

Tartu Ülikool
Loodus- ja täppisteaduste valdkond
Matemaatika ja statistika instituut

Jelizaveta Jerahtina
Panga klientide hoiuste stabiilsuse hindamine
Matemaatilise statistika eriala
Bakalaureusetöö (9 EAP)

Juhendaja: dots. Meelis Käärik

Tartu 2018

Panga klientide hoiuste stabiilsuse hindamine

Lühikokkuvõte. Viimase majanduskriisi käigus selgus kui tähtis on pankadel likviidsuse hindamine. Eesti Pangaliit lõi 2002. aastal Tagatisfondi, mille eesmärgiks oli tagada krediitiasutuste stabiilsust. Alates aastast 2011 on Tagatisfond kindlustanud panga iga kliendi hoiust 100 000 euro piires, mistõttu on selle hoiusegrupi riskikoeffitsient kõige madalam. Ülejäänud klientide stabiilsust peab pank ise hindama. Selle töö eesmärgiks on leida stabiilsust prognoosiv mudel, kui hoiuse suurus ületab Tagatisfondi poolt esitatud piiri. Analüüsi käigus treenitakse kolm mudelit, kus esimeses mudelis kasutatakse logit-seosefunktsiooni, teises cauchit-seosefunktsiooni ja kolmandas log-log seosefunktsiooni. Töö viimases osas valitakse parim mudel, mille prognoositulemuste abil on võimalik hinnata hoiuste stabiilsust ja hoiustega kaasnevaid riske.

Märksõnad: hoiused, prognoosimudel, regressioonanalüüs, binaarse funktsioontunnuse mudelid

CERCS teaduseriala: Statistika, operatsioonianalüüs, programmeerimine, finants- ja kindlustusmatemaatika (P160)

Evaluating the stability of clients of a bank

Abstract. During the last financial crisis it became evident how important it is for managing liquidity. The Estonian Banking Association founded a Guarantee Fund in 2002 to guarantee stability of the financial sector. Since 2011, the Guarantee Fund insured deposits in the amount of 100 000 euro per depositor in the bank, therefore guaranteed deposits have the lowest risk factor. For other depositors bank has to find means of stability rating itself. The aim of this thesis is to create model that will forecast the stability of depositors whose deposits are larger than the limit set by Guarantee Fund. During the analysis there was 3 models created. The first model being logit link function, the second a cauchit link function and the third log-log link function. In the last chapter the best fit predictive model will be chosen, which will be used to evaluate stability of deposits and occurring risks.

Keywords: deposits, predictive model, regression analysis, binary regression models

CERCS research specialisation: Statistics, operations research, programming, actuarial mathematics (P160)

Sisukord

Sissejuhatus	4
1 Teema tutvustus	6
1.1 Eelnevad uuringud.....	7
1.2 Euribor.....	8
2 Meetodid	9
2.1 Binaarse funktsioontunnusega regressioonimudelid (<i>Binary regression models</i>).....	9
2.1.1 Logit-mudel.....	9
2.1.2 Cauchit-mudel.....	10
2.1.3 Täiend-log-log mudel (<i>CLog-Log model</i>) ja log-log mudel.....	10
2.2 Mudeli parameetrite hindamine.....	11
2.3 Mudeli headuse hindamine.....	12
2.4 Mudelite võrdlemine.....	13
3 Praktiline osa	15
3.1 Andmestiku kirjeldus.....	15
3.2 Mudeli konstrueerimine.....	17
3.3 Mudelite võrdlemine.....	17
3.3.1 „stable“- mudel.....	18
3.4 Mudeli interpreteerimine.....	20
3.5 Tulevased uuringud.....	21
Kokkuvõte	22
Kasutatud allikad	23

Sissejuhatus

Aastatel 2007 – 2009 toimunud majanduskriisi käigus nähti, kui tähtis on pankade likviidsus. Kriisi ajal viisid kliendid kõrgema riskitasemega pankadest raha välja, mille tagajärjel tekkis sellistel pankadel probleeme likviidsusega ning paljud nendest pankrotistusid. Majanduskriisi ajal saadi aru, et peab likviidsuse juhtimisele, sealhulgas ka hoiuste stabiilsusele suuremat tähelepanu pöörama.

Väikese hoiusega klientide puhul on tähele pandud, et nende kontojäägid on volatiilsemad kui suure hoiusega klientidel, sest väikestel kontodel kasutatakse tavaliselt terve sissetulek kuu jooksul ära. Samuti on märgatud, et väiksema kontojäägiga klientidel on rohkem tervisehäireid, sissetuleku katkestusi ja muid probleeme (Bald, 2008). Eesti Pangaliit asutas 2002. aastal Tagatistfondi, mille üheks eesmärgiks on tagada krediitiasutuste klientide poolt paigutatud vahendite stabiilsust. Selle raames on hoiused tagatud 100 000 euro ulatuses, mistõttu on pangal iseseisvalt vaja hinnata klientide stabiilsust, kellel jääb hoiuse suurus määratud piirist üle.

Hoiuste stabiilsuse teadmine on vajalik igapäevases panga tegevuses, nagu näiteks LCR (*Liquidity Coverage Ratio*) või laenumahu arvutamisel. Baseli komitee on seadnud eesmärgiks, et 1. jaanuariks 2019 on kõikide kommertsbankade minimaalne LCR tase 100%. See tähendab, et pangal peab olema vähemalt 100% likviidseid varasid, et toimida järgmise 30 kalendripäeva jooksul. Selle kriteeriumi eesmärgiks on tugevdada panganduse süsteemi. Stressiolukorra tekkimisel soovib komitee kasutada kõrge kvaliteediga likviidsusvarasid (*HQLA – High Quality Liquid assets*). (Basel III)

Pärast majanduskriisi on majapidamised olnud ettevaatlikumad oma rahaliste vahenditega, mille tagajärjel on hakatud rohkem säästma ning võtma vähem laene (Colmant, Peters, Gussé, Vanderheere, 2013). Vaatamata sellele, et praegu ei ole väga soodne majanduskeskkond, on toimunud pankades üllatavalt suur hoiuste kasv (Colmant, Peters, Gussé, Vanderheere, 2013). Panga hoiuste dünaamika jälgimiseks vaadatakse klientide hoiuseid 12 erineval ajahetkel aastatel 2015-2018. Mudeli koostamisel vaadatakse lisaks klientidega seotud andmetele ka makroökonomilisi näitajaid, millest üheks on 6 kuu Euribor. Kuna Euribor mõjutab otseselt panga poolt pakutavat hoiuse intressimäära, peab töö autor selle jälgimist oluliseks.

Selle töö käigus näidatakse kuidas on võimalik hinnata kommertsbanka kõrgema riskiga hoiustajate stabiilsust. Analüüsi käigus on eesmärgiks leida hoiuste stabiilsust mõjutavad tegurid ning moodustada prognoosimudel, mille abil oleks võimalik ennustada vastavalt

klientide andmetele ja välisteguritele panga hoiuste stabiilsust. Kasutades panga definitsiooni määratakse, kas tegemist on stabiilse või ebastabiilse hoiusega. Prognoosimise käigus saab jälgida hoiustega seotud riske, vaadates läbi erinevaid stsenaariume. Selle abil on võimalik ette valmistada erinevateks stressiolukordadeks.

Bakalaureusetöö on kirjutatud kolmes osas. Esimeses osas tutvustatakse teemat ning eelnevalt läbiviidud uuringuid. Teises osas antakse pikem ülevaade logit, cauchit ning log-log mudelitest. Kolmandas peatükis lahendatakse praktiline ülesanne ning valitakse parim mudel.

Töö autor tänab juhendajat dots. Meelis Käärikut rohkete täpsustuste, selgituste ja soovitude eest.

1 Teema tutvustus

Kommertsbankade üheks tähtsamaks kohustuseks on klientide hoiused. Klientidel on võimalik paigutada oma raha erinevatesse toodetesse, nagu näiteks väärtpaberid või hoiused. Kui klient on deponeerinud oma vara, tekib pangal kohustus kliendile maksta intressi. Pangal jääb aga õigus muuta kliendi intressimäära hoiustamise perioodil, kusjuures intressimäär on mõjutatud erinevate turgude poolt (Frauendorfer ja Schürle, 2006). Antud töös vaadatakse kahte tüüpi deposiite, millest üheks on nõudmiseni hoius ja teiseks on tähtajaline hoius.

Nõudmiseni hoiuse puhul on tegemist kliendi rahaga, mille ta on panka paigutanud, kuid samas säilib kliendil võimalus see raha igal momendil välja võtta. Seega tegemist on tähtajatu ehk nõudmiseni hoiusega, sest hoiusel ei ole fikseeritud tähtaega. Samuti on nõudmiseni hoiusele määratud kindel intressimäär, kuid see võib muutuda hoiustamise perioodi vältel. Vaatamata sellele, et tegemist on kerge tootega, on sellega kaasnevad riskid keerulised ning nende hindamine on pankade jaoks väga tähtis. Sellel teemal on eelnevalt kirjutanud Tynys L. (2012), O'Brien J.M. (2000) ning Feilizen (2011) uurimistöid ja artikleid. Eelnevalt nimetatud autorid on jaganud esinenud riskid kahte rühma.

- Likviidsusrisk.

See on risk, et krediitiasutus ei suuda täita õigeaegselt või täies mahus oma kohustusi ilma sealjuures olulisi kulusid kandmata (Finantsinspektsiooni soovituslik juhend..., 2013). Likviidsusriski kontrolli all hoidmiseks on Baseli komitee seadnud standardid, mida kõik pangad peavad jälgima ja täitma. Üheks tähtsamaks näitajaks on Liquidity Coverage Ratio (LCR), mis tagab pankadele vajaliku likviidsuse. 2007. aastal alanud majanduskriisi üheks põhjuseks oli halb likviidsuse juhtimine (Basel III).

- Intressirisk.

Tegemist on riskiga, mis kaasneb intressimäärade muutustega ning millel on võimalik mõju panga varade ja kohustuste väärtustele.

Kuigi paljud eelnevalt nimetatud tööd põhinevad USA pankade andmetel, siis Dewacher, H., Lyrio, M. ja Maes, K., (2006) toovad oma töös välja, et hoiuste hindamine ja riskide juhtimine

on Euroopas palju olulisem, sest *Continental-European* majandusstruktuurid on rohkem pangakesksed, kui Ameerika Ühendriikides.

Tähtajalise hoiuse puhul sõlmitakse kliendiga kindlaks ajavahemikuks leping, kus on välja toodud vastavalt hoiuse suurusele ja perioodi pikkusele intressimäär, mis kestab terve hoiustamise perioodi vältel. See deposiit on panga vaates palju stabiilsem, seetõttu on pank nõus maksma tähtajalisele hoiusele kõrgemat intressi, kui nõudmiseni hoiusele.

1.1 Eelnevad uuringud

Antud töö koostamisel on autor toetunud välismaal tehtud uuringutele. Seetõttu tuuakse välja eraldi peatükk, mis tutvustaks eelnevaid uuringuid ja võtaks kokku saadud tulemused ning järeldused.

Arvatakse, et jaehoiused on üks odavamaid ja stabiilsemaid pankade rahastamise võimalusi. Tavaliselt jagavad pangad jaehoiused mitmesse kategooriasse vastavalt hoiuste väljavoolu koefitsiendile ning kliendiga loodud suhtele. Bašič (2015) jagas enda uuringu käigus jaepanga hoiused kolme gruppi vastavalt kliendiga seotud riskifaktoritele. Uuringu käigus leidis ta 3 hoiuste stabiilsust hindavat mudelit kasutades vähimruutude meetodit, kus iga leitud mudel vastas ühele kindlale hoiuste kategooriale. Kõigis kolmes mudelis osutus statistiliselt oluliseks tunnuseks 6 kuu Euribor, mida vaadatakse ka selles töös.

Hutchinson ja Pennacchi (1996), Jarrow ja van Deventer (1998), O'Brien (2000) ning Kalkbrener ja Willing (2004) hindavad oma töödes tähtajatute rahavoogude mahtusid ning klientide intressimäärasid kasutades hinnastamise mudeleid. Erinevalt Hutchinsonist ja Pennacchist (1996) käsitlevad Jarrow ja van Deventer (1998) oma töös *arbitrage-free* hinnastamise meetodit, et maandada ja hinnata nõudmiseni hoiuseid ja krediitkaartide laene. Selleks, et eelnevalt nimetatud meetodit kasutada, eeldavad nad, et ainult pankadel on õigus pakkuda nõudmiseni hoiust ja krediitkaarte. Seda eeldust kasutades, näitavad nad, et tähtajatud kohustused (*non-maturing liabilities*) on võrdsed intressi vahetuslepinguga (*interest rate swap*). Tänu sellele võrdusele võib saada vajalikke sisendeid nii hoiuste hinnastamiseks kui ka riskide maandamiseks (Jarrow ja van Deventer, 1998).

O'Brien (2000) töötas välja hoiuste intressimäärade hindamiseks *arbitrage-free* mudeli, kasutades autoregressiivseid protsesse. O'Brien (2000), Orphanides ja Small (1994) pidasid sümmeetrilisust väga tähtsaks hoiuse väärtuse ja intressiriski hindamisel.

Kalkbrener ja Willing (2004) kasutavad likviidsus- ja intressiriski hindamiseks kolme-faktorilist stohhastilist mudelit, kus faktoriteks on turumäärad (*market rates*), hoiuste intressimäärad ning hoiuste summad. Nad väidavad, et hoiuste intressimäärad on tugevalt mõjutatud turumääradest, kuid erinevate hoiuste tüüpide intressimäärad on omavahel erinevad (Kalkbrener ja Willing, 2004).

Paraschiv ja Schürle (2010) leiavad enda töö käigus mudelid, mis hindavad klientidele vastavaid hoiuste intressimäärasid ning nõudmiseni hoiuste mahte. Selleks kasutavad nad *multistage stochastic programming model*'it, mille pakkusid välja Frauendorfer ja Schürle (2007). Samuti leidsid nad, et mahtude muutused mõjutavad turumäärade ja klientide intressimäärade seosekordajaid (Paraschiv ja Schürle, 2010).

1.2 Euribor

Järgmine peatükk põhineb EMMI (European Money Markets Institute) allikal Euribor reform ... (2017). Euribor (*Euro Interbank Offered Rate*) on intressimäär, millega EMU (*The Economic and Monetary Union*) tsoonis olevad kõrge reitinguga pangad on nõus eurodes laenama raha teistele samade standarditega pankadele. Intressimäär arvutatakse iga päev pankade tähtjaliste hoiuste puhul 8 erineva tähtajaga kuni 12 kuud.

Euribori parima täpsuse tagamiseks ning kõikumise välistamiseks jälgitakse 20 suurima mahuga panka. Iga tähtaja arvutamiseks välistatakse 15% kõige kõrgematest ja madalamatest kogutud määradest, mille käigus langeb välja suurem osa erinditest. Alles jäänud intressite abil leitakse keskmine ning ümardatakse see kolme komakohani.

2 Meetodid

Töö koostamisel pööratakse suurt tähelepanu varem läbiviidud uuringutele. Cipu ja Udriste (2009) jaotasid nõudmiseni hoiused enda uuringus stabiilseteks ja ebastabiilseteks hoiusteks. Seda tehakse ka selles töös ning seejärel hinnatakse “stabiilset” hoiuste osa. Kuna prognoositakse tõenäosust, mis on tõkestatud lõigus $[0, 1]$, kasutatakse ülesande lahendamiseks binaarse funktsioontunnusega regressioonimudeleid.

2.1 Binaarse funktsioontunnusega regressioonimudelid (*Binary regression models*)

Järgnev peatükk põhineb Tutz, G. (2014) õpikul.

Binaarse funktsioontunnusega regressioonimudelite korral prognoositakse binaarse tunnuse y kaks võimalikku väärtust: 0 ja 1. Olgu $(y_i, \mathbf{x}_i), i = 1, \dots, n$ sündmuste vektor, kus y_i tähistab i -nda sündmuse väärtust, \mathbf{x}_i tähistab i -nda sündmuse seletavate tunnuste vektorit ning n on valimi maht. Juhul, kui sündmus toimub on tunnuse y_i väärtus 1, sündmuse mittetoimumise korral on väärtus 0.

Mudel avaldub kujul:

$$g(\mu_i) = \eta(\mathbf{x}_i),$$

kus g on seosefunktsioon ja $\eta(\mathbf{x}_i) = \beta_0 + \mathbf{x}_i^T \boldsymbol{\beta}$ on lineaarne prediktor, kus $(\beta_0, \boldsymbol{\beta})$ tähistab otsitavate parameetrite vektorit. Mudelit on võimalik kirja panna ka teisel kujul:

$$\mu_i = h(\eta(\mathbf{x}_i)),$$

kus μ_i on keskmine ja h on vastavusfunktsioon.

Binaarse tunnuse korral on mudel järgmisel kujul:

$$\pi_i = F(\beta_0 + \mathbf{x}_i^T \boldsymbol{\beta}), \quad (1)$$

kus F on mingi jaotusfunktsioon ning $\pi_i = P(y_i = 1 | \mathbf{x}_i)$ on i -nda sündmuse toimumise tõenäosus.

2.1.1 Logit-mudel

Logistiline regressioon on kõige tihedamini kasutatud meetod binaarse uuritava tunnuse modelleerimiseks. Mudeli üldkuju avaldub järgmiselt:

$$\pi_i = F(\eta(\mathbf{x}_i)),$$

kus $F(\eta(\mathbf{x}_i)) = \frac{\exp(\eta(\mathbf{x}_i))}{1 + \exp(\eta(\mathbf{x}_i))}$ on logistilise jaotuse jaotusfunktsioon ning $\eta(\mathbf{x}_i) = \mathbf{x}_i^T \boldsymbol{\beta}$ on lineaarne prediktor. π_i on sündmuse toimumise tõenäosus, mis sõltub seletavatest tunnustest \mathbf{x}_i . Teisenduste abil on võimalik logit-mudelit viia mitmele kujule:

$$\pi_i = \frac{\exp(\mathbf{x}_i^T \boldsymbol{\beta})}{1 + \exp(\mathbf{x}_i^T \boldsymbol{\beta})},$$

$$\frac{\pi_i}{1 - \pi_i} = \exp(\mathbf{x}_i^T \boldsymbol{\beta}),$$

$$\log\left(\frac{\pi_i}{1 - \pi_i}\right) = \mathbf{x}_i^T \boldsymbol{\beta}.$$

Esimene kuju näitab, kuidas mõjutavad seletavad tunnused sündmuse toimumise tõenäosust. Teine kuju näitab seletavate tunnuste mõju šansile. Kolmas kuju näitab kuidas šansi logaritmil on lineaarne sõltuvus seletavate tunnustega.

2.1.2 Cauchit-mudel

Cauchit-seosefunktsioon kasutab Cauchy jaotusfunktsiooni $F(\eta(\mathbf{x}_i)) = \frac{\tan^{-1}(\eta(\mathbf{x}_i))}{\pi} + \frac{1}{2}$. Cauchy jaotusel puudub keskvärtus ja dispersioon ning kõrgemat järku momendid on defineerimata. Samas langeb jaotus kokku Studenti t-jaotusega vabadusastmega 1. *Cauchit*-seosefunktsioon avaldub Cauchy kvantiili funktsiooni kaudu $g(\mu_i) = \tan\left(\pi\left(\mu_i - \frac{1}{2}\right)\right)$ ning selle mudeli kuju avaldub kahel järgneval kujul:

$$\pi_i = \frac{\tan^{-1}(\mathbf{x}_i^T \boldsymbol{\beta})}{\pi} + \frac{1}{2}, \quad \tan\left(\pi\left(\pi_i - \frac{1}{2}\right)\right) = \mathbf{x}_i^T \boldsymbol{\beta},$$

kus π_i tähistab sündmuse toimumise tõenäosust ning π väärtust $\pi = 3,14159 \dots$

Cauchy jaotusel on raskemad sabad, mis võimaldavad paremat hinnangut ekstreemväärtustele, kui normaaljaotus. Seega Cauchy mudelit on sobiv kasutada juhtudel, kui uuritava tunnuse väärtused on väga ebasümmeetriliselt jaotunud. Võrreldes *logit*-seosefunktsiooniga võtab *cauchit* selliseid „erindeid“ paremini arvesse

2.1.3 Täiend-log-log mudel (*CLog-Log model*) ja log-log mudel

Täiend-log-log seosefunktsiooni korral on jaotusfunktsioon Gompertzi jaotusega: $F(\eta(\mathbf{x}_i)) = 1 - \exp(-\exp(\eta(\mathbf{x}_i)))$. Seosefunktsioon, mis on eelmise funktsiooni kumulatiivse jaotusfunktsiooni pöördfunktsioon, avaldub kujul

$$g(\pi_i) = \log(-\log(1 - \pi_i)),$$

kus π_i tähistab sündmuse tõenäosust. Erinevalt eelnevalt vaadatud jaotustest on tegemist asümmeetrilise jaotusega ning selle mudeli kujud on järgmised:

$$\pi_i = 1 - \exp(-\exp(\mathbf{x}_i^T \boldsymbol{\beta})), \quad \log(-\log(1 - \pi_i)) = \mathbf{x}_i^T \boldsymbol{\beta}.$$

Täiend-log-log mudelit kasutatakse, kui ühtede osakaal on suur ning prognoositakse 1 tõenäosust. Vastasel juhul, kui nullide osakaal on suur, sobib log-log mudel.

Täiend-log-log mudeliga on tihedalt seotud log-log mudel, mille korral eeldame, et $1 - \pi_i = 1 - \exp(-\exp(\mathbf{x}_i^T \boldsymbol{\beta}))$. Sellisel juhul on seosefunktsioonile vastav jaotusfunktsioon Gumbeli jaotusega:

$F(\eta(\mathbf{x}_i)) = \exp(-\exp(-\eta(\mathbf{x}_i)))$ ning seosefunktsioon avaldub kujul:

$$g(\pi_i) = \log(-\log(\pi_i)).$$

Seega log-log mudel avaldub järgmiselt:

$$\pi_i = \exp(-\exp(-\mathbf{x}_i^T \boldsymbol{\beta})), \quad \log(-\log(\pi_i)) = -\mathbf{x}_i^T \boldsymbol{\beta}.$$

Kuna tegemist on ebasümmeetriliste mudelitega, siis neid kasutatakse väga tihti juhtudel, kui sündmuse toimumise tõenäosus on väga väike või vastupidiselt väga suur. Arvestades, kuidas täiend-log-log ja log-log mudelid on konstrueeritud, on lihtne näha, et täiend-log-log mudeli sobitamine 1 tõenäosusele on samaväärne log-log mudeli sobitamisega 0 tõenäosusele.

2.2 Mudeli parameetrite hindamine

Järgmine peatükk on kirjutatud Hosmer, D.W. ja Lemeshow, S. (2000) õpiku põhjal. Lineaarse regressiooni korral kasutatakse parameetrite hindamiseks vähimruutude meetodit, kuid binaarse tunnuse korral ei maksimeeri see enam tõepära. Selle asemel kasutatakse binaarse funktsioontunnusega regressioonimudelite parameetrite hindamiseks suurima tõepära meetodit (STP), mille abil leitakse parameetritele väärtused, mille korral tõepärafunktsioon saavutab maksimumi.

Olgu meil n sõltumatut vaatlust (\mathbf{x}_i, y_i) , $i = 1, 2, \dots, n$, kus $\mathbf{x}_i' = (x_{i0}, x_{i1}, \dots, x_{ik})$, $x_{i0} = 1$ on i -nda objekti kirjeldavate tunnuste väärtused ning olgu $\boldsymbol{\beta}' = (\beta_0, \beta_1, \dots, \beta_k)$ suurima tõepära meetodil hinnatud mudeli parameetrite vektor, kus k on kirjeldavate tunnuste arv. Logistilise regressiooni korral hinnatakse $p = k + 1$ parameetrit kasutades tõepära funktsiooni

$$L(\boldsymbol{\beta}) = \prod_{i=1}^n \pi_i^{y_i} (1 - \pi_i)^{1-y_i}, \quad (2)$$

kus π_i eelmises peatükis kirjeldatud kujul (1). Eelmise funktsiooni (2) tulemuseks saadakse parameetrite $\beta_0, \beta_1, \dots, \beta_k$ STP hinnangud. Eesmärgiks on leida selline k väärtus, mis maksimeerib $L(\boldsymbol{\beta})$ väärtust. Samaväärselt saame maksimeerida ka log-tõepära, millega on edaspidi kergem tööd teha.

2.3 Mudeli headuse hindamine

Järgmine peatükk põhineb Akaike' (1973) ja Schwarz'i (1978) artiklitel, kui ei ole märgitud teisiti.

Pärast mudeli kuju leidmist kontrollitakse mudeli headust. Esimese sammuna vaadatakse kirjeldavate tunnuste statistilist olulisust, mida hinnatakse χ^2 -statistikuga. Juhul, kui mingi tunnus on statistiliselt mitteoluline, jäetakse see mudelist välja. Tõepärasuhte test näitab mudeli kui terviku olulisust.

Mudeli sobivuse hindamise testid kirjeldavad kui hästi sobib leitud mudel kasutatud andmetega. Sobivuse hindamiseks leitakse *outcome variable* ja potentsiaalse riski suhe. Mudeli headuse näitajate eesmärgiks on hinnata, kas leitud mudel sobib andmete kirjeldamiseks, vastasel juhul võivad tehtud järeldused olla eksitavad.

Üks kasutatavamaid mudeli sobivuse indekseid on Akaike informatsioonikriteerium, mida vaadatakse ka selles töös, statistik avaldub kujul:

$$AIC = -2LL + 2p,$$

kus LL on log-tõepära ning p on mudeli parameetrite arv. Akaike kriteeriumi ei kasutata hüpoteeside kontrollimiseks, vaid mudeli selekteerimiseks, kus kõige madalama kriteeriumi väärtusega mudel osutub valituks.

Teise mudeli sobivuse indeksina vaadatakse Bayesi informatsioonikriteeriumi, mis hindab mudeli üleüldist sobivust ning põhineb mudelite Bayesi võrdlusel. Eeldusel, et meil on kaks mudelit ning me ei eelista ühte mudelit teisele, tunneb Bayesi kriteerium andmeid paremini kirjeldava mudeli ära (Williams, 2017). Kriteerium avaldub kujul:

$$BIC = -2LL + p \log n,$$

kus LL tähistab mudeli log-tõepära, p on sõltumatute parameetrite arv ning n on valimi suurus. Mida väiksem on AIC või BIC, seda parem on mudel.

2.4 Mudelite võrdlemine

See peatükk põhineb Fawcett (2005) artiklil. Mudeli prognoosimisvõime hindamiseks kasutatakse selles töös ROCi graafikut ning AUC statistikut. ROC-graafik on teatud viis visualiseerimiseks, organiseerimiseks ja klassifitseerijate valimiseks vastavalt nende sooritusele.

Spackman (1989) oli esimene, kes hakkas ROC graafikuid masinõppes algoritmide võrdlemiseks ja hindamiseks kasutama.

ROC graafik on lihtsa kontseptsiooniga, kuid vaatamata sellele ilmnevad selle kasutamisel mitmed mitte nii ilmsed keerukused. Klassifitseerimisprobleemide lahendamiseks kasutatakse alguses klassifitseerimismudelit, kus on võimalik teha 2 liiki vigu. Vea indikeerimiseks klassifitseeritakse iga element positiivseks või negatiivseks. Positiivseks loetakse tulemust, mille väärtus on 1 ning negatiivseks, kui väärtus on 0. Selleks, et eristada tegelikku ja prognoositud klassi kasutatakse tähistusi {P, N} mudeli prognoosimistulemuste märkimiseks. Kokkuvõttes on võimalik saada neli väljundit, nagu on seda tabelis 1 välja toodud.

Tabel 1. Klassifitseerimismudel ja sellel põhinevad statistikud

	Tegelik positiivne	Tegelik negatiivne	
Prognoos positiivne (P)	Tõeselt positiivne (TP)	Väärpositiivne (FP)	Kordustäpsus $Pr = \frac{TP}{TP + FP}$
Prognoos negatiivne (N)	Väärnegatiivne (FN)	Tõeselt negatiivne (TN)	Negatiivsete prognooside täpsus $NPV = \frac{TN}{TN + FN}$
	Tundlikkus $Sens = \frac{TP}{TP + FN}$	Spetsiifilisus $Spec = \frac{TN}{TN + FP}$	Täpsus $Acc = \frac{TP + TN}{TP + TN + FP + FN}$

Tegemist on tõeselt positiivse tulemusega (TP), kui juhtum on nii klassifitseeritud kui ka tegelik positiivne. Kui juhtum klassifitseeritakse negatiivseks, kuid see on tegelikult positiivne, siis tegemist on väärnegatiivse tulemusega (FN) ehk tehakse I liiki viga. Tulemuseks saame tõeselt negatiivse tulemuse (TN), kui sündmuse tegelik väärtus kui ka prognoositud tulemus on negatiivne. Juhul, kui prognoositakse sündmus positiivseks, siis tegemist on väärpositiivse

tulemusega (FP). Kirjeldataud maatriksi abil leitakse mitmeid statistikuid, mida kasutatakse mudeli prognoosimisvõime hindamiseks.

- Täpsus (ingl. k *accuracy*, lüh. *Acc*) näitab õigesti klassifitseeritud sündmuste osakaalu.
- Kordustäpsus (ingl. k *precision*, lüh. *Pr*) näitab positiivseks prognoositud sündmuste seas tegelike positiivsete osakaalu.
- Negatiivsete prognooside täpsus (ingl. k *negative predictive value*, lüh. *NPV*) näitab negatiivseks prognoositud sündmuste seas tegelike negatiivsete osakaalu.
- Tundlikkus (ingl. k *sensitivity*, lüh. *Sens*) näitab kui palju positiivseid sündmuseid hindab mudel positiivseks.
- Spetsiifilisus (ingl. k *specificity*, lüh. *Spec*) näitab kui palju negatiivseid sündmuseid hindab mudel negatiivseks.
- AUC statistik (ingl. k *area under the ROC curve*, lüh. *AUC*) näitab tõenäosust, et suvaline positiivne tulemus saab kõrgema tulemuse, kui suvaline negatiivne tulemus.

AUC statistiku väärtus varieerub lõigus $[0, 1]$, kus väärtus 1 tähendab, et mudel klassifitseeris kõik positiivsed sündmused kõrgemalt kui negatiivsed. Vastupidiselt eelmisele $AUC = 0$, kui kõik negatiivsed sündmused hinnatakse kõrgemalt kui positiivsed. Tulemuseks saadakse $AUC = 1/2$, kui mudeli tulemused on juhuslikud. Seega mida kõrgem on statistiku väärtus, seda parem on mudel.

3 Praktiline osa

Selles peatükis kirjeldatakse töös kasutatud andmestikke ning valitud tunnuseid, rakendatakse teoreetilises osas kirjeldatud meetodeid ning analüüsitakse saadud tulemusi. Praktilise osa täitmiseks kasutatakse tarkvara R ja selle lisapakette.

3.1 Andmestiku kirjeldus

Töö praktilise osa läbiviimiseks kasutatakse panga tegelikke andmeid, kuhu kuulub 10 000 klienti, keda on vaadatud kaheteistkümnel ajahetkel. Enne andmete analüüsimist, on andmestikust välja võetud kõik „erandid“. Umbes 17% valimisse sattunud klientidest on sõlmitud uuritud ajavahemikus tähtajalise hoiuse leping, seega ülejäänud klientidel on vaadatud ainult nõudmiseni hoiust. Andmed on kogutud vahemikus aprill 2015 - jaanuar 2018. Valitud on selline ajavahemik, sest 2015. aasta lõpus muutus 6 kuu Euribor negatiivseks, mille tagajärjel muutusid panga poolt pakutud tähtajalise hoiuse intressimäärad eelnevast madalamaks. Kokku oli andmestikus 30 tunnust, mis jagunevad kolme ploki:

- klientide profiil,
- klientide hoiuste andmed,
- makroökonoomsed näitajad.

Uuritavaks tunnuseks on binaarne tunnus „*stable*“, millel on 1/0 väärtus ning mis leitakse igale kliendile individuaalselt vastavalt kliendi hoiuse suurusele. Andmete tundlikkuse tõttu ei ole võimalik kõiki andmestikus kasutatud tunnuseid nimetada, kuid sellegipoolest antakse järgnevates peatükkides täpsem ülevaade eelnevalt nimetatud rühmadena.

1. Klientide profiil - Siia rühma kuulub 12 tunnust, mis on põhiliselt klientide isikuandmed. Enamus andmed on kvalitatiivsed ning kogutud kliendi lepingu sõlmimise ajal.
2. Klientide hoiuste andmed - Selles ploki on 15 tunnust, mis puudutavad klientide hoiuseid. Põhiliselt vaadatakse selles töös nõudmiseni ja tähtajaliste hoiuste jääke ning nende osakaale läbi kaheteistkümnepäevaste valitud ajaperioodi. Neid kahte hoiusetüüpi vaadatakse eraldi kuna tegemist on kahe erineva tootega. Nõudmiseni hoiuse puhul on kliendil võimalus raha igal hetkel välja kanda. See tähendab, et kliendil ei ole panga ees mingit kohustust ning minimaalse intressitulu tõttu on tema kaotus väga väike.

Tähtajalise hoiuse puhul sõlmitakse kliendiga leping, kus määratakse ära hoiustamise perioodile vastav intressimäär, mis on tunduvalt kõrgem, kui nõudmiseni hoiuse oma. Lepingu sõlmimisega tekib kliendil kohustus hoida oma raha selles pangas kuni sõlmitud perioodi lõpuni, vastasel juhul on pangal õigus nõuda kahjutasu. Kõige tähtsamaks tunnuseks selles plokis on „stable“, mis on ühtlasi ka selle tööuuritavaks tunnuseks ning määrab kas tegemist on stabiilse või ebastabiilse hoiusega.

3. Makroökonoomsed näitajad - Kuna klientide investeerimisotsuseid mõjutab suuresti majanduse kui terviku käitumine, siis lisaks pangasisestele andmetele vaadatakse lisaks ka makroökonoomseid näitajaid. Esimeseks näitajaks on 6 kuu Euribor'i määr (Euriborist on kirjutatud pikemalt peatükis 1.2). See annab kliendile hea ülevaate missugused võiksid olla tähtajalise hoiuse intressimäärad. Teisteks näitajateks on likviidsusriski mõõdikud, mille hindamiseks kasutatakse Baseli komitee poolt väljastatud dokumenti (Basel III: The Liquidity coverage ratio and liquidity risk monitoring tools).

Stabiilseks saame lugeda kõik need kliendid, kelle hoiuse suurus jääb alla 100 000 euro, kuna selles ulatuses on kliendi hoiused tagatud Tagatisfondi poolt. Seega mudel prognoositakse nendele klientidele, kelle jääk ületab seda piiri.

Mudeli prognoosimisvõime kontrollimiseks jagatakse andmestik juhusliku valiku põhjal kaheks, kus esimene osa ehk treeningandmestik moodustab ~70% ning teine osa ehk testandmestik ~30% algsest andmestikust. Kasutades treeningandmestikku leitakse mudel, mille prognoosimisvõimet hinnatakse hiljem testandmestiku peal. Tabelis 1 tuuakse välja kõikide valimite suurused ning stabiilsete hoiuste osakaalud.

Tabel 2. Andmestiku ülevaade

	Valimi suurus	Ebastabiilsed hoiused
Terve andmestik	2 431	204 (8,39%)
Treeningandmestik	1 704	148 (8,69%)
Testandmestik	727	56 (7,70%)

3.2 Mudeli konstrueerimine

Eesmärgiks on koostada mudel, mis hindaks antud panga kõrgema riskiga hoiuste stabiilsust. Kuna hinnatakse binaarset tunnust, siis seetõttu rakendatakse mudeli konstrueerimiseks binaarse funktsioontunnusega regressiooni. Mudeli koostamisel kasutatakse eelnevaid teadmisi klientide finantskäitumise kohta ning valitakse välja need tunnused, mida peetakse oluliseks. Seejärel kontrollitakse valitud tunnuste statistilist olulisust olulisusenivool $\alpha = 0.05$. Järgmise sammuna lisatakse mudelisse ühe kaupa uusi tunnuseid ning vaadatakse järgi, kas tegemist on statistiliselt olulise tunnusega või mitte. Seda protsessi korratakse nii kaua kuni mudelisse saavad kõik olulised tunnused. Parima mudeli leidmiseks võrreldakse leitud mudelite näitajaid ning valitakse välja mudel, millel on kõige paremad tulemused.

3.3 Mudelite võrdlemine

Selle töö kontekstis on parim mudel selline, mis suudab kõige täpsemini prognoosida panga klientide hoiuste stabiilsust. Kuna reeglina ebastabiilsete klientide hoiused on keskmisest suurema jäägiga, on nende õigesti klassifitseerimine mitmel eesmärgil oluline. Teisest küljest vaadates on stabiilsete klientide õigesti määramine oluline ressursside kokkuhoiu mõttes. Lisaks, kui klassifitseerimisel tekib liiga palju väärpositiivseid tulemusi, siis võib likviidusrisiki hindamisel tekkida ülehindamine. Seega selleks, et pank saaks oma ressursse võimalikult optimaalselt kasutada ning vigadega kaasnevad kulutused oleksid minimaalsed, peame mudeli tundlikkust tähtsamaks kui spetsiifilisust.

Uuritava tunnuse ebavõrdse gruppide jagunemise tõttu on klassifitseerimislävendid leitud ROC graafiku abil. Klassifitseerimislävend on piir, millest väiksema tõenäosusega kliendid määratakse stabiilseks ja suurema tõenäosusega määratakse ebastabiilseks.

Mudelite võrdlemisel vaadatakse mudeli headuse näitajaid, spetsiifilisust ning tundlikkust. Parima mudeli valimisel võrreldakse alguses mudeli headuse näitajaid. Kui mõlema mudeli korral on AIC ja BIC tulemuste vahed väikesed, siis võrreldakse omavahel mudelite klassifitseerimismatrikseid ning nendega seotud näitajaid. Parimaks mudeliks valitakse klassifitseerimismudel, mille korral on panga ressursside jaotus kõige optimaalsem.

3.3.1 „stable“- mudel

Mudeli uuritavaks tunnuseks on „stable“, millel on kaks väärtust: 0, kui tegemist on stabiilse hoiusega ja 1, kui tegemist on ebastabiilse hoiusega. Tunnuse moodustamisel kasutatakse panga stabiilse hoiuse definitsiooni.

Töö käigus moodustatakse 3 mudelit, mida võrreldakse omavahel ning seejärel valitakse nende seast parim. Esimese mudeli leidmiseks kasutatakse *logit*-seosefunktsiooni, teise moodustamiseks kasutatakse *cauchy*-seosefunktsiooni ning kolmanda mudeli korral kasutatakse *log-log* seosefunktsiooni.

Ekspertvaliku mudeli konstrueerimisel valitakse alguses eksperdi hinnangul välja 3 tunnust, seejärel kontrollitakse nende statistilist olulisust ja prognoosimisvõimet ning lisatakse eelnevalt kirjeldatud meetodil kirjeldavaid tunnuseid juurde.

Tabel 3. Mudelite võrdlemine

	AIC	BIC	Spetsiifilisus	Tundlikkus	Klassifitseerimis- lävend	Oluliste parameetrite arv
Logit	275,95	314,03	0,90462	0,875	0,05	6
Cauchy	287,71	331,27	0,806259	0,875	0,015	7
Log-log	292,38	330,47	0,943368	0,8571429	0,90	5

Teooria järgi peaks hästi sobima kas log-log või Cauchy mudel, kuna uuritava tunnuse jaotus on ebasümmeetriline ning sündmuse toimumise tõenäosus on väga väike. Võrreldes mudeli headuse näitajaid: AIC ja BIC, näeme, et kõige parema tulemuse annab hoopis logit mudel ning sellest veidi halvema tulemuse Cauchy mudel. Log-log mudeli tulemused on osutusid kõige halvemateks.

Kuigi mudeli headuse näitajate järgi saame öelda, et parim mudel on logit seosefunktsiooniga, võrdleme omavahel ikkagi kõikide mudelite klassifitseerimismatrikseid. Klassifitseerimisel loetakse sündmus positiivseks, kui tegemist on ebastabiilse hoiusega ehk kui uuritava tunnuse väärtus on 1. Sündmus loetakse negatiivseks, kui tegemist on stabiilse hoiusega.

Tabel 4. Logit-mudeli klassifitseerimismatriks

	Tegelik positiivne	Tegelik negatiivne
Proгноos positiivne	49 (6,74%)	64 (8,80%)
Proгноos negatiivne	7 (0,96%)	607 (83,49%)

Tabel 5. Cauchit-mudeli klassifitseerimismatriks

	Tegelik positiivne	Tegelik negatiivne
Proгноos positiivne	49 (6,74%)	130 (17,88%)
Proгноos negatiivne	7 (0,96%)	541 (74,42%)

Tabel 6. Log-log mudeli klassifitseerimismatriks

	Tegelik positiivne	Tegelik negatiivne
Proгноos positiivne	48 (6,60%)	38 (5,27%)
Proгноos negatiivne	8 (1,10%)	633 (87,07%)

Panga seisukohast on II tüüpi viga teha mitmeid kordi kallim kui I tüüpi viga. Täpset hinnangut ei ole võimalik sellele määrata, sest tuleb arvestada ka mitterahalisi väärtuseid. Seetõttu peame mudeli tundlikkust tähtsamaks, kui mudeli spetsiifilisust. II tüüpi viga tehes määratakse klient stabiilseks, kuigi tegelikult on ta ebastabiilne ning I tüüpi vea korral klassifitseeritakse stabiilne hoius ebastabiilseks. Mudelite spetsiifilisuse ja tundlikkuse (tabel 3) võrdlemisel näeme, et positiivseid tulemusi klassifitseerivad logit mudel ja Cauchy mudel sama hästi. Negatiivseid sündmuseid klassifitseerib kõige paremini log-log mudel (tabel 3).

Logit mudeli korral näeme täpsemalt mudeli klassifitseerimismatriksist (tabel 4), et $\approx 0,96\%$ sündmustest prognoositi stabiilseks, kuigi tegelikult oli tegemist ebastabiilsete hoiustega. Umbes $8,80\%$ sündmustest prognoositi stabiilne hoius ebastabiilseks ehk tehti I tüüpi viga.

Logit ja cauchit mudeli klassifitseerimismatriksite võrdlemisel näeme, et mudelite tundlikkus on samasugune. Mudelite spetsiifilisuse (tabel 3) võrdlemisel on logit mudeli tulemus $\approx 10\%$ võrra parem, mis tähendab, et mudel klassifitseerib täpsemini stabiilseid kliente. Selle tulemusena säästetakse panga ressursse ning hinnatakse täpsemini üldiseid riske.

Samuti võrreldes omavahel logit ja log-log mudelite klassifitseerimismatrikseid, näeme, et log-log mudeli spetsiifilisus on $\approx 4\%$ võrra parem, samas mudeli tundlikkus on $\approx 2\%$ võrra halvem. Kuna stabiilseid hoiuseid on pangas palju rohkem kui ebastabiilseid, siis tänu kõrgemale spetsiifilisusele klassifitseeritakse log-log mudeliga summaarselt kõige rohkem kliente õigesti. Vaatamata sellele, loeme logit mudeli siiski paremaks, sest selle tundlikkus on kõrgem, mille abil välditakse suuremaid vigu.

Seega parimaks mudeliks valime endiselt logit seosefunktsiooniga mudeli, kuna nii headuse näitajate (tabel 3) kui ka klassifitseerimismatriksite (tabel 4, 5 ja 6) võrdlemisel oli see sobivaim.

3.4 Mudeli interpreteerimine

Akaike' ja Bayes'i informatsioonikriteeriumite ning klassifitseerimismatriksi ja sellega seotud näitajate tulemuste järgi valiti parimaks mudeliks logit mudel. Mudelil on 6 statistiliselt olulist tunnust ning selle kuju avaldub järgmiselt:

$$\log\left(\frac{\pi_i}{1 - \pi_i}\right) = -12,38 + 2,414 \cdot T1 + 1,639 \cdot T2 + 0,0156 \cdot T3 \\ + 1,575 \cdot T4 + 2,172 \cdot T5 + 9,651 \cdot 10^{-6} \cdot T6$$

Juhul, kui tunnuse $T1$ väärtus tõuseb $0,01$ ühiku võrra ning ülejäänud väärtused jäävad samaks, siis šanss, et hoiused muutuvad ebastabiilsemaks kasvab $e^{2,414 \cdot 0,01} = 1,0244$ korda ehk $2,44\%$ võrra. Tunnusel $T2$ on kaks väärtust. Seega hoiustel, mille korral $T2$ on 2 , on šanss olla ebastabiilne $e^{1,639} = 5,15$ korda suurem, kui tunnuse väärtuse 1 korral. Kuigi tunnuse $T6$ koefitsient on väike, avaldab see siiski mõju, sest hinnatakse $100\ 000$ eurost suuremate hoiuste stabiilsust.

3.5 Tulevased uuringud

Käesoleva uuringu käigus leiti mudel, mis hindaks suurema riskikaaluga klientide stabiilsust. Tulevaste analüüside käigus võiks muuta nii vaadeldud perioodi kui ka täiendada kasutatud andmestikku. Andmestikus võiks kasutada rohkem majanduslikku olukorda kirjeldavaid näitajaid nagu näiteks töötuse määr ja keskmine palk. Nende näitajate abil oleks võimalik hinnata, kui paljud inimesed on võimelised oma raha kasvatama.

Lisaks võiks jälgida kliente pikemal ajaperioodil, võttes andmestikku juurde vähemalt 100 ajahetke. See võimaldaks kasutada alternatiivse meetodina aegridu, mida rakendab Bašič (2015) oma klientide stabiilsust hindava mudeli leidmiseks.

Kuna selles uuringus osutus statistiliselt oluliseks tunnuseks nõudmiseni hoiuse summa, siis tulevastes uuringutes võiks tähelepanu pöörata hoopis klientide hoiuste väljavoolu hindamisele. Mudeli leidmisel saaks hinnata stressiolukordade simuleerimiste kaudu väljavoolude mahte ning mahtude muutustega kaasnevaid mõjusid panga tegevusele.

Kokkuvõte

Stressiolukordades kipuvad kliendid pankadest raha välja viima, selleks on oluline hinnata hoiuste stabiilsuse taset. Selle töö käigus analüüsiti panga suurema likviidsusriskiga kliente ning leiti nendele stabiilsust hindav mudel.

Viimase majanduskriisi ajal toimus suur muutus finants- ja rahaturgudel. Hoiuste väljavool oli kõrgema riskiga pankades rekordiliselt suur, mille tagajärjel oli laene preaaegu võimatu välja anda, tagades neid isegi kõige kvaliteetsemate hoiustega (Eisenbach, Keister, McAndrews ja Yorulmazer, 2014). Aastal 2013 andis Baseli komitee välja likviidsusriski jälgimiseks eeskirja, mille eesmärgiks on stabiliseerida pangandussektorit ning ära hoida võimalikku likviidsusega seotud stressiolukorda.

Antud uuringu eesmärgiks oli luua mudel, mis prognoosiks pangasisest hoiuste stabiilsust. Kliendi stabiilsuse staatuse määramiseks jälgiti nii Baseli komitee eeskirja kui ka pangasisesele definitsioonile vastavat väljavoolu koefitsienti. Töös kasutatud andmestikku kuulus 10 000 klienti, keda jälgiti kvartaalsete vahemikega aastatel 2015-2018 ning 34 tunnust, mis jagunesid kolme plokki: klientide profiil, klientide hoiuste andmed ja makroökonoomsed näitajad. Mudeli leidmiseks kasutati binaarse funktsioontunnusega regressioonimudeleid, kus võrreldi omavahel kolme erineva seosefunktsiooniga leitud mudelit. Seosefunktsioonideks valiti logit-, cauchit- ja log-log-funktsioonid, millest kaks viimast peaksid paremini kirjeldama asümmeetriliselt jaotunud uuritavat tunnust. Vaatamata mudelite teoreetilistele eeldustele, osutus parimaks mudeliks logit mudel.

Mudeli abil saadud tulemused olid ootuspärased. Enne läbiviidud analüüsi eeldati, et osade diskreetsete tunnuste korral mõjutavad tunnuste väärtused klientide stabiilsust märkimisväärselt erinevalt. Saadud mudeli abil on võimalik hinnata kui suur on selliste tunnuste väärtuste erinevus kliendi hoiuse stabiilsuse hindamisel.

Bakalaureusetöö raames keskenduti klientide hoiuste stabiilsuse hindamisele. Leitud mudelit kasutades saab anda hinnangu suurema riskikoefitsiendiga hoiustele ning jälgida kaudselt likviidsus- ja intressiriski.

Kasutatud allikad

1. Akaike, H. (1973). Information theory and an extension of the maximum likelihood principle. *2nd International Symposium of Information Theory*, B.N. Petrov and F. Csaki, eds., Akademiai Kiado, Budapest, 267-281.
2. Bald, J. (2008). *Stability of small balance deposits*. Kasutatud 17.04.2018 <https://www.cgap.org/sites/default/files/CGAP-Technical-Guide-Stability-Small-Balance-Deposits-Jun-2009.pdf>
3. *Basel III: The Liquidity Coverage Ratio and liquidity risk monitoring tools* (2013). Kasutatud: 03.03.2018 <https://www.bis.org/publ/bcbs238.pdf>
4. Bašič, A., M. (2015). Model for determining the stability of retail deposits with higher outflow rates. *Naše gospodarstvo our economy*, 61(5), 12-22. doi: 10.1515/ngoe-2015-0018
5. Cipu, E., C., Udriste, S., (2009). Estimating Non-Maturity Deposits. *Proceedings of the 9th WSEAS International Conference on SIMULATION, MODELLING and OPTIMIZATION*, lk 369-374.
6. Colmant, B., Peters, K., Gussé, J., Vanderheere, W. (2013). *Retail deposits – Prepare for a bumpy ride*. Roland Berger Strategy Consultants.
7. Dewachter H., Lyrio M., Maes K. (2006). A multi-factor model for the valuation and risk management of demand deposits. *NBB Working paper reasearch, no. 83*.
8. *Euribor reform frequently asked questions*. (2017). Kasutatud: 20.04.2018 https://www.emmi-benchmarks.eu/assets/files/D0255A-2017-QUESTIONS%20AND%20ANSWERS%20UPON%20PLVP%20OUTCOME-FOR%20PUBLICATION_clean.pdf
9. Fawcett T., (2005). An introduction to ROC analysis. *Pattern Recognition Letters*, 27, 861-874. doi:10.1016/j.patrec.2005.10.010
10. Feilitzen, H. (2011). *Modeling Non-maturing Liabilities*.
11. *Finantsinspektsiooni soovituslik juhend. Nõuded likviidsusriski juhtimisele*. (2013). Kasutatud: 22.04.2018 https://www.fi.ee/failid/Soovituslik_juhend_Nouded_likviidsusriski_juhtimisele.pdf
12. Frauendorfer, K. ja Schürle, M. (2007). Dynamic modelling and optimization of non-maturing accounts. L. Matz, P. Neu (toim). *Liquidity Risk Measurement and Management* (lk 327-359). Singapore: Wiley.
13. Hosmer, D.W., ja Lemeshow, S. (2000). *Applied Logistic Regression* (2nd Edition). New York: Wiley. <http://dx.doi.org/10.1002/0471722146>

14. Hutchinson, D., Pennacchi, G. (1996). Measuring rents and interest rate risk in imperfect financial markets: the case of retail bank deposits. *Journal of Financial and Quantitative Analysis*, 31(3), 399-417. doi: 10.2307/2331398
15. Jarrow ja van Deventer (1998). The arbitrage-free valuation and hedging of demand deposits and credit card loans. *Journal of Banking and Finance*, 22, 249-272. doi: 10.1016/S0378-4266(97)00058-7
16. Kalkbrenner ja Willing (2004). Risk management of non-maturing liabilities. *Journal of Banking and Finance*, 28, 1547-1568. doi:10.1016/S0378-4266(03)00131-6
17. O'Brien J.M. (2000). *Estimating the Value and Interest Rate Risk of Interest-Bearing Transactions Deposits*. Division of Research and Statistics, Board of Governors of the Federal Reserve System.
18. Paraschiv, F., Schürle, M. (2010). *Modeling client rate and volumes of non-maturing accounts*. University of St. Gallen.
19. Schwarz, G. (1978). *Estimating the dimension of model*. *Ann. Statist.*, 6(2), 461-464. doi:10.1214/aos/1176344136
20. Tutz, G. (2011). Alternative Binary Regression Models. *Regression for Categorical Data* (lk. 123-142). Cambridge: Cambridge University Press. doi:10.1017/CBO9780511842061.006
21. Tynys, L. (2012). *Estimating the Value and Interest Rate Risk of Demand Deposits in Concentrated Markets*. Magistritöö. Aalto University School of Economics, Finance.
22. Williams, R. (2017). *Scalar Measures of Fit: Pseudo R^2 and Information Measures (AIC & BIC)*. Kasutatud 10.04.2018 <https://www3.nd.edu/~rwilliam/stats3/L05.pdf>
23. Eisenbach, T., Keister, T., McAndrews, J., Yorulmazer, T. (2014). The stability of funding models. *Economic policy review*, 20(1), 29-45.

Lihlitsents lõputöö reprodutseerimiseks ja lõputöö üldsusele kättesaadavaks tegemiseks

Mina, **Jelizaveta Jerahtina**,

1. annan Tartu Ülikoolile tasuta loa (lihlitsentsi) enda loodud teose „Panga klientide hoiuste stabiilsuse hindamine“, mille juhendaja on dots. Meelis Käärik,
 - 1.1.reprodutseerimiseks säilitamise ja üldsusele kättesaadavaks tegemise eesmärgil, sealhulgas digitaalarhiivi DSpace-is lisamise eesmärgil kuni autoriõiguse kehtivuse tähtaja lõppemiseni;
 - 1.2.üldsusele kättesaadavaks tegemiseks Tartu Ülikooli veebikeskkonna kaudu, sealhulgas digitaalarhiivi DSpace´i kaudu kuni autoriõiguse kehtivuse tähtaja lõppemiseni.
2. olen teadlik, et punktis 1 nimetatud õigused jäävad alles ka autorile.
3. kinnitan, et lihlitsentsi andmisega ei rikuta teiste isikute intellektuaalomandi ega isikuandmete kaitse seadusest tulenevaid õigusi.

Tartus, **08.05.2018**