

Bankroto prognozavimas Lietuvos maitinimo paslaugų sektoriuje: tradicinių, mašininio mokymosi ir hibridinių modelių taikymas bei makroekonominių veiksnių įtaka

Miglė Martusevičiūtė

El. paštas: stud.martuseviciute@gmail.com

Ramunė Budrionytė

Vilniaus universitetas, Lietuva

El. paštas: ramune.budrionyte@evaf.vu.lt

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

<https://ror.org/03nadee84>

Anotacija. Straipsnyje analizuojamas bankroto prognozavimo modelių taikymas Lietuvos maitinimo paslaugų sektoriui, kuriam būdingas didelis ekonominis jautrumas ir aukšta bankroto rizika. Sprendžiama problema – tradicinių bankroto prognozavimo modelių nepakankamas tikslumas šio sektoriaus įmonių bankroto prognozavimui riboja jų efektyvų taikymą priimant verslo valdymo ir investicinius sprendimus. Tyrimo tikslas – įvertinti skirtingų bankroto prognozavimo modelių tipų tinkamumą Lietuvos maitinimo paslaugų sektoriaus įmonėms ir sukurti pažangiomis technologijomis pagrįstą hibridinį bankroto prognozavimo modelį, pritaikytą sektoriaus specifikai. Tyrimui taikyti Altman Z, Ohlson O, atraminių vektorių klasifikatoriaus (SVM) ir gradiento didinimo mašinų (GBM) modeliai, į pažangiuosius modelius integruojant ir makroekonominius rodiklius. Duomenų analizė atlikta su 96 Lietuvos maitinimo paslaugų įmonėmis, modelių veikimas vertintas naudojant AUC (ROC), F1, Brier ir kitus rodiklius. Tyrimo rezultatai parodė, kad sukurtas hibridinis modelis su makroekonominių veiksnių integracija pasiekė aukščiausią tikslumą (93,06 %) ir geriausią pusiausvyrą tarp jautrumo, preciziškumo bei kalibracijos, todėl gali būti laikomas efektyviu įrankiu praktiniam bankroto rizikos vertinimui maitinimo paslaugų sektoriuje.

Raktiniai žodžiai: hibridiniai bankroto prognozavimo modeliai, mašininis mokymasis, maitinimo paslaugų sektorius, vertinimas.

JEL klasifikacija: G33, M49, C53.

Bankruptcy Prediction in Lithuania's Food Service Sector: Application of Traditional, Machine Learning, and Hybrid Models and the Impact of Macroeconomic Factors

Miglė Martusevičiūtė

E-mail: stud.martuseviciute@gmail.com

Ramunė Budrionytė

Vilnius University, Lithuania

E-mail: ramune.budrionyte@evaf.vu.lt

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

<https://ror.org/03nadee84>

Annotation. This study examines bankruptcy prediction models specifically for Lithuania's food service sector, which is known for its high economic sensitivity and significant bankruptcy risk. The primary issue addressed is the limited accuracy of traditional bankruptcy prediction models when applied to this industry—an important concern for business management and investors. The aim of the study is to evaluate the effectiveness of different types of bankruptcy prediction models for companies in Lithuania's food service sector and to develop a hybrid model based on advanced technologies, tailored to the specific characteristics of the sector. The models investigated include the Altman Z-score, Ohlson O-score, Support Vector Machine (SVM), and Gradient Boosting Machine (GBM), with macroeconomic indicators incorporated into the advanced models. The empirical analysis was conducted using a dataset comprising 96 Lithuanian food service companies. Model performance was assessed through metrics such as AUC (ROC), F1 score, Brier score, and other key indicators. The findings reveal that the developed hybrid model with integrated macroeconomic factors achieved the highest prediction accuracy at 93.06%, along with the best overall balance of sensitivity, precision, and calibration, highlighting its potential as an effective tool for practical bankruptcy risk assessment in this sector.

Keywords: hybrid bankruptcy prediction models, machine learning, food service sector, evaluation.

JEL Code: G33, M49, C53.

Įvadas

Bankroto prognozavimo modeliai yra neatsiejama šiuolaikinės finansų analitikos ir verslo valdymo dalis dinamiškoje ir dažnai nestabiliroje ekonominėje aplinkoje. Gebėjimas iš anksto numatyti įmonės finansinius sunkumus ir bankroto riziką tampa esminiu veiksniu, leidžiančiu laiku imtis korekcinų veiksmų ir taip išvengti reikšmingų finansinių nuostolių bei užtikrinti ilgalaikį verslo stabilumą. Nuolatinė įmonių veiklos analizė ir gebėjimas reaguoti į netikėtus ekonomikos pokyčius yra būtini ne tik siekiant išvengti bankroto, bet ir užtikrinant įmonių ilgalaikį augimą. Bankroto prognozavimo modelių reikšmė nuolat auga dėl ekonomikos globalizacijos, didėjančios konkurencijos ir greitėjančių technologinių pokyčių. Nuolat kintančios rinkos sąlygos lemia, kad įmonės susiduria su vis sudėtingesniais iššūkiais, todėl bankroto prognozavimo modelių tyrimas ir tobulinimas yra itin svarbus, siekiant užtikrinti finansinį stabilumą ir skatinti tvarų ekonomikos augimą (Soukal ir kt., 2022).

Šiuo metu dauguma įmonių veikia sudėtingoje, konkurencingoje, nuolat kintančioje ir neapibrėžtumų kupinoje aplinkoje, kurioje nepakanka vien tradicinių valdymo metodų. Visgi kai kurie ūkio sektoriai patiria ypač dideles rizikas. Vienas iš tokių – maitinimo paslaugų sektorius, priklausantis HORECA segmentui, kuris pasižymi itin dideliu dinamiškumu, pažeidžiamumu ir jautrumu sezoniskumui, vartotojų elgsenai bei ekonominiams svyravimams. Šis sektorius dažnai išskiriamas analizuojant ekonominių krizių ar pandemijų poveikį dėl jautrumo išoriniams veiksniams bei būdingo didelio mažų įmonių skaičiaus. Pastaraisiais metais reikšmingai išaugęs maitinimo sektoriaus įmonių bankrotų skaičius (Registrų centras, n. d.) atskleidžia šio sektoriaus pažeidžiamumą ir išryškina būtinybę vertinti bankroto tikimybę. Maitinimo paslaugų sektorius pasižymi specifinėmis savybėmis, tokiomis kaip antai griežti kokybės kontrolės reikalavimai, stipri priklausomybė nuo vartotojų elgsenos bei ekonominių svyravimų. Todėl klasikiniai bankroto prognozavimo modeliai gali būti šiam sektoriui nepakankami – itin svarbiomis tampa pažangios ir tikslios bankroto prognozavimo priemonės, padedančios iš anksto priimti pagrįstus verslo rizikos valdymo ir finansinius sprendimus.

Tradiciniai bankroto prognozavimo modeliai yra plačiai nagrinėti tiek mokslinėje literatūroje, tiek ir taikomuosiuose tyrimuose. Pastaruoju metu vis daugiau dėmesio skiriama pažangių technologijų integravimui į bankroto prognozavimo procesus: Park ir Hancer (2012), Becerra-Vicario ir kt. (2020), Gavurova ir kt. (2022), Kim ir kt. (2022) analizavo tradicinių finansinių rodiklių ir neuroninių tinklų derinimą; Kim ir Upneja (2014), Chou (2019), Bateni ir Asghari (2020), Kim ir Upneja (2021), Gaurav ir kt. (2025) tyrė hibridinių metodų – sprendimų medžių, gilaus mokymosi ir kitų, efektyvumą; du Jardin (2021) pristatė modeliavimo metodą, kuris leidžia kurti bankroto prognozavimo modelius, pagrįstus dvigubu grupavimu (angl. *biclustering*); Máté ir kt. (2023) bei Ainan ir Nur-E-Arefin (2022) nagrinėjo

dirbtinio intelekto ir genetinių algoritmų taikymą bankroto prognozavimui. Dasilas ir Rigani (2024) teigimu, šiuo metu vyrauja tendencija kurti hibridinius modelius, kurie derina keletą metodikų ir kintamųjų, siekiant pagerinti bankroto prognozavimo tikslumą. Mūsų tyrime taip pat taikytos pažangios analizės metodikos – statistiniai modeliai ir mašininio mokymosi technologijos, siekiant sukurti hibridinį prognozavimo modelį, geriau atitinkantį maitinimo paslaugų sektoriaus specifiką ir leidžiantį tiksliau prognozuoti bankroto rizikas.

Tyrimo tikslas – įvertinti skirtingų bankroto prognozavimo modelių tipų tinkamumą Lietuvos maitinimo paslaugų sektoriaus įmonėms ir jų pagrindu sukurti pažangiomis technologijomis pagrįstą hibridinį bankroto prognozavimo modelį, pritaikytą šio sektoriaus specifikai.

Tyrimo uždaviniai:

- 1) atlikus mokslinės literatūros analizę, išnagrinėti bankroto prognozavimo modelių patikimumą maitinimo paslaugų sektoriuje;
- 2) naudojantis Lietuvos maitinimo paslaugų sektoriuje veikiančių ir bankrutavusių įmonių duomenimis, įvertinti pasirinktų bankroto prognozavimo modelių tikslumą ir patikimumą;
- 3) remiantis atlikta bankroto prognozavimo modelių patikimumo analize, sukurti hibridinį bankroto prognozavimo modelį, atliepiantį maitinimo sektoriaus specifiką.

Tyrimo metodai: lyginamoji mokslinės literatūros analizė ir sintezė, duomenų imties ir atrankos sudarymo metodai, aprašomosios statistikos metodai, regresinė analizė, mašininio mokymosi metodai, modeliavimas, modelių ir prognozavimo tikslumo vertinimo metodai.

1. Bankroto prognozavimo teoriniai aspektai

1.1 Bankroto prognozavimo modelių tipai ir jų tikslumo tyrimai

Bankroto prognozavimo modeliuose naudojami įvairūs finansiniai ir rinkos rodikliai, siekiant prognozuoti galimą finansinę krizę ir padėti suinteresuotosioms šalims priimti pagrįstus sprendimus (Horváthová ir kt., 2023; Marsenne ir kt., 2024). Tai sudėtingi analitiniai įrankiai, vertinantys tikimybę, kad įmonė patirs finansinių sunkumų, galinčių sukelti bankrotą. Modeliai leidžia anksčiau identifikuoti finansinės būklės pablogėjimo požymius dar prieš pasireiškiant realiems finansiniams sutrikimams. Pagal metodologinį-technologinį principą šiuolaikinius bankroto prognozavimo modelius galima suskirstyti į statistinius (klasikinius), mašininio mokymosi ir hibridinius.

Statistiniuose bankroto prognozavimo modeliuose įprastai naudojami įvairūs finansiniai rodikliai, siekiant nustatyti ankstyvus galimo bankroto požymius. Šie modeliai dažniausiai grindžiami diskriminantine analize arba logistine regresija. Tarp žinomiausių – Altman Z balo modelis, padėjęs tvirtus pagrindus bankroto prognozavimui, taip pat Ohlson O balo modelis, kuriuo buvo siekta patobulinti Altman Z metodiką, taikant logistinę regresiją ir įtraukiant kai kuriuos nefinansinius kintamuosius (Lisin ir kt., 2022). Reikšmingi ir Zavgren, Grove, Springate, Zmijewski, Fulmer modeliai – kiekvienas jų pasižymi skirtinga taikymo sritimi bei tikslumu, todėl praktikoje dažnai rekomenduojama naudoti kelių modelių derinius. Naujausi tyrimai siekia toliau tobulinti šiuos modelius, integruojant nefinansinius duomenis ir pritaikant juos konkrečioms ekonominėms kontekstams (Máté ir kt., 2023).

Tobulėjant duomenų analitikai, bankroto prognozavime vis dažniau taikomi mašininio mokymosi modeliai, kurie gali apdoroti didelius duomenų kiekius ir aptikti tendencijas, kurios dažnai lieka nepastebėtos taikant tradicinius statistinius metodus (Park ir kt., 2021; Huo ir kt., 2024). Tarp dažniausiai naudojamų mašininio mokymosi metodų yra sprendimų medžiai, atraminių vektorių klasifikatoriai, neuroniniai tinklai ir gradiento didinimo mašinos (Dasilas ir Rigani, 2024; Cialone, 2020; Becerra-Vicario ir kt., 2020; Jones, 2017). Sprendimų medžiai pasižymi gebėjimu efektyviai apdoroti įvairius duomenis, aiškiai vizualizuoja sprendimus ir yra lengvai interpretuojami (Podhorska ir kt., 2020). Tačiau šie modeliai linkę koncentruotis į dominuojančias duomenų klases ir gali būti neefektyvūs vertinant reikšmingas, bet mažas klases, taip pat gali pateikti netikslius rezultatus, jei naudojami

nesubalansuoti duomenų rinkiniai (Syed Nor ir kt., 2019; Akosa, 2017). Alam ir kt. (2021) nustatė, jog taikant sprendimų medžius Lenkijos įmonių bankrotų prognozavimui, pasiektas net 99 % prognozių tikslumas pirmiesiems metams, o tai pranoko kito mašininio mokymosi modelio – atraminių vektorių klasifikatoriaus (toliau – SVM) rezultatus. SVM modeliai veikia ieškodami geriausios ribos – hiperplokštumos, skiriančios du duomenų klasių taškų rinkinius taip, kad būtų maksimaliai padidintas atstumas tarp artimiausių dviejų klasių taškų – atramos vektorių. SVM ypač tinkamas klasifikavimo užduotims, nes padeda suskirstyti duomenis į aiškias kategorijas, tačiau didėjant duomenų kiekiui, didėja rezultatų interpretavimo sudėtingumas, o tai gali reikalaus daugiau laiko ir resursų (Horak ir kt., 2020). Neuroniniai tinklai imituoja žmogaus smegenų informacijos apdorojimo principus. Modelis mokomas remiantis istoriniais duomenimis, nuolat koreguojami vidiniai ryšiai, siekiant pagerinti prognozių tikslumą. Kartą apmokytas tinklas gali prognozuoti įmonių bankroto riziką pagal jų finansinę informaciją (Narvekar ir Guha, 2021). Gradiento didinimo mašinos (toliau – GBM) veikia nuosekliai generuodamos sprendimų medžius, kur kiekvienas naujas medis koreguoja ankstesniųjų klaidas, taip nuolat didinant bendrą modelio tikslumą. Nors modeliai pasižymi aukštu prognozavimo našumu, GBM turi keletą hiperparametrų, kuriuos reikia tinkamai sureguliuoti, kad būtų pasiektas optimalus našumas, o tai gali užimti daug laiko (Hossain ir kt., 2022). Jones (2017) pažymi, jog įmonių bankroto rizika geriausiai paaiškinama naudojant didelės apimties modelius, kurie įtraukia netradicinius kintamuosius, tokius kaip antai nuosavybės struktūra, rinkos koncentracija ar generalinio direktoriaus atlyginimas. GBM modeliai išsiskiria gebėjimu apdoroti įvairius prognozavimo veiksnus, pasižymi dideliu našumu ir atsparumu duomenų problemoms, tačiau dėl sudėtingos vidinės struktūros gali būti sunkiai interpretuojami – stebimas „juodosios dėžės“ efektas (Jones, 2017).

Hibridiniai bankroto prognozavimo modeliai sujungia statistinių ir mašininio mokymosi metodų elementus, siekiant padidinti prognozių tikslumą. Tarp dažniausiai minimų modelių yra *Logit Model Trees* (toliau – LMT), *AdaBoost*, atraminių vektorių klasifikatorius sujungtas su genetiniu algoritmu (toliau – SVMGA), hibridiniai neuroniniai tinklai su dirbtinių bičių kolonijos algoritmu (toliau – ABC) bei sprendimų medžiai, integruoti su giliais neuroniniais tinklais (Máté ir kt., 2023; Kim ir kt., 2022; Ainan ir Nur-E-Arefin, 2022; Bateni ir Asghari, 2020; Marso ir Merouani, 2020; Chou, 2019; Kim ir Upneja, 2014). Hibridiniai modeliai pasižymi aukštu tikslumu, tačiau jų veiksmingumas labai priklauso nuo tyrimo srities, duomenų pobūdžio ir techninio įgyvendinimo. Vienas žymiausių šių modelių – LMT, daugelyje tyrimų parodė gerus rezultatus, tačiau Bateni ir Asghari (2020) tyrime šio modelio tikslumas siekė tik 75–77 %. Gaurav ir kt. (2025) hibridinis giluminio mokymosi modelis pasiekė 81 % tikslumą, derindamas konvoliucinius neuroninius tinklus su metodais, skirtais valdyti klasių disbalansą ir požymių sudėtingumą, ir pranoko logistinę regresiją ir SVM. Geresnius rezultatus Marso ir Merouani (2020) tyrime pademonstravo ABC modelis: jį naudojant vienerių ir trejų metų laikotarpių iki bankroto duomenims, vienerių metų prognozių tikslumas siekė 92 %. Dar geresnių rezultatų pasiekė *AdaBoost* modelis, kuris, tinkamai suregulius hiperparametrus, pasiekė net 100 % tikslumą (Máté ir kt., 2023). Panašų tikslumą užfiksavo ir SVMGA modelis, taikytas banko veiklos prognozavimui (Ainan ir Nur-E-Arefin, 2022). Kita vertus, Kanapickienė ir kt. (2023) tyrime bazinis logistinės regresijos modelis, apimantis finansinius, nefinansinius, sektoriaus ir makroekonominis rodiklius, pasiekė 82 % bendrą tikslumą, pranokdamas tiek MARS, tiek pavienius neuroninių tinklų sprendimus, o dvipakopiai hibridiniai modeliai nedidino prognozės galios – geriausi variantai tik prilygo baziniam logistinės regresijos modeliui. Todėl galima manyti, jog papildomas sudėtingumas ne visuomet pasiteisina. Įvairūs tyrimai rodo, kad tiek statistiniai, tiek mašininio mokymosi modeliai gali veiksmingai prognozuoti bankrotą, tačiau jų tikslumas priklauso nuo turimų duomenų kokybės, struktūros ir taikymo konteksto. Tiksliausi rezultatai dažniausiai pasiekiami taikant hibridinius modelius, tačiau verta pažymėti, kad sudėtingi modeliai, tokie kaip *AdaBoost* ar GBM, reikalauja daug laiko ir resursų hiperparametrų optimizavimui.

1.2 Bankroto prognozavimas maitinimo paslaugų sektoriuje

Maitinimo paslaugų sektorius, apimantis restoranus, kavines ir kitas viešojo maitinimo formas, pasižymi itin dinamiška veikla ir dideliu jautrumu išoriniams ekonominiams veiksniams. Net nedideli išoriniai sukrėtimai, tokie kaip pasikeitęs reglamentavimas, ekonominiai svyravimai, konkurencija, vartotojų

elgesio pokyčiai, gali greitai virsti rimtais tokių įmonių finansiniais sunkumais (Huo ir kt., 2024). Istoriniai duomenys rodo, kad sektoriaus veiklos rezultatai yra glaudžiai susiję su ekonomikos svyravimais – per 2007–2009 m. krizę restoranų lankymas smarkiai sumažėjo, o greitojo maisto segmentas išliko stabilus (Hamrick ir Okrent, 2014). Panašią priklausomybę patvirtina ir dabartiniai tyrimai: Parsa ir kt. (2019) nustatė, kad ekonomikos nuosmukiai ir atsigavimas tiesiogiai veikia restoranų veiklos rezultatus ir bankrotų intensyvumą. COVID-19 pandemija dar labiau išryškino sektoriaus pažeidžiamumą – vyriausybės apribojimai ir smarkiai pasikeitęs vartotojų elgesys sukėlė beprecedentę finansinę įtampą, daugelyje šalių restoranai buvo priverstinai uždaryti arba spaudžiami riboti savo veiklą, o tai lėmė masinį bankrotų skaičių ir didelius nuostolius (Huo ir kt., 2024; Aigbedo, 2021; Kaufman ir kt., 2020). Panaši situacija fiksuota ir Ukrainoje, kur karo sąlygomis smukusi paklausa tiesiogiai paveikė restoranų veiklos rezultatus (Aleskerova ir Fedoryshyna, 2023).

Be išorinių šokų, sektoriaus veiklą veikia ir ilgalaikiai makroekonominiai veiksniai, tokie kaip antai infliacija, nedarbo lygis, vartotojų pasitikėjimas. Kylant maisto produktų ir žaliavų kainoms, sektoriaus įmonių veiklos sąnaudos didėja, pelno maržos mažėja, dalis vartotojų pereina prie pigesnių alternatyvų – renka greitąjį maistą arba dažniau gamina namuose (Aleskerova ir Fedoryshyna, 2023). Tokiais laikotarpiais restoranai priversti balansuoti tarp augančių veiklos sąnaudų ir mažėjančios vartotojų perkamosios galios. Siekdamos išlikti, įmonės gali didinti kainas, arba mažinti išlaidas, tačiau tai gali lemti lankytojų srauto mažėjimą ar paslaugų kokybės prastėjimą (Kizildag ir kt., 2024). Kita vertus, Miljak ir kt. (2022) tyrimas rodo, kad kainų svyravimai lemia skirtingus vartotojų elgsenos pokyčius: augančios kainos įprastai skatina vartotojus riboti išlaidas valgymui ne namuose, tačiau tam tikruose turistiniuose regionuose paklausa išlieka stabili, nes turistai mažiau jautrūs kainų pokyčiams (Miljak ir kt., 2022). Vartotojų pasitikėjimo rodiklis taip pat svarbus sektoriaus veiklos stabilumui – didesnio optimizmo laikotarpiais vartotojai yra labiau linkę skirti lėšų laisvalaikio pramogoms ir maitinimui, o sektoriaus įmonės labai priklausomos nuo kasdienio vartotojų srauto. Park ir kt. (2021) tyrimas parodė, kad sezoniškumas, šventės ir ekonominės sąlygos gali lemti reikšmingus vartotojų srautų svyravimus, tiesiogiai veikiančius restoranų pajamas. Pasak Yost ir kt. (2020), restoranų veiklos indeksas atskleidžia, kad vartotojų pasitikėjimo ciklai gali būti vertinami kaip ankstyvieji sektoriaus augimo arba nuosmukio indikatoriai. Kitas svarbus veiksnys, darantis įtaką maitinimo paslaugų įmonių veiklai – nedarbo lygis. Aukštas nedarbas mažina gyventojų perkamąją galią ir tuo pačiu paklausą maitinimo paslaugoms. Aleskerova ir Fedoryshyna (2023) nustatė, kad nedarbo augimas sumažino gyventojų pajamas, o tai nulėmė maitinimo įstaigų lankytojų srautų mažėjimą bei personalo mažinimą šiose įstaigose. Parsa ir kt. (2014) tyrime pažymėta, kad vietinio užimtumo rodikliai tiesiogiai susiję su restoranų veiklos stabilumu: rajonuose, kuriuose nedarbo lygis siekė 7,8 %, fiksuotas vienas didžiausių restoranų uždarymo rodiklių.

Akivaizdu, kad maitinimo paslaugų sektoriui būtini pažangūs, lanksčiai pritaikomi bankroto prognozavimo modeliai, įtraukiantys ne tik finansinius įmonių, tačiau taip pat ir makroekonominis rodiklius, kurie atspindi veiksnis, svarbius sektoriaus įmonių veiklai. Tradiciniai statistiniai modeliai, tokie kaip antai logistinė regresija ar Altman Z balas, buvo plačiai taikomi dėl jų paprastumo ir efektyvumo. Tačiau jų priklausomybė nuo linijinių ryšių ir vien tik istorinių finansinių duomenų apriboja jų taikymą sudėtingoje daugialypėje aplinkoje. Patel (2022) tyrime taikyti logistinės regresijos ir dirbtinių neuroninių tinklų modeliai, prognozuojant JAV restoranų bankrotą, parodė, kad abiejų modelių prognozavimo tikslumas buvo vienodas – 63 %, paneigiant plačiai paplitusią nuomonę, kad dirbtiniai neuroniniai tinklai gali pasiekti geresnių rezultatų. Pabrėžiama, kad tinkamo modelio pasirinkimas turi būti grindžiamas duomenų specifika ir sektoriaus ypatumais – tai esminė sąlyga siekiant tikslesnių prognozių ir efektyvesnių sprendimų priėmimo (Patel, 2022). Kita vertus, Bogdan (2021) tyrime, analizuojant restoranų bankroto prognozavimo galimybes logistinės regresijos metodu, buvo gauti geresni rezultatai: pasiektas 82,8 % tikslumas prognozuojant bankrotą likus vieneriems metams iki bankroto, 76,7 % tikslumas – dviem ir 76,4 % tikslumas – trejiems metams iki bankroto (Bogdan, 2021). Savo ruožtu, Kim (2018) nagrinėjo finansinių sunkumų prognozavimą restoranų sektoriuje taikant Ohlson O modelį ir nustatė, kad modelis pasiekė 83 % tikslumą prognozuojant finansinius sunkumus

restoranų sektoriuje. Panašiai, Huo ir kt. (2024), JAV vertybinių popierių biržoje kotiruojamiems restoranams pritaikytas kanoninis daugialypės diskriminantinės analizės modelis teisingai klasifikavo 78,9 % stebėjimų, įskaitant 80,6 % bankroto atvejų, tuo tarpu logistinės regresijos modelis – atitinkamai 73,2 % ir 71,4 %. Tokie tyrimų rezultatai parodo, kad klasikiniai statistiniai bankroto prognozavimo modeliai neblogai prognozuoja maisto ir gėrimų sektoriaus įmonių finansinius sunkumus ir gali užtikrinti pakankamai veiksmingą rizikos valdymą.

Mašininio mokymosi modeliai, tokie kaip antai sprendimų medžiai, palaikymo vektorinės mašinos (SVM), dirbtiniai neuroniniai tinklai ir gradiento didinimo mašinos (GBM), pasižymi aukštu prognozavimo tikslumu bankroto rizikos vertinimo kontekste, ypač dėl jų gebėjimo apdoroti didelius duomenų kiekius ir identifikuoti sudėtingus nelineinius ryšius tarp kintamųjų. JAV atlikti tyrimai parodė, kad mašininio mokymosi modeliai pranašesni už tradicinius statistinius metodus prognozuojant restoranų bankrotus, ypač po COVID-19 pandemijos: GBM pasiekė 85 %, o neuroninių tinklų modelis – net 87 % prognozavimo tikslumą (Cialone, 2020). Park ir Hancer (2012) sukonstruoto keturių rodiklių logistinės regresijos modelio bendras tikslumas siekė 83,3 % su I-os rūšies klaidų tikimybe 16,7 %, tuo tarpu penkių rodiklių daugiapakopis dirbtinis neuroninis tinklas padidino bendrą tikslumą iki 87,5 % ir sumažino I-os rūšies klaidų tikimybę iki 12,5 %, akivaizdžiai pralenkdamas logistinės regresijos modelį. Li ir kt. (2025), ištyrę 2 838 Bostono restoranų finansinius duomenis, nustatė, kad logistinės regresijos modelio, pagrįsto vien finansiniais rodikliais, C-statistika tesiekė apie 0,71, o pažangūs mašininio mokymosi metodai – ypač *XGBoost-Cox* ir *Random Survival Forest* – pakėlė šį rodiklį iki 0,82–0,83, taip pagerindami prognozės tikslumą apytiksliai 10 procentinių punktų. Be to, mašininio mokymosi modelių našumas išliko stabilus net COVID-19 pandemijos laikotarpiu, kai logistinės regresijos tikslumas pastebimai smuko. Tyrimas taip pat atskleidė, jog į modelį įtraukus trijų lygių klientų atsiliepimų dispersiją, C-statistika *XGBoost-Cox* algoritme padidėjo maždaug 8 procentiniais punktais (Li ir kt., 2025). Panašiai Becerra-Vicario ir kt. (2020) giliojo rekursinio konvoliucinio neuroninio tinklo (angl. *Deep Recurrent Convolutional Neural Network*, DRCNN) modelis, pritaikytas Ispanijos restoranų bankroto prognozei, likus vieneriems metams iki bankroto teisingai klasifikavo 93,5 % įmonių, kai logistinės regresijos modelis – tik 80,4 %. Analogiškas DRCNN pranašumas išliko ir likus dvejiems bei trejiems metams iki bankroto. Aukštą modelio tikslumą lėmė neuroninio tinklo gebėjimas automatiškai aptikti nelineinius ir tarpusavyje priklausomus ryšius tarp 24 finansinių ir nefinansinių rodiklių bei išlaikyti minimalų skirtumą tarp mokymosi ir testavimo imčių tikslumo (Becerra-Vicario ir kt., 2020). Remiantis tokiais tyrimų rezultatais galima teigti, kad tinkamai pritaikius mašininio mokymosi modelį ir įtraukus į jį aktualius makroekonominis rodiklius, jis gali būti sėkmingai taikomas net ir didelio neapibrėžtumo ar ekonominių šokų sąlygomis.

Hibridiniai modeliai, kuriuose statistiniai metodai derinami su mašininio mokymosi metodais, leidžia pagerinti prognozių tikslumą bei stabilumą ir išnaudoti abiejų metodų pranašumus: statistiniai metodai naudojami išankstiniam duomenų apdorojimui, o mašininio mokymosi metodai – galutiniam prognozavimui. Taip Kim ir Upneja (2014) sukurta viešai listinguojamų JAV restoranų ankstyvoji finansinių sunkumų perspėjimo sistema, naudojant *AdaBoost* ansamblinį variantą, pasiekė 93,1–98,1 % bendrą klasifikavimo tikslumą, lyginant su baziniu C4.5 sprendimų medžiu, kurio tikslumas buvo apie 86 %, be to, sumažino I-os rūšies klaidų tikimybę iki maždaug 15 %. Pabrėžiama, kad hibridinių modelių kūrimo technika leido atskleisti nelineinius ryšius tarp didelio skolinto kapitalo, lėtesnio turto augimo, mažesnio pelningumo ir trumpalaiko mokumo prastesnių rodiklių, todėl gali suteikti restoranų vadovams ir kreditoriams patikimesnį įrankį už klasikinę logistinę regresiją ar diskriminantinę analizę (Kim ir Upneja, 2014). Vėlesnis tų pačių autorių sukurtas hibridinis bankroto prognozavimo modelis (angl. *majority voting ensemble method*), apjungęs sprendimų medžio ir logistinės regresijos prognozes, pasiekė 88,02 % bendrą tikslumą, o ekonominių nuosmukių ir plėtros pogrupiuose – atitinkamai 80,81 % ir 87,02 % tikslumą, gerokai sumažindamas I-os rūšies klaidas, t. y. bankrotų neatpažinimą (Kim ir Upneja, 2021). Kita vertus, Papíková ir Papík (2022) taikė septynis klasifikatorius ir požymių atrankas bei tris persvėrimo strategijas Slovakijos įmonių duomenų rinkiniui, siekdami sudaryti hibridinius bankroto prognozavimo srautus. Tačiau geriausią rezultatą, 99,4 % bendrą tikslumą, pasiekė pavienis *CatBoost*

be papildomų hibridinių procedūrų, o sudėtingi deriniai tik nežymiai pakeitė, arba net pablogino modelių našumą. Panašu, kad pažangus pavienis mašininio mokymosi algoritmas kartais gali pranokti hibridinius modelius.

Naujausi tyrimai rodo tendenciją plėsti prognozavimo modeliuose naudojamų duomenų apimtį, įtraukiant nefinansinius rodiklius, tokius kaip antai klientų pasitenkinimas, internetinės apžvalgos ir rinkos tendencijos. Svarbu bankroto prognozavimo modeliuose integruoti įvairius duomenų šaltinius, siekiant atskleisti kompleksinį ir įvairiapusį maitinimo paslaugų sektoriaus pobūdį. Hibridiniai modeliai demonstruoja aukštą našumą, todėl turėtų ypač tikti nepastoviam ir rizikingam maitinimo paslaugų sektoriui. Atsižvelgiant į atliktą mokslinės literatūros analizę, tyrime suformuluotos dvi hipotezės.

H1: Hibridinis bankroto prognozavimo modelis, sudarytas iš statistinių ir mašininio mokymosi metodų, tiksliau prognozuoja maitinimo paslaugų sektoriaus įmonių bankroto tikimybę, lyginant su atskirų modelių prognozėmis.

H2: Į hibridinį bankroto prognozavimo modelį įtraukus makroekonominis veiksnius – BVP augimą, infliaciją, nedarbo lygį, vartotojų pasitikėjimo rodiklį ir vartotojų kainų pokyčius, modelio tikslumas maitinimo paslaugų sektoriuje padidėja.

2. Tyrimo metodologija

2.1 Tiriamų įmonių atranka ir taikyti bankroto prognozavimo modeliai

2024 m. gruodžio 1 d. duomenimis Lietuvoje veikė 2 613 įmonių, registruotų pagal veiklos klasifikatorių 561 000 – restoranų ir pagaminto valgio teikimo veikla. Nors veikiančių įmonių skaičius šiame sektoriuje yra gana didelis, per 2020–2024 metų laikotarpį fiksuoti 188 bankrotų atvejai rodo reikšmingą rizikos lygį (Registru centras, n. d.). Siekiant užtikrinti tyrimo reprezentatyvumą, imties dydis buvo apskaičiuotas taikant Paniotto formulę (Nurmanditya ir kt., 2023), numatant 10 % leistiną paklaidą. Tyrimui atrinktos dviejų tipų įmonės: veikiančios, kurioms neiškelta bankroto byla ir bankrutavusios. Tyrimo imtį sudarė 96 įmonės: 48 bankrutavusios ir 48 veikiančios. Tyrime naudoti Lietuvos maitinimo paslaugų sektoriaus įmonių finansiniai rodikliai ir kiti vieši 2020–2024 metų laikotarpio duomenys. Įmonių 2020–2023 metų finansinių ataskaitų duomenys gauti iš atvirų duomenų platformos „Okredo“.

Imtis buvo sudaryta taikant stratifikuotą atrankos metodą, atsižvelgiant į veiklos sektorių, vietą (didieji miestai ir mažesni miestai bei regionai), veiklos trukmę (naujos, veikiančios iki 5 metų ir ilgiau nei 5 metus veikiančios įmonės) ir įmonės dydį (mažos, vidutinės, didelės įmonės). Įmonės atrinktos naudojant atsitiktinės atrankos metodą („Microsoft Excel“, funkcija = RAND()), tačiau užtikrinant jų pasiskirstymą pagal geografinius regionus, veiklos trukmę ir dydį, taip padidinant tyrimo rezultatų tikslumą ir bendrą reprezentatyvumą. Mašininio mokymosi modeliams mokytį buvo atrinktos likusios 140 bankrutavusių įmonių, iš kurių 20 įmonių buvo pašalintos dėl nepateiktų arba netinkamai pateiktų finansinių duomenų. Mokymo tikslams buvo parinktas toks pat skaičius veikiančių įmonių, atrinktų atsitiktiniu būdu. Iš viso mašininio mokymosi modelių mokymui buvo panaudoti 240 įmonių duomenys.

1 lentelė. Taikyti bankroto prognozavimo modeliai

Modelis	Modelio formulė	Modelio elementai
Altman Z balo	$Z = 1,2 \times X_1 + 1,4 \times X_2 + 3,3 \times X_3 + 0,6 \times X_4 + 1,0 \times X_5$	X_1 – Apyvartinis kapitalas/ Turtas X_2 – Nepaskirstytasis pelnas/ Turtas X_3 – Pelnas prieš palūkanas ir mokesčius (EBIT)/ Turtas X_4 – Kapitalo rinkos vertė/ Balansinė skolos vertė X_5 – Pardavimo pajamos/ Turtas
Ohlson O balo	$O = -1,32 - 0,407 \log(X_1) + 6,03 \times X_2 - 1,43 \times X_3 + 0,757 \times X_4 - 1,72 \times Y_1 - 2,37 \times X_5 - 1,83 \times X_6 + 0,285 \times Y_2 - 0,521 \times X_7$	X_1 – Turtas X_2 – Įsipareigojimai/ Turtas X_3 – Apyvartinis kapitalas/ Turtas X_4 – Trumpalaikiai įsipareigojimai/ Trumpalaikis turtas Y_1 – 1, jei įsipareigojimai > turtas, 0, jei atvirkščiai

		X_5 – Grynosios pajamos/ Turtas X_6 – Veiklos operacijų teikiamos lėšos/ Įsipareigojimai $Y_2 - 1$, jei grynas nuostolis yra dvejus metus iš eilės, 0, jei ne X_7 – (Grynosios šio laikotarpio pajamos – Grynosios praėjusio laikotarpio pajamos)/ (<i>Delta</i> grynosios šio laikotarpio pajamos + <i>Delta</i> grynosios praėjusio laikotarpio pajamos)
SVM	$f(x) = w^T x + b$	w – vektorius, reiškiantis svorius, kurie nustato, kaip kiekvienas kintamasis veikia sprendimo plokštumą (hiperplokštumą) x – vektorius, reiškiantis įvesties duomenis, kuriuos bando klasifikuoti SVM w^T – transponuotas svorių vektorius, kuris leidžia atlikti vidinį sandaugos veiksmą su įvesties duomenimis b – šališkumo koeficientas, kuris reguliuoja sprendimo plokštumos poziciją erdvėje
GBM	$F_m(x) = F_{m-1}(x) + \eta \times \sum_{i=1}^n g_i$	$F_m(x)$ – galutinė prognozė m -ajame iteracijos etape, kai yra sumuojami ankstesnių iteracijų rezultatai ir klaidos pataisymai $F_{m-1}(x)$ – prognozė praėjusiam iteracijos etape η – mokymosi greitis, kuris nustato kokių dydžių kiekviena iteracija prisideda prie galutinės prognozės. Mažesnė reikšmė sumažina kiekvienos iteracijos įtaką, bet didina tikslumą ilgesnėje perspektyvoje. g_i – klaidos gradientas, kuris nurodo klaidos dydį tarp dabartinės prognozės ir tikrosios vertės. Kiekviena iteracija bando minimizuoti šią klaidą, siekiant tiksliausios prognozės. n – silpnų modelių skaičius, t. y. kiek sprendimų medžių ar kitų silpnų prognozių naudojama siekiant pagerinti bendrą modelio tikslumą

Šaltinis: sudaryta autorių, remiantis Altman (1968); Ke ir kt. (2017); Ohlson (1980); Vapnik (2000)

Tyrimė taikyti du statistiniai ir du mašininio mokymosi bankroto prognozavimo modeliai, nurodyti 1 lentelėje. Šie modeliai atrinkti remiantis mokslinės literatūros analize kaip tinkamiausi prognozuojant bankrotą maitinimo paslaugų sektoriuje.

Altman Z balo modelis pasirinktas dėl plačiai pripažinto efektyvumo vertinant įmonių finansinę būklę ir aiškiai interpretuojamos finansinių rodiklių struktūros. Ohlson O balo modelis pasirinktas kaip apimantis platesnį finansinių rodiklių spektrą ir geriau pritaikomas skirtingo dydžio įmonių prognozėms. Šie statistiniai modeliai buvo pritaikyti naudojant *Python* programavimo kalbą, kuri užtikrina didesnį skaičiavimų automatizavimą bei pakartojamumą, leidžiantį atlikti modelių vertinimą ir hiperparametrų optimizaciją be rankinio įsikišimo (Rak-amnouykit ir kt., 2022). SVM modelis pasirinktas dėl gebėjimo identifikuoti netiesinius ryšius tarp rodiklių ir bankroto rizikos, kurie gali būti nepastebėti klasikiniuose statistiniuose modeliuose. Modeliui naudoti rodikliai (santykiai) buvo apskaičiuoti iš įmonių pelno (nuostolių) ataskaitų ir balansų remiantis Tsai ir kt. (2023), Lokanan ir Ramzan (2024) moksliniais tyrimais, susijusiais su mašininio mokymosi modeliais. Tačiau atrinkti tik tie rodikliai, kuriuos buvo galima apskaičiuoti pagal įmonių finansines ataskaitas, kiti buvo pašalinti dėl duomenų trūkumo. GBM taikyta kaip sustiprinantis algoritmas, paremtas sprendimų medžių seka. Jo paskirtis – sujungti visų finansinių rodiklių ir kitų modelių rezultatus, siekiant padidinti prognozavimo tikslumą.

2.2 Hibridinio modelio kūrimo procesas

Kuriant hibridinį modelį buvo pritaikyta Ozupek ir kt. (2024) universali tokio tipo modelio konstravimo metodika, t. y. pagrindiniai duomenų rinkimo, statistinių ir mašininio mokymosi modelių taikymo bei

rezultatų sujungimo žingsniai (Ozupek ir kt., 2024). Remiantis šia metodika, pirmiausiai buvo apskaičiuoti Altman Z ir Ohlson O balai 96 įmonėms, įtrauktoms į pagrindinę tyrimo imtį. Tuomet buvo atliktas duomenų paruošimas, reikalingas SVM modelio mokymui: 240 mokymo imčiai atrinktų įmonių finansinių ataskaitų reikšmingi finansiniai rodikliai buvo transformuoti, siekiant užtikrinti jų tinkamumą SVM modeliui. Kadangi SVM algoritmas yra jautrus duomenų masteliui, jo veikimas gali būti nepatikimas, jei naudojami rodikliai turi labai skirtingus reikšmių intervalus (Kundu ir Ari, 2017). Siekiant to išvengti, visi finansiniai rodikliai buvo standartizuoti taikant *Z-score* normalizaciją, kuri užtikrina, kad visi rodikliai turėtų nulį kaip vidutinę reikšmę ir vieneto standartinį nuokrypį, taip išvengiant situacijos, kai vienas rodiklis galėtų dominuoti modelyje dėl didesnių reikšmių (Kundu ir Ari, 2017). Be to, buvo atliktas trūkstamų duomenų apdorojimas: jei trūko duomenų iki 5 %, jie buvo užpildyti pagal kiekvienos klasės vidurkius, jei trūko reikšmingos duomenų dalies, buvo taikyta *k-nearest neighbors* (KNN) imputacija, kur trūkstamos reikšmės buvo apskaičiuojamos remiantis panašiausiais duomenų taškais. Duomenų rinkinys vėliau buvo padalintas į mokymo ir testavimo imtis: 80 % duomenų buvo naudota modelio mokymui, o likę 20 % – jo tikslumo testavimui. Siekiant užtikrinti modelio stabilumą, taikytas *K-fold* kryžminės patikros metodas: duomenys buvo suskirstyti į penkias dalis, o modelis buvo mokomas ir testuojamas pakaitomis su skirtingais duomenų rinkiniais. Modelio mokymo metu buvo naudojamas SVM algoritmas su radialinės bazės funkcijos (RBF) branduoliu, leidžiančiu efektyviai modeliuoti sudėtingus, nelineinius ryšius tarp finansinių rodiklių ir įmonės būsimos finansinės būklės (Gopi ir kt., 2020). Siekiant optimizuoti modelio veikimą, buvo koreguojami pagrindiniai hiperparametrai – *C*, reguliuojantis klaidų toleranciją, ir *gamma*, apibrėžiantis sprendimo ribos lankstumą. Po modelio apmokymo jis buvo išbandytas su testavimo rinkiniu, o galutinis prognozavimas atliktas 96 įmonėms, kurioms anksčiau buvo taikyti Altman Z ir Ohlson O modeliai.

Norint apskaičiuoti GBM modelį, finansiniai rodikliai buvo normalizuoti. Vis dėlto, skirtingai nei SVM, GBM algoritmas, nėra jautrus absoliučioms skalių reikšmėms, todėl dažniausiai taikoma *Min-Max* normalizacija vietoje *Z-score* standartizacijos (Lakshminarayanan ir Rojas, 2023). Ši normalizacija užtikrina, kad visi rodikliai būtų perkelti į intervalą $[0,1]$, kas padeda stabilizuoti modelio mokymosi procesą ir pagreitina optimizavimo algoritmus (Lakshminarayanan ir Rojas, 2023). Kadangi GBM modeliai gali būti jautrūs išskirtinėms reikšmėms, papildomai buvo taikytas duomenų ribojimas (angl. *winsorization*), siekiant sumažinti kraštinių reikšmių įtaką (Wang ir kt., 2022). Trūkstamų duomenų apdorojimas bei duomenų padalijimas į mokymo ir testavimo imtis buvo atliekamas identiška, kaip ir SVM modeliui. Pirmasis GBM sprendimų medis buvo sudarytas pagal pradines duomenų savybes, o kiekvienas vėlesnis mokėsi iš ankstesnių modelio klaidų. Siekiant užtikrinti modelio stabilumą ir išvengti peradaptavimo (*overfitting*), buvo taikytas *K-fold* kryžminės patikros metodas ($K = 5$) (Nti ir kt., 2021). Galiausiai, buvo optimizuotas sprendimų medžių skaičius pasitelkiant ankstyvo sustojimo metodą, leidžiantį nutraukti mokymą, kai rezultatai negerėja. Apmokytas GBM buvo pritaikytas toms pačioms 96 įmonėms, kurioms buvo sugeneruotos bankroto prognozės.

Paskutinis hibridinio modelio kūrimo etapas – visų keturių modelių rezultatų sujungimas. Tam buvo taikyta ansamblinė prognozavimo metodika, kur prognozės integruojamos taikant svorinius koeficientus, atspindinčius kiekvieno modelio indėlį į galutinį sprendimą (Hu ir Tang, 2023; Dasilas ir Rigani, 2024). Galutinis rezultatas – sudėtinis tikimybės įvertinimas, prognozuojantis įmonės bankroto tikimybę, pagrįstas visų keturių modelių prognozių deriniu.

Sukūrus hibridinį modelį, buvo atlikta jo verifikacija, siekiant įvertinti prognozavimo tikslumą ir patikimumą. Vertinimas buvo grindžiamas hibridinio modelio rezultatų palyginimu su atskirų modelių prognozavimo rodiklių reikšmėmis. Vienas pagrindinių vertinimo kriterijų – plotas po ROC kreive (AUC), rodantis modelio gebėjimą klasifikuoti bankrutuojančias ir veikiančias įmones. AUC reikšmė artima 1,0 indikuoja puikų klasifikatorių, kai 0,5 – atsitiktinę klasifikaciją, o mažesnės nei 0,5 reikšmės reiškia, kad modelis veikia blogiau, nei atsitiktinumas (Liu ir kt., 2023). Papildomai buvo vertinamas *F1* balas – apibendrinamasis rodiklis, atspindintis jautrumo ir preciziškumo pusiausvyrą, kuris ypač svarbus esant klasių disbalansui. Siekiant įvertinti prognozuojamų tikimybių atitikimą faktiniam bankroto dažniui, SVM ir GBM modeliams buvo sudarytos kalibravimo kreivės. Idealiu atveju šios kreivės turėtų sutapti su

įstrižąja linija, o nukrypimai nuo jos rodo sistemingą tikimybių pervertinimą ar nuvertinimą. Be to, buvo apskaičiuotas ir Brier rodiklis – prognozės tikslumo matas, kurio reikšmė svyruoja nuo 0 iki 1. Kuo reikšmė mažesnė, tuo tikslesnė yra modelio prognozė. Brier rodiklis yra ypač svarbus tais atvejais, kai prognozės naudojamos ne tik klasifikacijai, bet ir rizikos lygio vertinimui (Patel ir kt., 2024).

Pirmoji hipotezė (H1) buvo tikrinama taikant šiuos vertinimo rodiklius: tikslumas, jautrumas, specifiškumas, preciziškumas, F1 rodiklis, AUC, kalibravimo kreivės bei Brier rodiklis. Hipotezė laikoma pagrįsta, jei hibridinis modelis reikšmingai pagerina bent kelis pagrindinius vertinimo rodiklius – ypač AUC, F1 ar Brier rodiklius, lyginant su atskirai taikomais modeliais. Antroji hipotezė (H2) buvo tikrinama atliekant modelio papildomą mokymą, įtraukiant hipotezėje įvardintus makroekonominis rodiklius kaip papildomus nepriklausomus kintamuosius. Vėliau buvo lyginamas modelio veikimas su šiais veiksniais ir be jų, taikant tuos pačius vertinimo kriterijus: AUC, F1 ir Brier rodiklius, tikslumą ir kitus. Vertinant skirtingų modelio versijų rezultatus buvo stebima, ar įtraukus makroekonominis veiksniai padidėjo modelio prognozavimo tikslumas ir sumažėjo klaidų rodikliai. Tokia metodinė prieiga leidžia įvertinti makroekonominių kintamųjų pridėjamą vertę prognozei. Jei bent vienas iš pagrindinių rodiklių pagerėjo, hipotezė laikoma pagrįsta.

3. Bankroto prognozavimo modelių taikymas Lietuvos maitinimo paslaugų sektoriaus įmonėms

3.1 Statistinių ir mašininio mokymosi bankroto prognozavimo modelių taikymo rezultatai Lietuvos maitinimo paslaugų sektoriuje

Altman Z balo modelis buvo pritaikytas 96 įmonėms, trejų metų laikotarpiui (288 duomenų rinkiniai), Ohlson O balo modeliu tirtos 96 įmonės, dvejų metų laikotarpiui (skaičiuojant delta iš trejų metų duomenų galima buvo apskaičiuoti tik dvejų metų tikimybes), atraminių vektorių mašinos (SVM) ir gradiento didinimo mašinos (GBM) prognozavo 96 įmones, tačiau mokėsi iš 240 įmonių trejų metų duomenų.

2 lentelėje pateikti testuotų modelių veikimo rezultatai pagal pagrindinius vertinimo kriterijus: tikslumą, preciziškumą, jautrumą, F1 rodiklį, specifiškumą.

2 lentelė. Modelių veikimo rezultatų palyginimas

Modelis	Tikslumas (%)	Preciziškumas (%)	Jautrumas (%)	F1 rodiklis (%)	Specifiškumas (%)
Altman	70,1	67,7	77,1	72,1	63,2
Ohlson	75,5	72,1	83,3	77,3	67,7
SVM	70,49	67,88	77,78	72,49	63,19
SVM*	89,58	89,58	89,58	89,58	89,58
GBM	70,14	66,86	79,86	72,78	60,42
GBM*	91,67	93,48	89,58	91,49	93,75

*Į modelį įtraukus papildomus makroekonominis rodiklius.

Šaltinis: sudaryta autorių, remiantis tyrimo rezultatais

Kaip nurodyta 2 lentelėje, Altman Z balo modelio bendras prognozavimo tikslumas vertinamas kaip vidutinis – modelis teisingai klasifikavo 202 atvejus iš 288. Bankroto atpažinimo gebėjimas (jautrumas) siekia 77,1 % ir parodo, kad modelis gana tiksliai pažymi riziką turinčias įmones, t. y. didelė dalis modelio prognozuotų bankrotų iš tikrųjų įvyksta. Tuo tarpu bankroto identifikavimo patikimumas (preciziškumas) sudaro 67,7 % ir reiškia, kad apie du trečdalius modelio nurodytų rizikingų įmonių iš


tikrųjų bankrutuoja, tačiau trečdalis klasifikuojamos klaidingai. Modelio F1- rodiklis – subalansuotas jautrumo ir preciziškumo įvertis rodo pakankamą, bet ne optimalų modelio veikimą. Veikiančių įmonių atpažinimo tikslumas (specifiškumas) rodo modelio gebėjimą teisingai identifikuoti finansiškai stabilias įmones – 63,2 % modelio atveju rodo tendenciją priskirti bankroto riziką ir toms įmonėms, kurios realiai yra finansiškai stabilios (klaidingai teigiami atvejai). Taigi, Altman Z balo modelis, taikytas Lietuvos maitinimo paslaugų sektoriuje, pasižymėjo vidutiniu bendru tikslumu ir ribotu gebėjimu aiškiai atskirti bankrutuojančias įmones nuo veikiančių. Nors tam tikrais atvejais modelis gali gana tiksliai identifikuoti artėjančių bankrotą, jo rezultatai nėra pakankamai patikimi savarankiškam vertinimui. Analizuojant Z balo dinamiką, pastebėta aiški finansinės būklės blogėjimo tendencija: dveji metai iki bankroto rodikliai buvo nestabilūs, o bankroto metais fiksuotas reikšmingas nuosmukis, atspindintis augančią riziką. Todėl šis modelis gali būti naudingas tik kaip preliminarus rizikos vertinimo įrankis, tačiau jo išvados turėtų būti interpretuojamos atsargiai, derinant jas su papildomais analizės metodais bei platesniu kontekstu.

Ohlson O modelio bendras tikslumas buvo 5,4 procentinio punkto didesnis nei Altman Z balo modelio – iš 192 atvejų teisingai klasifikuoti 145. Todėl galima teigti, kad modelis geba pakankamai tiksliai prognozuoti įmonių bankrotą, nors vis dar neatitinka aukšto prognozavimo patikimumo kriterijų. Visi kiti šio modelio veikimo rodikliai taip pat buvo geresni nei Altman Z balo modelio 4–6 procentiniais punktais. Visgi 67,7 % specifiškumo reikšmė rodo nepakankamą gebėjimą atskirti stabilias įmones nuo rizikingų, o tai kelia riziką dėl klaidingų perspėjimų (angl. *false alarms*), galinčių lemti nepagrįstus finansinius ar vadybinius sprendimus. Dėl šios priežasties Ohlson O modelis gali būti naudingas kaip vienas iš bankroto rizikos vertinimo įrankių, tačiau derinant jį kartu su papildoma analize, siekiant išvengti neteisingų ar perteklinių sprendimų.

SVM ir GBM modeliai bankroto prognozavimo kontekste pasižymi vidutiniu efektyvumu ir, kiek netikėtai, demonstravo panašius arba netgi prastesnius prognozavimo rodiklius nei Altman Z balo ir Ohlson O modeliai (žr. 2 lentelę). Abiejų mašininio mokymosi modelių veikimo rezultatyvumo rodikliai yra panašūs, tačiau GBM pasižymėjo šiek tiek aukštesniu jautrumu (79,86 %), kuris yra vienas stipriausių šio modelio parametrų, patvirtina gerą rizikos atpažinimo gebėjimą ir leidžia manyti, kad modelis gali būti tinkamas taikymui situacijose, kuriose ypač svarbu nepraleisti realaus bankroto atvejo. Vis dėlto, GBM modelio specifiškumas buvo pats žemiausias tarp visų testuotų modelių ir siekia tik 60,42 %, o tai reiškia, kad modelis dažnai klaidingai priskiria stabilias įmones rizikingoms. Tokie rezultatai rodo konservatyvų klasifikavimo polinkį – modelis, siekdamas maksimaliai identifikuoti rizikas, linkęs perspėti net tada, kai grėsmė yra minimali. F1 rodiklis parodė, kad šie modeliai nėra nei pernelyg konservatyvūs, nei pernelyg rizikingi, visgi jų prognozės nėra optimalios.

Toliau 2 lentelėje matyti, kad gerokai aukštesnį veikimo rezultatyvumo lygį demonstravo mašininio mokymosi modeliai, papildyti Lietuvos makroekonominiais rodikliais: realiu BVP augimu, vidutine metine infliacija, nedarbo lygiu, vartotojų pasitikėjimo rodikliu ir vartotojų kainų pokyčiais, apskaičiuotais pagal vartotojų kainų indeksą (maisto ir nealkoholinių gėrimų kategorijos). SVM modelio su papildomais rodikliais (toliau – SVM*) tikslumas, preciziškumas, jautrumas, F-1 matuoklis ir specifiškumas yra 89,58 %, nes teisingai klasifikuota po 129 atvejus tiek tarp tikrųjų bankrotų (*true positives*), tiek tarp tikrųjų veikiančių įmonių (*true negatives*), o klaidingų prognozių (*false positives* ir *false negatives*) skaičius taip pat vienodas – po 15. Šie rezultatai rodo, kad modelis labai tolygiai apdoroja abi klases – tiek bankrutuojančias, tiek veikiančias įmones, ir nėra linkęs nei į perdėtą perspėjimų skaičių, nei į rizikų ignoravimą. Toks balansas klasifikavimo modeliuose pasitaiko retai, nes dažnai vienas rodiklis pagerinamas kito sąskaita, todėl toks rezultatas rodo aukštą modelio patikimumą praktiniam taikymui. GBM modelis su tais pačiais papildomais makroekonominiais rodikliais (toliau – GBM*) pasiekė dar geresnių rezultatų: tikslumas, preciziškumas, F1 rodiklis, specifiškumas dažnu atveju viršija 90 % ribą, o tai patvirtina GBM* modelio aukštą prognozavimo tikslumą ir gebėjimą subalansuotai klasifikuoti tiek rizikingas, tiek stabilias įmones.

Naudojant „Python“ buvo apskaičiuotos taikytų modelių be papildomų makroekonominių rodiklių ROC kreivės (žr. 1 paveikslą), parodančios modelių gebėjimą klasifikuoti bankrutuojančias ir veikiančias įmones. AUC reikšmė 1,0 reikštų tobulą modelį, o 0,5 – visiškai atsitiktines prognozes.




1 pav. Altman Z, Ohlson O, GBM ir SVM ROC kreivės

Šaltinis: sudaryta autorių, remiantis tyrimo rezultatais

Altman Z balo modelio ROC plotas po kreive (AUC) siekia 0,75, o tai rodo vidutinį modelio gebėjimą atskirti bankrutuojančias įmones nuo veikiančių. Nors modelio prognozavimo galia yra ribota, ji vis dėlto viršija atsitiktinio klasifikavimo lygį. Ohlson O modelio AUC reikšmė yra šiek tiek aukštesnė – 0,78, kas patvirtina šio modelio geresnį, tačiau vis dar ribotą prognozavimo tikslumą. Modelis veikia geriau nei atsitiktinis spėjimas, tačiau jo tikslumas nėra pakankamai aukštas, kad juo būtų galima remtis kaip vieninteliu bankroto prognozavimo įrankiu. Reikėtų atkreipti dėmesį į SVM modelio ROC kreivę, kuri tik minimaliai viršija atsitiktinio spėjimo liniją – AUC siekia vos 0,50. Tai rodo, kad modelio klasifikacinis tikslumas bankroto prognozavimo kontekste yra labai silpnas, todėl būtina tobulinti modelio architektūrą, pasirinkti alternatyvų algoritmą ar papildyti duomenis labiau informatyviais kintamaisiais. Tuo tarpu GBM modelis išlaiko aiškią atskirtį tarp dviejų klasių – didėjant klaidingų teigiamų atvejų skaičiui, tikrųjų teigiamų atvejų skaičius didėja pakankamai greitai, o tai rodo stabilų modelio jautrumą. GBM modelio ROC kreivė aiškiai viršija atsitiktinio klasifikavimo liniją, o tai liudija modelio gebėjimą teisingai identifikuoti rizikingas įmones. Dėl šių savybių GBM modelis laikytinas informatyviu ir tinkamu naudoti bankroto rizikos prognozės praktikoje.

Siekiant palyginti mašininio mokymosi modelių su ir be papildomų makroekonominių rodiklių rezultatus, 2 paveiksle pateikiamos šių modelių ROC kreivės.




2 pav. SVM ir GBM modelių be ir su papildomais makroekonominiais rodikliais ROC kreivės

Šaltinis: sudaryta autorių, remiantis tyrimo rezultatais

Kaip matyti 2 paveiksle, SVM* ROC kreivė tik šiek tiek viršija atsitiktinio spėjimo liniją, o jos forma rodo ribotą modelio gebėjimą atskirti klases. AUC reikšmė siekia vos 0,58 – tai tik šiek tiek aukštesnė vertė nei atsitiktinis klasifikavimas. Netikėta tai, kad netgi SVM modelis rodo geresnį rezultatą nei SVM* – tai reiškia, kad modelio diskriminacinė galia yra gana silpna. Tuo tarpu GBM* modelio ROC kreivė parodo išskirtinai gerą modelio gebėjimą atskirti klases. AUC reikšmė siekia net 0,97 – modelis beveik idealiai skiria bankrutuojančias ir veikiančias įmones ir tokia AUC reikšmė gerokai viršija aukštos kokybės ribą 0,8 ir ženkliai viršija visų kitų testuotų modelių AUC reikšmes. Modelio klasifikacinė galia išlieka stipri visame sprendimo slenksčių diapazone.

Siekiant įvertinti prognozuojamų tikimybių atitikimą faktiniam bankroto dažniui SVM, SVM*, GBM ir GBM* modeliams buvo sudarytos kalibravimo kreivės ir apskaičiuotas Brier rodiklis – prognozės tikslumo matas (žr. 3 pav.).



3 pav. SVM ir GBM modelių be ir su papildomais rodikliais kalibravimo kreivės

Šaltinis: sudaryta autorių, remiantis tyrimo rezultatais

SVM modelio kalibravimo kreivės rezultatai rodo, kad modelio prognozuotos tikimybės tik iš dalies atitinka realų įvykių dažnį, ką patvirtina ir Brier rodiklio reikšmė 0,27, kuri šiuo atveju laikoma gana aukšta. Kadangi Brier rodiklis matuoja vidutinį kvadratinį skirtumą tarp prognozuotų tikimybių ir faktinių rezultatų, šis rezultatas rodo vidutinį prognozės patikimumą, o ne aukštą preciziškumą. 3 paveiksle parodytoje GBM kalibravimo kreivėje dauguma taškų išsidėstę netoli idealiosios linijos, ypač intervale tarp 0,4 ir 0,8. Kalibracijos kokybę patvirtina ir gera Brier rodiklio reikšmė 0,194, t. y. modelis ne tik gana gerai atpažįsta klasifikacijas, bet ir pakankamai tiksliai įvertina jų tikimybinus pagrindus. SVM* modelio kalibravimo kreivė signalizuoja apie jo nepatikimumą, jo Brier rodiklio reikšmė yra prasčiausia ir beveik dvigubai viršija leidžiamą ribą – modelio pateiktomis tikimybėmis remtis negalima. GBM* modelio patikimumą kalibravimo kreivė tik dar labiau sustiprina: kreivė beveik idealiai seka tobulai kalibruoto modelio liniją – modelio pateiktos tikimybės puikiai atitinka realų bankroto dažnį, ką patvirtina ir žemas Brier rodiklis. Nors šis rodiklis nėra tobulas ($0,06 > 0,05$), jis visgi rodo aukštą vidutinį tikimybės atitikimą realiems rezultatams, o tai itin svarbu priimant sprendimus.

Apibendrinant galima teigti, kad nors SVM modelis su papildomais makroekonominiais rodikliais pasižymėjo aukštu bendru klasifikavimo tikslumu, jo kalibravimo kreivė atskleidžia, kad prognozuotos tikimybės dažnai neatitinka realių rezultatų. Modelis nėra tinkamas naudoti ten, kur svarbu tikslus rizikos vertinimas procentine išraiška – pavyzdžiui, priimant sprendimus dėl finansavimo, draudimo ar investicijų. Visiškai kitokie rezultatai gauti naudojant GBM su papildomais makroekonominiais rodikliais, kuris pasiekė itin aukštus rezultatus visose vertinimo srityse. Jis išsiskiria tiek klasifikavimo tikslumu (91,67 %), tiek balansu tarp klaidingų sprendimų (aukštas F1), tiek aukšta diskriminacine galia (AUC = 0,97), tiek ir gana tiksliai kalibruotomis prognozėmis (Brier = 0,06). Toks modelis laikytinas itin tinkamu praktiniam taikymui, kai sprendimai grindžiami tikimybiniais rizikos vertinimais.

3.2. Hibridinis bankroto prognozavimo modelis ir jo rezultatai

Tyrimo rezultatai parodė, kad skirtingi modeliai pasižymi nevienodu tikslumu, todėl jų indėlis į galutinį hibridinį prognozavimo modelį turi būti diferencijuotas. Hibridinio modelio prognozė apskaičiuota kaip svertinė kiekvieno modelio prognozių suma. Siekiant įvertinti kiekvieno modelio svorį, buvo taikoma normalizacija – kiekvieno modelio tikslumas, nurodytas 2 lentelėje, padalintas iš visų modelių (be papildomų makroekonominių rodiklių) tikslumų bendros sumos. Tokiu būdu gauta hibridinio modelio (HM) formulė:

$$HM = 0,2449 \times P_{Altman} + 0,2638 \times P_{Ohlson} + 0,2462 \times P_{SVM} + 0,2450 \times P_{GBM} \quad (1)$$


Ansamblinis metodas leido sudaryti hibridinį modelį, kuriame kiekvieno metodo indėlis nustatomas pagal jo prognozavimo tikslumą, todėl Ohlson O modelio lyginamasis svoris didžiausias. Metodas leidžia išnaudoti stipriausių modelių pranašumus, kartu sumažinant silpnusių modelių įtaką galutinei prognozei.

Modelio veikimo rodikliai patvirtina patikimą, tačiau ne aukščiausią prognozavimo tikslumą: bendras tikslumas siekė 70,49 %, preciziškumas – 68,32 %, jautrumas – 76,39 %, F1 rodiklis – 72,13 %, o specifiškumas – 64,58 %. Šie rezultatai rodo, kad modelis yra pakankamai subalansuotas, tačiau linkęs kiek pervertinti riziką finansiškai stabilių įmonių atžvilgiu, t. y. iš esmės paveldi vidutinius atskirų komponentinių modelių bruožus. Iš 288 atvejų, neteisingai priskirti buvo 85 (34 klaidingai neigiamų, 51 klaidingai teigiamų), o teisingai – 203 (110 teigiamų teisingų, 93 neigiamų teisingų).

Taip pat buvo suformuotas hibridinis prognozavimo modelis, kuriam pritaikyti ne tik finansiniai, bet ir papildomi makroekonominiai rodikliai. Naudotas tas pats ansamblinis metodas kaip ir HM modelio konstravime, tačiau atskirų modelių svoriai buvo perskaičiuoti naudojant modelių su makroekonominiais rodikliais tikslumo reikšmes. Gauta tokia hibridinio modelio, kuris buvo papildytas makroekonominiais rodikliais (HMR), formulė:

$$HMR = 0,2145 \times P_{Altman} + 0,2310 \times P_{Ohlson} + 0,2741 \times P_{SVM*} + 0,2805 \times P_{GBM*} \quad (2)$$

Šis modelis taip pat buvo testuojamas naudojant 96 Lietuvos maitinimo paslaugų sektoriaus įmonių finansinių ataskaitų duomenis – viso 288 metinius duomenų rinkinius. Gauti modelio rezultatai parodė itin aukštą klasifikavimo kokybę. Bendras modelio tikslumas siekė 93,06 %, preciziškumas – 92,47 %, jautrumas – 93,75 %, F1 rodiklis – 93,10 %, o specifiškumas – 92,36 %. Tokie rezultatai atspindi labai gerą balansą tarp gebėjimo identifikuoti bankrutuojančias įmones ir išvengti klaidingų pavojaus signalų veikiančioms įmonėms. Iš 288 prognozuotų atvejų net 268 buvo įvertinti teisingai, o klaidingų priskyrimų buvo tik 20 (11 atvejų, kai veikiančios įmonės priskirtos rizikingoms, ir 9 atvejai – priešingai).



4 pav. Hibridinio modelio su ir be papildomų makroekonominių rodiklių ROC kreivės

Šaltinis: sudaryta autorių, remiantis tyrimo rezultatais

HMR modelis išsiskyrė ir ROC kreivės rezultatu. Kaip matyti 4 paveiksle, AUC reikšmė siekė 0,972, kas rodo beveik idealų modelio gebėjimą atskirti bankrutuojančias įmones nuo stabiliai veikiančių. Šis rezultatas reikšmingai viršija tiek visų individualių modelių, tiek bazinio hibridinio modelio (HM) AUC reikšmes.

Galima teigti, kad hibridinis modelis HM, pagrįstas Altman, Ohlson, SVM ir GBM modelių prognozėmis, pasiekė geriausią rezultatą tarp visų modelių, nenaudojančių papildomų kintamųjų. Jis užtikrino gerą jautrumo ir preciziškumo balansą ($F1 = 72,13\%$) bei stiprią diskriminacinę galią ($AUC = 0,802$). Nors šis modelis pasižymėjo efektyviu klasių atskyrimu, jo prognozių patikimumas išliko vidutinis, todėl šio modelio praktinis taikymas turi būti vertinamas atsargiai – ypač situacijose, kai itin svarbi prognozės kokybė, ne vien klasifikacija. Tuo tarpu hibridinis modelis su papildomais makroekonominiais rodikliais HMR išsiskyrė aukšta prognozavimo kokybe. Aukštos tikslumo, jautrumo, preciziškumo ir F1 reikšmės rodo subalansuotą modelio veikimą, o AUC reikšmė patvirtina, labai stiprią diskriminacinę galią. Lyginant su HM modeliu, pastebimas reikšmingas pagerėjimas visais vertinimo aspektais. Tai leidžia teigti, kad makroekonominių veiksnių įtraukimas ne tik pagerino modelio veikimą, bet ir buvo esminis veiksnys, padidinęs prognozės tikslumą ir patikimumą. Šis modelis laikytinas pažangiausia bankroto prognozavimo priemone, taikytina Lietuvos maitinimo paslaugų sektoriaus įmonėms.

Lyginant visų modelių veikimą pagal atskirus vertinimo rodiklius, akivaizdu, kad pagal bendrą klasifikavimo tikslumą geriausius rezultatus pasiekė hibridinis modelis su papildomais makroekonominiais rodikliais HMR. Šis modelis pranoko tiek klasikinius statistinius, tiek bazinius

mašininio mokymosi modelius, o tai leidžia teigti, kad makroekonominių veiksnių įtraukimas reikšmingai pagerino bendrą klasifikavimo kokybę. Aukštas HMR tikslumas glaudžiai susijęs su tuo, kad itin gerus rezultatus pademonstravo ir SVM* bei GBM* modeliai, kuriuose taip pat buvo integruoti makroekonominiai rodikliai. Vertinant modelių gebėjimą atpažinti bankrutuojančias įmones, geriausiai pasirodė tie patys modeliai, kuriuose naudoti papildomi makroekonominiai duomenys – HMR* (93,75 %), GBM* (89,58 %) ir SVM* (89,58 %).

Tai patvirtina, kad papildomų makroekonominių duomenų įtraukimas ženkliai padidina modelių jautrumą – gebėjimą atskirti rizikingas įmones. Skirtingų modelių preciziškumo, F1 rodiklio, specifiškumo, AUC ir Brier rodiklių lyginamoji analizė patvirtino makroekonominių kintamųjų vertę: jų įtraukimas ne tik pagerino rizikos atpažinimą, bet ir sumažino klaidingų teigiamų prognozių (angl. *false positives*) kiekį, užtikrino subalansuotą klasifikaciją abejose klasėse, efektyviai sumažino klaidingų perspėjimų (angl. *false alarms*) dažnį, padidino modelių diskriminacinį pajėgumą bei gebėjimą generuoti interpretuojamas ir statistiškai patikimas prognozės tikimybes. Nors GBM* pasiekė aukštus rezultatus, tačiau pažangiausių sprendimų laikytinas hibridinis modelis su papildomais rodikliais (HMR), kuris sistemingai pirmavo visose modelio veikimo vertinimo kategorijose. Toks rezultatyvumo rodiklių derinys leidžia patvirtinti abi tyrime keltas hipotezes – tiek dėl hibridinio modelio pranašumo, tiek dėl makroekonominių veiksnių teigiamos įtakos prognozės tikslumui.

Tyrimo apribojimai

Nemaža dalis tirtų mažų įmonių teikė sutrumpintas finansines ataskaitas, o tai apribojo galimybę įtraukti platesnį ir išsamesnį finansinių rodiklių spektrą, galėjusį padidinti modelių prognozavimo tikslumą. Be to, dalis Lietuvos mažų įmonių nėra teisiškai įpareigosotos atlikti finansinių ataskaitų auditą, todėl gali kilti abejonių dėl pateikiamos finansinės informacijos patikimumo. Tyrime buvo vertinami keli pagrindiniai modelių veikimo rodikliai – tikslumas, jautrumas, specifiškumas, F1 rodiklis, preciziškumas, tačiau tam tikri aspektai, kaip antai modelių stabilumas skirtinguose duomenų pogrupiuose ar jautrumas ekstremalioms reikšmėms, analizuoti nebuvo.

Išvados

1. Tradiciniai statistiniai bankroto prognozavimo modeliai išlieka plačiai naudojami dėl jų paprasto taikymo, nors prognozavimo tikslumas gali skirtis priklausomai nuo sektoriaus ypatumų ir analizės laikotarpio. Mokslinės literatūros analizė parodė, kad mašininio mokymosi modeliai, tokie kaip antai sprendimų medžiai, SVM, neuroniniai tinklai ir GBM pasižymi aukštu tikslumu dėl gebėjimo apdoroti didelius duomenų kiekius ir aptikti nelineinius ryšius, o hibridiniai modeliai, kaip antai *Logit Model Trees*, *AdaBoost*, SVM su genetiniu algoritmu ir hibridiniai neuroniniai tinklai dar labiau pagerina prognozavimo rezultatus, nes sujungia statistinių ir mašininio mokymosi metodų privalumus. Maitinimo paslaugų sektoriuje, kuris yra itin dinamiškas ir jautrus ekonominiams pokyčiams, tradiciniai statistiniai modeliai dažnai nesugeba tinkamai atspindėti sektoriaus sudėtingumo, todėl tikslesnį prognozavimą demonstruoja mašininio mokymosi ar hibridiniai modeliai, ypač kai įtraukiami nefinansiniai duomenys, kaip klientų atsiliepimai ir socialinių tinklų nuotaikos.

2. Pritaikius du tradicinius statistinius bankroto prognozavimo modelius – Altman ir Ohlson, taip pat du mašininio mokymosi modelius – SVM ir GBM, reprezentatyviai Lietuvos maitinimo paslaugų įmonių imčiai (2021–2023 metų finansiniai duomenys), nustatyta, kad nei vienas iš tradicinių modelių nesugebėjo užtikrinti pakankamo klasifikavimo tikslumo ir diskriminacinės galios, ypač atskiriant stabilias įmones nuo rizikingų. Tačiau ir baziniai SVM ir GBM modeliai neparodė geresnių rezultatų ir tam tikrais aspektais veikė net prasčiau nei statistiniai modeliai – jų specifiškumas buvo žemas, o prognozuojamų tikimybių patikimumas ribotas, kas riboja jų praktinį taikymą. Į SVM ir GBM modelius įtraukus makroekonominius rodiklius – BVP augimą, vidutinę metinę infliaciją, nedarbo lygį, vartotojų pasitikėjimo rodiklį, vartotojų kainų (maisto ir nealkoholinių gėrimų) pokytį, abiejų modelių prognozavimo tikslumas ženkliai pagerėjo, ypač modelių jautrumo, preciziškumo, tikslumo atžvilgiu. Vis dėlto tik GBM* modelis su papildomais rodikliais sugebėjo generuoti ir kokybiškai sukalibruotas prognozes, tinkamas

sprendimų priėmimui, tuo tarpu SVM* modelio su papildomais rodikliais kalibracija liko netiksli, parodydama skirtumą tarp klasifikavimo tikslumo ir tikėtinos rizikos pagrįstumo.

3. Integravus testuotų Altman, Ohlson, SVM, GBM modelių prognozes ir pritaikius papildomus makroekonominis rodiklius, buvo suformuotas išplėstinis hibridinis modelis HMR, kuris užtikrino ne tik aukščiausią klasifikavimo tikslumą, bet ir pusiausvyrą tarp visų vertinimo kriterijų – jautrumo, preciziškumo bei specifiškumo. Dėl gebėjimo tiksliai identifikuoti rizikingus atvejus ir generuoti interpretuojamas tikimybes, šis modelis laikytinas tinkamiausiu naudoti praktiniuose bankroto rizikos valdymo sprendimuose Lietuvos maitinimo paslaugų sektoriuje. O tradicinius bankroto prognozavimo modelius (geriausia – Ohlson) rekomenduojama taikyti tik preliminariam rizikos vertinimui, kai turimi duomenys yra riboti ar sprendimų priėmimui nereikalingas aukštas tikslumo lygis. Tokie modeliai gali būti ypač naudingi kaip pirmosios rizikos identifikavimo priemonės mažoms įmonėms, o detalesnei rizikos analizei ir sprendimų priėmimui tikslinga taikyti HMR hibridinį modelį.

4. Tolesniuose tyrimuose siūloma išplėsti šio modelio taikymo sritį kitų ekonomikos sektorių įmonėms, siekiant įvertinti modelio universalumą, taip pat analizuoti ilgalaikį sukurto modelio veikimo stabilumą skirtinguose ekonominio ciklo etapuose. Tai leistų geriau suprasti modelio atsparumą kintančiomis ekonominėmis sąlygomis bei užtikrinti aktualumą dinamiškoje verslo aplinkoje. Siekiant tolesnio modelio tobulinimo, galima būtų įtraukti ne tik finansinius ir makroekonominis rodiklius, bet taip pat papildomus kokybinius kintamuosius, tokius kaip reputacijos indeksai, vadovų kaitos duomenys ar klientų nuomonių analizė.

Autorių indėlis

Miglė Martusevičiūtė: duomenų tvarkymas, formalioji analizė, tyrimo vykdymas, metodologija, programinė įranga, vizualizavimas, pirminio projekto rašymas. **Ramunė Budrionytė:** konceptualizavimas, metodologija, tyrimo vykdymas, priežiūra, straipsnio peržiūra ir redagavimas.

Literatūra

Aigbedo H. (2021) Impact of COVID-19 on the hospitality industry: A supply chain resilience perspective. *International Journal of Hospitality Management*, 98, 103012. <https://doi.org/10.1016/j.ijhm.2021.103012>

Ainan, U. H. ir Nur-E-Arefin, M. (2022). Prediction of bank performance using machine learning and genetic algorithm hybrid models. *2022 International Conference on Advancement in Electrical and Electronic Engineering (ICAEEE)*, Gazipur, Bangladesh, 1–6. <https://doi.org/10.1109/ICAEEE54957.2022.9836440>

Akosa, J. S. (2017). Predictive accuracy: A misleading performance measure for highly imbalanced data classified negative. *SAS Global Forum*, 1–12. Prieiga per <http://support.sas.com/resources/papers/proceedings17/0942-2017.pdf>

Alam, T. M., Shaukat, K., Mushtaq, M., Ali, Y., Khushi, M., Luo, S. ir Wahab, A. (2021). Corporate bankruptcy prediction: An approach towards better corporate world. *The Computer Journal*, 64(11), 1731–1746. <https://doi.org/10.1093/comjnl/bxaa056>

Aleskerova, Y. ir Fedoryshyna, L. (2023). Financial mechanism in the system of economic vectors of development of hotel and restaurant and agricultural enterprises. *Baltic Journal of Economic Studies*, 9(4), 19–30. <https://doi.org/10.30525/2256-0742/2023-9-4-19-30>

Altman, E. I. (1968). Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. *The Journal of Finance*, 23(4), 589–609. <https://doi.org/10.1111/j.1540-6261.1968.tb00843.x>

Bateni, L. ir Asghari, F. (2020). Bankruptcy prediction using logit and genetic algorithm models: A comparative analysis. *Computational Economics*, 55, 335–348. <https://doi.org/10.1007/s10614-016-9590-3>

Becerra-Vicario, R., Alaminos, D., Aranda, E. ir Fernández-Gámez, M. A. (2020). Deep recurrent convolutional neural network for bankruptcy prediction: A case of the restaurant industry. *Sustainability*, 12(12), 5180. <https://doi.org/10.3390/su12125180>

- Bogdan, S. (2021). Predviđanje stečaja u restoranskoj industriji Hrvatske. *Ekonomski misao I praksa*, 30(1), 99–119. <https://doi.org/10.17818/EMIP/2021/1.5>
- Chou, T. N. (2019). An explainable hybrid model for bankruptcy prediction based on the decision tree and deep neural network. *2019 IEEE 2nd International Conference on Knowledge Innovation and Invention (ICKII)*, Seoul, Korea, 122–125. <https://doi.org/10.1109/ICKII46306.2019.9042639>
- Cialone, G. (2020). *Bankruptcy Prediction Using Machine Learning Methods*. Stanford University. Prieiga per https://cs230.stanford.edu/projects_winter_2020/reports/32569269.pdf
- Dasilas, A. ir Rigani, A. (2024). Machine learning techniques in bankruptcy prediction: A systematic literature review. *Expert Systems with Applications*, 255(C), 124761. <https://doi.org/10.1016/j.eswa.2024.124761>
- du Jardin, P. (2021). Forecasting bankruptcy using biclustering and neural network-based ensembles. *Annals of Operational Research*, 299, 531–566. <https://doi.org/10.1007/s10479-019-03283-2>
- Gaurav, A., Gupta, B., Bansal, S. ir Psannis, K. E. (2025). Bankruptcy forecasting in enterprises and its security using hybrid deep learning models. *Cyber Security and Applications*, 3, 100070. <https://doi.org/10.1016/j.csa.2024.100070>
- Gavurova, B., Jencova, S., Bacik, R., Miskufova, M. ir Letkovsky, S. (2022). Artificial intelligence in predicting the bankruptcy of non-financial corporations. *Oeconomia Copernicana*, 13(4), 1215–1251. <https://doi.org/10.24136/oc.2022.035>
- Gopi, A. P., Jyothi, R. N. S., Narayana, V. L. ir Sandeep, K. S. (2020). Classification of tweets data based on polarity using improved RBF kernel of SVM. *International Journal of Information Technology*, 15(2), 965–980. <https://doi.org/10.1007/s41870-019-00409-4>
- Hamrick, K. ir Okrent, A. (2014). *The Role of Time in Fast-Food Purchasing Behavior in the United States*. Department of Agriculture, Economic Research Service. ERR-178. Prieiga per <https://www.ers.usda.gov/publications/pub-details?pubid=45302>
- Horak, J., Vrbka, J. ir Suler, P. (2020). Support vector machine methods and artificial neural networks used for the development of bankruptcy prediction models and their comparison. *Journal of Risk and Financial Management*, 13(3), 60. <https://doi.org/10.3390/jrfm13030060>
- Horváthová, J., Mokrišová, M. ir Bača, M. (2023). Bankruptcy prediction for sustainability of businesses: The application of graph theoretical modeling. *Mathematics*, 11, 4966. <https://doi.org/10.3390/math11244966>
- Hossain, T., Ferdous, E. H., Bahadur, A. K. M., Masum, A., Yas ir Arafat, A. (2022). Data mining for predicting and finding factors of bankruptcy. *2022 International Conference on Innovations in Science, Engineering and Technology (ICISSET)*, Chittagong, Bangladesh, 504–509. <https://doi.org/10.1109/ICISSET54810.2022.9775887>
- Hu, G. ir Tang, Y. (2023). A geographically weighted stacking ensemble learning-based urban residential rents prediction model. *Mathematics*, 11, 3160. <https://doi.org/10.3390/math11143160>
- Huo, Y., Chan, L. H. ir Miller, D. (2024). Bankruptcy prediction for restaurant firms: A comparative analysis of multiple discriminant analysis and logistic regression. *Journal of Risk and Financial Management*, 17(9), 399. <https://doi.org/10.3390/jrfm17090399>
- Yost, E., Ridderstaat, J. ir Kizildag, M. (2020). Early warning indicators? The effect of consumer and investor sentiments on the restaurant industry. *International Journal of Hospitality Management*, 89, 102575. <https://doi.org/10.1016/j.ijhm.2020.102575>
- Jones, S. (2017). Corporate bankruptcy prediction: A high dimensional analysis. *Review of Accounting Studies*, 22, 1366–1422. <https://doi.org/10.1007/s11142-017-9407-1>
- Kanapickienė, R., Kanapickas, T. ir Nečiūnas, A. (2023). Bankruptcy for micro and small enterprises using financial, non-financial, business sector and macroeconomic variables: The case of the Lithuanian construction sector. *Risks*, 11(5), 97. <https://doi.org/10.3390/risks11050097>
- Kaufman, M. S., Avery, J. J. ir Goldberg, L. G. (2020). *Restaurant Revolution: How the Industry is Fighting to Stay Alive*. Harvard Business School. Prieiga per <https://www.library.hbs.edu/working-knowledge/restaurant-revolution-how-the-industry-is-fighting-to-stay-alive>

- Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye, Q., Liu, Z., Wang, W., Chen, Z. ir Liu, T. Y. (2017). LightGBM: A highly efficient gradient boosting decision tree. *Advances in Neural Information Processing Systems*, 30, 3146–3154. https://papers.nips.cc/paper_files/paper/2017/hash/6449f44a102fde848669bdd9eb6b76fa-Abstract.html
- Kim, H., Cho, H. ir Ryu, D. (2022) Corporate bankruptcy prediction using machine learning methodologies with a focus on sequential data. *Computational Economics*, 59, 1231–1249. <https://doi.org/10.1007/s10614-021-10126-5>
- Kim, S. Y. (2018). Predicting hospitality financial distress with ensemble models: The case of US hotels, restaurants, and amusement and recreation. *Service Business*, 12(3), 483–503. <https://doi.org/10.1007/s11628-018-0365-x>
- Kim, S. Y. ir Upneja, A. (2014) Predicting restaurant financial distress using decision tree and AdaBoosted decision tree models. *Economic Modelling*, 36, 354–362. <https://doi.org/10.1016/j.econmod.2013.10.005>
- Kim, S. Y. ir Upneja, A. (2021). Majority voting ensemble with decision trees for business failure prediction during economic downturns. *Journal of Innovation & Knowledge*, 6(2), 112–123. <https://doi.org/10.1016/j.jik.2021.01.001>.
- Kizildag, M., Ozdemir, O., Dogru, T., Demirer, I. ir Gultek, M. (2024). Macroeconomic conditions, cash holdings, and financial constraints in restaurant firms. *Tourism Economics*. <https://doi.org/10.1177/13548166241306473>
- Kundu, S. ir Ari, S. (2017). Score normalization of ensemble SVMs for brain-computer interface P300 speller. *8th International Conference on Computing, Communication and Networking Technologies (ICCCNT)*, Delhi, India, 1–5. <https://doi.org/10.1109/ICCCNT.2017.8204119>
- Lakshminarayanan, B. ir Rojas, C. R. (2023). Minimax two-stage gradient boosting for parameter estimation. *62nd IEEE Conference on Decision and Control (CDC)*, Singapore, Singapore, 1189–1194. <https://doi.org/10.1109/CDC49753.2023.10383385>
- Li, H., Zhou, A., Zheng, K., Xu, J. ir Zhang, J. (2025). Restaurant survival prediction using machine learning: Do the variance and sources of customers' online reviews matter? *Tourism Management*, 107, 105038. <https://doi.org/10.1016/j.tourman.2024.105038>
- Lisin, A., Kushnir, A., Koryakov, A. G., Fomenko, N. ir Shchukina, T. (2022). Financial stability in companies with high ESG scores: Evidence from North America using the Ohlson O-Score. *Sustainability*, 14, 479. <https://doi.org/10.3390/su14010479>
- Liu, Y., Li, Y. ir Xie, D. (2023). Implications of imbalanced datasets for empirical ROC-AUC estimation in binary classification tasks. *Journal of Statistical Computation and Simulation*, 94(1), 183–203. <https://doi.org/10.1080/00949655.2023.2238235>
- Lokanan, M. E. ir Ramzan, S. (2024). Predicting financial distress in TSX-listed firms using machine learning algorithms. *Frontiers in Artificial Intelligence*, 7, 1466321. <https://doi.org/10.3389/frai.2024.1466321>
- Marsenne, M., Ismail, T., Taqi, M. ir Hanifah, I. A. (2024). Financial distress predictions with Altman, Springate, Zmijewski, Taffler and Grover models. *Decision Science Letters*, 13(1), 181–190. <https://doi.org/10.5267/j.dsl.2023.10.002>
- Marso, S. ir EL Merouani, M. (2020). Bankruptcy prediction using hybrid neural networks with artificial bee colony. *Engineering Letters*, 28(4), EL_28_4_26. Prieiga per https://www.engineeringletters.com/issues_v28/issue_4/EL_28_4_26.pdf
- Máté, D., Raza, H. ir Ahmad, I. (2023). Comparative analysis of machine learning models for bankruptcy prediction in the context of Pakistani companies. *Risks*, 11, 176. <https://doi.org/10.3390/risks11100176>
- Miljak, T., Perman, L. ir Lozić, I. (2022). The impact of inflation on restaurant prices in Croatia in the tourist season 2022. *81st International Scientific Conference on Economic and Social Development – „Green Economy & Sustainable Development“*, 61–68. Prieiga per https://www.researchgate.net/publication/367656175_The_impact_of_inflation_on_restaurant_prices_in_Croatia_in_the_tourist_season_2022
- Narvekar, A. ir Guha, D. (2021). Bankruptcy prediction using machine learning and an application to the case of the COVID-19 recession. *Data Science in Finance and Economics*, 1(2), 180–195. <https://doi.org/10.3934/DSFE.2021010>

- Nti, I. K., Nyarko-Boateng, O. ir Aning, J. (2021). Performance of machine learning algorithms with different k values in k-fold cross-validation. *International Journal of Information Technology and Computer Science*, 13(6), 61–71. <https://doi.org/10.5815/ijitcs.2021.06.05>
- Nurmanditya, M. I., Risnanto, S., Gunawan, T., Wiharko, T., Sukmana, R. N., Pudjoatmodjo, B. ir Plojović, Š. (2023). MySSOF: Gamification reward system for enhancing employee participation and activeness in organizational activities. *TEM Journal*, 12(4), 2339–2349. <https://doi.org/10.18421/TEM124-46>
- Ohlson, J. A. (1980). Financial ratios and the probabilistic prediction of bankruptcy. *Journal of Accounting Research*, 18(1), 109–131. <https://doi.org/10.2307/2490395>
- Ozupek, O., Yilmaz, R., Ghasemkhani, B., Birant, D. ir Kut, R. A. (2024). A Novel Hybrid Model (EMD-TI-LSTM) for enhanced financial forecasting with machine learning. *Mathematics*, 12(17), 2794. <https://doi.org/10.3390/math12172794>
- Papíková, L. ir Papík, M. (2022). Effects of classification, feature selection, and resampling methods on bankruptcy prediction of small and medium-sized enterprises. *Intelligent Systems in Accounting, Finance and Management*, 29(4), 254–281. <https://doi.org/10.1002/isaf.1521>
- Park, M. S., Son, H., Hyun, C. ir Hwang, H. J. (2021). Explainability of machine learning models for bankruptcy prediction. *IEEE Access*, 9, 124887–124899. <https://doi.org/10.1109/ACCESS.2021.3110270>
- Park, S. S. ir Hancer, M. (2012). A comparative study of logit and artificial neural networks in predicting bankruptcy in the hospitality industry. *Tourism Economics*, 18(2), 311–338. <https://doi.org/10.5367/te.2012.0113>
- Parsa, H. G., Kreeger, J. C., van der Rest, J. P., Xie, L. “Karen” ir Lamb, J. (2019). Why restaurants fail? Part V: Role of economic factors, risk, density, location, cuisine, health code violations and GIS factors. *International Journal of Hospitality & Tourism Administration*, 22(2), 142–167. <https://doi.org/10.1080/15256480.2019.1598908>
- Parsa, H. G., van der Rest, J. P. I., Smith, S. R., Parsa, R. A. ir Bujisic, M. (2014). Why restaurants fail? Part IV: The relationship between restaurant failures and demographic factors. *Cornell Hospitality Quarterly*, 56(1), 80–90. <https://doi.org/10.1177/1938965514551959>
- Patel, A. R., Dhingra, A. ir Liggesmeyer, P. (2024). Leveraging the Brier score to enhance predictive accuracy in learning-based risk assessment. *8th International Conference on System Reliability and Safety (ICSRS)*, 418–425. IEEE. <https://doi.org/10.1109/ICSRS63046.2024.10927572>
- Patel, R. (2022). Estimate US restaurant firm failure: The artificial neural system model versus logistic regression model. *International Journal of Innovative Research in Computer Science & Technology*, 10(3), 1–5. Prieiga per <https://journals.acspublisher.com/index.php/ijircst/article/view/10414>
- Podhorska, I., Vrbka, J., Lazaroiu, G. ir Kovacova, M. (2020). Innovations in financial management: Recursive prediction model based on decision trees. *Marketing and Management of Innovations*, 3, 276–292. <https://doi.org/10.21272/mmi.2020.3-20>
- Rak-amnouykit, I., Milanova, A., Baudart, G., Hirzel, M. ir Dolby, J. (2022). The raise of machine learning hyperparameter constraints in Python code. *Proceedings of the 31st ACM SIGSOFT International Symposium on Software Testing and Analysis (ISSTA '22)*, 18–22. <https://doi.org/10.1145/3533767.3534400>
- Registru centras (n. d.). *Įmonių finansinių duomenų bazė*. Prieiga per <https://www.registrucentras.lt> [žiūrėta 2024-12-01]
- Syed Nor, S. H., Ismail, S. ir Yap, B. W. (2019). Personal bankruptcy prediction using a decision tree model. *Journal of Economics, Finance and Administrative Science*, 24(47), 157–170. <https://doi.org/10.1108/JEFAS-08-2018-0076>
- Soukal, I., Mačí, J., Trnková, G., Svobodova, L., Hedvičáková, M., Hamplova, E., Maresova, P. ir Lefley, P. (2022). A state-of-the-art appraisal of bankruptcy prediction models focussing on the field's core authors: 2010–2022. *Central European Management Journal*, 32(1), 3–30. <https://doi.org/10.1108/CEMJ-08-2022-0095>
- Tsai, P., Gao, C. ir Yuan, S. (2023). Stock selection using machine learning based on financial ratios. *Mathematics*, 11, 4758. <https://doi.org/10.3390/math11234758>
- Vapnik, V. (2000). *The Nature of Statistical Learning Theory*. Springer. <https://doi.org/10.1007/978-1-4757-3264-1>

Wang, N., Xu, Y. ir Wang, S. (2022). Interpretable boosting tree ensemble method for multisource building fire loss prediction. *Reliability Engineering & System Safety*, 225, 108587. <https://doi.org/10.1016/j.ress.2022.108587>

Miglė Martusevičiūtė: Vilniaus universiteto, Ekonomikos ir verslo administravimo fakulteto magistrė. Moksliniai interesai: apskaita, finansų analizė, bankroto prognozavimo modeliai.

Miglė Martusevičiūtė: Master's degree from Vilnius University, Faculty of Economics and Business Administration. Scientific interests include accounting, financial analysis, and bankruptcy prediction models.

Ramunė Budrionytė: Vilniaus universiteto Ekonomikos ir verslo administravimo fakulteto docentė, socialinių mokslų daktarė. Moksliniai interesai: tarptautinės ir nacionalinės finansinės apskaitos sistemų vystymo, mokesčių apskaitos, finansinės įmonių analizės problemos. Institucijos adresas: Saulėtekio al. 9, II rūmai, LT-10222, Vilnius.

Ramunė Budrionytė: Associate Professor at Vilnius University, Faculty of Economics and Business Administration, Doctor of social sciences in the field of management and administration. Scientific interests include the development of international and national accounting and financial reporting systems, financial analysis, and taxes. Address of institution: Saulėtekio av. 9, II building, LT-10222, Vilnius.