

Bankroto prognozavimo modeliai Europos bankų sektoriui

Kazakevičiūtė, Goda; Budrionytė, Ramunė
Bankroto prognozavimo modeliai Europos bankų sektoriui
Buhalterinės apskaitos teorija ir praktika, núm. 19, 2019
Vilniaus Universitetas, Lituania

Disponible en: <https://www.redalyc.org/articulo.oa?id=693074827003>

DOI: <https://doi.org/10.15388/batp.2019.3>



Esta obra está bajo una Licencia Creative Commons Atribución 4.0 Internacional.

Bankroto prognozavimo modeliai Europos bankų sektoriui

Bankruptcy Prediction Models for the Banking Sector of
Europe

Goda Kazakevičiūtė goda.kazakeviciute@gmail.com

Danske Bank A/S Lietuvos filialas, Lithuania

Ramunė Budrionytė ramune.budrionyte@evaf.vu.lt

Vilniaus universitetas, Lithuania

 <https://orcid.org/0000-0002-6889-5598>

Buhalterinės apskaitos teorija ir praktika,
nám. 19, 2019

Vilniaus Universitetas, Lithuania

DOI: <https://doi.org/10.15388/batp.2019.3>

Redalyc: <https://www.redalyc.org/articulo.oa?id=693074827003>

Summary: Prieš dešimtmetį vykusį Pasaulinį finansų krizę skaudžiai paveikė pasaulio verslą bei visuomenę ir sukėlė nepasitikėjimą vykdoma bankų sektoriaus stebėseną ir kontrole. Šis nepasitikėjimas paskatino priežiūros institucijas sustiprinti bankų bankrotų prevencines priemones, kurios vis tobulinamos siekiant išvengti ar sušvelninti naujos krizės neigiamus padarinius. Viena iš tokių prevencinių priemonių – patikimų banko bankroto prognozavimo modelių kūrimas ir nuolatinis taikymas vertinant ir prognozuojant bankų veiklą. Tyrimo tikslas – ištyrus bankų veiklą apibūdinančius finansinius rodiklius pateikti Europoje veikiantiems bankams lengvai pritaikomą bankų bankroto prognozavimo modelį. Darbe taikyti teoriniai mokslinės literatūros lyginamosios analizės, kritinio vertinimo, sisteminimo, apibendrinimo metodai. Empiriniam tyrimui naudoti bankų finansinių ataskaitų analizė, ekspertinio vertinimo metodas, duomenų rinkimas ir sisteminimas, duomenų modifikavimas, modeliavimas, dvinarė logistinė regresija, koreliacija, grafinis duomenų atvaizdavimas, ROC kreivė. Atrinkus 24 kintamuosius rodiklius sukurti penki dvinarės logistinės regresijos bankroto prognozavimo modeliai. Modelių tikslumas buvo vertinamas pagal sugeneruotų II rūšies klaidų kiekį, prognozuojant bankų žlugimą likus vieniems ir dvejiems metams iki žlugimo įvykio, ir ROC kreivės pagrindu. Įvertinus modelių prognozavimo kokybę nustatyta, kad modelis Z5- tinkamiausias Europos bankų bankrotui prognozuoti ir 78,57% tikslumu identifikuoja žlungančius Europos bankus likus vieniems metams iki žlugimo.

JEL klasifikacija: F 37, G2, G3

Keywords: bankų bankroto prognozavimo modeliai, Europos bankai, finansiniai rodikliai.

Abstract: The global financial crisis has hit the global business and society hard and has caused a mistrust in the monitoring and control of the banking sector a decade ago. The distrust encouraged supervisory authorities to reinforce the bankruptcy preventive measures, that are being developed to prevent or mitigate the negative effects of the new crisis. The development and permanent application of reliable bankruptcy prediction models are the part of such preventive measures. The aim of the study was to create a universal straightforward bankruptcy prediction model for the European banking sector, based on the analysis of financial ratios. The study examines the scholarly literature and deploys the theoretical methods of comparative analysis, critical evaluation, systematisation, generalisation. The empirical research involves expert assessment method, analysis of financial statements, data collection, structuring and modification, modelling: binary logistic regression, correlation, graphical representation of data, ROC curve. Research and results: based on selected 24 variables (ratios), five binary logistic regression models were created. The accuracy was tested on the ROC curve, together with the comparison of II type errors, which were made while predicting

bank's failure 1 year and 2 years before the distress. Main findings were: when models were validated and their II type errors were compared, the conclusion was made that model Z5 is the most suitable for predicting bankruptcy for the European banking sector. The accuracy to identify failing banks 1 year before the distress was 78.57%.

JEL: F 37, G2, G3

Keywords: bankruptcy forecasting models for banks, European banks, financial ratios.

Įvadas

Pasaulinė finansų krizė, neigiamai paveikusi daugelio valstybių ekonomikas, išryškino bankų sektoriaus svarbą ir poveikį šalių ekonominiam stabilumui, sukėlė nepasitikėjimą vykdoma bankų sektoriaus stebėseną, kontrole bei prevencinių priemonių veikimu. Bankų sukurtos sofistikuotos finansinės priemonės ir padidėjęs rizikos „apetitas“, pasireiškęs didžiuliu būsto paskolų gyventojams augimu, paveikti suprastėjusia portfelio kredito kokybe ir nekilnojamo turto „burbulo sproginimu“, privertė JAV bankus registruoti milijardinius nuostolius (Mockaitienė, Žmiejauskaitė, 2010). Vien Europos Sąjungoje nuo 2008 m. spalio iki 2012 m. gruodžio buvo skirta daugiau nei 590 milijardų eurų mokesčių mokėtojų pinigų bankų kapitalo injekcijoms, siekiant apsaugoti juos nuo žlugimo ir sustabdyti ekonominę suirutę (Europos Centrinis Bankas, 2018). Adekvatus nepasitikėjimas ir siekis tobulinti bankų priežiūros procesus paskatino priežiūros institucijas inicijuoti reformas ir sustiprinti bankų bankrotų prevencines priemones. Ir nors 2012 - 2018 m. ECB identifikavo tik penkis bankus, priskirtinus prie žlungančių (failing or likely to fail) kategorijos, skausminga pastarosios krizės patirtis neleidžia atsipalaiduoti: siekiama sukurti tokias prevencines priemones, kurios padėtų išvengti ar bent sumažinti būsimų krizių neigiamus padarinius. Viena iš tokių prevencinių priemonių – patikimų banko bankroto modelių sukūrimas ir nuolatinis jų taikymas vertinant ir prognozuojant šių institucijų veiklą.

Darbo tikslas – ištyrus bankų veiklą apibūdinančius finansinius rodiklius pateikti Europoje veikiančioms bankams lengvai pritaikomą bankų bankroto prognozavimo modelį.

Tikslui pasiekti išskelti darbo uždaviniai:

1. identifikuoti rodiklius, geriausiai atskiriančius sėkmingai veikiančius bankus nuo žlungančių bankų;
2. sukurti bankroto prognozavimo modelį Europos bankams;
3. įvertinti bankroto prognozavimo modelio tinkamumą Europos bankų sektoriui ir jo patikimumą.

Darbo objektas – bankų bankroto prognozavimo modeliai.

Darbe taikyti teoriniai mokslinės literatūros lyginamosios analizės, kritinio vertinimo, sisteminimo, apibendrinimo metodai. Empiriniam tyrimui naudoti bankų finansinių ataskaitų analizė, ekspertinio vertinimo metodas, duomenų rinkimas ir sisteminimas, duomenų modifikavimas, modeliavimas, dvinarė logistinė regresija, koreliacija, grafinis duomenų atvaizdavimas, ROC kreivė.

1. Bankų bankroto prognozavimo modelių tyrimų rezultatų analizė

Įmonių bankrotas nėra atsitiktinis ar savaiminis rezultatas - jį sukelia tam tikri veiksniai, padidinantys bankrotą lemiančias rizikas: kredito, likvidumo (trumpalaikio mokumo), kapitalo, operacinę, rinkos ir kitas (Gudelytė, Valužis, 2012). Nors visos rizikos yra svarbios ir susijusios, visgi kredito rizika išlieka svarbiausia ir reikšmingiausia banko veikloje: prieš krizę bankai prisiėmė daugiau rizikos siekdami didesnės gražos ekonomikos pakilimo metu ir neužtikrino kredito rizikos prevencijos. Toks neapdairus bankų valdymas sukėlė milžiniškus neigiamus padarinius pasaulio ekonomikai, todėl Bazelio bankų priežiūros komitetas (BBPK) parengė bankų kapitalo reikalavimų reformą, kuri įgyvendinama pasauliniu mastu. Reformos pagrindinė paskirtis – didinti finansinių įstaigų atsparumą galimiems nuostoliams ir tokiu būdu apsaugoti visuomenę bei šalių ekonomikas nuo galimų bankų bankrotų padarinių (Lietuvos bankas, 2015). Šiuo metu ES veikiantys bankai privalo tenkinti minimalų 8% kapitalo ir 2,5 % papildomo kapitalo apsaugos rezervo reikalavimus - jeigu bankas patirtų didesnius nuostolius, nei sukaupta papildomame kapitalo apsaugos rezerve, gali būti pradėtas pertvarkymo arba bankroto procesas (Lietuvos bankas, 2017). Visi ES sisteminės svarbos bankai turi turėti ir specialų sisteminės svarbos įstaigų kapitalo rezervą galimiems nuostoliams padengti: kuo finansinė įstaiga svarbesnė, tuo didesnis kapitalo rezervas. Kai bankai suformuoja sisteminės svarbos įstaigų kapitalo rezervus, tuomet gali patirti nuostolius, didesnius negu 2,5% bendros pagal riziką įvertintų pozicijų sumos vertės - papildomas kapitalo rezervas absorbuos dalį nuostolių ir taip sumažins kredito riziką, kuri yra viena pagrindinių bankų bankrotų ir krizių priežasčių (Lietuvos bankas, 2015; Valvonis, 2004). ES šalyse bankų priežiūros institucijos savo nuožiūra gali nustatyti anticiklinio kapitalo rezervo dydį konkrečiai finansų institucijai ar grupei ir tokiu būdu sumažinti netvaraus augimo riziką, kuri gali neigiamai paveikti bankų sektorių ir ekonomiką dėl atsiradusio kreditavimo bumo ar suteikti papildomą kapitalo rezervą ekonomikos nuosmukio metu. Be kapitalo rezervų reikalavimų, bankai turi atitikti likvidumo ir didelių pozicijų reikalavimus, taip pat turi išlaikyti svarto rodiklį, ne mažesnę negu 3%, o tarptautinių sistemiškai svarbių bankų svarto dydis yra padidintas dar puse procentų nuo jiems priskirtų G-SIBs rezervo dydžio (Bazelio Komitetas, b. m.). Vis dėlto šie reikalavimai yra tik kriterijai, kuriuos bankas turi atitikti siekdamas išlaikyti licenciją ir vykdyti privalomąją prevenciją. Tačiau bankų priežiūros institucijos, kreditoriai, klientai bei verslas nelaukia, kol bankas pažeis nustatytus reikalavimus: suinteresuoti asmenys siekia sukurti tam tikras išpėjamas sistemas - bankroto prognozavimo modelius, kad galėtų iš anksto identifikuoti blogėjančią finansinių institucijų būklę ir tokiu būdu gautų papildomo laiko įvykdyti prevencines priemones ar bent sumažinti galimą žalą ir nuostolius šalies ekonomikai.

Bankroto prognozavimo modeliai įprastai kuriami įvairiose ūkio šakose veikiančių įmonių rizikai įvertinti, vis dėlto dažnai jie nėra tinkami finansinių institucijų - bankų bankroto rizikos identifikavimui dėl specifinės jų veiklos ir finansinių rodiklių. XX a. 9-ame dešimtmetyje JAV bankų priežiūros institucija paskelbė penkių dalių bankų reitingavimo sistemą CAMEL, kurią sudarė kapitalo pakankamumo, turto kokybės, vadovų kompetencijos, pajamingumo ir likvidumo rodikliai. Būtent tinkamas banko kapitalo įvertinimas yra vienas svarbiausių CAMEL reitinge, nes tik pakankamas kapitalo dydis gali absorbuoti nuostolius ir apsaugoti neapdraustus indėlininkus ir kreditorius nuo praradimų (Huang ir kt, 2012). Siekiant modelį labiau orientuoti į bendrą riziką, vėliau buvo įtrauktas dar vienas rodiklis – jautrumas rinkos rizikai, todėl dabar modelis įvardijamas kaip CAMELS reitingavimo sistema, kurios kiekviena dalis sudaryta iš atitinkamų kintamųjų, o jų bendras įvertinimas sugeneruoja atitinkamos grupės reitingą nuo 1 (labai gerai) iki 5 (labai blogai) (Sahajwala, Van Den Bergh, 2000). Sistema suteikia galimybę reitinguoti bankus nuo blogiausio iki geriausio ir identifikuoti sėkmingus bei prastai veikiančius. Bankų bankroto teorinius prognozavimo modelius, į kuriuos įtraukiama kokybinė ir kiekybinė informacija, taip pat vysto tarptautinės reitingavimo agentūros (Moody's, Fitch, Standard and Poor's), o nuo 2007 metų Bazelio komitetas skatina ir pačius bankus kurti reitingavimo sistemas, kurios atspindėtų finansinių institucijų bankroto tikimybę.

Be priežiūros ar pačių finansinių institucijų bei reitingavimo įmonių, bankų bankroto modeliais domisi, analizuoja bei kuria pavieniai mokslininkai ar jų grupės. Sinkey buvo pirmasis, kuris sukūrė diskriminantinės analizės modelį, sudarytą iš dviejų finansinių rodiklių: veiklos išlaidų ir veiklos pajamų santykio bei investicijų ir turto santykio, pritaikytą komercinių bankų bankroto tikimybei apskaičiuoti. Vėliau E. Kaciak (1997), taikydamas daugiamatės diskriminantinės analizės metodą, iš 85 rodiklių atrinko 8 finansinius santykinius rodiklius, geriausiai identifikuojančius bankus, kuriems kilusi bankroto rizika, ir bankus, kuriems bankrotas negresia (Marcišauskienė ir Mekaitė, 2015).

Kolari, Glennon, Shin ir Caputo (1999) pateikė logistinės regresijos ir charakteristikų atpažinimo modelius, kurie buvo sukurti išanalizavus 18 didžiausių 1989 – 1992 m. laikotarpiu bankrutavusių JAV bankų ir virš 1000 nebankrutavusių bankų, o modelių sugeneruoti rezultatai buvo pritaikyti keturiasdešimt dviem į modelio mokymosi procesą neįtrauktiems bankams. Logistinės regresijos modelis galėjo 96 % tikslumu identifikuoti bankroto riziką prieš vienus metus ir 95 % tikslumu likus dvejiems metams iki bankroto. Pastebėta, kad II rūšies klaidų (identifikuoti veikiančius bankus kaip bankrutuojančius) buvo sąlyginai daugiau nei I rūšies klaidų (identifikuoti bankrutuojančius bankus kaip veikiančius bankus). Dirbtinio intelekto (charakteristikų atpažinimo) modelio tikslumas, pritaikius jį tiems patiems 42 bankams buvo 100%, vis dėlto autoriams pradėjus manipuluoti testavimo imtimi, modelio tikslumas sumažėjo. Taip pat buvo pastebėta, kad dirbtinio intelekto modelio tikslumas laiko atžvilgiu išliko gana stabilus,

kai logistinės regresijos modelio tikslumas mažėjo. Autorių teigimu, atsižvelgiant į bankų priežiūros institucijos poreikius, charakteristikų atpažinimo modelio atnaujinimui reikėtų mažesnių išlaidų (Kolari, Glennon, Shin ir Caputo, 2002).

Konstandina (2006) analizavo Rusijos bankų sektorių, siekdama sukurti bankų bankroto prognozavimo modelį. Tyrime buvo naudota ne tik mikro-lygio informacija, t.y. banko veiklą apibūdinantys rodikliai, bet ir makro-lygio duomenys (BVP, vartotojų kainų indeksas, valiutos konvertavimo kursas) siekiant prognozuoti bankų bankrotą. Sukurti du modeliai, kurie turėjo skirtingus tikslus: daugiakriterinis logistinės regresijos modelis turėjo apskaičiuoti banko bankroto tikimybę ir identifikuoti pagrindinius kintamuosius, darančius įtaką banko nesėkmei, proporcingas streso modelis turėjo identifikuoti, kurie kintamieji daro didžiausią įtaką sėkmingai veikiančių bankų atvejais. Atlikus tyrimą paaiškėjo, kad banką nusakantys kintamieji (mikro-faktoriai) yra reikšmingi norint paaiškinti banko sėkmės ir nesėkmės atvejus, kai makroekonomikos kintamieji nebuvo tokie svarbūs. Išskirti šie pagrindiniai faktoriai, lemiantys banko sėkmę ar nesėkmę: banko efektyvumas (kiekybinis tinkamos banko valdybos įvertis), neveiksnių paskolų dydis (turto kokybė), valstybės (Rusijos) vertybinių popierių dalis, banko likvidumas (Konstandina, 2006).

Nur Ozkan-Gunay ir Ozkan (2007) analizavo Turkijos bankų bankrotus ir pateikė netiesinį dirbtinio neuronų tinklų modelį. Tyrime analizuoti 59 Turkijoje įsteigti bankai (23 bankrutavę ir 36 toliau veikiantys) 1989-2000 metų laikotarpyje. Modeliui buvo įdiegtas mokymosi algoritmas, kuris naudodamas 20 finansinių santykinių rodiklių, reprezentuojančių banko kapitalo pakankumą, turto kokybę, pajamingumą ir likvidumą, turėjo sugeneruoti tiksliausią bankų bankroto prognozavimo modelį. Galiausiai, apmokius modelį, su 10% paklaida, netiesinis dirbtinio neuronų tinklų modelis 76% tikslumu identifikavo bankrutavusius bankus ir 90% tikslumu identifikavo toliau veikusius bankus. Autorių teigimu dirbtinio neuronų tinklų modelis galėtų būti naudojamas bankų priežiūros institucijų kaip alternatyvi išankstinė įspėjamųjų signalų priemonė, tačiau pabrėžia, kad modelis gali sėkmingai prognozuoti tik atitinkamo regiono bankų bankroto tikimybę - kitoms šalims modelis iš naujo turi būti apmokomas (Nur Ozkan-Gunay, Ozkan, 2007).

1998-2006 metais bankrutavo maždaug trečdalis virtualių bankų, todėl Dandapani ir Lawrence (2008) atliko tyrimą, kurio tikslas – išanalizuoti virtualių bankų bankrotus, lyginant bankrutavusius ir nebankrutavusius virtualius bankus su įprastais (fiziniais) bankrutavusiais bankais. Autoriai naudojo Probit regresiją, siekdami palyginti bankrutavusius virtualius bankus ir veikiančius virtualius bankus, bankrutavusius virtualius bankus ir bankrutavusius fizinius bankus. Tyrimo išvadose nurodoma, kad didžiausią įtaką virtualių bankų bankrotui turėjo itin didelės nepalūkanų išlaidos, o fiziniams bankams – prasta suteiktų paskolų kokybė (Dandapani, Lawrence, 2008).

Mavri (2013) atlikto tyrimo tikslas buvo sukurti Bankų reitingavimo indekso (BRI) modelį, kuris sureitinguotų Graikijos bankus pagal jų efektyvumą. Modelio sugeneruota skaitinė išraiška leido identifikuoti banko poziciją tirtoje imtyje. Tyrimo imtį sudarė 16 Graikijos bankų, o indekso kiekybinius kintamuosius sudarė bankų finansinę padėtį nusakantys rodikliai bei informacija apie banko infrastruktūrą ir šalies ekonominę aplinką. Mavri teigimu, pagrindiniai indekso privalumai – dinamiškumas (naudojama tik naujausia informacija, kuriai pakitus keičiasi ir sugeneruojama indekso reikšmė) ir paprastumas (beveik visą informaciją galima gauti iš banko finansinių ataskaitų). Modelį sudarė 21 kintamasis, o pagal sugeneruotas BRI reikšmes, bankai buvo suskirstyti į 5 kategorijas (A grupei priklausė efektyviausias bankas, o E grupei – mažiausiai efektyvūs bankai) (Mavri, 2013). Po septynerių metų straipsnio autorėms analizuojant 16 tirtų Graikijos bankų veiklą nustatyta, kad 5 bankams buvo atimta licencija ir jiems paskelbtos likvidavimo procedūros - 3 iš jų turėjo mažiausias BRI reikšmes, todėl galima teigti, kad modelis sugebėjo išskirti prasčiausiai veikiančius bankus. Kita vertus, vienas iš bankų (ATE) turėjo aukščiausią balą C grupėje, tačiau 2012 m. buvo pradėtas banko likvidavimo procesas. Netikslų banko reitingavimą galėjo lemti įvairios aplinkybės: tuometinė Graikijos krizė, likvidumo rizikos nesuvaldymas, tam tikrų rodiklių neįtraukimas į modelį, taigi galima teigti, kad modelis sugebėjo sureitinguoti bankus efektyvumo mažėjimo tvarka su tam tikromis išimtimis. Kita vertus, šis modelis buvo pritaikytas tik Graikijos bankų sektoriui, todėl negalima teigti, kad modelis galėtų būti tinkamas kitose šalyse veikiančioms bankams.

Huang, Chang ir Liu (2012) pritaikė logistinės regresijos modelį 858 pasaulio bankams, įskaitant ir motinines įmones, pagal 2005 – 2008 metų duomenis. Tyrimo metu buvo analizuojami penki finansiniai rodikliai ir jų reikšmingumas banko bankroto atveju. Autorių teigimu tiksliausiai banko bankroto riziką identifikavo kapitalo ir turto santykio rodiklis bei palūkanų pajamų ir sąnaudų skirtumo santykis su grynosiomis pajamomis, kai ROA, ROE ir ilgalaikio turto ir ilgalaikių įsipareigojimų santykiniai rodikliai neturėjo reikšmingos įtakos bankų bankrotui (Huang ir kt., 2012).

Betz, Oprică, Peltonen ir Sarlin (2013) paskelbė apie sukurtą išankstinę įspėjamųjų signalų priemonę Europos bankams. Į tyrimą buvo įtraukti ne tik bankai, kurie bankrutavo, tačiau ir gavę valstybės paramą ar prijungti prie kitų bankų dėl patiriamų finansinių sunkumų. Modelio kintamuosius sudarė finansiniais santykiniais rodikliai pagal CAMELS sistemą ir rodikliai, makro lygiu charakterizuojantys šalies bankų sektorių ir pačią šalį. Nustatyta, kad šalį charakterizuojantys rodikliai geriau prognozuoja galimą bankų bankrotą (24% naudingumas), negu vien banką charakterizuojantys santykiniai finansiniai rodikliai (16% naudingumas). Taip pat pastebėta, kad įtraukus banką ir šalį charakterizuojančius rodiklius prognozavimo naudingumas padidėjo iki 36 %, o analizuojant banko, šalies bankų sektoriaus ir pačios šalies rodiklius naudingumas siekia 37 %, todėl šalies bankų sektoriaus

duomenys suteikia nedidelę pridedamąją vertę bankų bankroto prognozavimui (Betz ir kt., 2013). Šis darbas pateikė naują požiūrį į žlugusių bankų apibrėžimą, be to parodė šalies charakteristiką nusakančių rodiklių įtraukimo būtinybę, todėl gali būti gaire tolimesniems tyrimams ir bankroto modelio kūrimui.

Özel (2013) atliko tyrimą su septyniasdešimt Turkijos bankų, veikusių nuo 2000 iki 2008 metų. Autorius atrinko 37 finansinius rodiklius, kurie tarpusavyje nekoreliavo, tačiau manomai buvo susiję su bankų bankrotais. Pritaikius Cox'o regresijos modelį, nustatyta, kad didesnė nuosavo kapitalo grąža ir didesnis atidėjinių santykis su grynosiomis pajamomis parodo mažesnę banko bankroto tikimybę. Pritaikius streso situacijos modelį, nustatyta, kad bankai, kurių pelningumo rodikliai buvo didesni ir valstybės vertybinių popierių dalis turto atžvilgiu buvo didesni, turėjo mažesnę tikimybę bankrutuoti. Pritaikius logistinę regresiją identifiukuota, kad bankai, kurių palūkanų ir kitos veiklos išlaidos yra mažesnės už sugeneruojamas palūkanų ir kitas veiklos pajamas, užsienio valiutos investavimo grąža ir konsoliduotas banko grupės turtas yra didesnis, o suteiktų paskolų dalis turto atžvilgiu yra mažesnė turi mažesnę bankroto tikimybę. Autorių teigimu Cox'o regresijos modelis geriau suklasifikavo bankus į bankrutuojančius ir nebankrutuojančius negu streso modelis ir logistinė regresija, o mažos įplaukos, likvidumas ir rizikingų paskolų portfelio dydis turėjo reikšmingą svorį vertinant banko bankroto tikimybę (Özel, 2013).

Mekaitė ir Marcišauskienė (2015), pritaikydamos E. Kaciak daugiamatės diskriminantinės analizės modelį, išanalizavo panašaus dydžio 50 JAV komercinių bankų (25 bankrutavusių ir 25 nebankrutavusių) remiantis 2008 – 2011 metų duomenimis. Pagal sugeneruotas Z reikšmes buvo nustatyta, kad modelis 100% tikslumu identifikavo bankrutavusius bankus likus 1 metams iki bankroto ir 84% tikslumu likus dvejiems metams iki bankroto. Modelis taip pat 100% tikslumu identifikavo nebankrutavusius bankus analizuojamu laikotarpiu. Autorių teigimu didžiausią įtaką Z reikšmės sumažėjimui (bankroto rizikos signalo atsiradimui) turėjo nuostoliai, blogų paskolų padidėjimas ir kapitalo pakankamumo sumažėjimas, o 2 modelio rodikliai (vertybinių popierių ir uždirdančio pajamas turto santykis bei nebankinių operacijų ir vidutinio turto santykis), neturėjo reikšmingos įtakos Z reikšmės pokyčiui nebankrutavusių bankų imčiai (Marcišauskienė ir Mekaitė, 2015).

Išanalizavus atliktų bankų bankroto modelių mokslinių tyrimų duomenis galima teigti, kad dažniausiai modeliai kuriami tam tikrai šaliai. Šalims, kuriose įvyko vos kelių bankų bankrotai, kurti bankų bankroto prognozavimo modelius nėra prasminga dėl mažos bankrutavusių bankų populiacijos ir būsimo modelio netikslumo. Kai Betz, Oprică, Peltonen ir Sarlin (2013) pateikė pasiūlymą į žlugusių bankų apibrėžimą įtraukti bankus, kuriems buvo suteikta valstybės parama, tyrimo populiacija buvo išplėsta, vis dėlto norint sukurti tikslius bankų bankroto prognozavimo modelius, reikia analizuoti kelių šalių ar regionų bankų žlugimo atvejus, kad modelio mokymosi imtis būtų didesnė ir leistų atrasti pagrindinius

faktorius, išskiriančius veikiančius bankus nuo bankų, kuriems gresia žlugimas. Reikia pažymėti, kad tyrimuose analizuoti įvairūs - tiek mikro, tiek makro – kintamieji, vis dėlto universalus pripažinto kintamųjų, kurie geriausiai identifikuotų sėkmingai veikiančius ir žlugusius bankus, sąrašo nėra. Daugumos autorių (Konstandina (2006), Dandapani ir Lawrence (2008), Özel (2013), Mekaitė ir Marcišauskienė (2015)) teigimu banko turto kokybė ar neveiksnių paskolų dydis yra svarbus rodiklis analizuojant bankų bankrotą. Tačiau nuomonės dėl makroekonominių rodiklių naudos bankų bankroto modelyje yra skirtingos.

Didelis susidomėjimas bankų bankrotų prevencija ir bankų bankroto modeliais padeda sukurti vis tobulesnius ir tikslesnius bankų bankroto riziką identifikuojančius modelius. Visgi sukurti bankų bankroto prognozavimo modeliai nesugeba iš anksto identifikuoti visų bankų bankrotų, nes sukurti tik tam tikro regiono (šalies) bankų sektoriui analizuoti, paprastai reikalauja didelių resursų ar nesuteikia pakankamai laiko įvykdyti prevencinių priemonių. Todėl universalus, lengvai interpretuojamas ir pritaikomas bankų bankroto prognozavimo modelio sukūrimas, kuris aukštu patikimumo laipsniu leistų kuo anksčiau identifikuoti bankų veiklos sustabdymo riziką, vis dar yra siekiamybė.

2. Bankų bankroto prognozavimo modelio kūrimo ir vertinimo metodika

Atlikta mokslinės literatūros analizė leido teigti, kad kol kas nesukurtas universalus bankų bankroto prognozavimo modelis, kuris: 1) būtų pritaikomas įvairiose šalyse veikiančioms bankams, 2) turėtų aukštą patikimumo lygį, 3) suteiktų pakankamai laiko įgyvendinti banko bankroto prevenciją, 4) būtų lengvai naudojamas (pritaikomas). Todėl straipsnio autorės išskėlė tyrimo tikslą – išanalizuoti Europoje veikiančius ir žlugusius bankus bei sukurti *patikimą ir lengvai pritaikomą* bankroto prognozavimo modelį Europos bankų sektoriui.

Tyrimui veikiančios ir bankrutavę bankai buvo atrinkti patogiosios atrankos būdu. Veikiančių ir bankrutavusių Europos bankų sąrašas buvo gautas iš SNL duomenų bazės ir jį sudarė 2709 įmonės. Siekiant išgryninti tik Europos (kontinento) šalis, buvo eliminuoti bankai, veikiančios ar veikę Grenlandijoje, Armėnijoje, Kirgizijoje, Monake, Tadžikistane, Turkmėnistane, Uzbekistane, Gruzijoje, Azerbaidžane, Kazachstane, Rusijoje ir Turkijoje. Pritaikant Betz, Oprică, Peltonen ir Sarlin (2013) metodologiją, prie žlugusių bankų buvo priskirti ir bankai, kurie gavo specialią šalies paramą arba dėl patiriamų finansinių sunkumų buvo prijungti prie kito banko – ši informacija gauta naudojantis Europos Komisijos pateiktais duomenimis. Žlugusių bankų identifikavimas atliktas rankiniu būdu, dabartinį bankų statusą tikrinant Orbis (Bureau van Dijk Bank Focus) duomenų bazėje. Į žlugusių bankų sąrašą buvo įtraukti bankai, kurių statusas buvo: „bankrutavo/bankrutuoja“, „likviduojamas“, „uždarytas“, „nebeveikiantis“.

Tyrime naudoti kintamieji buvo atrinkti išanalizavus atliktus mokslinius tyrimus bei atsižvelgiant į ekspertų nuomones. Ekspertų vertinimo metodas parinktas siekiant sužinoti specialistų ekspertines žinias ir patyrimą, analizuojant veikiančius ir žlugusius bankus (Baležentis ir Žalimaitė, 2011). Kadangi šias ekspertines žinias turi ribotas skaičius specialistų, ekspertai buvo atrinkti patogumo principu, atsižvelgiant į jų užimamas pareigas ir darbo patirtį analizuojant finansines institucijas. Ekspertų apklausa buvo įgyvendinta dvejomis formomis: nestruktūrizuotu interviu arba atviru klausimu ekspertams (raštu). Siekiant identifikuoti modeliui svarbius kintamuosius, buvo pasirinkti 4 bankų ekspertai, turintys daugiau nei 4 metų patirties reitinguojant finansines institucijas, vykdant finansinių institucijų kredito analizę. Ekspertų identifikuoti rodikliai buvo įtraukti į preliminarų banko ir makro rodiklių sąrašą. Taip pat į preliminarų rodiklių sąrašą buvo įtraukti rodikliai, kurie atliktuose moksliniuose tyrimuose leido atskirti veikiančius ir bankrutavusius bankus ir buvo reikšmingi bankų bankroto modeliuose arba panašūs į minėtus rodiklius, siekiant toliau analizuoti šių rodiklių svarbą prognozuojant bankų žlugimą.

Analizuoti atrinktų bankų 2008 – 2017 metų finansinių ataskaitų duomenys, finansinių ataskaitų rodiklių reikšmės buvo gautos iš SNL duomenų bazės, makro rodikliai - iš Pasaulio banko duomenų bazės. Analizuojant gautus duomenis, buvo pastebėta, kad jie nėra pilni, todėl buvo atrinkti tik kokybiški duomenys, t.y. tam tikri bankai, kuriems trūko didžiosios dalies rodiklių informacijos ir rodikliai, kurių nepateikė didžioji žlugusių bankų dalis, buvo eliminuoti. Tačiau siekiant išlaikyti kiek įmanoma didesnę žlugusių bankų sąrašą, dalis žlugusių bankų nepateiktos informacijos buvo užpildyta atsižvelgiant į bendrą trūkstamos informacijos kiekį, bendrą imties vidurkį, šalies vidurkius, buvusių metų duomenis.

Bankų bankroto prognozavimo modeliai buvo modeliuojami dvinarės logistinės regresijos pagrindu:

$$P(Y = 1) \frac{e^z}{1 + e^z} = \frac{1}{1 + e^{z-z}} P(Y = 1) Z = C + b_1 x_1 + b_2 x_2 + b_3 x_3 \quad (1)$$

$P(Y = 1)$ – tikimybė, kad Y yra 1, $P(Y = 0)$ – tikimybė, kad Y yra 0, Z – tikimybių santykių logaritmas, C – konstanta, $b_1 b_2 b_3$ – koeficientai, $x_1 x_2 x_3$ – nepriklausomi kintamieji (Čekanavičius ir Murauskas, 2014). Atskyrimo riba (angl. cut off), kuri nusako nuo kurios P reikšmės Y yra lygus 1, dažniausiai būna 0,5 ir tik vėliau modifikuojama, siekiant padidinti modelio tikslumą, todėl ir šiame darbe atskyrimo ribos buvo keičiamos.

Dvinarė logistinė regresija buvo pasirinkta, nes 1) daroma prielaida, kad ryšys tarp nepriklausomų kintamųjų (rodiklių) ir priklausomo kintamojo (banko statuso) nėra tiesinys, ir 2) Y (priklausomo kintamojo) įgyjamos reikšmės yra dvinarės (0 arba 1), tai reiškia, kad modelis, atsižvelgdamas į pateiktus nepriklausomus kintamuosius, suklasifikuoja bankus į žlugusius ($Y=1$) ir veikiančius ($Y=0$). Be to, modelio

sugeneruojamos dvinarės reikšmės leidžia lengviau interpretuoti modelio rezultatą (bankas žlugs arba toliau veiks), negu tiesinės regresijos reikšmės, kurias dažniausiai suskirto į intervalus ir tik tada interpretuoja.

Kaip teigė Bužinskienė ir Karalevičienė (2012), nėra prasminga skaičiuoti daug santykinų rodiklių, svarbu skaičiuoti tokius rodiklius, kurie praktiškai pritaikomi“ (46 p.), todėl iš atrinktų kintamųjų buvo atrinkti tik statistiškai reikšmingi (reikšmingumo lygis lygus 5%) kintamieji pagal kintamųjų įrašymo (angl. *forward*) ir išbraukymo (angl. *backward*) metodus. Šie skaičiavimai buvo atlikti E-Views programa. Siekiant, kad modelis nebūtų permokytas, tai yra, kad prognozavimo patikimumo lygis būtų aukštas ne tik mokymo metu įtrauktiems duomenims, bet ir dar neanalizuotiems bankams, buvo naudojamas kryžminio patikrinimo metodas (angl. *cross-validation*). Tokiu būdu gaunamas n skaičius modelių, kurių nepriklausomų kintamųjų vidurkiai yra panaudojami galutinio modelio sukūrimui (Paulauskienė, 2013). Tačiau šiame tyrime dvinarės logistinės regresijos modeliai buvo analizuoti atskirai, o galutinis modelis su nepriklausomų kintamųjų koeficientų vidurkiais nebuvo kuriamas, nes skirtingi dvinarės logistinės regresijos modeliai naudojo skirtingus nepriklausomus kintamuosius (kai kurie kintamieji sutapo).

Siekiant modelius palyginti, buvo analizuoti trys modelių charakteristiką nusakantys kriterijai: McFadden R^2 , Akaike informacijos kriterijus ir Schwarz kriterijus (Čėkanavičius ir Murauskas, 2014). Modelio prognozavimo tikslumas buvo vertinamas pagal modelio sugeneruotos reikšmės (0, kai modelis prognozuoja, kad bankas sėkmingai veiks, ir 1, kai modelis prognozuoja, kad bankas žlugs) ir banko realios situacijos kombinaciją, kaip nurodyta 1 lentelėje.

1 lentelė

Modelio prognozių ir banko realios situacijos kombinacijos

Prognozė\Reali situacija	Veikiantis bankas (0)	Žlugęs bankas (1)
Veikiantis bankas (0)	(0,0)	(0,1)
Žlugęs bankas (1)	(1,0)	(1,1)

sudaryta autorių.

I rūšies klaida laikoma, kai modelis prognozuoja, kad bankas yra žlugęs ar žlungantis, nors iš tiesų yra veikiantis (1,0), II rūšies klaida - kai modelis prognozuoja, kad bankas yra veikiantis, nors iš tiesų yra žlugęs (0,1). Šios klaidos nėra lygiavertės, nes II rūšies klaida yra pavojingesnė (neidentifikuojama reali grėsmė), todėl modelio tikslumas buvo vertinamas pagal sugeneruotų II rūšies klaidų kiekį.

Modelio tikslumas taip pat buvo analizuotas ROC kreivės pagrindu. ROC kreivė grafiškai atvaizduoja modelio jautrumo ir specifškumo sąryšį. Modelio jautrumas yra apskaičiuojamas kaip teisingai atspėtų žlugusių bankų santykis su teisingai atspėtų žlugusių bankų ir II rūšies klaidų suma. Modelio specifškumas yra apskaičiuojamas kaip teisingai atspėtų veikiančių bankų santykis su teisingai atspėtų veikiančių

bankų ir I rūšies klaidų suma. Bankų bankroto modelių patikimumas taip pat buvo vertinamas likus dvejiems metams iki žlugimo įvykio, atsižvelgiant į II rūšies klaidų kiekį. Reikia paminėti, kad vertinant modelių patikimumą likus 2 metams iki žlugimo įvykio, buvo naudoti tik tų bankų duomenys, kurie pateikė visą reikalingą informaciją, naudojamą bankų bankroto prognozavimo modeliuose, todėl modelių patikimumas nebuvo iškraipytas modifikuotais duomenimis.

3. Bankroto prognozavimo modelis Europos bankams: tyrimo rezultatai

Atlikus kokybiškų duomenų atrinkimą, iš preliminarų žlugusių ir veikiančių banko sąrašo buvo atrinkti 1356 bankai. Į tyrimą buvo įtraukti 1244 veikiančios bankai, kurių daugiausiai rezidavo Jungtinėje Karalystėje (10,5%), Šveicarijoje (10,5%), Italijoje (10,3%) ir Vokietijoje (10,1%). Kitų šalių bankai sudarė mažiau nei po 4% į galutinį sąrašą įtrauktų veikiančių bankų visumos. Tyrime buvo analizuoti 112 žlugusių Europos bankų, kurių daugiausia priskiriama Italijai ir Ukrainai (po 12), Graikijai (11 žlugusių bankų) ir Airijai (9 žlugę bankai).

Tyrimo kintamieji (rodikliai) buvo atrinkti atsižvelgus į ekspertinio vertinimo ir atliktų mokslinių tyrimų analizės rezultatus. Ekspertai apklausos metu identifikavo 20 rodiklių, kaip svarbiausių vertinant bankų bankroto riziką. Šie rodikliai buvo įtraukti į preliminarių rodiklių sąrašą ir suskirstyti į 7 kategorijas: 1) kapitalo pakankamumo, 2) pelningumo, 3) pelningumo ir banko valdymo įvertinimo, 4) turto kokybės ir banko valdymo įvertinimo, 5) augimo, 6) likvidumo ir 7) makro rodiklių. Vėliau atliktos rodiklių sąrašo modifikacijos. Pirmiausia pastebėta, kad neveiksnių paskolų ir visų paskolų santykio rodiklio SNL duomenų bazė nepateikė, todėl šis rodiklis buvo eliminuotas, kaip ir rodikliai, kurių nepateikė didžioji dalis žlugusių bankų. Likusių rodiklių (išskyrus makro rodiklius) duomenys buvo paimti iš SNL duomenų bazės. Paskolų augimo rodiklio duomenys nebuvo kokybiški, todėl paskolų augimo ir BVP augimo palyginimo rodiklis buvo pakeistas į turto augimo ir BVP augimo palyginimo rodiklį. Galiausiai 10 ekspertų pateiktų rodiklių buvo identifikuoti kaip tinkami ir įtraukti į galutinį rodiklių sąrašą. Išanalizavus mokslinius tyrimus, buvo atrinkta 16 kintamųjų bei papildomi 4 rodikliai, panašūs į moksliniuose tyrimuose nagrinėtus ir pateikti SNL duomenų bazėje, tačiau atlikus kokybiškų duomenų atrinkimą, rodikliai, kurių nepateikė didžioji dalis žlugusių bankų, buvo eliminuoti. Todėl iš 20 tik 14 rodiklių buvo įtraukti į galutinį rodiklių sąrašą (žr. 1 pav.).

Galutinis rodiklių sąrašas	Rodiklių trumpiniai
Kapitalo pakankamumo rodikliai	
Nuosavas kapitalo ir turto santykis	Solvency
Kapitalo pakankamumo koeficientas	CapitalR
Pelningumo rodikliai	
Vidutinio turto pelningumas	ROAA
Vidutinio nuosavo kapitalo pelningumas	ROAE
Grynųjų palūkanų pajamų marža	NIM
Pelningumo ir banko valdymo įvertinimo rodikliai	
Išlaidų ir pajamų santykio rodiklis	CostIncome
Turto kokybės ir banko valdymo įvertinimo rodikliai	
Blogų paskolų ir visų paskolų santykis	ProblemGross
Neveiksnių paskolų rezervų ir visų paskolų santykis	LResGross
Paskolų ir turto santykis	Loans.Asset
Augimo rodikliai	
Nuosavo kapitalo augimas	EquityG
Operacinių išlaidų augimas	OperExpGr
Grynųjų palūkanų pajamų augimas	NIIG
Turto augimas	AssetG
Likvidumo rodikliai	
Likvidaus turto ir viso turto santykis	Liquidity
Depozitų ir turto santykis	DepAsset
Santykių rodikliai	
Grynųjų palūkanų pajamų ir veiklos pajamų santykis	NIIO
Paslaugų ir komisinių pajamų ir veiklos pajamų santykis	FCCO
Vertybinių popierių ir turto santykis	SecAssets
Grynųjų palūkanų pajamų ir vidutinio turto santykis	NIAsset
Grynųjų paslaugų pajamų ir vidutinio turto santykis	FecAsset
Makro rodikliai	
BVP augimas	GDP
Inflacija	Inflacija
Darbo lygis	Darbing
Turto augimo ir BVP augimo palyginimas	AssetGDP
Banko statusas (0 - veikiantis, 1 - žlugęs bankas)	Result

1 pav.
Galutinis rodiklių sąrašas ir rodiklių trumpiniai
sudaryta autorių.

Galutinį rodiklių sąrašą sudarė 24 kintamieji (rodikliai), suskirstyti į 8 kategorijas, t.y. viena kategorija („Santykių rodikliai“) daugiau nei ekspertų pateiktame rodiklių sąraše. Makro rodiklių kategorijai priklauso 4 kintamieji rodikliai, iš kurių turto augimo ir BVP augimo palyginimo kintamasis yra išvestinis: jo reikšmė yra 1, kai banko turtas augo greičiau negu šalies BVP, ir atvirkščiai 0, kai banko turtas augo lėčiau negu šalies BVP.

Bankų bankroto prognozavimo modelis buvo kuriamas E-views programa. Pirmiausiai, buvo paimiti visi duomenys ir sukurta tiesinė regresija, siekiant patikrinti ar funkcija yra tiesinė. Buvo pritaikytas Ramsey RESET testas ir gauta, kad t-statistikos p.value = 0.0000, t.y. funkcija nėra tiesinė. Naudojant visus duomenis, buvo bandoma sukurti logistinę regresiją, tačiau nesėkmingai, nes kažkuris (kažkurie) kintamieji puikiai atskiria veikiančius ir žlugusius bankus, todėl programa negalėjo sugeneruoti modelio. Norint išsiaiškinti šiuos kintamuosius, buvo analizuojama koreliacija tarp bankų statuso (1 = žlugęs bankas, 0 = sėkmingai veikiantis bankas) ir parinktų kintamųjų. Pastebėta, kad didžiausia banko statuso koreliacija yra su išlaidų ir pajamų santykio rodikliu (koreliacija lygi 0,856) bei su grynųjų palūkanų pajamų marža (koreliacija lygi -0,492). Kadangi su šiais kintamaisiais negalima sukurti logistinės regresijos modelio, išlaidų ir pajamų santykio rodiklis ir grynųjų palūkanų pajamų marža buvo išimti iš kintamųjų sąrašo, kuris buvo naudotas logistinės regresijos kūrimui.

Iš kintamųjų sąrašo išėmus išlaidų ir pajamų santykio rodiklį bei grynųjų palūkanų pajamų maržą, programa leido sugeneruoti logistinę regresiją. Atlikus kintamųjų išbraukymo metodą, buvo gauta logistinės regresijos išraiška (visų kintamųjų p.value buvo mažesnės už reikšmingumo lygį):

$$Z_i = 1,880666 - 0,034086ROAE - 0,473323GDP + 0,051365PROBLEMGROSS + 0,024312SECASSEST - 0,156059INFLIACIJA - 0,724345ASSETGDP - 0,053078LRESGROSS$$

Pagal pateiktą Z_1 modelį matyti, kad didėjantis neveiksnių paskolų ir visų paskolų santykis bei vertybinių popierių ir turto santykis didina banko tikimybę žlugti, kai kitų kintamųjų rodiklių didėjimas didina sėkmingos veiklos tikimybę. Jei banko veikla tampa nuostolinga, jo vidutinis nuosavo kapitalo pelningumas bus neigiamas, t.y. padidės tikimybė, kad bankas žlugs. Kita vertus, neveiksnių paskolų rezervų dydžio augimas mažina banko žlugimo tikimybę. Turto augimo ir šalies BVP augimo palyginimo kintamąjį derėtų interpretuoti: jeigu banko turto dydis auga greičiau nei šalies BVP, tikimybė bankui žlugti mažėja, tačiau jeigu banko turto dydis auga lėčiau nei šalies BVP, įtakos banko žlugimo prognozei nėra. Taip pat galima manyti, kad didėjanti šalies infliacija mažina banko žlugimo tikimybę, o galima defliacija ją padidintų, nors labai staigi ir didelė infliacija realybėje turėtų neigiamai paveikti bankus dėl pablogėjusios paskolų turėtojų finansinės padėties

Taip pat buvo sugeneruotos 4 logistinės regresijos lygtys pagal kryžminio patikrinimo metodą. Pirmiausia apmokymo imtyje nebuvo įtraukti 1 bloko duomenys. Atlikus kintamųjų išbraukimo metodą, buvo gauta ši logistinės regresijos išraiška (visų kintamųjų p.value mažesnė už reikšmingumo lygį 0,05):

$$Z_2 = -1,502203 - 0,033322ROAE - 0,309672GDP + 0,035513PROBLEMGROSS + 0,017195SECASSETS - 0,010400DEPASSET - 0,841052ASSETGDP - 0,0428451RESGROSS$$

Lyginant šią funkciją su Z_1 , infliacijos kintamąjį pakeitė depozitų ir turto santykio rodiklis, kuris identifikuoja, kad didėjantis santykis mažina banko žlugimo tikimybę. Banko depozitai yra laikomi gana stabiliu bankų finansavimo šaltiniu, tačiau yra tam tikri skirtumai tarp klientų ir verslo depozitų (klientų depozitai laikomi stabilesniais), kurių šis rodiklis negali identifikuoti. Likusiųjų rodiklių koeficientų ženklai nepakito, todėl interpretacija išliko tokia pati.

Vėliau apmokymo imtyje nebuvo įtraukti 2 bloko duomenys ir pritaikius kintamųjų išbraukimo metodą buvo gauta tokia logistinės regresijos išraiška (visų kintamųjų p.value buvo mažesnė už reikšmingumo lygį 0,05):

$$Z_3 = -2,801013 - 0,070808ROAE - 0,493278GDP + 0,040510PROBLEMGROSS + 0,024812SECASSETS + 0,264653ROAA$$

Lyginant funkciją su Z_1 ir Z_2 , funkcijos kintamųjų skaičius sumažėjo, bet atsirado naujas kintamasis – turto pelningumas, kurio padidėjimas didina banko žlugimo tikimybę. Dėl padidėjusios banko prisiimamos rizikos (paskolos suteikiamos nepatikimiems klientams), rizikingesni klientai apmokestinami didesne marža, todėl pelnas sugeneruojamas didesnis. Kita vertus, pelningai veikiančio banko vidutinio nuosavo kapitalo pelningumas bus teigiamas (jei kapitalas yra teigiamas), tačiau šio pelningumo rodiklio didėjimas mažina banko žlugimo tikimybę. Galima sakyti, kad šie rodikliai vienas kitam iš dalies prieštarauja.

Vėliau apmokymo imtyje nebuvo įtraukti 3 bloko duomenys. Atlikus kintamųjų išbraukimo metodą, buvo gauta logistinės regresijos išraiška (visų kintamųjų p.value buvo mažesnė už reikšmingumo lygį 0,05):

$$Z_4 = -1,330142 - 0,040666ROAE - 0,295072GDP + 0,049577PROBLEMGROSS + 0,040749SECASSETS - 0,324430INFLIACIJA - 0,028885LIQUIDITY - 0,680790ASSETGDP - 0,0532951RESGROSS$$

Lyginant funkciją su Z_1 , Z_2 ir Z_3 , atsirado naujas kintamasis – likvidumo rodiklis, kurio didėjimas mažina banko žlugimo tikimybę. Likvidaus turto didėjimas, gerina banko galimybes trumpuoju laikotarpiu padengti turimus trumpalaikius įsipareigojimus, vadinasi, bankas geba geriau valdyti likvidumo riziką.

Galiausiai apmokymo imtyje nebuvo įtraukti 4 bloko duomenys. Atlikus kintamųjų išbraukimo metodą, buvo gauta logistinės regresijos išraiška (visų kintamųjų p.value buvo mažesnė už reikšmingumo lygį 0,05):

$$Z_4 = 0,571069 - 0,023544ROAE - 0,605623GDP + -0,178248INFLIACIJA - 0,018085LIQUIDITY - 0,691589ASSETGDP + 0,008529OPEREKXPGR - 0,024974LOANASSET$$

Lyginant šią funkciją su buvusiomis funkcijomis, buvo atrinkti du nauji kintamieji: operacinių išlaidų augimo rodiklis ir suteiktų paskolų ir viso turto santykio rodiklis. Operacinių išlaidų augimas didina banko žlugimo tikimybę, o tai galima paaiškinti dėl nesuvaldytų išlaidų ir neefektyvumo. Kita vertus, didėjantis paskolų ir turto santykis didina banko sėkmingos veiklos tikimybę ir tai galėtų būti laikoma vertybinių popierių ir turto santykio alternatyviu rodikliu.

Modelių (Z funkcijų) charakteristikas nusakantys kriterijai pateikti 2 lentelėje

2 lentelė
Z funkcijų charakteristikos

Funkcijos charakteristikos pavadinimas	Z_1	Z_2	Z_3	Z_4	Z_4
McFadden R^2	0,329540	0,290265	0,392620	0,347152	0,345521
Akaike informacijos kriterijus	0,394048	0,420372	0,358084	0,389906	0,390836
Schwarz kriterijus	0,424799	0,459111	0,387138	0,433487	0,434416

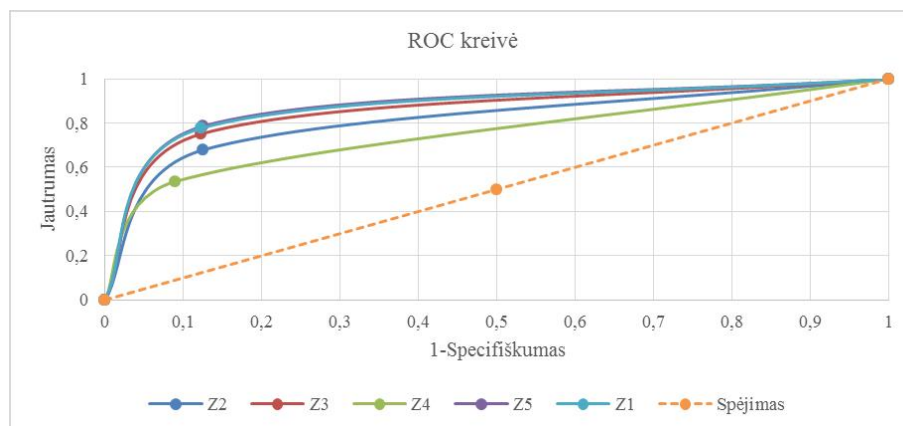
sudaryta autorių

Įvertinus modelių prognozavimo patikimumą visai imčiai, kai $P > 0,5$, $P > 0,2$, $P > 0,1$ nustatyta, kad visų modelių tikslumas, siekiant mažiausio skaičiaus II rūšies klaidų, yra tuomet, kai $P > 0,1$. Atlikus patikrinimą, kai $P > 0,05$, visais atvejais II rūšies klaidų nepadaugėjo, tačiau padaugėjo I rūšies klaidų. Todėl galima teigti, kad tinkamiausia funkcijų P riba yra virš 0,1 – šiuo atveju modeliai sugeneruoja mažiausiai II rūšies klaidų.

Visuose logistinės regresijos modeliuose pasikartoję trys rodikliai: 1) vidutinio nuosavo kapitalo pelningumo rodiklis, kurio didėjimas mažina banko žlugimo tikimybę; 2) blogų paskolų ir visų paskolų santykio rodiklis, kurio didėjimas didina banko žlugimo tikimybę; 3) BVP augimo rodiklis, kurio didėjimas mažina banko žlugimo tikimybę. Keturiuose iš penkių modelių buvo panaudoti vertybinių popierių ir turto santykio rodiklis (jo augimas didina banko žlugimo tikimybę) ir turto ir BVP augimo palyginimo rodiklis (kai turto augimas yra greitesnis nei BVP - mažėja banko žlugimo tikimybė). Trijuose iš penkių modelių buvo panaudoti neveiksnių paskolų rezervų ir visų paskolų santykis (didėjimas mažina banko žlugimo tikimybę) ir infliacija (didėjant infliacijai mažėja

banko žlugimo tikimybė). Kiti rodikliai buvo naudoti viename ar dvejuose modeliuose, todėl jų statistiniam reikšmingumui įtakos turėjo vykdytas kryžminio patikrinimo metodas.

Sugeneravus 5 logistinės regresijos modelius, buvo siekiama grafiškai pavaizduoti modelių tikslumą. Pagal 2 paveiksle pateiktas ROC kreives galima teigti, kad visų funkcijų prognozavimo kokybė yra geresnė už atsitiktinį spėjimą.



2 pav
ROC kreivės
sudaryta autorių.

Iš 2 paveiklo grafikų matyti, kad geriausia prognozavimo kokybė pasižymi Z₅, Z₁ ir Z₃ modeliai. Išanalizavus funkcijų charakteristikas matyti, kad didžiausią McFadden R² ir mažiausius Akaike informacijos, Schwarz kriterijus sugeneravo Z₃ funkcijos modelis, kurio tikslumas likus vieniems metams iki banko žlugimo siekia 75%, kai P>0,1. Tačiau atsižvelgiant į modelio apmokymo procesą ir modelio tikslumą, padaryta išvada, kad pranašesnis yra Z₅ modelis: likus 1 metams iki banko žlugimo jis 78,57% tikslumu identifikuoja žlungančius bankus ir 87,46% tikslumu identifikuoja sėkmingai veikiančius bankus.

Įvertinus sugeneruotų modelių tikslumą likus vieniems metams iki bankų žlugimo, buvo patikrinta modelių prognozavimo kokybė likus dvejiems metams iki žlugimo. Modelių tikslumas buvo tikrintas tik su bankais, kurie buvo pateikę rodiklius, naudojamus bankroto prognozavimo modeliuose. Trūkstama informacija nebuvo modifikuota, siekiant išgryninti bankų bankroto prognozavimo modelių tikrą prognozavimo kokybę analizuojamai imčiai. Nustatyta, kad modelių Z₁, Z₃, Z₄ ir Z₅ tikslumas, identifikuojant žlungančius bankus, likus dvejiems metams iki žlugimo įvykio viršijo 70%. Didžiausiu tikslumu pasižymėjo Z₁ ir Z₅ modeliai.

Z ₁ funkcijos modelio tikslumas likus 2 metams iki banko bankroto/žlugimo		
Prognozė/Realī situacija	Veikiantis bankas (0)	Žlugęs bankas (1)
Veikiantis bankas (0)	78.04%	24.24%
Žlugęs bankas (1)	21.96%	75.76%

Z ₂ funkcijos modelio tikslumas likus 2 metams iki banko bankroto/žlugimo		
Prognozė/Realī situacija	Veikiantis bankas (0)	Žlugęs bankas (1)
Veikiantis bankas (0)	83.13%	33.33%
Žlugęs bankas (1)	16.87%	66.67%

Z ₃ funkcijos modelio tikslumas likus 2 metams iki banko bankroto/žlugimo		
Prognozė/Realī situacija	Veikiantis bankas (0)	Žlugęs bankas (1)
Veikiantis bankas (0)	83.86%	28.79%
Žlugęs bankas (1)	16.14%	71.21%

Z ₄ funkcijos modelio tikslumas likus 2 metams iki banko bankroto/žlugimo		
Prognozė/Realī situacija	Veikiantis bankas (0)	Žlugęs bankas (1)
Veikiantis bankas (0)	74.65%	27.69%
Žlugęs bankas (1)	25.35%	72.31%

Z ₅ funkcijos modelio tikslumas likus 2 metams iki banko bankroto/žlugimo		
Prognozė/Realī situacija	Veikiantis bankas (0)	Žlugęs bankas (1)
Veikiantis bankas (0)	78.50%	23.08%
Žlugęs bankas (1)	21.50%	76.92%

3 pav

Modelių tikslumas du metai iki banko žlugimo įvykio

sudaryta autorių.

Modelių tikslumas (teisingai identifikuojant žlungančius bankus) likus 2 metams iki banko žlugimo siekė atitinkamai 75,76% ir 76,92%, kita vertus, modeliai atitinkamai 78,04% ir 78,50% tikslumu teisingai identifiko sėkmingai veikiančius bankus pagal dviejų metų senumo finansinius rodiklius. Didžiausiu tikslumu identifikuojant sėkmingai veikiančius bankus pasižymėjo Z₂ ir Z₃ modeliai (83,13% ir 83,86%), o žlugusius bankus teisingai identifiko atitinkamai 66,67% ir 71,21% tikslumu. Iš sugeneruotų dvinarės logistinės regresijos modelių, Z₅ modelio tikslumas yra didžiausias likus 1 metam (78,75%) ir likus 2 metams (76,92%) iki banko žlugimo.

Išvados

1. Išanalizavus bankų bankroto modelių mokslinių tyrimų duomenis nustatyta, kad dažniausiai modeliai kuriami tam tikrai šaliai. Tačiau norint sukurti tikslus bankų bankroto prognozavimo modelius reikia analizuoti kelių šalių ar regionų bankų žlugimo atvejus, idant modelio mokymosi imtis būtų didesnė ir leistų atrasti pagrindinius faktorius, išskiriančius veikiančius bankus nuo bankų, kuriems gresia žlugimas. Didelis susidomėjimas bankų bankrotų prevencija padeda sukurti vis tobulesnius ir tikslesnius bankų bankroto riziką identifikuojančius modelius, visgi kol kas jie nesugeba iš anksto identifikuoti visų bankų bankrotų, nes sukurti tik tam tikro regiono (šalies) bankų sektoriui analizuoti, paprastai reikalauja didelių resursų ar (arba) nesuteikia pakankamai laiko įvykdyti prevencinių priemonių.
2. Pagal iš anksto numatytą bankroto prognozavimo modelio kūrimo metodologiją, buvo sukurti 5 skirtingi bankų bankroto

- prognozavimo modeliai, pagrįsti dvinare logistine regresija. Visuose penkiuose logistinės regresijos modeliuose pasikartojo trys rodikliai: 1) vidutinio nuosavo kapitalo pelningumo rodiklis, kurio didėjimas mažina banko žlugimo tikimybę, 2) blogų paskolų ir visų paskolų santykio rodiklis, kurio didėjimas didina banko žlugimo tikimybę, 3) BVP augimo rodiklis, kurio didėjimas mažina banko žlugimo tikimybę. Modeliai apėmė tiek mikro, tiek makro lygio rodiklius
3. Išanalizavus 5 sugeneruotus bankroto prognozavimo modelius nustatyta, kad dvinarės logistinės regresijos modelis Z5 78,57% tikslumu gali teisingai identifikuoti žlungančius bankus likus metams iki žlugimo įvykio, o likus dvejiems metams – 76,92% tikslumu. Modelį sudaro 8 kintamieji rodikliai: vidutinio nuosavo kapitalo pelningumas, BVP augimo rodiklis, blogų paskolų ir visų paskolų santykis, infliacija, likvidaus turto ir viso turto santykis, turto augimo ir BVP augimo palyginimo rodiklis, operacinių išlaidų augimo rodiklis bei paskolų ir turto santykio rodiklis. Iš jų blogų paskolų ir visų paskolų santykio bei operacinių išlaidų augimo rodiklių didėjimas didina banko žlugimo tikimybę.
 4. Siekiant anksčiau identifikuoti galimą banko žlugimo grėsmę, siūloma sukurtą dvinarės logistinės regresijos Z5 modelį naudoti analizuojant bankų metines finansines ataskaitas. Kadangi tyrime analizuoti tik Europos kontinente veikiantys ar žlugę bankai, tolimesnės tyrimų kryptys galėtų būti Z5 modelio pritaikymas kitų šalių ar kontinentų bankų sektoriui, siekiant ištirti modelio universalumą ir patikimumą kitomis sąlygomis. Importar lista

Literatūra

- Baležentis, A.; Žalimaitė, M., 2011. Ekspertinių vertinimų taikymas inovacijų plėtros veiksnių analizėje: Lietuvos inovatyvių įmonių vertinimas. *Management theory and studies for rural business and infrastructure development*, Vol. 3 (27), p. 23-31. Prieiga per: <http://mts.asu.lt/mtsrbid/article/viewFile/269/298> [žiūrėta 2018 09 21]
- Bazelio Komitetas (b. m.). Finalising Basel III: in brief. Prieiga per: https://www.bis.org/bcbs/publ/d424_inbrief.pdf [žiūrėta 2018 09 27]
- Betz, F.; Oprică, S.; Peltonen, T. A.; Sarlin, P., 2013. Predicting distress in European banks. ECB working paper series, Nr. 1579. Prieiga per: <https://www.ecb.europa.eu/pub/pdf/scpwps/ecbwp1597.pdf> [žiūrėta 2018 10 02]
- Bužinskienė, R.; Karalevičienė, J., 2012. Moderniųjų bankroto modelių tinkamumo įvertinimas įmonių bankroto diagnozavimui. *Vadyba-Journal of Management*, Vol. 1 (20), p. 45–54. Prieiga per: <http://etalpykla.lituanistikadb.lt/fedora/objects/LT-LDB-0001:J.04~2012~1367187261497/datastreams/DS.002.0.01.ARTIC/content> [žiūrėta 2018 10 02] <https://doi.org/10.3846/btp.2006.24>

- Čekanavičius, V.; Murauskas, G., 2014. Taikomoji regresinė analizė socialiniuose tyrimuose. Vilnius: Vilniaus universiteto leidykla. Prieiga per: <http://www.statistika.mif.vu.lt/wp-content/uploads/2014/04/regresine-analize.pdf> [žiūrėta 2018 10 10 02] <https://doi.org/10.3846/791-s>
- Dandapani, K.; Lawrence, E. R., 2008. Virtual bank failures: an investigation. *Managerial Finance*, Vol. 34 (6), p. 399-412. <https://doi.org/10.1108/03074350810872778> ; <https://doi.org/10.1108/03074350810872778>
- Europos Centrinis bankas, 2018. What happens when a bank is failing or likely to fail? Prieiga per: https://www.bankingsupervision.europa.eu/press/publications/newsletter/2018/html/ssm.nl180516_3.en.html [žiūrėta 2018 09 15]
- Gudelytė, L.; Valužis, M., 2012. *Rizikos valdymas banke: Žinynas*. Vilnius: VšĮ Socialinių mokslų kolegija. Prieiga per: http://www.esparama.lt/es_parama_pletra/failai/ESFproduktai/2012_Rizikos_valdymas_banke.pdf [žiūrėta 2018 09 15] <https://doi.org/10.20334/2018-008-s>
- Huang, D.T.; Chang, B.; Liu, Z.C., 2012. Bank failure prediction models: for the developing and developed countries. *Quality & Quantity*, Vol. 46 (2), p. 553-558. <https://doi.org/10.1007/s11135-010-9386-9> ; <https://doi.org/10.1007/s11135-010-9386-9>
- Kolari, J.; Glennon, D.; Shin, H.; Caputo, M., 2002. Predicting large US commercial bank failures. *Journal of Economics and Business*, Vol. 54, p. 361-387. Prieiga per: https://ac.els-cdn.com/S0148619502000899/1-s2.0-S0148619502000899-main.pdf?_tid=842ff939-f723-4f42-8941-dc3f3cf6cd19&acdnat=1525897456_1c7c1573847c6c486f1f2d95b86048cd [žiūrėta 2018 10 02] [https://doi.org/10.1016/s0148-6195\(02\)00089-9](https://doi.org/10.1016/s0148-6195(02)00089-9)
- Konstandina, N., 2006. Probability of Bank Failure: The Russian Case. *Economics Education and Research Consortium: Working Paper Series*. Vol. 1. Prieiga per: https://www.google.com/url?sa=t&rcrt=j&q=&esrc=s&source=web&cd=1&ved=2ahUKEwj5qbDN2s_fAhXjkYsKHS--BFUQFjAAegQICBAC&url=http%3A%2F%2Ffeercnetwork.com%2Fdefault%2Fdownload%2Fcreator%2Fworking_papers%2Ffile%2F0e03ed325992612292bb5f4c315c03a7a397fcad.pdf&usq=AOvVaw3o0BAH3IPDKF-FpFd2L_3z [žiūrėta 2018 10 08]
- Lietuvos bankas, 2017. Veiklos reikalavimai ir normatyvai. Prieiga internetu: <https://www.lb.lt/lt/veiklos-reikalavimai-ir-normatyvai-1> [žiūrėta 2018 10 01]
- Marcišauskienė, J.; Mekaitė, A., 2015. JAV komercinių bankų bankroto analizė. *Studijos šiuolaikiniėje visuomenėje: Mokslo darbai*, 2015 Vol. 6 (1), p. 236-246. Prieiga per: https://www.slk.lt/sites/default/files/studijos_siuolaikineje_visuomeneje_2015.pdf [žiūrėta 2018 10 16] <https://doi.org/10.15181/mtd.v0i3.1660>
- Mavri, M., 2013. Classifying Greek banks based on Bank Ranking Index (BRI). *Benchmarking: An International Journal*, Vol. 20 (5), p. 607-624. <https://doi.org/10.1108/BIJ-09-2011-0069> ; <https://doi.org/10.1108/bij-09-2011-0069>
- Mockaitienė, S.; Žmiejauskaitė, K., 2010. Finansų rinkų krizės priežastys ir pasekmės Pabaltijo šalių akcijų rinkai.

- Ekonomikos ir vadybos aktualijos*, 2010, p. 178-188. Prieiga per: <http://etalpykla.lituanistikadb.lt/fedora/get/LT-LDB-0001:J.04~2010~1367173570425/DS.002.0.01.ARTIC> [žiūrėta 2018 10 16]
- Nur Ozkan-Gunay, E.; Ozkan, M., 2007. Prediction of bank failures in emerging financial markets: an ANN approach. *The Journal of Risk Finance*, Vol. 8 (5), p. 465-480. <https://doi.org/10.1108/15265940710834753>; <https://doi.org/10.1108/15265940710834753>
- Özel, G., 2013. Probabilistic prediction of bank failures with financial ratios: An empirical study on Turkish banks. *Pakistan Journal of Statistics and Operation Research*, 2013 Vol. 9 (4), p. 407–428. <https://doi.org/10.18187/pjsor.v9i4.492>
- Paulauskienė, K., 2013. Duomenų tyrybos sistemų galimybių tyrimas įvairių apimčių duomenims analizuoti: ataskaita. Prieiga per: http://old.mii.lt/files/vu_mii_sas_paulauskiene_2013_at.pdf [žiūrėta 2018 10 02] <https://doi.org/10.15388/im.2013.0.2052>
- Sahajwala, R.; Van den Bergh, P., 2000. Supervisory Risk Assessment and Early Warning Systems. Basel Committee on Banking Supervision Working Paper, Vol. 4. Prieiga per: https://www.bis.org/publ/bcbs_wp4.pdf [žiūrėta 2018 10 07]
- Valvonis, V., 2004. Kredito rizikos valdymas banke. *Pinigų studijos*, Vol. 4, p. 57 – 82. Prieiga per: http://elibrary.lt/resursai/DB/LB/LB_pinigu_studijos/Pinigu_studijos_2004_04_04.pdf [žiūrėta 2018 10 02]

Notas de autor

yra Danske Bank A/S Lietuvos filialo analitikė, socialinių mokslų magistrė. Mokslinių interesų kryptis – verslo subjektų finansinė analizė.

yra Vilniaus universiteto Ekonomikos ir verslo administravimo fakulteto Apskaitos ir audito katedros asistentė, socialinių mokslų daktarė. Ji taip pat yra verslo apskaitos standartų komiteto prie Lietuvos Respublikos Finansų ministerijos ekspertė. Moksliniai interesai: tarptautinės ir nacionalinės finansinės apskaitos sistemų vystymo, mokesčių apskaitos, finansinės įmonių analizės problemos