učenje in veliko količino parametrov, njihovi rezultati pa so slabo razločljivi, zato niso primerne za vse vrste problemov (Han et al., 2012). Omogočajo pa tudi klasifikacijo vzorcev, pri katerih imamo malo vedenja o povezanosti atributov in razredov (Han et al., 2012). Uporabijo se lahko za napovedovanje diskretnih spremenljivk (klasifikacijo) ali zveznih spremenljivk (regresijo).


Obstaja veliko vrst algoritmov nevronske mreže. Eden od bolj popularnih je vzvratno učenje (angl. *backpropagation algorithm*), ki se uči na večnivojski mreži, ki je sestavljena iz vhodnega nivoja, enega ali več skritih nivojev in izhodnega nivoja (Han et al., 2012). Zapisi vstopijo v nevronske mreže v vhodnem nivoju, kjer se utežijo ter prenesejo na skriti nivo, nato na naslednji skriti nivo (običajno v praksi nevronske mreže uporabijo samo en skriti nivo), uteženi zapisi zadnjega skritega nivoja pa se prenesejo v izhodni nivo in predstavljajo rezultat (Han et al., 2012). Statistično gledano se v nevronske mreže uteži določijo z nelinearno regresijo, pri čemer se poskuša minimizirati kvadratno napako od zadnjega nivoja nazaj, od koder izvira tudi ime vzvratno učenje (Han et al., 2012).

Eden od algoritmov nevronske mreže je tudi perceptron – gre za preprosto nevronske mreže, ki ima linearne meje razredov (nevronske mreže imajo sicer kompleksne, nelinearne meje razredov) in je odgovor na dolge čase učenja, ki jih sicer potrebujejo nevronske mreže za doseganje rezultata (Rohrer, 2016).

Slika 10 prikazuje primer nevronske mreže. X_1 , X_2 in X_3 predstavljajo vhodne spremenljivke, W_{xy} predstavljajo uteži, številke 1 do 3 vhodni nivo s tremi enotami, številki

4 in 5 skriti nivo z dvema enotama in številka 6 izhodni nivo z eno enoto (rezultat z eno enoto ima lahko dva razreda).

Slika 10: Nevronska mreža



Vir: J. Han, M. Kamber & J. Pei, *Data Mining Concepts and Techniques*, 2012, str.405, slika 9.5.

5.2.1.5 Druge metode

Obstajajo tudi druge metode nadzorovanega učenja, med katerimi se najbolj pogosto uporabljajo še metode najbližjega sosesa (angl. *nearest neighbor*), metoda podpornih vektorjev (angl. *support vector machine*) in Bayesovske metode.

Metoda najbližjega sosesa (k-NN) je eden od bolj preprostih algoritmov strojnega učenja, ki spada med tako imenovane počasne učence (angl. *lazy learners*), saj si zgolj shranjuje rezultate zapisov, na katerih se uči, nato pa razvrstitev novih zapisov izvede glede na shranjene zapise, ki so mu najbližje (Han et al., 2012). Metoda je časovno zahtevna, saj mora za vsak zapis izračunati oddaljenost od sosedov (Han et al., 2012).

Metoda podpornih vektorjev je v zadnjem času precej aktualna metoda, ki je sposobna formiranja zapletenih nelinearnih, večdimenzionalnih ravnin (t.i. hiperravnin), ki razmejujejo razrede (Han et al., 2012). Ravnina razmejuje razrede tako, da je med njimi kar največja razdalja (Rohrer, 2016). Uporabi se lahko za napovedovanje diskretnih spremenljivk (klasifikacijo) ali zveznih spremenljivk (regresijo). Metoda podpornih vektorjev zahteva veliko časa, vendar je zelo natančna in nima problema preveč natančnega določevanja razredov, kar je lahko problem pri odločitvenih drevesih (Han et al., 2012).

Bayesovske metode izvirajo iz Bayesovega izreka, ki je ime dobil po svojem izumitelju, menihu Thomasu Bayesu v 18. stoletju (Han et al., 2012). Bayesov teorem opiše verjetnost dogodka glede na pogoje, povezane s tem dogodkom (Han et al., 2012). Algoritmi, ki

upoštevajo Bayesov teorem delujejo tako, da predpostavijo kakšna bo distribucija rezultata (Rohrer, 2016). To jim omogoča, da dobijo rezultat z majhno količino parametrov in se izognejo problemu preveč natančnega določevanja razredov (Rohrer, 2016). V praksi se Bayesovske metode uporabljajo za napovedovanje diskretnih spremenljivk (klasifikacijo) ali zveznih spremenljivk (regresija) (Rohrer, 2016).

5.2.2 Metode nenadzorovanega strojnega učenja

Cilj algoritmov nenadzorovanega strojnega učenja je strukturirati kompleksne podatke na nek organiziran način, brez predhodnih podatkov o rezultatih (Rohrer, 2016). Algoritmi nenadzorovanega strojnega učenja spadajo glede na pričakovane rezultate v razvrščanje v skupine (angl. *clustering*) (Rohrer, 2016). Ena od uporab nenadzorovanega strojnega učenja je tudi razvrstitev zapisov oz. podatkov v skupine za nadaljnjo obdelavo s pomočjo nadzorovanih algoritmov strojnega učenja (Han et al., 2012). Eden od bolj znanih algoritmov nenadzorovanega strojnega učenja je algoritem *k-means*.

5.2.3 Metode okrepitvenega učenja

Pri okrepitvenem učenju se algoritmi odločajo glede na podatke, ki jih pridobijo, nato pa za svoje odločitve dobivajo vzpodbudne signale, ki jim povedo, kako dobra je bila posamezna odločitev (Rohrer, 2016).

5.3 Uporaba strojnega učenja v praksi

V poslovnem svetu se strojno učenje uporablja za veliko različnih namenov, npr. (Schapire, 2008; Pangeršič, 2015):

- kot analitični CRM za podjetja, ki se ukvarjajo z maloprodajo (trgovine, telekomunikacije, finančne storitve, ipd.):
 - za ugotavljanje vrednosti stranke,
 - za ugotavljanje strukture košarice,
 - za optimizacijo tržnih kampanj,
 - za analizo socialnega omrežja,
 - za analizo uporabe spletnih strani,
 - ipd.;
- za optimizacijo vzdrževanja strojev (v proizvodnji, distribuciji, zdravstvu);
- za zagotavljanje kvalitete v proizvodnji;
- za optimizacijo garancijskih pogojev;
- za zaznavanje prevar:
 - v zavarovalništvu (goljufivi škodni zahtevki, ipd.),
 - v bančništvu (prepoznavanje vzorcev pranja denarja in goljufij),

- v proizvodnji in distribuciji (prepoznavanje kraj);
- za določitev kreditnega tveganja (npr. za odobravanje posojil);
- v medicinski diagnostiki (za odkrivanje bolezenskih stanj in analize);
- za telemetrijo vozil;
- za prepoznavanje varnostnih vdorov;
- za napovedovanje vremena;
- za optično prepoznavanje znakov;
- za prepoznavanje obrazov;
- za filtriranje neželene pošte;
- za razumevanje govora;
- v robotiki, npr. pri avtomatizirani vožnji vozila;
- ipd.

5.4 Strojno učenje z »Microsoft Azure machine learning«

Program »Microsoft Azure machine learning« je spletna storitev, ki jo ponuja Microsoft, in omogoča kreiranje napovednih modelov strojnega učenja v oblaku (Gronlund, 2016). Napovedne modele je po kreiranju mogoče testirati, jih urejati, ter jih, ko so naučeni, uporabljati za nadaljnje napovedovanje (Gronlund, 2016).

Program »Microsoft Azure machine learning« vključuje naslednje algoritme strojnega učenja:

- linearno regresijo in variacijo:
 - bayesovsko regresijo,
- Poissonovo regresijo,
- logistično regresijo in variacijo:
 - ordinalno logistično regresijo,
- nevronske mreže,
- odločitvena drevesa in variacije:
 - *boosting* odločitvena drevesa,
 - odločitveni gozd,
 - odločitveno džunglo,
- metodo podpornih vektorjev (angl. *support vector machine*),
- povprečni perceptron (angl. *averaged perceptron*),
- kvantilno regresijo,
- detekcija anomalij na principu analize glavnih komponent (angl. *primary component analysis*),
- *k-means*.

5.5 Izbor metode in parametrov za napovedovanje denarnega toka s strojnim učenjem

Izbor metode strojnega učenja je odvisen od več dejavnikov, kot so npr. struktura podatkov, cilji in čas, ki je na razpolago za pridobitev rezultatov (Rohrer, 2016). V splošnem je potrebno pri izbiri algoritma upoštevati (Rohrer, 2016):

- potrebno natančnost rezultatov;
- čas učenja;
- linearnost;
- število parametrov, ki jih je mogoče nastaviti v algoritmu;
- število lastnosti podatkov.

Natančnost rezultatov načeloma lahko povečujemo s tem, da povečujemo število lastnosti podatkov, na katerem se algoritem uči, vendar pa s tem podaljšujemo čas učenja. Prav tako lahko nastopi težava, če je število lastnosti preveliko glede na obseg vhodnih podatkov. Pri tem pride do prekomernega prilagajanja modela podatkom, s čemer sicer lahko dobimo zelo dobro ujemanje modela z vhodnimi podatki za učenje, a zelo slabo ujemanje s testnimi podatki (angl. *overfitting*) (Hawkins, 2004).

Na natančnost vpliva tudi izbor metode, če vzamemo metodo, ki predpostavlja linearnost, a je podatki ne izkazujejo. Linearnost v tem kontekstu pomeni, da je možno več razredov med seboj ločiti z ravno črto, če imamo samo dve lastnosti, ali večdimenzionalnim ustreznikom (ravnino, hiperravnino) v primeru več lastnosti (Rohrer, 2016).

V našem primeru smo želeli pridobiti čimbolj natančne rezultate napovedi, pri čemer čas učenja ni bil tako pomemben. Med možnimi algoritmi za uporabo, naj bi bila najbolj natančna ter zato tudi nekoliko počasnejša, odločitvena drevesa oz. izpeljanke odločitvenih dreves (odločitveni gozd in odločitvena džungla) ter nevronske mreže. Algoritem odločitvenega drevesa se je najboljše odrezal tudi pri napovedi denarnega toka s strojnim učenjem, ki so jo izvedli Zeng, Melville, Lang, Boier-Martin, in Murphy (2008). Omenjeni algoritmi tudi ne zahtevajo linearnosti podatkov. To so bili glavni razlogi, da smo se odločili za uporabo algoritmov odločitvenega gozda ter nevronskih mrež. Odločitveni gozd se nam je zdela boljša izbira kot odločitveno drevo zaradi velikega števila uporabljenih spremenljivk, ki bi pri algoritmu odločitvenega drevesa lahko povzročile probleme s preveč natančnim določevanjem razredov. *Boosting* odločitvenega drevesa pa nismo mogli uporabiti, ker je primeren zgolj za napovedovanje dveh razredov. Za primerjavo smo se odločili uporabiti še logistično regresijo, ki prav tako spada med klasifikacijske algoritme (terjatve smo razvrščali v predvidene razrede zamude, za kar smo potrebovali klasifikacijske algoritme) in ne predpostavlja linearne odvisnosti med neodvisnimi in odvisno spremenljivko. Večina ostalih metod ni prišla v poštev prav zaradi predpostavke linearne

odvisnosti spremenljivk ali pa zaradi napačnega tipa algoritma (regresija namesto klasifikacije).

Ker je strojno učenje v tej nalogi samo orodje za izdelavo napovedi denarnega toka, moramo na izbiro modelov in parametrov gledati tudi s stališča kvalitete napovedi denarnega toka. Napovedi prometa ali povpraševanja, tako za fizične dobrine, kot za denar, nikoli niso točne, zato je prav tako kot samo napoved, pomembno spremljati, kakšna je napaka te napovedi (Blocher, Mabert, Soni, & Venkataramanan, 2004). Da bi ugotovili, kako dobro deluje model za napovedovanje, je potrebno primerjati dejanske zneske z napovedanimi zneski za določeno obdobje (Blocher, et al., 2004). Mere, ki se najpogosteje uporabljajo za ocenjevanje napake modelov (običajno gre za modele za napovedovanje povpraševanja) so (Blocher, et. al., 2004; Hyndman & Koehler, 2006):

- povprečna napaka (angl. *average error*);
- pristranskost napovedi oz. kumulativna napaka (angl. *bias*);
- povprečna absolutna napaka (angl. *mean absolute deviation* oz. *MAD*);
- povprečna odstotna absolutna napaka (angl. *mean absolute percentage error* oz. *MAPE*);
- povprečna kvadratna napaka (angl. *mean squared error* oz. *MSE*);
- kazalnik spremljanja pristranskosti napovedi (angl. *tracking signal* oz. *TS*);
- povprečna absolutna skalirana napaka (angl. *mean absolute scaled error* oz. *MASE*);
- koren povprečne kvadratne napake (angl. *root-mean-square error* oz. *RMSE*).

Kazalniki povprečna napaka, pristranskost napovedi, povprečna absolutna napaka in povprečna kvadratna napaka kažejo absolutne vrednosti napake in so zato uporabni za ocenjevanje posameznega modela predvsem v primeru, da med seboj primerjamo različne modele oz. napovedi iz različnih modelov (Measures of Forecast Error, 2015). Kazalniki povprečna odstotna absolutna napaka, povprečna absolutna skalirana napaka in spremljanje pristranskosti napovedi pa kažejo relativno napako modela, slednji pa tudi smer napake in jih je mogoče uporabiti za ovrednotenje modela, neodvisno od drugih modelov (Measures of Forecast Error, 2015; Forecast Accuracy, 2016).

Povprečna napaka se izračuna kot (Blocher, et. al., 2004):

$$AE_n = \frac{1}{n} \sum_{i=1}^n E_i \quad (13)$$

pri čemer velja:

- AE_n je povprečna napaka v obdobju 1 do n ,
- n je število obdobji,
- i je obdobje,

- E_i je napaka v obdobju i .

Pristranskost napovedi oz. kumulativna napaka se izračuna kot (Blocher, et. al., 2004):

$$bias_n = \sum_{i=1}^n E_i \quad (14)$$

pri čemer velja:

- $bias_n$ je pristranskost napovedi za obdobja od 1 do n ,
- n je število obdobji,
- i je obdobje,
- E_i je napaka v obdobju i .

Pristranskost napovedi se uporablja za ugotavljanje sistemskih napak – seštevek pozitivnih in negativnih napak bi morala biti blizu nič, sicer je potrebno popraviti model (Blocher, et. al., 2004).

Povprečna absolutna napaka se izračuna kot (Blocher, et. al., 2004):

$$MAD_n = \frac{1}{n} \sum_{i=1}^n |E_i| \quad (15)$$

pri čemer velja:

- MAD_n je povprečna absolutna napaka za obdobja od 1 do n ,
- n je število obdobji,
- i je obdobje,
- $|E_i|$ je absolutna napaka v obdobju i .

Manjša kot je vrednost povprečne absolutne napake, bolj točna je napoved, pri čemer je točnost odvisna tudi od tega, kolikšne so vrednosti podatkov (Russell & Taylor, 1999). Če so napovedi oz. dejanski zneski visoki, je majhna povprečna absolutna napaka pokazatelj dobrega modela, če pa so napovedani in dejanski zneski zelo nizki, lahko tudi majhna absolutna napaka pomeni veliko napako modela (Russell & Taylor, 1999). Povprečna absolutna napaka je ena od najpogostejše uporabljenih mer pri primerjavi napovedi z različnimi modeli (Russell & Taylor, 1999).

Povprečna odstotna absolutna napaka se izračuna kot (Blocher, et. al., 2004):

$$MAPE_n = \frac{1}{n} \sum_{i=1}^n \left| \frac{E_i}{D_i} \right| \times 100 \quad (16)$$

pri čemer velja:

- $MAPE_n$ je povprečna odstotna absolutna napaka za obdobja od 1 do n ,
- n je število obdobji,
- i je obdobje,
- $\left| \frac{E_i}{D_i} \right|$ je absolutna vrednost napake v obdobju i nasproti dejanski vrednosti v obdobju i .

Zaradi upoštevanja napake kot odstotka dejanskih vrednosti, se povprečna odstotna absolutna napaka izogne problemu, ki ga ima povprečna absolutna napaka pri razlaganju točnosti napovedi zgolj na podlagi izračunanih vrednosti enega modela in omogoča lažjo interpretacijo rezultatov (Russell & Taylor, 1999).

Povprečna kvadratna napaka se izračuna kot (Blocher, et. al., 2004):

$$MSE_n = \frac{1}{n} \sum_{i=1}^n E_i^2 \quad (17)$$

pri čemer velja:

- MSE_n je povprečna kvadratna napaka za obdobja od 1 do n ,
- n je število obdobji,
- i je obdobje,
- E_i^2 je kvadratna napaka v obdobju i .

Kazalnik povprečna kvadratna napaka se uporablja tudi pri ocenjevanju regresijskih modelov (Blocher, et. al., 2004). Namesto, da bi samo seštevali napake, se tu napake kvadrirajo in šele nato seštejejo, kar da večjo težo napakam, ki so najdlje od dejanskih vrednosti (Blocher, et. al., 2004).

Kazalnik spremljanja pristranskosti napovedi se izračuna kot (Blocher, et. al., 2004):

$$TS = \frac{bias}{MAD} \quad (18)$$

pri čemer velja:

- TS je kazalnik spremljanja pristranskosti napovedi,
- $bias$ je pristranskost napovedi,
- MAD je povprečna absolutna napaka.

Kazalnik spremljanja pristranskosti napovedi se uporablja za ugotavljanje, ali model omogoča dovolj dobre napovedi, ali pa bi ga bilo potrebno spremeniti (Blocher, et. al., 2004). Različni avtorji navajajo različne empirično določene meje kazalnika, pri katerih naj bi bil model še uporaben – skrajne meje, pri katerih naj bi bil model še uporaben, se pri nekaterih avtorjih gibajo med -6 in +6, pri drugih pa med -2 in +2 (Blocher, et. al., 2004; Measures of Forecast Error, 2015; Russell & Taylor, 1999). Pozitivne vrednosti kazalnika pomenijo, da model podcenjuje vrednosti (dejanske vrednosti so višje od napovedi), negativne vrednosti pa pomenijo, da model precenjuje vrednosti (dejanske vrednosti so nižje od napovedi) (Russell & Taylor, 1999).

Povprečna absolutna skalirana napaka se izračuna kot (Hyndman & Koehler, 2006):

$$MASE_n = \frac{1}{n-1} \sum_{i=2}^n \left| \frac{E_i}{\frac{1}{i-1} \sum_{j=2}^i |Y_j - Y_{j-1}|} \right| \quad (19)$$

pri čemer velja:

- $MASE_n$ je povprečna absolutna skalirana napaka za obdobja od 1 do n
- n je število obdobj
- i je trenutno obdobje
- j je obdobja pred obdobjem i
- Y_j je dejanska vrednost v obdobju j
- E_i je napaka v obdobju i

Rezultat je od skale neodvisna (brez enote) mera, ki meri razmerje med dejanskimi napakami v napovedi od kumulativne napake, ki bi nastala z uporabo najbolj naivnega napovedovanja časovne vrste, kjer je napovedana vrednost časovnega zaporedja enaka dejanski vrednosti v predhodnem koraku (Hyndman & Koehler, 2006).

Poleg naštetih je znana tudi metoda **koren povprečne kvadratne napake**, ki je podobna povprečni absolutni napaki (Shcherbakov, et al., 2013):

$$RMSE_n = \sqrt{\frac{1}{n} \sum_{i=1}^n E_i^2} \quad (20)$$

pri čemer velja:

- $RMSE_n$ je koren povprečne kvadratne napake za obdobja od 1 do n
- n je število obdobj
- i je trenutno obdobje
- E_i je napaka v obdobju i

Obe metodi dajeta primerljive rezultate, vendar je v literaturi najti nesoglasja, katera metoda je boljša (Chai & Draxler, 2014). Koren povprečne kvadratne napake zaradi kvadriranja tudi bolj izpostavi večje napake. Ker pričakujemo posamezne večje odmihe, smo v tej nalogi uporabili povprečno absolutno napako namesto korena povprečne kvadratne napake.

V našem primeru smo za ugotavljanje točnosti napovedi modelov uporabili tri mere, in sicer povprečno absolutno napako, kazalnik spremljanja pristranskosti napovedi in povprečno absolutno skalirano napako. Povprečna absolutna napaka lepo kaže spreminjanje napake skozi čas in je primerljiva za modele znotraj skupine kupcev, ker pa so vrednosti absolutne, ni primerljiva za modele med različnimi skupinami kupcev, odvisna je namreč od višine zneskov izdanih računov. Za takšne primerjave se da lepo uporabiti povprečno absolutno skalirano napako, ki je neodvisna od velikosti zneskov. Kazalnik spremljanja pristranskosti napovedi smo uporabili zgolj, da bi preverili, ali so izbrani modeli dovolj dobri (ali je nihanje kazalnika dovolj majhno), da bi jih lahko uporabili za napovedovanje denarnega toka v praksi.

Kazalnik pristranskost napovedi v našem primeru ni tako pomemben, saj smo denarni tok z modeli napovedovali zgolj iz že izdanih faktur. To pa pomeni, da bi vrednosti takšnega kazalnika morale biti blizu nič, saj je večina računov sčasoma plačanih. Neplačanih ostane zgolj manjši del računov, ki predstavljajo slabe terjatve.

Prav tako v našem primeru nismo uporabili povprečne kvadratne napake, saj bi kvadriranje bolj izpostavilo večje napake. Pričakovali pa smo posamezne večje napake, kar pomeni, da povprečna kvadratna napaka ne bi prikazala realnega razmerja med modeli.

Povprečne odstotne absolutne napake pa nismo uporabili zaradi situacij, kjer je bil dejanski znesek denarnega toka 0, napovedan znesek pa različen od 0. V takšnih primerih bi po formuli prišlo do deljenja z 0, kar ni mogoče. Odločiti bi se bilo torej potrebno, ali se v takšnih primerih upošteva npr. 100 odstotna napaka. Problem te metode je tudi, da je lahko napaka 100 ali več odstotna tudi pri zelo majhnih zneskih, kar lahko bistveno poslabša

vrednosti kazalnika, kljub temu, da vrednosti takšnega denarnega toka na skupen denarni tok pravzaprav nimajo skoraj nikakršnega vpliva.

6 NAPOVEDOVANJE DENARNEGA TOKA V IZBRANEM PODJETJU

6.1 Načrtovanje denarnega toka in upravljanje z denarnimi sredstvi v izbranem podjetju

Izbrano podjetje prodaja storitve fizičnim osebam in podjetjem. Podjetje posluje v več državah. Funkcija zakladništva v podjetju je centralizirana v Sloveniji, kjer se planira denarni tok ter določa politiko upravljanja z denarnimi sredstvi. Glede na potrebe po denarnih sredstvih prihaja do prenosov denarnih sredstev med podružnicami, ki pa lahko trajajo nekaj časa, ter prinašajo določene stroške, zaradi poslovanja v različnih državah in z različnimi valutami. Avtomatskega združevanja denarnih sredstev pri bankah se zaenkrat ne uporablja.

Prodaja v podjetju precej variira glede na sezono, zato je planiranje denarnega toka odvisno od meseca in ni mogoče zgolj s preslikavo preteklih mesecev na bodoče. Prav tako je bil v preteklih letih v porastu tržni delež podjetja, kar pomeni, da je težko primerjati prodajo v preteklosti s trenutno prodajo oz. napovedovati denarni tok na podlagi preteklih let. Zaradi narave posla in poslovanja na trgu izvedenih finančnih instrumentov, kjer se določene pozicije dnevno vrednotijo, izbrano podjetje vedno vzdržuje tudi precej veliko varnostno zalogo denarnih sredstev.

Podjetje svoje kupce ločuje v skupine, glede na to ali gre za fizične ali pravne osebe in glede na njihovo velikost. Za različne skupine uporablja različne plačilne pogoje, za večje kupce pa spremlja tudi bonitetne ocene ter na njihovi podlagi določa kreditni limit. Ti podatki se spremljajo izven poslovno informacijskega sistema AX.

Izbrano podjetje svojim kupcem račune večinoma izstavlja obdobjno (mesečno). Račune pošilja fizično, vendar ima za fizične osebe omogočeno plačevanje preko direktnih obremenitev. Takšen način plačila podjetju zagotavlja zelo predvidljiv denarni tok, saj je velika večina računov, plačanih z direktno obremenitvijo, plačanih na rok. Izjema so le računi, pri katerih kupec v trenutku plačila na transakcijskem računu nima zadostnega zneska za pokritje računa.

Za terjatve, ki niso pravočasno plačane, vršijo v podjetju precej kompleksen postopek izterjave. Manjšim kupcem pošiljajo opomine (2 nivoja) in jih ob daljšem neplačilu predlagajo v izvršbo, izvedba katerih je prav tako podprta v AX. Za večje kupce vršijo tudi telefonsko izterjavo. Zamudne obresti obračunavajo na odprte in zaprte postavke.

Podjetje stroške in posledično odlive nadzoruje preko potrjevanja nabavnih naročil (nabavnih nalogov). Proračun sicer spremljajo, vendar ne vršijo kontrole proračuna pri naročanju, kar pomeni, da ob potrditvi s strani odgovorne osebe lahko proračun tudi prekoračijo. Podjetje svoje obveznosti večinoma plačuje na rok zapadlosti, uporablja pa tudi medsebojne kompenzacije, s katerimi minimizira stroške plačilnega prometa oz. potrebne prenose denarnih sredstev.

V primeru pomanjkanja likvidnostnih sredstev se podjetje običajno zadolžuje pri poslovnih bankah, v primeru presežkov likvidnostnih sredstev pa sredstva najpogosteje naloži v depozite. Podjetje posluje tudi na trgih izvedenih finančnih instrumentov, večinoma z namenom minimiziranja izpostavljenosti valutnemu tveganju.

6.1.1 Uporabljeni postopki in viri za napovedovanje denarnega toka

Izbrano podjetje planira denarni tok centralno za vse podružnice, in sicer v Sloveniji. Za napovedovanje uporablja metodo prejemkov in izdatkov, pri čemer se ne omejuje na fiksno obdobje napovedi. Razmeroma natančno napoved denarnega toka ima narejeno za mesec dni v naprej, vendar pa v napovedi vodi tudi vse planirane prilive in odlive za naprej. Napoved denarnega toka se pripravlja v Excelu, kjer se združuje različne vire podatkov. Podružnice podjetja za spremljanje poslovanja uporabljajo različne rešitve oz. programe, pa tudi slovensko podjetje ne uporablja samo enega programa. Združevanje podatkov je tako precej zahteven in zamuden posel, pri katerem sodeluje kar nekaj zaposlenih v podjetju.

Viri, ki se trenutno uporabljajo za napovedovanje denarnega toka:

- podatkovno skladišče, kamor črpajo podatke o pogodbah, ki jih sklepajo z večjimi kupci in dobavitelji za različne storitve;
- preglednice v Excelu, kamor v podjetju ročno vpisujejo:
 - pričakovane prilive iz naslova prodaje oz. terjatev za vse manjše kupce oz. maloprodajo (vnese neposredno v napoved denarnega toka oddelek zakladništva);
 - pričakovane odlive iz naslova obveznosti oz. naročila blaga in storitev (vnašajo jih vsi oddelki v podjetju);
 - pričakovane odlive iz naslova plač in potnih stroškov (javi računovodstvo, v zakladništvu se vnesejo neposredno v napoved denarnega toka);
 - pričakovane odlive iz naslova DDV (javi računovodstvo, v zakladništvu se vnesejo neposredno v napoved denarnega toka);
 - stanja na bančnih računih (vnese neposredno v napoved denarnega toka oddelek zakladništva vsako jutro);
 - depozite (vnese neposredno v napoved denarnega toka oddelek zakladništva);
 - kredite (vnese neposredno v napoved denarnega toka oddelek zakladništva);
 - devizne tečaje;

Pričakovane prilive za maloprodajo se večinoma planira na podlagi preteklih mesecev oz. na podlagi izkušenj zaposlenih v zakladništvu.

Stanja na bančnih računih, depozite in kredite se spremlja za posamezno državo, posamezen bančni račun in razdrobljeno po valutah. Pričakovane prilive in odlive iz poslovanja pa se spremlja po državah in valutah. Končni rezultat planiranja je napoved denarnega toka po državah in valutah po dnevih.

6.1.2 Viri, za napovedovanje denarnega toka, ki jih je mogoče nadomestiti z Microsoft Dynamics AX

Izbrano podjetje že nekaj let za spremljanje poslovanja v Sloveniji uporablja Microsoft Dynamics AX 2012 R2. V programu spremlja tudi veliko podatkov, ki jih je mogoče uporabiti za napovedovanje denarnega toka (podrobnejši opis posamezne funkcionalnosti je v poglavju 4.1):

- knjižene izdane račune oz. terjatve do kupcev;
- nabavna naročila;
- neknjižene prejete račune;
- knjižene prejete račune oz. obveznosti do dobaviteljev;
- bančne račune;
- zakladništvo (ga še ne spremljajo, vendar je v fazi vpeljave);
- potne naloge oz. obračune potnih stroškov;
- DDV.

6.1.2.1 Terjatve do kupcev

Podatki o terjativah do kupcev se v planu denarnega toka trenutno ne spremljajo na podlagi podatkov iz sistema AX. V načrtu denarnega toka se večje terjatve planira posamično preko sistema, kjer se spremljajo prodajne pogodbe, ki jih ima z njimi sklenjene podjetje. Za fizične osebe in druge manjše terjatve se plan dela z ročnim vnosom zneskov, glede na predvideno prodajo oz. glede na pretekle mesece in izkušnje zaposlenih v zakladništvu. Podatke bi podjetje sicer lahko pridobilo iz AX, vendar pa so ti podatki v AX zelo pozno – šele ko se knjižijo izdani računi. Ker roki zapadlosti izdanih računov niso zelo dolgi, bi to pomenilo, da bi bili plani, dokler se ne bi knjižili računi, precej netočni. Podjetje zato zaenkrat nima večjega interesa, da bi te zneske planiralo iz AX za kupce s katerimi sklepa pogodbe, medtem ko bi okvirne plane prodaje, ki jih upoštevajo kot predvidene prilive za manjše terjatve v določeni točki lahko nadomestili s podatki o izdanih računih v AX.

6.1.2.2 Nabavna naročila in obveznosti do dobaviteljev

Namesto ročnega vpisovanja podatkov o naročilih, lahko izbrano podjetje podatke za planiranje odlivov pridobi iz AX, z upoštevanjem naslednjih virov:

- nabavnih nalogov;
- neknjiženih prejetih računov;
- knjiženih prejetih računov oz. obveznosti do dobaviteljev (te vključujejo tudi obveznosti za izplačilo potnih stroškov zaposlenim, ki se sedaj spremljajo ločeno, in sicer z ročnim vnosom v načrt denarnega toka).

Pri upoštevanju navedenih virov, pa je potrebno paziti, da se izloči naslednje naloge in račune:

- vse naloge in račune s pogodbami, ki se jih spremlja v zunanjem sistemu, saj se te avtomatično prenašajo v napoved denarnega toka;
- vse naloge in račune, ki se nanašajo na podjetja v skupini, saj se ta med seboj pobotajo in do dejanskega prenosa sredstev običajno ne pride, razen ko gre za zagotavljanje sredstev drugi podružnici.

Za pridobitev podatkov smo zagnali obdelavo za preračun denarnega toka, nato pa izvozili vse podatke, ki so se nanašali na omenjene vire. Pri tem smo ugotovili, da so podatki v AX problematični. Zadnjih nekaj let, ko je bil AX v uporabi, se nabavnih nalogov ni sproti pregledovalo in zapiralo, kar je pomenilo, da je bilo kar nekaj nalogov, ki so ostali odprti ter so s tem še vedno vplivali na napoved denarnega toka. Določeni nalogi niso bili nikoli realizirani (ni bilo prevzema blaga ali storitev in računa), drugi nalogi pa so ostali v vmesnem statusu (bili so prevzeti, zanje pa ni bil knjižen račun). Vsi takšni nalogi so se upoštevali v napovedi denarnega toka poleg ostalih podatkov o aktualnih nabavnih nalogih, kar je kvarilo napoved. Vse naloge, ki niso bili niti prevzeti niti fakturirani, je bilo potrebno zapreti, za vse ostale naloge (v vmesni fazi) pa je bilo potrebno preveriti, kakšen je pravilen status, ter na podlagi tega izvesti ustrezno akcijo. Za določene naloge je bilo treba stornirati prevzem, ker je prišlo do napake pri prevzemu, za druge naloge pa knjižiti račun z zneskom nič. Slednje je npr. prišlo v poštev v primeru, da je bila določena storitev prevzeta na nabavnem nalogu, nato pa je bil prejeti račun knjižen mimo nabavnega naloga. V takšnem primeru je nalog ostal odprt, medtem ko je bil račun dejansko že knjižen.

Razčiščevanje nabavnih nalogov je povzročilo zamudo pri implementaciji uporabe podatkov iz AX.

6.1.2.3 Stanje na bančnih računih

Bančni izpiski se za slovensko podjetje v AX vsakodnevno uvažajo. Transakcije na bančnih računih se nato na podlagi sklicev povežejo z odprtimi terjatvami oz. na podlagi lastnih sklicev s pripravljenimi plačili obveznosti, ter se knjižijo. S tem se knjiži tudi stanje na bančnem računu, ki se ga lahko preveri v AX. Podjetje lahko stanje denarnih sredstev na bančnih računih zato pridobi iz AX s pomočjo poizvedbe ali pa s pomočjo planiranja denarnega toka v AX.

Pri spremljanju stanja na bančnih računih v AX pa se pojavi nekaj problemov. Prvi problem nastane pri uvozu izpiskov. Izpiski se v AX uvozijo zjutraj za transakcije, ki so se na bančnem računu zgodile prejšnji dan, kar pomeni, da podjetje tekom dneva ne vidi, kakšno je stanje na bančnem računu oz. mora zjutraj najprej v AX uvoziti bančne izpiske, preden lahko vidi stanje na bančnih računih.

Redko se tudi zgodi, da se vse transakcije na bančnih računih takoj poveže s kupci oz. odprtimi terjatvami v sistemu, kupci namreč pogosto plačujejo z napačnimi sklici, kar pomeni, da določene transakcije v izpisku ostajajo odprte dlje časa (dokler se ne ugotovi na katerega kupca se nanaša plačilo). To posledično pomeni, da stanja o stanju na bančnem računu ni mogoče črpati iz samega bančnega računa, ker je tam pravilno stanje zabeleženo prepozno, pač pa so vir podatkov lahko zgolj uvoženi bančni izpiski, v katerih je zabeleženo kakšno je stanje denarnih sredstev na bančnem računu po izvedenih transakcijah, ki jih izpisek vsebuje.

Problem predstavljajo tudi bančni računi, ki so odprti pri bankah v tujini in za katere uvoz transakcij ni urejen. Za takšne bančne račune je stanje v AX pravilno šele, ko uporabniki ročno vnesejo in knjižijo transakcije, ki so se izvedle preko takšnega bančnega računa.

Končno pa v AX ni mogoče spremljati stanja na bančnih računih za podjetja, ki trenutno uporabljajo drug poslovno informacijski sistem.

Iz vsega naštetega sledi, da je AX pri določitvi stanja na bančnem računu lahko kvaliteten vir podatkov za slovensko podjetje (in nekaj podružnic, ki tudi že uporabljajo AX), za vse bančne račune, za katere se podatki uvažajo (trenutno za bančne račune v Sloveniji), pri čemer je potrebno črpati podatke o stanju iz izpiskov. Proces uvoza podatkov pa lahko nekoliko izboljša uporaba sistema »European gate« oz. uporaba SWIFT sistema za izmenjavo podatkov, ki lahko omogoči avtomatske uvoze stanja na bančnih računih tudi za ostale banke slovenskega podjetja.

SWIFT (Society for Worldwide Interbank Financial Telecommunications) je mreža, za standardizirano pošiljanje podatkov oz. navodil, ki jo uporabljajo finančne institucije (Shobhit, 2016). SWIFT dodeli vsaki finančni organizaciji unikatno šifro, preko katere se

prenašajo sporočila o prenosih denarja (Shobhit, 2016). SWIFT sistema pa ne uporabljajo samo banke, ampak tudi borze, korporativna podjetja in drugi (Shobhit, 2016). Formata, ki se uporabljata za sporočanje podatkov o plačilih (bančni izpisek) v SWIFT sistemu sta MT940 (dnevni promet) in MT942 (promet dela dneva).

Banka Unicredit podjetjem ponuja storitev »European gate«, ki je namenjena podjetjem s podružnicami v tujini, ki želijo centralizirati plačilno funkcijo (European Gate Unicredit Bank, 2016). Storitve omogoča, da podjetje pridobi podatke o plačilih (bančne izpiske) iz različnih virov (bank) v enotni strukturi za vse bančne račune, in sicer v strukturi, ki jo sicer uporablja SWIFT, to je formatu MT940 ali MT942. To pa omogoča standardizirano obdelavo podatkov. Izbrano podjetje je v fazi implementacije tega sistema, kar mu bo omogočalo ažurno spremljanje stanja na bančnih računih v poslovno informacijskem sistemu ter prenos stanja v preglednico za napoved denarnega toka, namesto sedanjega, ročnega vnosa podatkov v preglednico.

6.1.2.4 Zakladništvo

V napovedi denarnega toka se ročno spremlja kredite, depozite in druge finančne instrumente. Uporaba zakladništva znotraj AX bi omogočila avtomatičen izvoz podatkov o predvidenih prilivih in odlivih iz naslova kreditov in depozitov. Podjetje že dlje časa planira uporabo modula zakladništvo znotraj AX, vendar zaradi dodatnih zahtev pri uporabi funkcionalnosti do realizacije tega še ni prišlo. Plan je, da se zakladništvo prične uporabljati v kratkem, kar bo omogočilo izvoz podatkov, namesto ročnih vnosov v načrt denarnega toka.

6.1.2.5 Obračuni potnih stroškov

V napovedi denarnega toka se trenutno ročno spremlja predvidene potne stroške. Potne stroške, ki so bili že obračunani, ne pa še knjiženi (čakajo na obdelavo v računovodstvu), bi se lahko spremljalo iz AX. Ko so obračuni potnih stroškov knjiženi, pa se v AX zabeležijo kot obveznost do dobaviteljev oz. zaposlenih, kar pomeni, da jih lahko spremljamo ter zanje napovedujemo odlive na enak način, kot za ostale obveznosti.

6.1.2.6 DDV

Za vse knjižene in neknjižene izdane in prejete račune ter tudi nabavne naloge, se v napovedi denarnega toka v AX izračuna predvideni znesek za plačilo DDV-ja. Plačilo DDV-ja izbrano podjetje v načrtu denarnega toka trenutno načrtuje ročno. Kot vir podatkov bi lahko uporabilo AX, ki bi bil kljub morebitnemu poznemu knjiženju določenih računov, še vedno dovolj dober vir za napoved plačila za DDV, saj se plačilo izvede šele konec meseca za račune, ki se vsebinsko nanašajo na pretekli mesec.

6.2 Napovedovanje denarnega toka iz naslova terjatev z uporabo metod strojnega učenja

Napovedovanje denarnega toka iz naslova terjatev je trenutno vezano na ocene zaposlenih v zakladništvu in na okvirne zneske obračunov. Bolj natančno se planirajo samo večji zneski iz naslova sklenjenih pogodb. Za bolj natančno planiranje bi lahko kot vir vzeli podatke iz AX, vprašanje pa je, ali so podatki o tem, na kateri dan zapade kakšen znesek izdanih računov, dovolj dobri za kvalitetno napoved denarnega toka. Napoved denarnega toka iz izdanih računov smo zato poskušali napovedati z uporabo strojnega učenja, in sicer po posamičnem izdanem računu.

Vsak račun je bil z uporabo metod strojnega učenja, opisanih v predhodnih poglavjih, razvrščen v eno izmed kategorij zamude. Nato smo kategorije prevedli na pričakovan dan plačila. Poleg tega smo za primerjavo denarni tok sočasno napovedali tudi z uporabo podatkov datum zapadlosti in povprečno število dni zamude za do sedaj plačane račune.

6.2.1 Priprava podatkov

Podatki za napovedovanje denarnega toka iz naslova terjatev so bili izvoženi iz AX iz terjatev do kupcev (oz. iz knjiženih izdanih računov) ter iz podatkov na karticah kupcev, s pomočjo SQL poizvedbe (strukturirani povpraševalni jezik za delo s podatkovnimi bazami) nad AX bazo.

Izvoženi so bili vsi knjiženi izdani računi, od 1.1.2015 naprej, ki so že bili plačani. Za račune, ki še niso bili plačani, ni mogoče reči, kolikšna bo zamuda pri plačilu oz. iz njihovih podatkov ni mogoče potegniti nikakršnih spoznanj, zato v analizi niso bili upoštevani.

Upoštevani so bili samo računi, ki so bili zaprti s postavko tipa plačilo. To je bilo potrebno zaradi izločitve poračunov, ki se v programu knjižijo kot dobropisi ter zapirajo račune ter zaradi izločitve raznih drugih preknjižb. Upoštevanje teh bi kvarilo statistiko plačil, saj se zapiranja takšnih listin običajno v programu knjižijo na datum knjiženja računa in ne kažejo vzorcev plačevanja kupcev.

Upoštevani so bili samo računi, ki so bili zaprti z eno samo postavko. Ta pogoj je izločil izdane račune, ki so bili plačani v več obrokih. Pri pregledovanju podatkov smo ugotovili, da se je obroke velikokrat kreiralo naknadno, kot del sheme za odplačilo dolga stranke, in da se je v takšnem primeru s tem spremenilo datume zapadlosti računov, ki so imeli originalno drugačen datum zapadlosti. Takšnih računov zato ni bilo smiselno upoštevati v izračunih.

Dodatno so bili izločeni še računi, pri katerih se datum zapadlosti na terjatvi ni ujemal z datumom zapadlosti na odprtem deležu postavke, kar je pomenilo še izločitev drugih računov, kjer se je datum zapadlosti naknadno spreminjal (neposredno na terjatvi spreminjanje datuma zapadlosti po knjiženju računa ni mogoče, mogoče pa je spreminjanje datuma zapadlosti na odprtem deležu terjatve v drugi tabeli).

Nazadnje pa so bili izločeni še računi, pri katerih je bil datum plačila manjši od datuma dokumenta na izdanem računu. Ta pogoj je izločil račune, ki so bili takoj delno ali v celoti zaprti s preplačili – pogosto se namreč zgodi, da kupci plačajo napačne zneske (npr. višji znesek iz preteklega meseca), ki se nato koristijo za zapiranje terjatev v naslednjem mesecu - kar bi zopet lahko kvarilo statistiko vzorcev plačevanja.

Vzorec izvoženih podatkov je bil kljub izločitvi nekaterih računov zelo velik in je obsegal 96,2 odstotka vseh izdanih, že zaprtih (plačanih) računov. Približno tretjina računov je bila označena za plačilo s Sepa direktno obremenitvijo. Te račune smo izločili iz nadaljnjih izračunov, saj je velika večina takšnih računov plačanih na datum zapadlosti. Račun, ki je označen za plačilo s Sepa direktno obremenitvijo ni plačan samo v primeru, da kupec na računu nima dovolj sredstev za pokritje računa. Na datum zapadlosti je bilo v letu 2015 plačanih 98,55 odstotka računov, označenih za plačilo z direktno obremenitvijo, v prvem tednu po zapadlosti pa še 0,37 odstotka takšnih računov. Napovedovanje denarnega toka s kakršnokoli drugačno metodo kot na datum zapadlosti zato ni imelo pravega smisla.

Podatke, ki so bili izvoženi, ter izračunani pri izvozu iz AX baze, prikazuje Tabela 4.

Tabela 4: Podatki iz AX, uporabljeni pri napovedovanju denarnega toka iz izdanih računov

Podatek	Opis podatka
Številka kupca	Številka kupca iz AX.
Datum računa	Datum dokumenta za vse račune, ki imajo datum dokumenta vnesen, za ostale račune pa datum knjiženja v glavno knjigo (to je vsebinsko datum opravljene storitve).
Znesek računa	Znesek izdanega računa.
Datum zapadlosti	Rok za plačilo računa.
Način plačila	Vsebuje podatek o tem, ali kupec plačuje z direktnimi obremenitvami.
Plačilni pogoji	Plačilni pogoji so izračunani kot razlika med datumom zapadlosti in datumom računa.
Klasifikacija za fakturiranje	Klasifikacija za fakturiranje se uporablja za ločitev različnih vrst faktur – izbrano podjetje jo uporablja predvsem za ločevanje med kupci (računi, namenjeni manjšim kupcem imajo drugačno klasifikacijo za fakturiranje kot računi, namenjeni večjim kupcem).
Dan v tednu, ko zapade račun	Podatek o tem, kateri dan v tednu (od 1 do 7 oz. od ponedeljka do nedelje) zapade račun.

(se nadaljuje)

(nadaljevanje)

Podatek	Opis podatka
Zamuda pri plačilu za račun	Zamuda pri plačilu za posamičen račun, izračunana kot razlika med datumom plačila in datumom zapadlosti računa.
Datum plačila računa	Datum, ko je bil posamičen račun plačan.
Število predhodno izdanih računov	Število računov, ki so bili izdani, preden je bil izdan račun na katerega se nanaša zapis.
Vsota predhodno izdanih računov	Vsota računov, ki so bili izdani, preden je bil izdan račun, na katerega se nanaša zapis.
Število predhodno izdanih računov, ki so bili plačani	Število računov, ki so bili izdani, preden je bil izdan račun, na katerega se nanaša zapis in so že bili plačani.
Vsota predhodno izdanih računov, ki so bili plačani	Vsota računov, ki so bili izdani, preden je bil izdan račun, na katerega se nanaša zapis in so že bili plačani.
Povprečno število dni zamude predhodno izdanih računov, ki so bili plačani	Povprečno število dni zamude računov, ki so bili izdani, preden je bil izdan račun, na katerega se nanaša zapis in so že bili plačani.
Število predhodno izdanih računov, ki so bili plačani prepozno	Število računov, ki so bili izdani, preden je bil izdan račun, na katerega se nanaša zapis in so že bili plačani, vendar prepozno.
Vsota predhodno izdanih računov, ki so bili plačani prepozno	Vsota računov, ki so bili izdani, preden je bil izdan račun, na katerega se nanaša zapis in so že bili plačani, vendar prepozno.
Povprečno število dni zamude predhodno izdanih računov, ki so bili plačani prepozno	Povprečno število dni zamude računov, ki so bili izdani, preden je bil izdan račun, na katerega se nanaša zapis in so že bili plačani, vendar prepozno.
Število predhodno izdanih računov, ki še niso bili plačani, a so že v zamudi	Število računov, ki so bili izdani, preden je bil izdan račun, na katerega se nanaša zapis, so že zapadli, in še niso bili plačani.
Vsota predhodno izdanih računov, ki še niso bili plačani, a so že v zamudi	Vsota računov, ki so bili izdani, preden je bil izdan račun, na katerega se nanaša zapis in še niso bili plačani.

Poleg podatkov, navedenih v Tabela 4, smo v enem od poskusov izboljšave napovedi izvozili tudi podatke o kombinacijah dneva v tednu in dneva v mesecu, ko so bili plačani posamezni računi, ter to dodali kot vir podatkov v izračun algoritmu odločitvenemu drevesu. Vendar so bili rezultati slabši kot zgolj z uporabo zgoraj navedenih parametrov, zato smo podatke v nadaljnjih izračunih opustili.

6.2.2 Uporabljene metode izračuna pričakovanega denarnega toka iz izdanih računov

6.2.2.1 Uporabljene metode napovedi

Najpreprostejša metoda, ki jo lahko uporabijo podjetja, ki napovedujejo denarni tok z metodo prejemkov in izdatkov, je napoved na podlagi datuma zapadlosti, ki ne zahteva nikakršnih podatkov o kupcih. Zato smo napoved denarnega toka na podlagi datumov

zapadlosti posameznih terjatev vzeli kot osnovo, s katero smo nato primerjali ostale izračune.

Pri izvozu podatkov iz AX smo za vsak račun izračunali tudi povprečno število dni zamude predhodno izdanih računov za posamičnega kupca. To nam je omogočilo napoved denarnega toka z upoštevanjem povprečne zamude pri plačilu. Napoved na podlagi povprečnega števila dni zamude zahteva pretekle podatke o plačilni disciplini kupcev – če pretekli podatki ne obstajajo oz. gre za kupce, katerim račune izdajamo prvič, je napoved enaka kot napoved na podlagi datuma zapadlosti.

Manipulacije podatkov smo izvedli s programskim paketom R, saj je bila količina podatkov prevelika za obravnavo v Excelu. Napoved smo nato prenesli v Excel, sešteto na dnevnem in tedenskem nivoju, kjer smo lahko izračunali kazalnike, ki so nam omogočili primerjavo različnih uporabljenih metod.

Za napoved denarnega toka smo nato uporabili Microsoft Azure Machine Learning, in sicer metode odločitveni gozd, nevronske mreže in logistično regresijo. Izkazalo se je, da je razmeroma kvalitetno napoved nemogoče narediti na podatkih o vseh računih. Velika količina podatkov iz naslova prodaje fizičnim osebam je namreč povsem zakrila vzorce plačevanja podjetij. Algoritmi so denarni tok večinoma napovedali v enem razredu, kar je pomenilo povsem nerealne napovedi. Ugotovili smo, da vzorec podatkov vsebuje manjši del poslovnih partnerjev, kjer so bili zneski terjatev visoki in večji del terjatev fizičnih oseb, kjer so bili zneski terjatev večinoma majhni. Algoritmi strojnega učenja v množici podatkov niso razločili vzorcev plačevanja podjetij. V nadaljevanju smo zato podatke razbili na dva dela – na poslovne partnerje (podjetja) in fizične osebe. Rezultati napovedi z algoritmi strojnega učenja so se s tem precej izboljšali, predvsem za pravne osebe, medtem ko so napovedi za fizične osebe ostale razmeroma slabe.

Za namene primerjave podatkov iz napovedi na podlagi datuma zapadlosti in na podlagi povprečnega števila dni zamude pri plačilu iz preteklih računov, je bilo potrebno tudi izračune teh pripraviti ločeno za račune za podjetja in račune za fizične osebe.

Denarni tok smo z algoritmi strojnega učenja sprva poskušali napovedati na dnevnem nivoju, vendar smo zaradi slabih rezultatov kasneje napoved spremenili v napovedovanje z razredi. Razrede smo sprva postavili na mesečnem nivoju – plačane do roka, zamuda 30 dni, zamuda 60 dni, zamuda 90+ dni - kjer so se napovedi izkazale za precej boljše, nato pa smo mesec razbili še na približno tedenski nivo, kar je še vedno dalo zadovoljive rezultate. Zato smo vse nadaljnje napovedi izvedli z upoštevanjem slednjih razredov. Mesečno planiranje namreč za podjetje ni tako aktualno, saj prilive in odlive sicer planirajo na dnevnem nivoju. Iz razredov smo pričakovan dan plačila določili po dveh metodah – z upoštevanjem zadnjega dneva razreda in z upoštevanjem sredinskega dneva razreda.

6.2.2.2 Struktura delovnega toka za preračun napovedi denarnega toka s strojnim učenjem

Delovni tok (v terminologiji Azure Machine Learning *eksperiment*), ki smo ga uporabili v končni napovedi, je vseboval korake, ki jih prikazuje Slika 11.

V 1. koraku smo v eksperiment pripeljali podatke o računih (fakture_nosdd_data.csv). V 2. koraku smo filtrirali račune (pravne ali fizične osebe) ter izračunali kazalnike, ki jih prikazuje Tabela 5 (Execute R Script).

Tabela 5: Podatki, izračunani iz podatkov v AX, uporabljeni za napoved denarnega toka iz izdanih računov

Podatek	Opis podatka
Kazalnik 1	Število predhodno izdanih računov, ki so bili plačani / število predhodno izdanih računov.
Kazalnik 2	Število predhodno izdanih računov, ki so bili plačani prepozno / število predhodno izdanih računov.
Kazalnik 3	Število predhodno izdanih računov, ki še niso bili plačani, a so že v zamudi / število predhodno izdanih računov.
Kazalnik 4	Vsota predhodno izdanih računov, ki so bili plačani / vsota predhodno izdanih računov.
Kazalnik 5	Vsota predhodno izdanih računov, ki so bili plačani prepozno / vsota predhodno izdanih računov.
Kazalnik 6	Vsota predhodno izdanih računov, ki še niso bili plačani, a so že v zamudi / vsota predhodno izdanih računov.

V 3. koraku (Group Data Into Bins) smo določili razrede, v katere smo želeli napovedati plačila. Strojno učenje smo zagnali z različnimi razredi. Natančnost modela se je večala, če smo postavili širše meje razredov, vendar pa je širjenje meja razredov pomenilo manjši doprinos modela k napovedi denarnega toka. Podjetje namreč denarni tok planira na dnevnem nivoju. Ker na dnevnem nivoju ni bilo mogoče dobiti zadovoljivih rezultatov modela, smo za končni izračun, katerega rezultati so predstavljeni v nadaljevanju, postavili meje:

- razred 1 (vrednost 1): računi, za katere je napovedano, da bodo plačani na datum zapadlosti ali prej – plačilo takšnih računov je predvideno na datum zapadlosti;
- razred 2 (vrednost 8): računi, za katere je napovedano, da bodo plačani med 1. in 7. dnem po datumu zapadlosti – plačilo takšnih računov je po prvi metodi predvideno na 7. dan in po drugi metodi na 4. dan;
- razred 3 (vrednost 15): računi, za katere je napovedano, da bodo plačani med 8. in 14. dnem po datumu zapadlosti – plačilo takšnih računov je po prvi metodi predvideno na 14. dan in po drugi metodi na 11. dan;


- razred 4 (vrednost 23): računi, za katere je napovedano, da bodo plačani med 15. in 22. dnem po datumu zapadlosti – plačilo takšnih računov je po prvi metodi predvideno na 22. dan in po drugi metodi na 18. dan;
- razred 5 (vrednost 30): računi, za katere je napovedano, da bodo plačani med 23. in 29. dnem po datumu zapadlosti – plačilo takšnih računov je po prvi metodi predvideno na 29. dan in po drugi metodi na 26. dan;
- razred 6 (vrednost 38): računi, za katere je napovedano, da bodo plačani med 30. in 37. dnem po datumu zapadlosti – plačilo takšnih računov je po prvi metodi predvideno na 37. dan in po drugi metodi na 33. dan;
- razred 7 (vrednost 45): računi, za katere je napovedano, da bodo plačani med 38. in 44. dnem po datumu zapadlosti – plačilo takšnih računov je po prvi metodi predvideno na 44. dan in po drugi metodi na 41. dan;
- razred 8 (vrednost 53): računi, za katere je napovedano, da bodo plačani med 45. in 52. dnem po datumu zapadlosti – plačilo takšnih računov je po prvi metodi predvideno na 52. dan in po drugi metodi na 48. dan;
- razred 9 (vrednost 60): računi, za katere je napovedano, da bodo plačani med 53. in 59. dnem po datumu zapadlosti – plačilo takšnih računov je po prvi metodi predvideno na 59. dan in po drugi metodi na 56. dan;
- razred 10 (vrednost 68): računi, za katere je napovedano, da bodo plačani med 60. in 67. dnem po datumu zapadlosti – plačilo takšnih računov je po prvi metodi predvideno na 67. dan in po drugi metodi na 63. dan;
- razred 11 (vrednost 75): računi, za katere je napovedano, da bodo plačani med 68. in 74. dnem po datumu zapadlosti – plačilo takšnih računov je po prvi metodi predvideno na 74. dan in po drugi metodi na 71. dan;
- razred 12 (vrednost 84): računi, za katere je napovedano, da bodo plačani med 75. in 83. dnem po datumu zapadlosti – plačilo takšnih računov je po prvi metodi predvideno na 83. dan in po drugi metodi na 79. dan;
- razred 13 (vrednost 90): računi, za katere je napovedano, da bodo plačani med 84. in 89. dnem po datumu zapadlosti – plačilo takšnih računov je po prvi metodi predvideno na 89. dan in po drugi metodi na 86. dan;
- razred 14 (nad 90): računi, za katere je napovedano, da bodo plačani od 90. dne po datumu zapadlosti naprej – plačilo takšnih računov je predvideno na 365. dan oz. jih ne planiramo v letu, za katerega smo pripravljali napoved.

V 4. koraku (Split Data) smo definirali odstotek podatkov namenjen učenju modela oz. odstotek podatkov, namenjen izvedbi analize z modelom, ter preverjanju rezultatov modela. Podatke je program (glede na definirane odstotke) naključno razporedil – 50 odstotkov računov se je uporabilo za učenje, 50 odstotkov računov pa za ugotavljanje točnosti modela.

V 5. koraku (Execute R Script) smo podatke v višjih razredih pomnožili, da bi vsaj delno uravnotežili razmerja v razredih. To pomeni, da smo namesto enega računa naredili nekaj

enakih računov in s tem umetno povečali število računov v podatkih. Število računov v razredih 4 do 9 smo pomnožili s faktorjem 5, število računov v razredih 10 do 14 pa s faktorjem 10. Problem višjih razredov je namreč v tem, da je podatkov, ki spadajo vanje, zelo malo, zato obstaja nevarnost, da pri učenju modelov lastnosti teh razredov izrinejo lastnosti pretežnega deleža podatkov, torej računi iz nižjih razredov. Umetno povečanje števila zapisov, ki sodijo v te razrede, lahko poveča natančnost modela, saj se lahko ta uči na večjem vzorcu. Poenostavljeno lahko rečemo, da tako model manj pogoste primere obravnava večkrat, in si jih zato lažje zapomni.

Slika 11: Koraki pri napovedi denarnega toka z algoritmi strojnega učenja



V 6. koraku (Edit Metadata) smo oblikovali podatke in določili podatke, na podlagi katerih je bil izračunan model. V model za pravne osebe smo vključili tudi številko kupca, medtem ko smo v modelu za fizične osebe ta podatek opustili zaradi velike količine podatkov. Po prvih izkušnjah smo izločili tudi podatka o znesku računa in povprečno število dni zamude predhodno izdanih računov, ki so bili plačani, ker je izločitev teh podatkov izboljšala točnost napovedi.

V 7. koraku smo izbrali algoritem za izračun. Na sliki je izbran algoritem odločitveni gozd (Multiclass Decision Forest). V tem primeru je bilo potrebno določiti tudi maksimalno število odločitvenih dreves (28 dreves) in največjo globino dreves (48 nivojev). Te številke je predlagala funkcija Tune Model Hyper Parameters, ki predlaga optimalne količine in globine dreves z uporabo nekaj naključnih izborov parametrov algoritma (funkcija omogoča tudi sistematični sprehod po prostoru vseh parametrov, vendar je čas potreben za tako iskanje zelo dolg) in izvedbe N-kratne navzkrižne validacije (privzeto $N = 10$) nad takim modelom.

V 8. koraku (Train Model) smo določili spremenljivko za napovedovanje (zamuda pri plačilu za račun) in izvedli učenje modela na prvi polovici podatkov. V 9. koraku (Score Model) smo izvedli izračun na drugi polovici podatkov. V 10. koraku pa smo izvedli ocenjevanje modela. Ocenjevanje modela Microsoft Azure machine learning izvede preko izračuna skupne točnosti napovedi ter povprečne točnosti napovedi.

6.2.3 Rezultati napovedi denarnega toka s pomočjo različnih modelov

6.2.3.1 Primerjava rezultatov algoritmov strojnega učenja za napoved denarnega toka pri poslovanju s podjetji

Med uporabljenimi algoritmi strojnega učenja se je najbolje obnesel odločitveni gozd. Rezultati logistične regresije in nevronske mreže so bili precej slabši, zato smo v nadaljevanju za primerjave z ostalimi napovedmi (na podlagi datuma zapadlosti in povprečnega števila dni zamude pri plačilu) uporabili zgolj rezultate odločitvenega gozda. Tabela 6 kaže primerjavo rezultatov navedenih algoritmov, na podatkih plačil za podjetja.

Tabela 6: Primerjava rezultatov pri napovedi denarnega toka iz računov za podjetja z algoritmi strojnega učenja

Algoritem	Skupna točnost napovedi (v odstotkih)
Odločitveni gozd	85,11
Logistična regresija	43,46
Nevronske mreže	43,38

S pomočjo odločitvenega gozda smo dobili napoved, ki je bila točna v 85,11 odstotkih primerov, kar pomeni, da je bilo 85,11 odstotkov računov plačanih v razredu, v katerem je to predvidel naučeni model odločitvenega gozda. Napoved logistične regresije je bila točna v 43,46 odstotkih primerov in napoved nevronske mreže v 43,38 odstotkih primerov. Kot rezultat modela, oz. za lažjo vizualno predstavitev rezultatov, Microsoft Azure Machine Learning v koraku ocenitve modela izriše tudi matriko zmedenosti (angl. *confusion matrix*), ki podrobno prikazuje podatke o tem, kolikšen odstotek računov, katerih plačilo je bilo predvideno v nekem razredu, je bilo plačano v katerem od razredov. Matrike za vse 3 uporabljene algoritme so v Prilogah 1 do 3. Iz matrik je razvidno, da je logistična regresija napačno napovedala večjo količino plačil v zadnjem razredu (torej nad 90 dni), nevronske mreže pa so napačno večino plačil napovedale v petem razredu (od 23 do 29 dni po zapadlosti). Matrika je precej bolj enakomerna pri odločitvenem gozdu, ki se je pri napovedi tudi najbolj odrezal.

To je možno razložiti na podlagi dejstva, da so modeli z odločitvenimi drevesi v veliki meri neodvisni od načina zapisa podatkov. Uporabijo se lahko absolutni zneski, razmerja, nizi znakov. Pri uporabi nevronske mreže je priporočljivo vhodne podatke normalizirati. Algoritem sam omogoča uporabo nekaj postopkov – uskupinjevanje (angl. *binning*), prevedba na standardno porazdelitev (angl. *Gaussian normalizer*), prevedba na razpon od 0 do 1 (angl. *min-max normalizer*). Tekstovne oznake (npr. klasifikacija fakture) se prevede v N stolpcev z vrednostjo 0 ali 1 (npr. KLASIFIKACIJA_A, KLASIFIKACIJA_B itd.). Kljub temu, da smo se poskusili izogniti uporabi zneskov (za razliko od prej omenjenih koeficientov) in uporabi prej omenjene pretvorbe tekstovnih oznak v dodatne stolpce pri učenju nevronske mreže, nismo uspeli povečati točnosti napovedi.

6.2.3.2 Vizualizacija napovedi z odločitvenim gozdom

Napoved denarnega toka iz izdanih računov na podlagi odločitvenega gozda je bila narejena s pomočjo 28-ih odločitvenih dreves, ki so ta gozd sestavljala. Za vsak izdani račun se je izračunal predvideni rezultat preko vsakega od izračunanih odločitvenih dreves. Nato so se verjetnosti za posamičen rezultat (te so enakomerno utežene za vsa odločitvena drevesa) zapisale v tabelo. Plačilo posamičnega računa je bilo napovedano v razredu, katerega je kot končni rezultat dobilo največje število odločitvenih dreves v gozdu oz. tisti razred, kjer je bila verjetnost najvišja. Vizualizacija enega od odločitvenih dreves v odločitvenem gozdu z razlago poti je predstavljena v Prilogi 7. V Prilogi 8 pa je slika izbora razreda za posamičen račun. V vrstici se nahajajo posamezni računi, v stolpcih pa razredi. Za vsak račun so zapisane verjetnosti, da bo ta plačan v določenem razredu ter končni izbor razreda.

6.2.3.3 Primerjava napovedi z odločitvenim gozdom in drugimi metodami za podjetja

Napoved denarnega toka za podjetja, ki smo jo dobili z uporabo algoritmov strojnega učenja, bolj natančno odločitvenega gozda, smo primerjali z metodami, ki jih je mogoče uporabiti v

preglednicah. Takšni metodi sta napoved denarnega toka na datum zapadlosti in napoved denarnega toka glede na povprečno število dni zamude pri plačilu predhodno izdanih in že plačanih računov. Gre za podatke, ki smo jih sicer vključili tudi v nabor podatkov za izračun napovedi denarnega toka s strojnimi učenjem. Pri napovedi denarnega toka na datum zapadlosti smo predvideli, da bo račun plačan na datum zapadlosti. Za namene napovedi denarnega toka glede na povprečno število dni zamude pri plačilu prejšnjih računov, pa smo za vsak račun izvozili podatek o tem, kolikšna je bila povprečna zamuda pri plačilu predhodno izdanih računov za vse že plačane račune tega kupca, nato smo ta podatek prišteli k datumu zapadlosti računa.

Za primerjavo so bili uporabljeni samo računi, ki v procesu učenja modelov strojnega učenja niso bili del nabora podatkov, nad katerimi je bilo izvajano učenje. Podatke o računih, ki so bili uporabljeni za testiranje točnosti modela odločitvenega gozda, ne pa tudi za učenje modela, smo izvozili iz »Microsoft Azure Machine Learning« po izvedenih izračunih. Dejanski denarni tok je rekonstruiran iz podatkov o dejanskih plačilih teh računov.

Primerjavo napovedi smo izvedli v Excelu. Napoved denarnega toka za posamične račune za podjetja, ki smo jih dobili z odločitvenim gozdom, smo sešteli po dnevih, da smo dobili pričakovani denarni tok na dnevnem nivoju. Kot že omenjeno, je datum pričakovanega denarnega toka računa enak datumu zapadlosti in pričakovani zamudi glede na napovedan razred zamude, z uporabo dveh metod – na zadnji dan razreda in na srednji dan razreda. Denarni tok na dnevnem nivoju smo naredili tudi za napovedi na podlagi datuma zapadlosti ter za napovedi na podlagi povprečnega števila dni zamude.

Zneski so v vseh prikazih zaradi zagotavljanja zaupnosti podatkov pomnoženi s faktorjem.

Pri vseh metodah smo datume predvidenega plačila iz konca tedna (sobota, nedelja) predstavili na petek. Nismo pa upoštevali praznikov v Sloveniji ali drugih dni, na katere ne deluje plačilni promet (t.i. TARGET2 prazniki, npr. petek pred veliko nočjo).

Tabela 7: Prikaz glavnih kazalnikov za napoved denarnega toka na dnevnem nivoju


Metoda	Povprečna abs. napaka (v EUR)	Kazalnik spr. pristr. napovedi	Povprečna abs. sk. napaka (brez enote)
Datum zapadlosti	15.370,99	3,14	1,69
Povprečna zamuda	14.741,94	-10,52	1,62
Modelska napoved – zadnji dan	12.344,98	-0,60	1,46
Modelska napoved – srednji dan	14.538,16	-0,07	1,57

Za vse napovedi smo za napoved preko celotnega leta izračunali kazalnike povprečno absolutno napako, kazalnik spremljanja pristranskosti napovedi in povprečno absolutno

skalirano napako. To nam je omogočilo primerjavo modelov. Rezultate za podjetja pri planiranju na dnevnem nivoju na zadnji dan v letu 2015 prikazuje Tabela 7. Najlažja primerjava je preko povprečne absolutne skalirane napake, ker je količina brez enote in ni potrebne primerjave z drugim zneskom v EUR.

Slika 12 prikazuje primerjavo povprečnih absolutnih napak modelov za napoved denarnega toka za podjetja na dnevnem nivoju. Najslabše rezultate je dala napoved na datum zapadlosti, najboljše pa napoved z odločitvenim gozdom in upoštevanjem plačil na zadnji dan razreda napovedi. Absolutna napaka pri vseh napovedih je septembra močno porasla zaradi začetka spremljanja prodaje nekaterih storitev znotraj sistema AX.


Slika 12: Primerjava povprečne absolutne napake za napovedi denarnega toka za podjetja na dnevnem nivoju (od 1.1.2015 do datuma) v EUR




Izračun kazalnika spremljanja pristranskosti napovedi je pokazal, da je napoved na dnevnem nivoju zelo nenatančna in da niti en od uporabljenih modelov ni dovolj dober za točne napovedi denarnega toka na dnevnem nivoju. Vrednosti kazalnikov pri vseh modelih skoraj ves čas presegajo vrednost +6 ali -6, kjer je skrajna meja, ko model še lahko smatramo za ustreznega, razen v poletnih mesecih, kjer se vrednosti kazalnikov znižajo in so relativno stabilne.

Ogledamo si lahko še gibanje povprečne absolutne skalirane napake, ki ga prikazuje Slika 13. Kvaliteta napovedi se po tej meri pomembno ne razlikuje med pristopi, skozi večino obdobja je pristop z datumom zapadlosti najslabši, pristop z naučenim modelom z datumom plačila na zadnji dan razreda pa najboljši.

Slika 13: Primerjava povprečne absolutne skalirane napake za napovedi denarnega toka za podjetja na dnevem nivoju (od 1.1.2015 do datuma)



Slika 14: Primerjava povprečne absolutne skalirane napake za napovedi denarnega toka za podjetja na dnevem nivoju (30-dnevno drseče povprečje)



Zaradi upoštevanja celotnega leta v izračunih povprečne absolutne napake in povprečne skalirane absolutne napake, se lahko zakrijejo značilnosti oz. spremembe pri plačilih v posamičnih obdobjih. Zato smo preverili še, kakšne so vrednosti povprečne skalirane absolutne napake, če namesto celega leta pri izračunu upoštevamo zadnjih 30 dni –

izračunali smo drsečo povprečno absolutno napako. Vrednosti prikazuje Slika 14. Razlika je samo v večjem nihanju vrednosti kazalnika, sicer pa se rezultati ne razlikujejo bistveno od povprečne absolutne skalirane napake, računane za celo leto. Razvidno je, da je napoved sicer najboljša poleti, ko je imel AX že nekaj zgodovinskih podatkov o kupcih oz. preteklih plačilih računov teh kupcev, in preden se je iz AX začelo fakturirati dodatne storitve novim kupcem (septembra 2015).

Z namenom izboljšanja točnosti napovedi smo poskusili agregirati podatke in pogledati skladnost napovedi z dejanskim denarnim tokom na nivoju tedna. Za ta namen smo sešteli dnevne podatke glede na številko tedna, v katerem se nahaja dan. Tabela 8 prikazuje glavne kazalnike, izračunane za celotno leto. Izkazalo se je, da so napovedi točnejše, kot prikazuje manjša vrednost povprečne absolutne skalirane napake glede na napovedovanje po dnevih. Neposredna primerjava povprečne absolutne napake med obema primeroma pa ni najbolj ustrezna, ker je potrebno upoštevati vsaj dejstvo, da so tedenske vrednosti približno petkratnik dnevnih.

Tabela 8: Prikaz glavnih kazalnikov za napoved denarnega toka na tedenskem nivoju


Metoda	Povprečna abs. napaka (v EUR)	Kazalnik spr. pristr. napovedi	Povprečna abs. sk. napaka
Datum zapadlosti	64.574,01	0,81	1,78
Povprečna zamuda	36.251,94	-5,27	1,23
Modelska napoved – zadnji dan	35.506,22	-6,02	1,08
Modelska napoved – srednji dan	34.762,90	-5,99	1,04

Slika 15 kaže primerjavo povprečnih absolutnih napak modelov za napoved denarnega toka za podjetja na tedenskem nivoju (številke od 0 do 53, oz. na sliki 55, predstavljajo zaporedno številko tedna v letu). Najslabše rezultate pri planiranju na nivoju tedna je enako kot pri planiranju na dnevnem nivoju dala napoved na podlagi datumov zapadlosti računov. Najboljši rezultat pa je tu dala metoda odločitvenega gozda z upoštevanjem datuma plačila na srednji dan v razredu, vendar pa so razlike med uporabo zadnjega ali srednjega dneva razreda pri tedenskih podatkih minimalne. Slika 16 prikazuje tudi primerjavo povprečne absolutne skalirane napake za različne modele, za napoved denarnega toka za podjetja, na tedenskem nivoju, kjer so rezultati enaki, kot pri primerjavi povprečnih absolutnih napak. Najboljša je metoda odločitvenega gozda z upoštevanjem datuma plačila na srednji dan razreda.


Izračun kazalnika spremljanja pristranskosti napovedi je pokazal, da po tem sodilu napovedi sicer v večjem delu ustrezajo optimalnemu območju od -6 do +6, vendar pa vsake toliko časa zanihajo izven teh meja. Zopet kvaliteta pade po pričetku izdajanja računov za dodatne storitve iz AX.

Preverili smo še, kakšne so vrednosti kazalnika povprečna absolutna skalirana napaka, če namesto celotnega leta, upoštevamo samo zadnjih 30 dni. Slika 17 kaže, da je napoved zelo dobra poleti, medtem ko se precej poslabša jeseni. To lahko pripišemo spremljanju novih storitev v AX oz. izdajanju računov novim kupcem, ki se je pričelo septembra 2015. Za te kupce v AX pred tem ni bilo nikakršnih zgodovinskih podatkov. Algoritem se je zato učil na majhnem številu računov za posameznega kupca, iz katerih vzorca plačevanja še ni bilo mogoče posplošiti. Vrednosti kazalnika niso tako dobre, da bi lahko trdili, da je model dober, vseeno pa je napoved z odločitvenim gozdom precej boljša od napovedi na podlagi datuma zapadlosti in nekoliko boljša od napovedi na podlagi povprečne zamude pri plačilih. Odločitveni gozd v veliki meri zgladi večja nihanja v napaki, ki se zgodijo pri napovedih s prej omenjenima modeloma.


Slika 15: Primerjava povprečne absolutne napake za napovedi denarnega toka za podjetja na tedenskem nivoju (od 1.1.2015 do datuma) v EUR



Slika 16: Primerjava povprečne absolutne skalirane napake za napovedi denarnega toka za podjetja na tedenskem nivoju (od 1.1.2015 do datuma)



Slika 17: Primerjava povprečne absolutne skalirane napake za napovedi denarnega toka za podjetja na tedenskem nivoju (4-tedensko drseče povprečje)



6.2.3.4 Primerjava napovedi z odločitvenim gozdom in drugimi metodami za fizične osebe

Zaradi ugotovitve, do katere smo prišli pri napovedovanju denarnega toka za podjetja, da je najboljše napovedi mogoče dobiti z uporabo algoritma strojnega učenja odločitveni gozd, smo ta algoritem uporabili tudi za napoved denarnega toka iz naslova računov, izdanih fizičnim osebam. Rezultat je bil pri fizičnih osebah slabši, in sicer je bila skupna točnost napovedi zgolj 59,42 odstotna. Matrika zmedenosti je prikazana v Prilogi 4. Enako kot za podjetja, smo napoved denarnega toka z odločitvenim gozdom primerjali z metodo napovedi denarnega toka na podlagi datumov zapadlosti in metodo denarnega toka napovedi na podlagi upoštevanja povprečnega števila dni zamude pri plačilu predhodno izdanih in že plačanih računov tega kupca.


Tabela 9 prikazuje glavne kazalnike, izračunane za celotno leto. Najslabše rezultate je ponovno dala napoved denarnega toka na datume zapadlosti računov, najboljše rezultate pa je tu presenetljivo dala napoved denarnega toka na podlagi upoštevanja povprečnega števila dni zamude pri plačilu predhodno izdanih in že plačanih računov kupcev. Ta podatek je bil vključen tudi v naboru podatkov za algoritme strojnega učenja, vendar pa so očitno vzorci plačevanja pri fizičnih osebah tako neznačilni, da je rezultat strojnega učenja kljub upoštevanju tega in dodatnih podatkov dosegel slabši rezultat.

Tabela 9: Prikaz glavnih kazalnikov za napoved denarnega toka za fizične osebe na dnevnem nivoju

Metoda	Povprečna abs. napaka (v EUR)	Kazalnik spr. pristr. napovedi	Povprečna abs. sk. napaka
Datum zapadlosti	52.399,36	8,36	3,82
Povprečna zamuda	19.816,31	3,64	3,24
Modelska napoved – zadnji dan	38.270,41	-8,50	3,02
Modelska napoved – srednji dan	40.561,20	-7,64	3,12

Slika 18 prikazuje gibanje povprečne absolutne napake za vse modele. Gibanje povprečne absolutne napake se pri vseh modelih močno poveča v začetnih mesecih, zaradi vzorca podatkov – januarja in februarja je v plačilo zapadlo manj računov, izdanih v letu 2015, kot v vseh prihodnjih mesecih. Gibanje povprečne absolutne napake pa se skoraj povsem umiri od maja naprej, predvsem pri modelu z računanjem povprečne zamude. Pri ostalih modelih vrednosti zmerno narastejo konec leta, ko je tudi obseg vrednosti izdanih računov nekoliko večji zaradi sezonske narave dela storitev, ki jih podjetje prodaja. Sklepamo lahko, da je zaradi vse večjega števila podatkov v AX, izračun napovedi plačila na podlagi povprečne zamude pri plačilih, vedno boljši, in konec leta precej prekaša ostale algoritme. Ti očitno ne znajo enako dobro razbrati vzorcev plačevanja kupcev.


Slika 18: Primerjava povprečne absolutne napake za napovedi denarnega toka za fizične osebe na dnevni nivoju (od 1.1.2015 do datuma) v EUR




Izračun kazalnikov spremljanja pristranskosti napovedi je pokazal, da je napoved denarnega toka za fizične osebe na dnevni nivoju zelo slaba, saj so kazalniki pri vseh metodah napovedi večino časa močno presegali meje +6 oz. -6.

Enako slabe vrednosti so dali izračuni povprečne absolutne skalirane napake, katerih gibanje prikazuje Slika 19. Najboljša metoda ob upoštevanju tega kazalnika je sicer napoved denarnega toka z metodo odločitvenega gozda z upoštevanjem datuma plačila na zadnji dan razreda, vendar pa so vrednosti kazalnika zelo podobne za vse metode. Če pogledamo vrednost kazalnika povprečna absolutna skalirana napaka, ki ga prikazuje Slika 20, kjer je prikazano 30-dnevno drseče povprečje, pa vidimo, da se po nekaj začetnih mesecih, najbolje odreže metoda napovedi z upoštevanjem povprečne zamude pri plačilih, čeprav ima v začetku ta metoda največjo napako. To je razumljivo, saj v začetku leta 2015 v AX še ni bilo zgodovinskih podatkov o plačevanju kupcev in zato na podlagi povprečne zamude pri plačilu predhodno izdanih računov, ni bilo mogoče priti do pravih napovedi. Vrednosti v drugi polovici leta se gibajo pod 1, kar pomeni, da je model dovolj dober za uporabo.

Slika 19: Primerjava povprečne absolutne skalirane napake za napovedi denarnega toka za fizične osebe na dnevnom nivoju (od 1.1.2015 do datuma)



Slika 20: Primerjava povprečne absolutne skalirane napake za napovedi denarnega toka za fizične osebe na dnevnom nivoju (30-dnevno drseče povprečje)



Na tedenskem nivoju so bile napovedi bolj točne. Tabela 10 prikazuje glavne kazalnike, izračunane za celotno leto.


Tabela 10: Prikaz glavnih kazalnikov za napoved denarnega toka za fizične osebe na tedenskem nivoju

Metoda	Povprečna abs. napaka (v EUR)	Kazalnik spr. pristr. napovedi	Povprečna abs. sk. napaka
Datum zapadlosti	256.991,98	1,70	2,78
Povprečna zamuda	45.465,31	1,59	1,25
Modelska napoved – zadnji dan	140.169,72	-2,32	1,62
Modelska napoved – srednji dan	168.498,64	-1,84	1,86

Najslabše rezultate pri planiranju na nivoju tedna je enako kot pri vseh ostalih izračunih dala napoved na podlagi datumov zapadlosti računov. Najboljši rezultat pa je prav tako kot pri napovedi denarnega toka za fizične osebe na dnevnem nivoju dala napoved denarnega toka na podlagi upoštevanja povprečnega števila dni zamude pri plačilu predhodno izdanih in že plačanih računov kupca.

Slika 21 prikazuje primerjavo povprečnih absolutnih napak modelov za napoved denarnega toka za fizične osebe na tedenskem nivoju za leto 2015.


Slika 21: Primerjava povprečne absolutne napake za napovedi denarnega toka za fizične osebe na tedenskem nivoju (od 1.1.2015 do datuma) v EUR



Kazalniki spremljanja pristranskosti napovedi so bili na tedenskem nivoju nekoliko boljši kot na dnevnem nivoju, vendar je ravno pri metodi napovedi denarnega toka z upoštevanjem

povprečne zamude pri plačilih razmeroma pogosto presegele vrednost +6, kar pomeni, da model ni natančen.


Slika 22: Primerjava povprečne absolutne skalirane napake za napovedi denarnega toka za fizične osebe na tedenskem nivoju



Slika 22 prikazuje povprečno absolutno skalirano napako po tednih v letu 2015. Vrednost kazalnika se skozi vse leto izboljšuje. Najboljšo vrednost doseže konec leta pri metodi napovedi denarnega toka s povprečnim številom dni zamude pri plačilu, in sicer 1,25, kar pa še vedno ni rezultat, kakršnega bi si pri napovedovanju želeli. Zadovoljiv model naj bi imel vrednosti povprečne absolutne skalirane napake manjše od 1.

Ob podrobnejšem pregledu vrednosti na sliki pa vidimo, da vrednosti povprečne absolutne skalirane napake vztrajno padajo, in da so vrednosti v približno prvih petnajstih tednih tiste, ki močno vplivajo tudi na končne vrednosti kazalnika. Če namesto letnega nivoja spremljamo npr. drseče povprečje absolutne skalirane napake, ki ga prikazuje Slika 23, kjer pri izračunu kazalnika upoštevamo samo napake zadnjih 4-ih tednov (napake približno enega meseca), vidimo, da kazalnik pri metodi z napovedovanjem na podlagi povprečnih zamud pri plačilu v 19. tednu pade pod vrednost 1, ter nato tam tudi ostane, kar pomeni, da je ta metoda dovolj dobra za napovedovanje denarnega toka. To je razumljivo, če vzamemo v obzir dejstvo, da metoda z napovedovanjem na podlagi povprečne zamude pri plačilu potrebuje določeno število podatkov za izračun relevantnega povprečja zamude (računanje povprečne zamude pri plačilu na podlagi enega ali dveh plačil ne more dati dobrih rezultatov). Rezultati vseh ostalih metod so precej slabši, kljub temu, da se po začetnih tednih nekoliko popravijo.

Slika 23: Primerjava povprečne absolutne skalirane napake za napovedi denarnega toka za fizične osebe na tedenskem nivoju (4-tedensko drseče povprečje)



Pri fizičnih osebah slabost modela z odločitvenimi drevesi lahko poskusimo pojasniti s tem, da ne obstaja enoten model za skupino, ampak je obnašanje izjemno individualno. Zaradi velikega števila različnih kupcev v končnih modelih kot lastnost računa ni bila upoštevana številka kupca. Predhodni poskusi so pokazali, da z upoštevanjem številke kupca natančnost napovedi pada. Omejene dimenzije odločitvenih dreves namreč ne zmorejo zaobjeti vseh posameznih kupcev brez prekomernega povečevanja dreves.

Podatki o povprečni zamudi pri plačilu predhodno izdanih računov so od vseh uporabljenih podatkov v eksperimentu najbolj posamezniku prilagojeni podatki. Morda bi pomagal pristop s segmentiranjem posameznikov, vendar tega nismo preverjali, saj takšnih podatkov v sistemu nimamo, tudi zaradi omejitev, ki jih postavlja varovanje osebnih podatkov. Dejstvo, da tudi metoda z upoštevanjem samo povprečne pretekle zamude ne daje idealnih rezultatov, pa lahko pomeni, da tudi na nivoju posameznika ne obstaja nujno nek red pri plačevanju.


6.2.4 Primerjava rezultatov napovedi denarnega toka za podjetja in fizične osebe

Primerjava štirih metod izračuna napovedi denarnega toka je pokazala, da je pri podjetjih najboljša metoda napovedi metoda z uporabo odločitvenega gozda, in sicer sta se obe metodi – z upoštevanjem plačil na zadnji dan v razredu in z upoštevanjem plačil na srednji dan razreda – odrezali približno enako dobro. Pri fizičnih osebah pa se je po preteku nekaj začetnih mesecev najbolje odrezala metoda napovedi denarnega toka z metodo povprečne zamude pri plačilih. Povsod se je najslabše odrezala metoda napovedi denarnega toka na

datum zapadlosti računov, ki je tudi najlažja in najpogostejše uporabljena pri načrtovanju denarnega toka. Takšna metoda je z določenimi prilagoditvami (splošno določenim obdobjem do plačila) uporabljena tudi pri standardnem planiranju denarnega toka v AX.

Nobena od metod se ni najbolje odrezala pri planiranju denarnega toka na dnevnem nivoju. Na tedenskem nivoju pa sta najboljši metodi dali zadovoljive rezultate, pri čemer so rezultati za podjetja sicer boljši od rezultatov za fizične osebe, vendar pa so nihanja napake za podjetja precej večja kot nihanja napake za fizične osebe. Zneski računov pri fizičnih osebah so namreč večinoma primerljivih velikosti, zneski računov pri podjetjih pa se močno razlikujejo. Fizičnih oseb je tudi veliko več kot pravnih oseb. Zaradi razpršenosti je tako učinek posameznega, napačno napovedanega plačila, majhen. Pri podjetjih pa lahko že majhno število napačno napovedanih plačil močno spremeni potrebe po denarnih sredstvih v obdobju.

Slika 24: Prikaz porazdelitve velikosti računov za fizične osebe in podjetja (log10)



Porazdelitve zneskov računov prikazuje Slika 24, kjer so prikazani logaritmi zneskov zaradi prikaza vseh podatkov na enem grafu. Porazdelitev za podjetja je občutno širša od porazdelitve za fizične osebe in vsaka napaka pri posameznem računu v desnem repu porazdelitve lahko močno vpliva na kvaliteto napovedi denarnega toka.

6.3 Postopki za uporabo napovedi denarnega toka na podlagi strojnega učenja v praksi

V prejšnjih poglavjih smo za ugotavljanje kvalitete napovedi uporabili enak osnovni nabor podatkov, torej račune, izdane v letu 2015, razdeljene na dva dela - za učenje in preverjanje modela. To pokaže najboljše možno obnašanje algoritmov, saj smo imeli zelo velik nabor računov za učenje iz istega obdobja. V praksi bi strojno učenje izvedli drugače, in sicer bi učenje izvedli na preteklih podatkih, ter nato zagnali izračun napovedi denarnega toka na novih podatkih. Pri izboru zgodovinskih podatkov, nad katerimi izvajamo učenje, smo omejeni s tem, da za novejša račune morda še nimamo dovolj podatkov o zamudah. Če na primer vzamemo v učenje račune, izdane pred 30 dnevi in z zapadlostjo 30 dni, bomo v nabor podatkov dobili samo tiste račune, ki so bili plačani pred rokom zapadlosti. S tem smo ustvarili pristranski nabor podatkov za učenje. Z izborom 14 razredov, pri čemer 13. razred vsebuje plačila do 90 dni, 14. razred pa vsa plačila nad 90 dni, smo omejeni na to, da potrebujemo ustrezen vzorec računov, starih najmanj 90 dni.

Poudariti pa je potrebno, da odločitveni gozd poskuša zajeti pravila obnašanja. Ker so lastnosti računov, ki so podlaga za klasifikacijo, dejanski podatki ob izdaji računa, smatramo, da ob odsotnosti velike spremenljivosti vzorcev obnašanja (recimo zaradi večjih šokov v gospodarstvu) tudi zgoraj omenjena omejitve ni kritično omejujoča, vendar pa je pomembnost omejitve odvisna od izbire lastnosti računa. Ker je ena od lastnosti tudi oznaka kupca, vseeno lahko pride do tega, da algoritem preveč upošteva posameznega kupca namesto splošnih vzorcev, kar lahko privede do tega, da se ob morebitni spremembi obnašanja kupca algoritem ne odzove dovolj hitro. Vendar je potrebno tukaj utežiti na eni strani potencialno boljšo točnost napovedi, če upoštevamo tudi identiteto kupca in na drugi strani možno napako pri bodočih napovedih.

To dejstvo pa po drugi strani pomeni tudi, da ne smemo umetno krajšati časovnega razpona podatkov za učenje, kajti s tem lahko iz teh podatkov izpadejo primeri, ki so redkejši ali imajo sezonski vpliv. Če predpostavimo, da obstaja (vsaj pri nekaterih kupcih) korelacija med velikostjo računa in zamudo pri plačilu in sezonski vpliv na velikost računa, bi lahko kratek časovni razpon prikrajšal učenje odločitvenega gozda za takšne primere. V tem primeru pa bi morali ustrezno določiti tudi lastnosti računa, da bi zmogli ločiti časovno odvisnost obnašanja od časovne odvisnosti lastnosti računa, npr. z dodajanjem lastnosti meseca/kvartala.

Zaradi zgoraj navedenih omejitev pri uporabi podatkov smo se odločili, da preverimo še točnosti napovedi, ki jih dobimo z upoštevanjem samo zgodovinskih podatkov. Naredili smo dva poskusa, v prvem smo algoritem odločitvenega drevesa sprva učili na podatkih o izdanih računih od 1.1.2015 do 30.6.2015, ter ga uporabili za načrtovanje denarnega toka iz naslova računov, izdanih od 1.10.2015 do 31.12.2015. Nato pa smo algoritem učili še na malo

večjem naboru podatkov o izdanih računih od 1.1.2015 do 30.9.2015, ter ga uporabili za napoved denarnega toka iz naslova računov, izdanih od 1.2.2016 do 29.2.2016. Glede na prej zapisano, novejših podatkov v tej točki nismo mogli upoštevati.

Simulacijo napovedi, kot bi se lahko uporabila v praksi, smo naredili skupaj za 3 mesece v letu 2015 in skupaj za 2 meseca v letu 2016. V realnosti bi bilo napovedi seveda potrebno delati veliko bolj pogosto – lahko obdobjno, ali pa ob izdaji vsakega posameznega računa. S tem bi računu pripisali napovedani datum plačila, ki bi bil podlaga za planiranje denarnega toka iz naslova terjatev. Prav tako pa bi se lahko pogosteje zaganjalo učenje algoritma odločitvenega gozda. Za novembrske račune bi npr. lahko že upoštevali tudi izdane račune iz meseca julija, itd.

S pomočjo odločitvenega gozda smo za račune, izdane v obdobju od 1.10.2015 do 31.12.2015 dobili napoved, ki je bila točna v 77,83 odstotkih primerov, kar pomeni, da je bilo 77,83 odstotkov računov plačanih v razredu, v katerem je to predvidel naučeni model odločitvenega gozda. Za račune, izdane v obdobju od 1.1.2016 do 29.2.2016 smo dobili precej slabšo napoved, in sicer je bila ta točna samo v 61,22 odstotkih primerov. Matriki zmedenosti za obe napovedi sta v Prilogah 5 in 6. Predvsem pri napovedi za račune, izdane v letošnjem letu se vidi, da je bilo za veliko količino računov napovedano, da bodo plačani do datuma zapadlosti, pa se to ni zgodilo.


Preverjanje točnosti napovedi denarnega toka smo nato naredili tako, kot v predhodnih poglavjih, z rekonstruiranjem dejanskega in planiranega denarnega toka iz vseh teh računov. Rezultate obeh napovedi smo sešteli na tedenskem nivoju, saj smo že pri predhodnih izračunih ugotovili, da so napovedi na dnevnem nivoju preslabe za uporabo. Nato smo izračunali kazalnike povprečna absolutna napaka, kazalnik spremljanja pristranskosti napovedi in povprečno absolutno skalirano napako za celotno obdobje in 4-tedensko drseče povprečje za vse štiri uporabljene metode.

Kazalnik spremljanja pristranskosti napovedi se je večino časa gibal v mejah od +6 do -6 za vse metode, le občasno je prišlo do preseganja. Največkrat je kazalnik to mejo presegel pri metodi napovedi na datum zapadlosti računov.

Slika 25 prikazuje primerjavo povprečnih absolutnih napak. Enako kot pri izračunih za leto 2015 je začetne rezultate potrebno jemati z rezervo. Ti rezultati namreč temeljijo na majhnem številu zapadlih računov, saj smo upoštevali račune, ki so bili izdani od 1.10.2015 naprej. Ti pa so večinoma zapadli od konca meseca oktobra dalje. To pojasni, zakaj se vrednosti povprečne absolutne napake najprej močno povečajo, ne pojasni pa, zakaj se vrednosti povečujejo skozi celotno proučevano obdobje. Pričakovali bi, da se vrednosti po začetnem mesecu ali dveh umirijo, ter da večjih nihanj v napaki ni. Večjo napako lahko tu pojasni slabša napoved modela za račune iz leta 2016 in spremembe v vrednosti izdanih

računov. Zneski izdanih računov so se januarja, predvsem pa februarja, precej povečali zaradi sezonskega vpliva.

Slika 25: Primerjava povprečne absolutne napake za napovedi denarnega toka za podjetja na tedenskem nivoju (od 1.10.2015 do datuma) v EUR




Iz primerjave vrednosti povprečnih absolutnih napak je razvidno, da se je večino časa najbolj obnesla napoved s pomočjo odločitvenega gozda in z upoštevanjem plačil na zadnji dan izračunanega razreda. V zadnjih tednih (za plačila v aprilu 2016) pa je to metodo nekoliko presegla metoda napovedi z upoštevanjem povprečne zamude pri plačilu.


Slika 26 prikazuje primerjavo povprečnih absolutnih skaliranih napak od 1.10.2015 do datuma, Slika 27 pa primerjavo povprečnih absolutnih skaliranih napak, računanih kot 4-tedensko drseče povprečje. Najboljše vrednosti je večino časa dosegla metoda napovedi z odločitvenim gozdom ter upoštevanjem plačil na zadnji dan razreda. To je tudi edina metoda, kjer se je vrednost kazalnika večinoma gibala pod vrednostjo 1, kar je merilo za primernost modela napovedi. Enako kot pri primerjavah povprečnih absolutnih napak, se vidi, da je v zadnjih mesecih od te napovedi boljša napoved na podlagi povprečne zamude pri plačilu. To se da pojasniti z dvema dejavnikoma. Prvi je, da je bilo podjetjem do tega časa že izdanih dovolj računov in se je povprečje zamude pri plačilu toliko bolj približalo dejanskim zamudam, ki so jih imela podjetja. Drugi pa je, da ta metoda vedno upošteva tudi najnovejše podatke, kar pomeni, da v primeru, da pride do večjih sprememb v plačilni disciplini kupcev ta metoda bolje oceni datum predvidenega plačila kot metoda odločitvenega gozda, ki smo jo zagnali na 90 ali več dni starih podatkih. Slaba točnost napovedi odločitvenega gozda za leto 2016 kaže, da je prišlo do sprememb v plačilni disciplini, ki jih je metoda napovedi s povprečno zamudo pri plačilih že upoštevala v izračunih. Pogled v podatke kaže, da je prišlo

do enotedenskega zamika velikega zneska plačil, zaradi katerega se močno poviša vrednost povprečne absolutne napake.

Slika 26: Primerjava povprečne absolutne skalirane napake za napovedi denarnega toka za podjetja na tedenskem nivoju (od 1.10.2015 do datuma)



Slika 27: Primerjava povprečne absolutne skalirane napake za napovedi denarnega toka za podjetja na tedenskem nivoju (4-tedensko drseče povprečje)



6.4 Nadaljnji koraki pri napovedi denarnega toka v izbranem podjetju na podlagi ugotovitev pri izračunih

Analiza napovedi denarnega toka iz izdanih računov v AX na podlagi različnih metod je pokazala, da je denarni tok za fizične osebe mogoče najbolj točno napovedati z uporabo metode napovedi denarnega toka na podlagi povprečne zamude pri plačilu, denarni tok za pravne osebe pa z uporabo strojnega učenja, in sicer algoritma odločitveno drevo, razen v aprilu 2016, ko se je na sicer omejenem vzorcu računov (izdani do 29.2.2016) prav tako najbolje odrezala metoda napovedi denarnega toka na podlagi povprečne zamude pri plačilu. Rezultati napovedi na tedenskem nivoju so bili precej boljši kot rezultati napovedi na dnevnem nivoju, zato bi bilo za podjetje najbolj priporočljivo, da napoved izdela na tedenskem nivoju. V primeru izdelave na dnevnem nivoju, je napaka precej večja, še vedno pa so vse uporabljene metode boljše od upoštevanja plačil na datum zapadlosti listin, kar se upošteva pri trenutnih napovedih. Izbor kakršnekoli druge metode napovedi bi zato podjetju pomagal k točnejši napovedi denarnega toka iz izdanih računov, kljub temu, da se nobena od metod ni izkazala za zelo točno. Pravzaprav so vse metode napovedi relativno slabe.

Glede na to, da se je pri fizičnih osebah najbolje odrezala metoda napovedi denarnega toka z upoštevanjem povprečne zamude pri plačilih, bi bilo smiselno v AX narediti dodelavo, ki bi pri planiranju denarnega toka iz izdanih računov, izračunala povprečno zamudo pri plačilih prejšnjih računov za posamičnega kupca ter ta podatek upoštevala v izračunu pričakovanega denarnega toka. Napoved se že standardno dela za posamično listino, manjka pa izračun povprečnega števila dni zamude. Ta podatek bi se lahko dodal na kartico kupca, ter bi s tem omogočal tudi informacijo, ki bi podjetju pomagala pri komunikaciji s kupcem ter v postopku izterjave. Upoštevanje tega podatka pri izračunu napovedi denarnega toka bi morala biti nastavljiva, in sicer vezana na skupino kupcev. S tem bi omogočili, da bi lahko takšno napoved delali samo za določeno skupino, npr. samo za fizične osebe. Pri upoštevanju takšnih podatkov v napovedi denarnega toka, pa se pojavi tudi vprašanje, kakšna je smiselna dolžina obdobja, za katero se računa povprečno zamudo pri plačilu za kupca. Če je izbrano obdobje predlogo, se zakrijejo spremembe pri plačilni disciplini posamičnih kupcev, načrti denarnega toka pa so lahko napačni. Prekratko obdobje pa lahko pomeni netočne podatke pri upoštevanju povprečne zamude pri plačilih, kar je razvidno tudi iz vseh kazalnikov pri napovedih na podlagi metode s povprečno zamudo pri plačilih. Glede na to, da smo v izračunih povprečne zamude pri plačilih uporabljali podatke za celo leto 2015, in da se je napoved denarnega toka za fizične osebe skozi celotno leto 2015 izboljševala, je smiselno v obzir vzeti več podatkov, ne samo zadnjega ali nekaj zadnjih podatkov, kajti s tem lahko iz teh podatkov izpadejo primeri, ki so redkejši ali imajo sezonski vpliv. Verjetno pa nima smisla upoštevati podatkov za zelo dolgo obdobje (več kot leto dni), saj se v tem primeru morebitne spremembe v plačilni disciplini ne bi pravočasno odražale v napovedi.

V kolikor bi podjetje za napovedi denarnega toka iz izdanih računov želelo uporabiti algoritem odločitvenega gozda, bi bilo izračune potrebno zaganjati najmanj na tedenskem nivoju, saj se določeni izdani računi v AX-u knjižijo zelo pozno in imajo zelo kratke plačilne pogoje. Podatke bi iz baze lahko pridobili na enak način, kot so bili pridobljeni za namene te magistrske naloge – z SQL poizvedbo. Občasno (npr. enkrat mesečno) bi bilo potrebno posodobiti model z novimi podatki o računih oz. njihovih plačilih, sicer bi se lahko napovedi zaradi morebitnih sprememb v vzorcih plačevanja hitro poslabšale.

Prav tako bi bilo zanimivo videti, kako točne so napovedi denarnega toka za pravne osebe za nadaljnje mesece v letošnjem letu in s tem ugotoviti ali se za napovedovanje denarnega toka bolj splača uporabiti metodo napovedi z odločitvenim gozdom ali morda metodo napovedi na podlagi povprečnega števila dni zamude, ki je bila sicer boljša pri fizičnih osebah.

Rezultati, pridobljeni s strojnim učenjem in preglednicami v Excelu tako za podjetja kot tudi za fizične osebe niso bili dovolj dobri, da bi lahko z njimi zelo natančno načrtovali denarni tok. Se jih pa da uporabiti kot boljšo alternativo načrtovanju denarnega toka na podlagi dneva zapadlosti računa. Vendar bi se rezultate tudi v primeru, da se jih ne uporabi za načrtovanje denarnega toka, dalo izkoristiti. In sicer bi lahko s strojnim učenjem napovedali ali bo določen kupec zamudil s plačilom ter okviren razred zamude. Te podatke pa bi nato uporabili v izterjavi. Kupca, za katerega bi predvideli, da bo njegovo terjatev težko izterjati, bi lahko pričeli opozarjati prej kot kupca, za katerega bi bilo predvideno da bo račun plačal npr. v tednu ali dveh po zapadlosti.

Zaenkrat uvedba načrtovanja denarnega toka preko uporabe algoritmov strojnega učenja ni predvidena. Kar pa izbrano podjetje zagotovo čaka v naslednjih mesecih, je dokončanje nadomestitve podatkov, ki se trenutno v načrt denarnega toka vnašajo preko Excelovih tabel, ki se polnijo ročno, s podatki, ki se spremljajo v AX. Ugotovili smo, da so nabavni nalogi, prejeti, a še neknjiženi računi in obveznosti do dobaviteljev dovolj dober vir, ki lahko nadomestijo ročno vnesene plane. Zaradi problemov pri urejenosti podatkov pa izbrano podjetje AX še ni pričelo uporabljati kot vira podatkov. Plan je, da se to zgodi, ko bodo razčiščeni vsi odprti nabavni nalogi, ki trenutno vplivajo na izračune. Prav tako se je zavlekla implementacija novih predvidenih funkcionalnosti – zakladništva (spremljanje kreditov, depozitov, ipd.) ter uporaba »European Gate« sistema – kar bo prav tako omogočilo opustitev ročnih vnosov ter posledično pohitritev procesa planiranja.

SKLEP

Načrtovanje denarnega toka iz naslova terjatev s pomočjo metod strojnega učenja se je v pričelo omenjati v zadnjih letih, ko je načrtovanje denarnega toka močno pridobilo na pomenu zaradi zaostrenih pogojev pri zadolževanju na denarnih trgih. Za namene magistrskega dela je bilo planiranje denarnega toka sprva izvedeno s tremi metodami

strojnega učenja – odločitvenim gozdom, nevronskimi mrežami in logistično regresijo. Rezultati so bili daleč najboljši pri metodi odločitvenega drevesa, ki je tudi metoda, uporabljena pri končnih izračunih ter primerjavah z enostavnejšimi metodami načrtovanja denarnega toka, ki jih je mogoče izvesti tudi v Excelovih preglednicah.

Izračuni so bili narejeni ločeno za fizične in pravne osebe, saj se je tekom analize izkazalo, da se v primeru napovedovanja na združenih podatkih, povsem zakrijejo vzorci plačevanja pravnih oseb, in sicer zaradi veliko večjega števila fizičnih oseb v vzorcu podatkov. Takšne napovedi so bile zato preslabe, da bi jih bilo mogoče uporabiti v praksi. Prav tako je bilo nemogoče dobre podatke pridobiti iz napovedi na dnevnem nivoju. Izračuni so bili zato oblikovani po razredih, ki so obsegali približno teden dni. Končni rezultati pa so bili prikazani na dva načina – na nivoju dneva in na nivoju tedna. Rezultati ločenih napovedi so dovolj dobri, da je z njimi mogoče nadomestiti planiranje na podlagi datuma zapadlosti terjatev, ki se uporablja sedaj, poleg napovedovanja prilivov na podlagi preteklih izkušenj zaposlenih v zakladništvu. Pri podjetjih se je pri napovedi denarnega toka najbolje odrezala napoved z odločitvenim gozdom. Načrt denarnega toka na nivoju dneva se je izkazal za razmeroma nenatančnega, medtem ko je načrt na tedenskem nivoju bolj natančen in bi ga bilo bolj smiselno uporabiti za načrtovanje prilivov. Glede na to, da podjetje načrt denarnega toka sicer dela na dnevnem nivoju, bi lahko uporabili tudi načrtovanje na dnevnem nivoju, saj to v vsakem primeru prekaša uporabljeni metodi v preglednicah, vendar bi se ob tem morali sprijazniti s precej večjo napako oz. precejšnjo nezanesljivostjo modela.

Za podjetja smo zaradi razmeroma dobrih napovedi z odločitvenim gozdom simulirali tudi napovedovanje denarnega toka za obdobje 5-ih mesecev na podlagi preteklih podatkov, ki smo jih uporabili za učenje algoritma strojnega učenja. Napoved je bila nekoliko slabša od napovedi za celotno leto, kar pa je bilo pričakovano, saj je temeljila na starejših podatkih, ki so nam omogočili zagotoviti nepristranskost modela, ki bi v primeru uporabe novejših podatkov ne imel podatkov o plačilih v vseh načrtovanih razredih in bi se zato lahko naučil napačnih vzorcev plačevanja. Prav tako pa se je že pri prvotno izvedenih napovedih za leto 2015 opazilo, da je napoved za mesece proti koncu leta, ki smo jih uporabili tudi pri tej simulaciji, nekoliko slabša od predhodnih napovedi. Presenetljivo slabo se je algoritem odločitvenega gozda odrezal na letošnjih podatkih, kjer je bila ta metoda proti koncu preučevanega obdobja slabša, kot napoved a podlagi pretekle zamude pri plačilu predhodno plačanih računov kupca. Podatki so pokazali, da je prišlo do spremembe vzorcev plačevanja pri nekaterih kupcih, oz. do enotedenskega zamika pri plačilu nekaterih večjih terjatev, kar pa je lahko enkratni dogodek ali pa opozorilo glede slabšanja plačilne discipline kupcev. Tu je lahko prišlo tudi do sezonskega vpliva, saj so se nekoliko povečali zneski izdanih računov, ki so lahko vplivali na spremembe v plačilni disciplini. V primeru, da gre tu za sezonski vpliv, bi ga moral algoritem strojnega učenja v nadaljnjih letih prepoznati, če bi v učenju modela upoštevali tudi dovolj stare podatke. To sicer pomeni, da bi bila takšna napoved ob večjih spremembah plačilne discipline, ali pa ob splošnih gospodarskih spremembah, lahko precej slaba, saj bi algoritem predpostavil vzorce plačevanja iz preteklih let. V primeru, da

do večjih sprememb ne prihaja, pa bi upoštevanje sezonske komponente lahko napoved precej izboljšalo. Izbor podatkov v takšnem primeru mora biti kompromis, oz. potrebno bi bilo algoritem učiti na naborih računov iz različnih časovnih obdobj, ter preverjati, uporaba koliko zgodovinskih podatkov, da pri napovedovanju najboljše rezultate.

Prav tako so bili presenetljivi rezultati napovedi pri fizičnih osebah. Izkazalo se je, da je najboljša napoved na podlagi pretekle zamude pri plačilu predhodno plačanih računov kupca. Metoda je skozi celotno leto pridobivala na točnosti, saj se je večal vzorec podatkov za kupce in je močno prekašala vse ostale metode. To pa pomeni, da v primeru fizičnih oseb nima smisla zaganjati izračunov z odločitvenim drevesom, kljub temu, da prekašajo napoved na datum zapadlosti, saj je metoda napovedi s povprečno zamudo pri plačilu, ki jo je možno enostavno izvesti, primernejša. Takšno metodo bi bilo z razmeroma malo napora mogoče vpeljati tudi znotraj poslovno informacijskega sistema AX. Zahteva namreč zgolj preračunavanje povprečne zamude pri plačilih za posamične kupce, ter upoštevanje podatka v obstoječem preračunu napovedi denarnega toka.

Raziskovalno vprašanje dela, da lahko strojno učenje omogoči pripravo kvalitetne napovedi denarnega toka iz naslova terjatev, je tako potrjeno samo delno. Napoved na podlagi strojnega učenja je res boljša od najpreprostejše metode napovedi na datum zapadlosti v vseh primerih, vendar je zgolj pri pravnih osebah tudi najboljša od izbranih, uporabljenih metod, in ni dosegla željenega rezultata.

Prav tako smo zaenkrat uspeli samo delno potrditi drugo zastavljeno vprašanje – ali je določene podatke, ki se uporabljajo v načrtu denarnega toka tako, da se jih vanj vnaša ročno, mogoče kvalitetno nadomestiti s podatki iz AX, ter s tem pohitriti in izboljšati proces načrtovanja. Zamuda pri implementaciji nekaterih funkcionalnosti, npr. modula zakladništva, je povzročila, da določeni podatki v AX še niso na voljo, da bi jih lahko uporabili v načrtovanju denarnega toka. S primerjavo podatkov v AX ter trenutno uporabljanimi podatki, pa smo ugotovili, da bi se lahko kvalitetno uporabili podatki iz nabavnih nalogov, prejetih, a še neknjiženih računov, ter iz knjiženih obveznosti. Potrebna bi bila zgolj izločitev nekaterih podatkov, saj se nahajajo tudi v šifrantih pogodb, ki so preko podatkovnega skladišča že sedaj eden od vhodov v načrt denarnega toka. Preostanek nalogov (oz. prejetih računov in obveznosti) pa bi lahko nadomestil ročne vnose naročil, ki jih morajo trenutno delati zaposleni, ki s tem delajo dvojno delo. Pri vpeljavi AX kot vira podatkov za naštet, pa nas je ustavilo dejstvo, da so določeni podatki (nabavni nalogi) v AX trenutno neažurni ter jih je pred pričetkom uporabe potrebno prečistiti.

Ali se bo podjetje res poslužilo katere od predlaganih metod napovedi denarnega toka iz naslova terjatev, ostaja odprto. Nobena od uporabljenih metod se žal ni izkazala za zelo točno, izbrati je mogoče le najmanj slabo rešitev. Zanimivo pa bi bilo odločitveno drevo za podjetja zagnati še na novejših podatkih, in ugotoviti, ali se v letu, ko se v AX ne dodaja več fakturiranja za nove storitve, napoved z odločitvenim drevesom uspe kaj izboljšati.

LITERATURA IN VIRI

1. Allott, A., Besson-Levine, A., & Young, R. (2009). *Improving Cash Flow Using Credit Management*. b.k.: Chartered Institute of Management Accountants.
2. *Instrumenti denarnega trga*. Najdeno 8. maja 2016 na spletnem naslovu http://www.alta.si/Osnove_trgovanja/Izobrazevalne_vsebine/Instrumenti_denarnega_trga
3. Association for Financial Professionals. (2012). Strategic Global Cash Position Forecasting. Najdeno 1. maja 2016 na spletnem naslovu <http://www.treasury-management.com/docs/Reval-AFP-GlobalLiquidity-Guide-1.pdf>
4. Backlund, K. (2008, 12. avgust). It's Liquidity Management, Not Cash Forecasting. *OpusCapita*. Najdeno 1. maja 2016 na spletnem naslovu <http://www.treasury.nl/files/2008/02/502.pdf>
5. Balasubramanian, S. (2009, 8. avgust). Efficient Cash Management Through E-Billing. *Social Science research Network*. Najdeno 15. februarja 2016 na spletnem naslovu http://papers.ssrn.com/sol3/papers.cfm?abstract_id=1446029
6. Bank of America, Merrill Lynch. (2013). Best Practices in Cash Flow Forecasting. Najdeno 20. junija 2016 na spletnem naslovu https://corp.bankofamerica.com/documents/16303/570859/Cash_Flow_Best_Practices.pdf
7. Barga, R., Fontama, V., & Tok, W. H. (2015). *Predictive Analytics with Microsoft Azure Machine Learning* (2nd ed.). Berkeley, CA: Apress.
8. Baumol, W. J. (1952). The transactions Demand for Cash: An Inventory Theoretic Approach. *The Quarterly Journal of Economics*, 66(4), 545-556.
9. Berry, T. (b.l.). The Difference between Cash and Profits. *Bplans*. Najdeno 20. junija 2016 na spletnem naslovu <http://articles.bplans.com/difference-between-cash-and-profits/>
10. Berson, A., Smith, S., & Thearling, K. (b.l.). An Overview of Data Mining Techniques. Najdeno 27. aprila 2016 na spletnem naslovu <http://www.thearling.com/text/dmtechniques/dmtechniques.htm>
11. BizMove. (b.l.). *Credit and Collection Policies and Procedures Methods*. Najdeno 2. julija 2016 na spletnem naslovu <http://www.bizmove.com/finance/m3e1.htm>
12. Blatnik, K. (2010, junij). Finančni trgi in ustanove. *Ministrstvo za izobraževanje, znanost in šport*. Najdeno 8. maja 2016 na spletnem naslovu http://www.mizs.gov.si/fileadmin/mizs.gov.si/pageuploads/podrocje/ss/Gradiva_ESS/UNISVET/UNISVET_18ET_1Financni_Blatnik.pdf
13. Blocher, J. D., Mabert, V. A., Soni, A. K., & Venkataramanan, M. A. (2004, februar). Forecasting; Including an Introduction to Forecasting using the SAP R/3 System. *Indiana University Kelley School of Business*. Najdeno 27. maja 2016 na spletnem naslovu http://kelley.iu.edu/mabert/e730/forecasting_february_2004.pdf
14. Bozarth, C. (2011, 25. januar). Measuring Forecast Accuracy: Approaches to Forecasting : A Tutorial. *NC State University*. Najdeno 15. maja 2016 na spletnem

- naslovu <https://scm.ncsu.edu/scm-articles/article/measuring-forecast-accuracy-approaches-to-forecasting-a-tutorial>
15. Bragg, S. M. (2010). *Treasury Management: The Practitioner's Guide*. Hoboken, NJ: John Wiley & Sons, Inc.
 16. Bragg, S. M. (2012). *Corporate Cash Management: A Treasurer's Guide*. Centennial, CO: AccountingTools LLC.
 17. Brigham, E. F., & Daves, P. R. (2004). *Intermediate Financial Management* (8th ed.). Mason, OH: Thompson South-Western.
 18. Bryk, A., Lee, H., Thibault, P., & Stewien, B. (b.l.). Make Your Working Capital Work for You: Strategies for Optimizing Your Accounts Receivable. *Deloitte*. Najdeno 21. junija 2016 na spletnem naslovu <http://www2.deloitte.com/content/dam/Deloitte/ca/Documents/finance/ca-en-FA-strategies-for-optimizing-your-accounts-receivable.pdf>
 19. Carpenter, M. D., & Miller, J. E. (1979). Reliable Framework for Accounts Receivable. *Financial Management*, 8(4), 37-40.
 20. Chai, T., & Draxler, R. R. (2014). Root Mean Square Error (RMSE) or Mean Absolute Error (MAE)? – Arguments Against Avoiding RMSE in the Literature. *Geoscientific Model Development*, 7(3), 1247–1250.
 21. Corcoran, W. A. (1978). The Use of Exponentially-Smoothed Transition Matrices to Improve Forecasting of Cash Flows from Accounts Receivable. *Management Science*, 24(7), 732.
 22. Cyert, R. M., Davidson, H. J., & Thompson, G. L. (1962). Estimation of the Allowance for Doubtful Accounts by Markov Chains. *Management Science*, 8(3), 287-303.
 23. Čepelnik Knez, B., Jevšinek, S., & Mikolič, S. (b.l.). Finančno upravljanje in vodenje podjetij. *Univerza v Mariboru, Ekonomsko - poslovna fakulteta*. Najdeno 15. maja 2016 na spletnem naslovu <http://www.ssepf.si/pdf/baza-zapiskov/Financno-upravljanje-in-vodenje-podjetij.pdf>
 24. da Costa Moraes, M. B., Nagano, M. S., & Sobreiro, V. A. (2015). Stochastic Cash Flow Management Models: A Literature Review Since the 1980s. V P. Guarnieri (ur.), *Decision Models in Engineering and management* (str. 11-28). Cham: Springer International Publishing Switzerland.
 25. De Caux, T. (2005). Cash forecasting. V *Treasurer's Companion* (str. 105-110). London: Association of Corporate Treasurers.
 26. Driscoll, M. (2012). Accounts Receivable Performance. *APQC*. Najdeno 21. junija 2016 na spletnem naslovu <http://www.versapay.com/wp-content/uploads/2015/04/Doing-OK-Is-No-Longer-Good-Enough.pdf>
 27. Dougherty, C. (2007). *Introduction to Econometrics* (3rd ed.). Oxford: Oxford University Press.
 28. *Sources of Finance*. Najdeno 25. aprila 2016 na spletnem naslovu <https://www.efinancemanagement.com/sources-of-finance/sources-of-finance>

29. Fuchs, B. (2011, 6. december). Best Practices in Cash Flow Forecasting. *GTNews*. Najdeno 22. junija 2016 na spletnem naslovu <https://www.gtnews.com/articles/best-practices-in-cash-flow-forecasting/>
30. Gallinger, G. W., & Ifflander, J. A. (1986). Analysis, Monitoring Accounts Receivable Using Variance. *Financial Management*, 15(4), 69-76.
31. Gentry, J. A., & De La Garza, J. M. (1985). A Generalized Model for Monitoring Accounts Receivable. *Financial Management*, 14(4), 28-38.
32. Gentry, J. A., Vaidyanathan, R., & Lee, H. W. (1990). A Weighted Cash Conversion Cycle. *Financial Management*, 19(1), 90-99.
33. Gitman, L. J., Forrester, D. K., & Forrester, J. R. (1976). Maximizing Cash Disbursement Float. *Financial Management*, 5(2), 15-24.
34. Gitman, L. J., Moses, E. A., & White, I. T. (1979). An Assessment of Corporate Cash Management Practices. *Financial Management*, 8(1), 32-41.
35. Glas, M. (2001, 18. marec). Zakaj je vlaganj tveganega kapitala največ v ZDA? *Finance, str.* 18-19.
36. Gospodarska zbornica Slovenije. (b.l.). Poslovne bonitete. Najdeno 30. junija 2016 na spletnem naslovu https://www.gzs.si/skupne_naloge/informacije_in_pomoc/vsebine/Informacije-o-slovenskem-in-tujem-poslovnem-okolju/Informacije-o-tujem-poslovnem-okolju/Poslovne-bonitete
37. Greenwell, R. N., Ritchey, N. P., & Lial, M. L. (2003). *Calculus with Applications for the Life Sciences*. Boston, MA: Addison Wesley.
38. Gronlund, C. J. (2016, 28. april). Introduction to Machine Learning on Microsoft Azure. *Microsoft*. Najdeno 21. junija 2016 na spletnem naslovu <https://azure.microsoft.com/en-us/documentation/articles/machine-learning-what-is-machine-learning/>
39. Han, J., Kamber, M., & Pei, J. (2012). *Data Mining Concepts and Techniques* (3rd ed.). Waltham, MA: Elsevier Inc.
40. Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The Elements of Statistical Learning. Data Mining, Inference and Prediction*. New York, NY: Springer Science + Business Media, LLC.
41. Hawkins, D. M. (2004). The Problem of Overfitting. *J. Chem. Inf. Comput. Sci.*, 44(1), 1-12.
42. Higdon, P. (2011). Achieving Cash Visibility: How can Corporates Gain End-to-End Visibility over their Cash Flows? *Journal of Corporate Treasury Management*, 4(3), 251–258.
43. Horcher, K. A. (2006). *Essentials of Managing Treasury*. Hoboken, NJ: John Wiley & Sons, Inc.
44. HSBC Global Asset Management. (2014). The Treasurer's Global Guide to Investing Cash 2014. Najdeno 8. maja 2016 na spletnem naslovu <http://www.globalliquidity.hsbc.com/~media/amg-liquidity/news/treasurers-global-investing-cash.pdf>

45. Hyndman, R. J., & Koehler, A. B. (2006). Another Look at Measures of Forecast Accuracy. *International Journal of Forecasting*, 22(4), 679-688.
46. Kallberg, J. G., & Saunders, A. (1983). Markov Chain Approaches to the Analysis of Payment Behavior of Retail Credit Customers. *Financial Management*, 12(2), 5-14.
47. Maier, S. F., Robinson, D. W., & Vander Weide, J. H. (1981). A Short-Term Disbursement Forecasting Model. *Financial Management*, 10(1), 9-20.
48. Manyika, J., Chui, M., Brown, B., Bughin, J., Dobbs, R., Roxburgh, C., & Hung Byers, A. (2011). *Big Data: The Next Frontier for Innovation, Competition, and Productivity*. McKinsey & Company.
49. Matassi, G. M. (2011). An Integrative Approach to Cash Flow Forecasting. *Ledgewood Advisory Group*. Najdeno 16. februarja 2016 na spletnem naslovu <http://www.ledgewoodgroup.com/an-integrative-approach-to-cash-flow-forecasting/>
50. Michalski, G. (2009). Target Liquid Balances and Value of the Firm. *Zagreb International Review of Economics & Business*, 12(1), 1-18.
51. Microsoft. (2012, december). Product Availability, Localization and Translation Guide for Microsoft Dynamics AX. Najdeno 10. aprila 2016 na spletnem naslovu http://download.microsoft.com/download/0/b/4/0b4d5cc4-98fb-4d48-bce5-9d8fe3d76611/mbs_ax_availabilityguide_us.pdf
52. Microsoft. (2016, 2. marec). Microsoft Decision Trees Algorithm. SQL Server 2016 Technical Documentation. Najdeno 27. aprila 2016 na spletnem naslovu: <https://msdn.microsoft.com/en-us/library/ms175312.aspx>
53. The Microsoft Dynamics AX Team. (2012). *Inside Microsoft Dynamics AX 2012*. Redmond, WA: Microsoft Press.
54. Miller, M. H., & Orr, D. (1966). A Model of the Demand for Money by Firms. *The Quarterly Journal of Economics*, 80(3), 413-435.
55. Miller, T. W., & Stone, B. K. (1985). Daily Cash Forecasting and Seasonal Resolution: Alternative Models and Techniques for Using the Distribution Approach. *The Journal of Financial and Quantitative Analysis*, 20(3), 335-351.
56. Mungurwadi, V. (2015, 14. avgust). A Machine Learning Approach for Cash Flow Prediction. Najdeno 16. aprila 2016 na spletnem naslovu <http://blog.ekaplus.com/blog/a-machine-learning-approach-for-cash-flow-prediction>
57. Pangeršič, A. (2015). Poslovni primeri uporabe strojnega učenja. *Microsoft NT konferenca*. Najdeno 17. februarja 2016 na spletnem naslovu https://www.google.si/url?sa=t&rct=j&q=&esrc=s&source=web&cd=7&ved=0ahUK EwiyjLOC0_KAhVCUhQKHcErCzUQFgg8MAY&url=https%3A%2F%2Fwww.ntk.si%2Furnik%2Farhiv%2Fdownload%2F5ccd6f75-13a5-40d0-873d-6eda2a506794&usg=AFQjCNFDW4oDqPI9qBZhHGi-7XUiGXgKQO
58. Pohorec, S. (2014). Metode podatkovnega rudarjenja. *MonitorPro*, 5(2), 37-41.
59. Provost, F., & Fawcett, T. (2013). *Data Science for Business; What You Need to Know About Data Mining and Data-Analytic Thinking*. Sebastopol, CA: O'Reilly Media, Inc.
60. Rajendra, R. (2013). *The Handbook of Global Corporate Treasury*. Singapore: John Wiley and Sons Singapore Pte. Ltd.

61. Rappold, H. (2015, 8. junij). One Size Doesn't Always Fit All: Tips for Successful Cash flow Forecasts. *GTNews*. Najdeno 16. februarja 2016 na spletnem naslovu <https://www.gtnews.com/articles/one-size-doesnt-always-fit-all-tips-for-successful-cash-flow-forecasts/>
62. Rebel, B. (2007, oktober). Cash Pooling; Finding a Cost Efficient Equilibrium. *Treasury.nl*. Najdeno 25. aprila 2016 na spletnem naslovu http://www.google.si/url?sa=t&rct=j&q=&esrc=s&source=web&cd=3&cad=rja&uact=8&ved=0ahUKEwiuvYeF7anMAhUpCpoKHangBOMQFggpMAI&url=http%3A%2F%2Fwww.treasury.nl%2Ffiles%2F2007%2F10%2Ftreasury_225.pdf&usg=AFQjCN G4FsMgQBcqW1dq0ed6f_aKn2NzA
63. Rebernik M., & Repovž L. (2000). *Od ideje do denarja: podjetniški proces*. Ljubljana: Gospodarski vestnik.
64. Republika Slovenija, Ministrstvo za finance. (b.l.). eRačun - proračunski uporabniki. Najdeno 24. aprila 2016 na spletnem naslovu <http://www.ujp.gov.si/dokumenti/dokument.asp?id=258>
65. Reider, R., & Heyler, P. B. (2003). *Managing Cash Flow: An Operational Focus*. Hoboken, NJ: J. Wiley.
66. Rohrer, B. (2016, 10. februar). How to Choose Algorithms for Microsoft Azure Machine Learning. *Microsoft*. Najdeno 10. februarja 2016 na spletnem naslovu <https://azure.microsoft.com/en-us/documentation/articles/machine-learning-algorithm-choice/>
67. Rokach, L., & Maimon, O. (2005). Decision Trees. V L. Rokach, & O. Maimon, *Data Mining and Knowledge Discovery Handbook* (str. 165-192). New York, NY: Springer.
68. Russell, R.S., & Taylor, B.W. (1999). Forecast Accuracy. *Operations Management with Multimedia CD* (3rd ed.). Najdeno 27. maja 2016 na spletnem naslovu <http://www.prenhall.com/divisions/bp/app/russellcd/PROTECT/CHAPTERS/CHAP10/HEAD04.HTM>
69. Russel, S. & Norvig, P. (2009). *Artificial Intelligence: A Modern Approach* (3rd ed.). Edimburgh Gate: Pearson Education Limited.
70. Schapire, R. (2008, 4. februar). COS 511: Theoretical Machine Learning. *Princeton University*. Najdeno 26. aprila 2016 na spletnem naslovu http://www.cs.princeton.edu/courses/archive/spr08/cos511/scribe_notes/0204.pdf
71. Shcherbakov, M. V., Brebels, A., Shcherbakova, N. L., Tyuk, A. P., Janovsky, T. A., & Kamaev, V. A. (2013). A Survey of Forecast Error Measures. *World Applied Sciences Journal*, (24), 171-176.
72. *Direktne obremenitve*. Najdeno 24. aprila 2016 na spletnem naslovu http://www.sepa.si/SloPrenova/SepaProdukti_Storitve/DebetnaPlacila/SepaProdukti%20in%20storitve_DebetnaPlacila.htm
73. Shim, J. K. (1981). Estimating Cash Collection Rates from Credit Sales: A Lagged Regression Approach. *Financial Management*, 10(5), 28-30.

74. Shobhit, S. (b.l.). How The SWIFT System Works. V *Investopedia*. Najdeno 15. maja 2016 na spletni strani: <http://www.investopedia.com/articles/personal-finance/050515/how-swift-system-works.asp>
75. Slovenski računovodski standard 29. (2006). Računovodsko proučevanje (Računovodsko analiziranje). *Uradni list RS*, št. 118/2005.
76. Snyder, L. D. (2013). The 13-Week Cash-Flow... Keeping Your Eyes on the Road & Your Hands on the Wheel. *abfjournal*, 11(4).
77. *Sources of Finance – Explain the Types of Business Finance?* Najdeno 21. junija 2016 na spletnem naslovu <http://www.businessstudynotes.com/introduction-to-business/sources-of-finance-explain-types-business-finance/>
78. Stone, B. K. (1972). The Use of Forecasts and Smoothing in Control-Limit Models for Cash Management. *Financial management*, 1(1), 72-84.
79. Stone, B. K. (1976). The Payments-Pattern Approach to the Forecasting and Control of Accounts Receivable. *Financial Management*, 5(3), 65-82.
80. Stone, B. K., & Wood, R. A. (1977). Daily Cash Forecasting: A Simple Method for Implementing the Distribution Approach. *Financial Management*, 6(3), 40-50.
81. Stone, B. K., & Miller, T. W. (1987). Daily Cash Forecasting with Multiplicative Models of Cash Flow Patterns. *Financial Management*, 16(4), 45-54.
82. Tangsuecheeva, R., & Prabhu, V. (2014). Stochastic Financial Analytics for Cash Flow Forecasting. *Int. J. Production Economics*, 158(C), 65-76.
83. *Measures of Forecast Error*. Najdeno 27. maja 2016 na spletnem naslovu <http://www.threadpunter.com/supply-chain-management/demand-planning/measures-of-forecast-error/>
84. Treasury Alliance Group. (2012). Cash Pooling: A Treasurer's Guide. Najdeno 16. februarja 2016 na spletnem naslovu http://www.treasuryalliance.com/assets/publications/cash/Treasury_Alliance_cash_pooling_white_paper.pdf
85. Tsai, C.-Y. (2011). On Delineating Supply Chain Cash Flow Under Collection Risk. *Int. J. Production Economics*, 129(1), 186-194.
86. Turk, I. (b.l.). Pojmovnik. *Zveza računovodij, finančnikov in revizorjev*. Najdeno 20. junija, 2016 na spletnem naslovu <http://www.zvezarfr.si/pripomocki/slovar>
87. Van Horne, J. C., & Wachowicz, Jr., J. M. (2008). *Fundamentals of Financial Management* (13th ed.). Harlow: Pearson Education Limited.
88. van Kuelen, J. A., Spronk, J., & Corcoran, A. W. (1981). On the Cyert-Davidson-Thompson Doubtful Accounts Model. *Management Science*, 27(1), 108-112.
89. van Steenberghe, E. O. (2011). *Maximizing Cash Management with SAP ERP Financials* (1st ed.). Boston, MA: Galileo Press Inc.
90. Wang, G. C., & Jain, C. L. (2003). *Regression Analysis: Modeling & Forecasting*. Flushing, NY: Graceway Publishing Company, Inc.
91. Westerhaus, C. (2009). Better Business with SEPA Direct Debit. Corporate Customers Confirm Benefits of SEPA Implementation. *EPC Newsletter*. Najdeno 24. aprila 2016 na spletnem naslovu <http://www.europeanpaymentscouncil.eu/index.cfm/knowledge->

bank/epc-documents/better-business-with-sepa-direct-debit-corporate-customers-confirm-benefits-of-sepa-implementation-epc-newsletter/better-business-with-sepa-direct-debitpdf/

92. Unicredit Bank. (b.l.). Združevanje denarnih sredstev (cash pooling). Najdeno 25. aprila 2016 na spletnem naslovu http://www.unicreditbank.si/sl/Pravne_osebe/Upravljanje_z_denarnimi_sredstvi/Zdruzevanje_denarnih_sredstev_cash_pooling
93. Weygandt, J. J., Kimmel, P. D., & Kieso, D. E. (2012). *Accounting Principles*. Hoboken, NJ: John Wiley & Sons, Inc.
94. Zeng, S., Melville, P., Lang, C. A., Boier-Martin, I., & Murphy, C. (2008). Using Predictive Analysis to Improve Invoice-to-Cash Collection. *Proceedings of the 14th ACM SIGKDD international conference on Knowledge discovery and data mining* (str. 1043-1050). Las Vegas, NV: ACM New York, NY.


PRILOGE

KAZALO PRILOG

Priloga 1: Matrika zmedenosti algoritma odločitvenega gozda za podjetja.....	1
Priloga 2: Matrika zmedenosti algoritma logistične regresije za podjetja.....	2
Priloga 3: Matrika zmedenosti algoritma nevronske mreže za podjetja	3
Priloga 4: Matrika zmedenosti algoritma odločitvenega gozda za fizične osebe.....	4
Priloga 5: Matrika zmedenosti algoritma odločitvenega gozda za podjetja za račune izdane od 1.10.2015 do 31.12.2015.....	5
Priloga 6: Matrika zmedenosti algoritma odločitvenega gozda za podjetja za račune izdane od 1.1.2016 do 29.2.2016.....	6
Priloga 7: Vizualizacija enega od odločitvenih dreves, uporabljenih v odločitvenem gozdu	7
Priloga 8: Pregled verjetnosti, v kateri razred spada kateri od računov, izračunanih na podlagi odločitvenega gozda	8


Priloga 1: Matrika zmedenosti algoritma odločitvenega gozda za podjetja

Slika 1: Matrika zmedenosti algoritma odločitvenega gozda za podjetja




Priloga 2: Matrika zmedenosti algoritma logistične regresije za podjetja

Slika 2: Matrika zmedenosti algoritma logistične regresije za podjetja



Priloga 3: Matrika zmedenosti algoritma nevronske mreže za podjetja

Slika 3: Matrika zmedenosti algoritma nevronske mreže za podjetja




Priloga 4: Matrika zmedenosti algoritma odločitvenega gozda za fizične osebe

Slika 4: Matrika zmedenosti algoritma odločitvenega gozda za fizične osebe

		Predicted Class													
		1	2	3	4	5	6	7	8	9	10	11	12	13	14
Actual Class	1	90.3%	0.1%	0.1%	0.1%	0.1%	0.6%	3.1%	0.4%	3.6%	1.1%	0.4%	0.1%	0.1%	0.1%
	2	55.0%	0.3%	0.1%	0.2%	0.1%	1.0%	25.8%	3.3%	9.5%	2.7%	1.1%	0.4%	0.3%	0.2%
	3	33.5%	0.6%	0.3%	0.3%	0.2%	2.0%	16.5%	12.1%	23.7%	6.2%	2.5%	0.9%	0.6%	0.4%
	4	25.6%	1.2%	0.6%	0.7%	0.3%	3.5%	4.5%	2.8%	38.1%	13.4%	5.3%	2.0%	1.4%	0.8%
	5	20.1%	1.7%	1.0%	0.9%	0.4%	4.5%	2.5%	1.4%	33.2%	20.1%	8.0%	3.0%	1.8%	1.2%
	6	15.3%	2.3%	1.2%	1.4%	0.6%	6.1%	3.0%	1.2%	29.8%	19.2%	11.7%	4.0%	2.5%	1.5%
	7	12.8%	3.1%	1.9%	1.5%	0.7%	8.6%	2.0%	1.2%	28.6%	17.8%	10.0%	6.0%	3.4%	2.4%
	8	13.8%	4.2%	2.0%	2.4%	1.0%	12.5%	1.0%	0.6%	26.6%	14.3%	9.1%	5.3%	4.6%	2.6%
	9	13.5%	4.2%	2.6%	3.0%	1.3%	13.7%	1.1%	0.5%	24.2%	15.3%	8.7%	4.9%	3.6%	3.5%
	10	13.8%	4.8%	2.7%	2.9%	1.1%	15.2%	1.3%	0.4%	23.3%	12.8%	8.8%	5.3%	4.2%	3.5%
	11	12.7%	5.6%	3.2%	3.0%	1.5%	18.2%	1.9%	0.6%	21.0%	11.1%	8.5%	5.4%	4.1%	3.1%
	12	15.6%	4.3%	2.2%	4.0%	1.7%	20.5%	1.2%	0.4%	22.0%	10.6%	6.1%	4.2%	4.2%	3.1%
	13	16.0%	5.7%	3.0%	3.4%	3.3%	22.0%	1.3%	0.4%	19.2%	10.5%	6.2%	3.4%	3.2%	2.4%
	14	23.6%	3.7%	1.9%	2.1%	1.4%	26.7%	2.0%	0.6%	19.2%	7.8%	4.2%	2.4%	2.6%	1.7%


Priloga 5: Matrika zmedenosti algoritma odločitvenega gozda za podjetja za račune izdane od 1.10.2015 do 31.12.2015

Slika 5: Matrika zmedenosti algoritma odločitvenega gozda za podjetja za račune, izdane od 1.10.2015 do 31.12.2015




Priloga 6: Matrika zmedenosti algoritma odločitvenega gozda za podjetja za račune izdane od 1.1.2016 do 29.2.2016

Slika 6: Matrika zmedenosti algoritma odločitvenega gozda za podjetja za račune, izdane od 1.1.2016 do 29.2.2016



Priloga 7: Vizualizacija enega od odločitvenih dreves, uporabljenih v odločitvenem gozdu

Slika 7: Vizualizacija odločitvenega drevesa



Odebeljena črta na sliki prikazuje eno od poti do klasifikacije računa v razred 4. Odločitev se v tem primeru izvede v 8-ih korakih:

- oznaka skupine kupca ni enaka R-SA;
- povprečna zamuda predhodno izdanih faktur, plačanih z zamudo, je manjša od ali enaka 21 dni;
- številka kupca ni enaka CXYZ;
- povprečna zamuda predhodno izdanih plačanih faktur ni manjša od ali enaka 8 dni;
- kazalnik 4 (glej poglavje 6.2.2.2) je manjše od ali enako 0,8188;
- povprečna zamuda predhodno izdanih faktur, plačanih z zamudo, ni manjša od ali enaka 18 dni;
- število predhodno izdanih faktur ni manjše od ali enako 12;
- klasifikacija je razred 4 - faktura bo predvidoma plačana med 15. in 22. dnem po datumu zapadlosti.

Priloga 8: Pregled verjetnosti, v kateri razred spada kateri od računov, izračunanih na podlagi odločitvenega gozda

Tabela 1: Pregled izračunanih verjetnosti za plačilo računov – po razredih

Račun	Razred 1	Razred 2	Razred 3	Razred 4	Razred 5	Razred 6	Razred 7	Razred 8	Razred 9	Razred 10	Razred 11	Razred 12	Razred 13	Razred 14	Določeni razred
1	0,4568	0,1165	0,0704	0,1844	0,0711	0,0079	0,0000	0,0256	0,0000	0,0000	0,0350	0,0323	0,0000	0,0000	1
2	0,4145	0,1194	0,1636	0,1349	0,1114	0,0000	0,0000	0,0041	0,0000	0,0000	0,0052	0,0112	0,0000	0,0357	1
3	0,4049	0,1712	0,0631	0,1618	0,0711	0,0350	0,0000	0,0256	0,0000	0,0000	0,0350	0,0323	0,0000	0,0000	1
4	0,4049	0,1712	0,0631	0,1618	0,0711	0,0350	0,0000	0,0256	0,0000	0,0000	0,0350	0,0323	0,0000	0,0000	1
5	0,7795	0,1654	0,0188	0,0000	0,0190	0,0000	0,0030	0,0021	0,0000	0,0000	0,0034	0,0089	0,0000	0,0000	1
6	0,7797	0,1489	0,0262	0,0215	0,0000	0,0111	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0126	1
7	0,2882	0,0944	0,0820	0,1442	0,1033	0,1054	0,0425	0,1006	0,0000	0,0000	0,0114	0,0279	0,0000	0,0000	1
8	0,9078	0,0896	0,0026	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	1
9	0,8791	0,0680	0,0028	0,0341	0,0000	0,0111	0,0000	0,0049	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	1
10	0,1257	0,1758	0,1326	0,2786	0,0536	0,0863	0,0433	0,0908	0,0000	0,0000	0,0071	0,0063	0,0000	0,0000	4