



**Kauno technologijos universitetas**  
Matematikos ir gamtos mokslų fakultetas

# **Giliojo mokymosi metodų taikymas įmonių bankroto prognozavimui**

Baigiamasis magistro studijų projektas

---

**Ieva Rizgeliė**  
Projekto autorė

Doc. dr. Kęstutis Lukšys

Vadovas

Doc. dr. Aušrinė Lakštutienė

Vadovė

---

**Kaunas, 2022**



**Kauno technologijos universitetas**  
Matematikos ir gamtos mokslų fakultetas

# **Giliojo mokymosi metodų taikymas įmonių bankroto prognozavimui**

Baigiamasis magistro studijų projektas  
Didžiųjų verslo duomenų analitika (6213AX001)

---

**Ieva Rizgelienė**

Projekto autorė

**Doc. dr. Kęstutis Lukšys**

Vadovas

**Doc. dr. Aušrinė Lakštutienė**

Vadovė

**Doc. dr. Mantas Landauskas**

Recenzentas

**Doc. pr. dr. Mantas Valukonis**

Recenzentas

**Kaunas, 2022**



**Kauno technologijos universitetas**

Matematikos ir gamtos mokslų fakultetas

Ieva Rizgeliėnė

## **Giliojo mokymo metodų taikymas įmonių bankroto prognozavimui**

Akademinio sąžiningumo deklaracija

Patvirtinu, kad:

1. baigiamąjį projektą parengiau savarankiškai ir sąžiningai, nepažeisdama(s) kitų asmenų autorius ar kitų teisių, laikydamasi(s) Lietuvos Respublikos autorių teisių ir gretutinių teisių įstatymo nuostatų, Kauno technologijos universiteto (toliau – Universitetas) intelektinės nuosavybės valdymo ir perdavimo nuostatų bei Universiteto akademinės etikos kodekse nustatytų etikos reikalavimų;
2. baigiamajame projekte visi pateikti duomenys ir tyrimų rezultatai yra teisingi ir gauti teisėtai, nei viena šio projekto dalis nėra plagijuota nuo jokių spausdintinių ar elektroninių šaltinių, visos baigiamojo projekto tekste pateiktos citatos ir nuorodos yra nurodytos literatūros sąrašė;
3. įstatymų nenumatytų piniginių sumų už baigiamąjį projektą ar jo dalis niekam nesu mokėjęs (-usi);
4. suprantu, kad išaiškėjus nesąžiningumo ar kitų asmenų teisių pažeidimo faktui, man bus taikomos akademinės nuobaudos pagal Universitete galiojančią tvarką ir būsiu pašalinta(s) iš Universiteto, o baigiamasis projektas gali būti pateiktas Akademinės etikos ir procedūrų kontrolieriaus tarnybai nagrinėjant galimą akademinės etikos pažeidimą.

Ieva Rizgeliėnė

*Patvirtinta elektroniniu būdu*

Ieva Rizgelienė. Giliojo mokymosi metodų taikymas įmonių bankroto prognozavimui. Magistro studijų baigiamasis projektas, vadovai doc. dr. Kęstutis Lukšys ir doc. dr. Aušrinė Lakštutienė; Kauno technologijos universitetas, Matematikos ir gamtos mokslų fakultetas.

Studijų kryptis ir sritis (studijų krypčių grupė): Taikomoji matematika (Matematikos mokslai)

Reikšminiai žodžiai: *Gilusis mokymas, dirbtiniai neuroniniai tinklai, sąsūkų neuroninis tinklas, daugiasluoksnis perceptronas, įmonių bankroto prognozavimas.*

Vilnius, 2022. 65 p.

### **Santrauka**

Šiame darbe pristatomi sukurti giliojo mokymosi modeliai skirti įmonių bankroto prognozavimui. Tyrimo metu, naudojant Lietuvos įmonių duomenis, sukurti du giliojo mokymosi modeliai: daugiasluoksnis perceptronas ir sąsūkų neuroninis tinklas. Modelių hiperparametrų paieškai buvo naudojamas Bajeso optimizavimo metodas. Siekiant ištirti klasių disbalanso įtaką modelių apmokymui, modeliai buvo apmokomi su nesubalansuotais ir subalansuotais apmokymo duomenimis. Siekiant įvertinti modelių gebėjimą atskirti bankroto atvejus duomenų aibėje su dideliu klasių disbalansu, modelių testavimui buvo naudojamas testavimo poaibis, kuriame buvo išlaikytas pradinio duomenų rinkinio klasių disbalansas. Gauti giliojo mokymosi modeliai palyginami su atsitiktinio miško, logistinės regresijos ir atraminių vektorių metodais. Gauti rezultatai parodė, kad tiek apmokant modelius su subalansuota, tiek su nesubalansuota duomenų aibe, geriausiai bankroto atvejus atpažino sąsūkų neuroninis tinklas, o atsitiktinio miško modelis pralenkė daugiasluoksnį perceptroną. Apmokymo metu naudojant duomenis su išlaikytu pradinio duomenų rinkinio klasių disbalansu, geriausiai klases atskyrė giliojo mokymosi modeliai.

Ieva Rizgeliënė. Deep learning methods application for bankruptcy prediction. Master's Final Degree Project / supervisor assoc. prof. dr. Kęstutis Lukęsys and assoc. prof. dr. Auęrinė Lakęstutiene; Faculty of Mathematics and Natural Sciences, Kaunas University of Technology.

Study field and area (study field group): Applied Mathematics (Mathematics).

Keywords: *deep learning, artificial neural network, convolutional neural network, multilayer perceptron, bankruptcy prediction.*

Vilnius, 2022. 65 p.

### **Summary**

This work introduces the deep learning models developed to predict firms' bankruptcy. Two deep learning models were developed using data from Lithuanian companies: a multilayer perceptron and a convolutional neural network. Bayesian optimization method was used to find the hyperparameters of the models. To investigate the impact of class imbalance on models training, models were trained with imbalanced and balanced datasets. To assess the ability of models to recognize the bankruptcies in a data with high class imbalance, models were tested with imbalanced test sample. The results of deep learning models were compared with random forest, logistic regression, and support vector machine. The results showed, that in all cases, the convolutional neural network was the best model and deep learning models separated classes better than the random forest model, when models were trained with imbalanced dataset.

## Turinys

<b>Lentelių sąrašas .....</b>	<b>8</b>
<b>Paveikslų sąrašas .....</b>	<b>9</b>
<b>Įvadas.....</b>	<b>10</b>
<b>1. Literatūros analizė.....</b>	<b>11</b>
1.1. Įmonių bankrotą lemiantys veiksniai.....	11
1.2. Kintamieji bankroto prognozavimui.....	14
1.3. Giliojo mokymosi taikymas bankroto prognozavime .....	17
1.4. Hiperparametrų paieškos metodai .....	18
1.5. Klasių disbalanso poveikis neuroninių tinklų apmokymui. ....	19
1.6. Tikslumo metrikos.....	20
1.7. Tyrimo uždaviniai. ....	21
<b>2. Tyrimo metodai. ....</b>	<b>23</b>
2.1. Tyrime naudojami duomenys .....	23
2.1.1. Duomenų tvarkymas.....	24
2.1.2. Įmonių atranka.....	24
2.1.3. Statistinė kintamųjų analizė.....	25
2.2. Įmonių aibės sukūrimas. Įmonių skirtų testavimui, apmokymui ir validavimui atskyrimas....	28
2.3. Klasių balanso paieška .....	29
2.3.1. Apmokymo, validavimo ir testavimo poaibių sukūrimas.....	30
2.4. Giliojo mokymosi modeliai.....	32
2.4.1. Dirbtiniai neuroniniai tinklai. ....	32
2.4.2. Tiesioginio sklidimo neuroniniai tinklai .....	33
2.4.3. Sąsūkų neuroniniai tinklai .....	34
2.5. Dirbtinių neuroninių tinklų apmokymas. ....	36
2.5.1. Bajeso optimizavimas.....	37
2.5.2. Atgalinės sklaidos metodas .....	37
2.5.3. Optimizavimo algoritmai.....	37
2.5.4. Mokymosi greitis.....	38
2.5.5. Aktyvacijos funkcijos.....	38
2.5.6. Sluoksnių ir neuronų skaičius.....	40
2.5.7. Epochų skaičius ir partijos dydis.....	40
2.5.8. Neuronų pašalinimas ir normalizavimas. ....	40
2.6. Kiti klasifikavimo metodai .....	40
2.6.1. Atsitiktinis miškas .....	40
2.6.2. Logistinė regresija. ....	41
2.6.3. Atraminių vektorių metodas.....	41
<b>3. Tiriamoji dalis.....</b>	<b>42</b>
3.1. Klasių disbalansas modelio hiperparametrų paieškos metu .....	42
3.2. Daugiasluoksniu perceptrono modelio rezultatai .....	43
3.2.1. Gautas modelis .....	43
3.2.2. Modelio rezultatai, apmokant modelį su subalansuota apmokymo imtimi.....	44

3.2.3. Modelio rezultatai, apmokymo metu naudojant imtį su pradinio duomenų rinkinio klasių disbalansu .....	45
3.3. Sąsūkų neuroninio tinklo modelio rezultatai .....	46
3.3.1. Modelio rezultatai, apmokant modelį su subalansuota apmokymo imtimi .....	46
3.3.2. Modelio rezultatai, apmokymo metu naudojant imtį su pradinio duomenų rinkinio klasių disbalansu .....	47
3.4. Giliojo mokymosi modelių palyginimas su kitais klasifikavimo modeliais .....	48
3.4.1. ROC, PRC kreivės, apmokant modelius su subalansuota apmokymo aibe .....	49
3.4.2. ROC, PRC kreivės, apmokant modelius su nesubalansuota apmokymo aibe.....	50
3.4.3. Modelių rezultatai, testavimo metu .....	52
<b>Išvados .....</b>	<b>55</b>
<b>Literatūros sąrašas .....</b>	<b>57</b>
<b>Priedai.....</b>	<b>60</b>
1 Metiniai kintamieji, maksimumų reikšmės. ....	60
2 Mėnesiniai kintamieji. Maksimumų reikšmės.....	60
3 Metiniai kintamieji. Minimumo reikšmės. ....	61
4 Mėnesiniai kintamieji. Minimumo reikšmės .....	62
5 Metiniai kintamieji. Standartiniai nuokrypiai.....	62
6 Mėnesiniai kintamieji. Standartiniai nuokrypiai. ....	63
7 Metiniai kintamieji. Vidurkiai. ....	63
8 Mėnesiniai kintamieji. Vidurkiai.....	64
9 Atsitiktinio miško klasifikavimo rezultatai, apmokant modelį su skirtingais balansais. ....	65

## Lentelių sąrašas

<b>1 lentelė.</b> 1 tipo įmonių bankroto veiksnių analizė [17].....	12
<b>2 lentelė.</b> 2 tipo įmonių bankroto veiksnių analizė [17].....	13
<b>3 lentelė.</b> 3 tipo įmonių bankroto veiksnių analizė [17].....	14
<b>4 lentelė.</b> Modelio sudarymui naudojami kintamieji ir santykiniai rodikliai [5]. .....	15
<b>5 lentelė.</b> Sumaišymo matrica [21].....	20
<b>6 lentelė.</b> Modelių metrikos, apmokant su 85/15 klasių balansu .....	50
<b>7 lentelė.</b> Modelių metrikos, apmokant su 99/1 klasių balansu .....	51
<b>8 lentelė.</b> Modelių testavimo metrikos, apmokant su 85/15 klasių balansu.....	52
<b>9 lentelė.</b> Modelių tikslumo metrikos, apmokant su 99/1 klasių balansu .....	53



## Paveikslų sąrašas

<b>1 pav.</b> Tyrimo planas.....	23
<b>2 pav.</b> Bankrutavusių įmonių skaičius, pagal vykdytus veiklos metus iki bankroto. ....	25
<b>3 pav.</b> Pardavimo rodiklių vidurkiai. ....	26
<b>4 pav.</b> Pelno ir pinigų rodiklių vidurkiai. ....	26
<b>5 pav.</b> Turto, atsargų, kapitalo ir trumpalaikių įsipareigojimų vidurkiai. ....	27
<b>6 pav.</b> Einamojo likvidumo, įsiskolinimo, bendro mokumo, absoliutaus likvidumo, kritinio likvidumo, įsipareigojimų ir nuosavo kapitalo santykio koeficientų vidurkiai. ....	27
<b>7 pav.</b> Apyvartinio kapitalo ir įsipareigojimų vidurkiai.....	27
<b>8 pav.</b> Pvm rodiklių vidurkiai. ....	28
<b>9 pav.</b> Darbo užmokesčio, pajamų vienam darbuotojui ir VMI nepriemokų vidurkiai. ....	28
<b>10 pav.</b> Bankrutavusių ir nebankrutavusių įmonių klasių disbalansas, tiriamoje duomenų aibėje...	29
<b>11 pav.</b> Įmonių duomenų konvertavimas daugiasluoksnio perceptrono modeliui.....	31
<b>12 pav.</b> Įmonių duomenų konvertavimas sąsūkų neuroniniams tinklams .....	32
<b>13 pav.</b> Dirbtinio neurono schema .....	32
<b>14 pav.</b> Daugiasluoksnio perceptrono modelis .....	33
<b>15 pav.</b> Sąsūkų neuroninio tinklo schema.....	34
<b>16 pav.</b> Sąsūkos sluoksnis.....	35
<b>16 pav.</b> Surinkimo sluoksnis .....	36
<b>18 pav.</b> Pilnai sujungtas sluoksnis.....	36
<b>19 pav.</b> Atsitiktinio miško klasifikavimo rezultatai .....	42
<b>20 pav.</b> Gautas daugiasluoksnio perceptrono modelis .....	43
<b>21 pav.</b> Daugiasluoksnio perceptrono apmokymas, naudojant 85/15 klasių balansą .....	44
<b>22 pav.</b> Daugiasluoksnio perceptrono ROC ir PRC kreivės, apmokant modelį su 85/15 balansu ...	44
<b>23 pav.</b> Daugiasluoksnio perceptrono apmokymas, naudojant 99/1 klasių balansą. ....	45
<b>24 pav.</b> Daugiasluoksnio perceptrono ROC ir PRC kreivės, apmokant modelį su 99/1 balansu. ....	45
<b>25 pav.</b> Gautas sąsūkų neuroninio tinklo modelis.....	46
<b>26 pav.</b> Sąsūkų neuroninio tinklo apmokymas, naudojant 85/15 klasių balansą.....	47
<b>27 pav.</b> Sąsūkų neuroninio tinklo ROC ir PRC kreivės, apmokant modelį su 85/15 balansu .....	47
<b>28 pav.</b> Sąsūkų neuroninio tinklo apmokymas, naudojant 99/1 klasių balansą.....	48
<b>29 pav.</b> Sąsūkų neuroninio tinklo ROC ir PRC kreivės, apmokant modelį su 99/1 balansu .....	48
<b>30 pav.</b> Visų modelių ROC kreivės, apmokant modelius 85/15 klasių balansu .....	49
<b>31 pav.</b> Visų modelių PRC kreivės, apmokant modelius 85/15 klasių balansu.....	49
<b>32 pav.</b> Visų modelių ROC kreivės, apmokant modelius su 99/1 klasių balansu.....	51
<b>33 pav.</b> . Visų modelių PRC kreivės, apmokant modelius su 99/1 klasių balansu .....	51
<b>34 pav.</b> Modelių sumaišymo matricos, apmokant su 85/15 balansu.....	53
<b>35 pav.</b> Modelių sumaišymo matricos, apmokant su 99/1 balansu.....	54

## Įvadas

Įmonių bankrotas, tai neišvengiamas ekonomikos reiškinys. Įmonės bankroto prognozė, gali padėti identifikuoti įmones, susiduriančias su sunkumais, o tai gali užkirsti kelią bankrotui arba leisti tinkamai tam pasiruošti, taip sumažinant galimus nuostolius.

Giliojo mokymosi metodai vis dar yra retesnis pasirinkimas bankroto prognozės uždaviniui spręsti, lyginant su kitais klasifikavimo algoritmais. Gilusis mokymasis, kiekviename sluoksnyje gali išmokti vis abstraktesnius duomenų bruožus, todėl parinkus tinkamą neuroninio tinklo architektūrą galima gauti pakankamai tikslius prognozės rezultatus ir pranokti klasikinius bankroto prognozei taikomus metodus.

**Tyrimo aktualumas.** Įmonių bankroto prognozavimas gali padėti nustatyti ateityje bankrutuosiančias įmones ir taip padėti išvengti galimų nuostolių. Kuo tiksliau ir anksčiau nustatome įmonių bankrotą, tuo greičiau galime imtis veiksmų, mažinančių galimus nuostolius arba padedančių išvengti bankroto. Darbe yra siekiama sukurti bankroto prognozavimo modelį, kuris galėtų padėti nustatyti artėjantį įmonių bankrotą.

Įmonių bankroto prognozavimui pritaikomas sąsūkų neuroninis tinklas, kuris yra daugiausiai taikomas vaizdams klasifikuoti ir yra itin retas pasirinkimas bankroto prognozavimo uždaviniui spręsti.

**Tyrimo problematika.** Efektyvus turimų įmonių duomenų panaudojimas įmonių bankrotui prognozuoti – naudojant giliojo mokymosi modelius.

**Tyrimo tikslas.** Naudojant Lietuvos įmonių duomenis, sukurti giliojo mokymosi modelius, skirtus įmonių bankroto prognozavimui.

### Tyrimo uždaviniai:

1. tinkamai paruošti turimus duomenis giliojo mokymosi modeliams;
2. rasti geriausias neuroninių tinklų modelių architektūras ir geriausias modelių hiperparametrus;
3. ištirti giliojo mokymosi modelių gebėjimą prognozuoti bankroto atvejus duomenų aibėje su dideliu klasių disbalansu, apmokant modelius su subalansuota ir nesubalansuota apmokymo duomenų aibe;
4. palyginti giliojo mokymosi modelius su kitais klasifikavimo modeliais;
5. pateikti tolesnes rekomendacijas, giliojo mokymosi metodų taikymui įmonių bankrotui prognozuoti.

Šio baigiamojo projekto rezultatai pristatyti dvejose konferencijose: „Lietuvos magistrantų informatikos ir IT tyrimai“, „Matematika ir gamtos mokslai: teorija ir taikymas“. Išspausdintas straipsnis pirmosios konferencijos leidinyje<sup>1</sup>, antrosios konferencijos pranešimų medžiagai straipsnis pateiktas.

---

<sup>1</sup> Rizgelienė I. (2022) „Įmonių bankroto prognozavimas naudojant gilųjį mokymą“, *Vilnius University Open Series*, pp. 85-100. doi: 10.15388/LMITT.2022.9.

## 1. Literatūros analizė

Ekonomikos inžinieriai bankrotą pradėjo nagrinėti 1930 m. Pirmiausiai buvo susikoncentruota į bankrutavusių ir nebankrutavusių įmonių finansinių rodiklių palyginimą. 1968 m. Edward'as I. Altman'as pirmą kartą bankrotui prognozuoti pritaikė daugiamatės diskriminantinės analizės modelį [1]. Logistinė regresija pirmą kartą bankrotui prognozuoti buvo pritaikyta 1980 m. [2]. Gerokai vėliau (21a.) buvo pritaikyti tokie modeliai kaip pagrindinių komponentų analizė, sprendimų medžiai ir atraminių vektorių metodas. Giliojo mokymosi algoritmai vis dar yra retesnis pasirinkimas bankroto prognozavimo uždaviniui spręsti, lyginant su kitais klasifikavimo metodais.

### 1.1. Įmonių bankrotą lemiantys veiksniai

Ekonomistai, tiriantis įmonių bankrotą teigia, kad nėra vienos konkrečios priežasties, kuri lemtų įmonių bankrotą. Bankrotas ištinka įmonę, tuomet, kai yra susiduriama su daug nepalankių įmonei priežasčių ir aplinkybių [17]. Literatūroje bankroto priežastys yra skirstomos į:

- išorines, kurias sudaro reiškiniai susiję su bendra šalies ekonomine padėtimi;
- vidines, kurios yra skirstomos į tris grupes:
  - neoklasikinė grupė, susijusi su netinkamu, neefektyviu turto paskirstymu;
  - finansinė grupė, susijusi su neadekvačia finansavimo struktūra;
  - priežastys, susijusios su prastu įmonės valdymu.

H. Ooghe ir S. Prijcker 2006m. pristatė įmonių bankroto fazes. Šios fazės yra naudojamos tiriant įmonių bankroto reiškinį [17]. Kiekviena fazė turi skirtingą laikotarpį, šios fazės apibūdina įmonių gyvavimo ciklą, atsižvelgiant į įmonės tipą. Išskiriami 3 įmonių tipai:

1. jaunos įmonės, turėjusios nesėkmingą verslo pradžią;
2. įmonės turėjusios spartų augimą ir tokį pat spartų nuosmukį;
3. ilgą laikotarpį rinkoje veikiančios įmonės, kurioms būdingas rinkos pokyčių ignoravimas.

1 lentelėje, pateikiama pirmojo įmonių tipo bankroto veiksnų analizė. Šio tipo įmonių bankrotą daugiausiai lemia vidiniai įmonės veiksniai. Dažnu atveju jaunoje įmonėje, didelį vaidmenį vaidina įmonių vadovai. Tokios įmonės neturi tvirtos klientų ar tiekėjų bazės ir yra pažeidžiamos konkurentų, taip pat turi ribotą prieigą prie finansavimo šaltinio. Todėl pirmoje šių įmonių fazėje didelę įtaką bankrotui lemia šie veiksniai: prastas sprendimų priėmimo procesas, nesugebėjimas kontroliuoti rizikų, bendrųjų ir specifinių žinių trūkumas, per maža patirtis įmonės valdyme, negebėjimas spręsti iškilusių konfliktų įmonės viduje. Išvardintų kompetencijų trūkumas lemia neteisingai priimamus sprendimus įmonėje, kurie dažnai būna nulemti didelio vadovų optimizmo ir kompetencijų trūkumo. Įmonės negauna reikiamo finansavimo, o tai nulemia didelį įmonės kapitalo trūkumą. Dėl netinkamai priimtų sprendimų pirmoje įmonės fazėje, įmonėms tampa vis sunkiau konkuruoti rinkoje, o tai lemia didžiules įmonės sąnaudas ir nepakankamą pelną. Šio tipo įmonėms išoriniai veiksniai turi ne tokią didelę įtaką įmonės žlugimui kaip vidiniai, tačiau nepalankus valiutos kursas, didelė infliacija ir konkurencija dar greičiau priartina įmones prie bankroto.

**1 lentelė.** 1 tipo įmonių bankroto veiksnių analizė [17]

	1 fazė	2 fazė	3 fazė
Išorinės priežastys	Ekonominis ciklas (nuosmukis)		
	Palūkanų norma		
	Infliacija		
	Nepakankamai klientų		
	Klientų nepasitenkinimas		
Vidinės priežastys	Nekvalifikuoti vadovai	Nepakankamas išlaidų įvertinimas.	Didžiuliai finansiniai nuostoliai.
	Nepakankamos vadovų žinios apie konkretų pramonės sektorių kuriame veikia įmonė	Išlaidų kontrolės sistemos nebuvimas	Galimybės pagerinti finansinį likvidumą nebuvimas.
	Lyderystės trūkumas	Didžiulės kapitalo išlaidos	Nesugebėjimas restruktūrizuoti įmonę dėl didžiulių įmonės skolų, nėra papildomų šaltinių finansavimo šaltinių ir nekompetencijos vadovų
	Nepakankama finansinė patirtis	Mažos pajamos iš pardavimų	
	Nepakankamas kapitalas		
	Verslo plano nebuvimas	Nesėkmingas bandymas užimti rinką.	
	Nepakankamas techninių žinių lygis	Finansinių išlaidų padidėjimas	
	Pagrindinių sėkmės veiksnių trūkumas	Konsultacijų su verslo konsultantais trūkumas.	
	Skubėjimas		
	Investicijos į netinkamus projektus		
	Žemas produktų ir (arba) rinkų diversifikavimo lygis.		

2 lentelėje, pateikiama antrojo tipo įmonių bankroto veiksnių analizė. Šio tipo įmonėms išorės veiksniai turi daug didesnę įtaką, lyginant su pirmojo tipo įmonėmis. Per daug palankios makroekonominės sąlygos - įmonės gyvavimo pradžioje, gali prisidėti prie pirmojo bankroto fazės etapo, nes antrojo tipo įmonių vadovams būdingas per didelis optimizmas ir ambicijos. Pradiniu laikotarpiu šio tipo įmonėms yra būdingas spartus augimas. Gaunamas didelis pelnas pirmaisiais įmonės gyvavimo metais - skatina vadovus didelei plėtrai. Didelė sėkmė įmonės pradžioje, gali lemti padidėjusią vadovų aroganciją, o tai lemia ateities rinkos sąlygų ignoravimą. Tam, kad galima būtų finansuoti didelę įmonės plėtrą, įmonių vadovai neatsakingai ima dideles paskolas. Sparčiai augant įmonės dydžiui, valdymo struktūros tampa netinkamos, o sprendimų priėmimo procesas chaotiškesnis. Klaidos padarytos pirmoje įmonės fazėje veda įmonės į antrąją. Antroje fazėje per daug investuojama ir išlaidaujama. Įmonei pradeda trūkti veiksmingos finansų kontrolės, netinkama valdymo struktūra, personalo išlaidų didėjimas ir vadovų problemų ignoravimas, priveda įmonę prie kritinio taško – įmonės žlugimo.

**2 lentelė.** 2 tipo įmonių bankroto veiksnių analizė [17]

	1 fazė	2 fazė	3 fazė
Išorinės priežastys	Ekonominis ciklas (nuosmukis)		
		Infliacija	
		Didėjanti konkurencija	
		Sumažėjusi produktų paklausa	
	Valiutos kursas		
Klientų nepasitikėjimas		Bankų atsisakymas toliau finansuoti įmonę	
Vidinės priežastys	Netinkama valdymo struktūra augančiai įmonei.	Pelno pervertinimas	Nuostolių padidėjimas dėl nesėkmingos bendrovės plėtos.
		Pernelyg didelės investicinės išlaidos.	
	Nepakankamos vadovų žinios apie konkretų pramonės sektorių.	Išlaidų kontrolės sistemos nebuvimas.	Galimybės pagerinti finansinį likvidumą nebuvimas.
	Didelis pelnas pirmaisiais veiklos metais, lemia didelį būsimo pelno ateityje pervertinimą, kuris susijęs su produktų paklausa ir įmonės plėtros planais.	Nepakankama finansinė patirtis	Nežinojimas apie problemas, susijusias su finansinio likvidumo trūkumu.
		Vadybininkų ne pastabumas.	
	Vadovų kompetencijos trūkumas.	Efektyvios finansų kontrolės trūkumas.	Atsargų padidėjimas, po nesėkmingos plėtos rinkoje.
	Vadovų ignoravimas išaugusiam klientų nepasitikėjimui.	Nesėkminga bendrovės plėtra.	
	Neatsakingas įmonės skolų didinimas.	Per didelis ilgalaikio turto kiekis.	Prarastas klientų ir darbuotojų pasitikėjimas.
Pernelyg didelis vadovų optimizmas.	Darbo sąnaudų didėjimas.		

3 lentelėje pateikiama, trečiojo tipo įmonių bankroto veiksnių analizė. Šio tipo įmonėms, išorinės priežastys turi didžiausią poveikį bankrotui. Įmonės veikiančios ilgą laikotarpį jaučiasi saugiai. Investuotojai arba šių įmonių darbuotojai mano, kad jiems yra garantuotas stabilus pelnas arba darbo vieta. Galime teigti, kad tokios įmonės yra „apakintos“ kadaise turėtos sėkmės. Jos neanalizuoja besikeičiančios aplinkos. Nusistovėjęs įmonės valdymas ir tokie išoriniai veiksniai kaip: senstanti pramonės šaka, didėjantis konkurencingumas, produktų pakaitalų didėjimas, besikeičianti gamybos technologija, nepakankama vyriausybės rinkos apsauga yra pagrindinės pirmosios bankroto fazės priežastys. Apatija pokyčiams lemia, tai, kad įmonė praranda strateginį pranašumą rinkoje, dėl to krizė įmonėje dar labiau sustiprėja. Pajamos iš pardavimų mažėja. Esant tokiai situacija, nesiimama ryžtingų veiksmų, o tai lemia įmonės bankrotą.

**3 lentelė.** 3 tipo įmonių bankroto veiksnių analizė [17]

	1 fazė	2 fazė	3 fazė
Išorinės priežastys	Senstanti pramonė		
	Didėjantis konkurencinis spaudimas		
	Netinkama vyriausybės ekonominė politika		
	Vyriausybės rinkos apsaugos trūkumas		
	Globalizacija		
	Technologijų pokyčiai	Klientų pasitikėjimo praradimas	
Vidinės priežastys	Vadovų išipareigojimų ir motyvacijos stoka.	Palaiapsniui mažėjančios pajamos ir Pelnas.	Pelno, likvidumo ir mokumo praradimas.
	Strateginio pranašumo praradimas.	Pardavimų sumažėjimas	Atsargų padidėjimas.
	Bendra apatija	Nesėkminga, lėta restruktūrizacija	Iš įmonės išeinantys specialistai
	Lėtas produktų naujovių diegimo procesas arba jo nebuvimas	Chaosas operatyvinėje įmonės dalyje	
	Vadovybės pokyčių poreikių ignoravimas, tikėjimas įmonės sėkme, remiantis praeitimi.	Vadovybės saviapgaulė. Bendro sutarimo paieškos, vengiant radikalių pokyčių	
	Nenoras investuoti į naujas technologijas	Santykinai žemesnis produkto kokybės svertas.	
	Didelės pastoviosios sąnaudos		
	Nelankstus, "sustingęs" sprendimų priėmimo procesas		

Iš apžvelgtos [17] tyrimo įmonių bankroto veiksnių analizės, galime teigti, kad įmonės bankrotas nėra atsitiktinis reiškinys, tai yra ilgalaikis procesas, vykstantis fazėmis, kuriam įtaką daro daugybė veiksnių. Todėl galime daryti prielaidą, kad artėjant įmonių bankrotui, įmonių veiklos rodikliai tampa nebe tokie stabilūs, o įmonių duomenys pradeda rodyti ženklūs, kuriuos giliojo mokymosi algoritmai gali atpažinti.

## 1.2. Kintamieji bankroto prognozavimui

Remiantis [3, 4, 5, 6, 7] šaltiniais galime daryti prielaidą, kad geriausiai įmonių bankrotą prognozuoja įmonių likvidumo, mokumo, pelningumo rodikliai. Tačiau, kaip buvo pastebėta [7] publikacijoje, makroekonominiai ir rinkos kintamieji taip pat pagerina modelio prognozės rezultatus.

Jardin'as Philippe atliko išsamų tyrimą, kuriame nagrinėjama, kokie kintamieji geriausiai prognozuoja bankrotą [12]. Autoriaus teigimu, dažniausiai bankrotui prognozuoti, naudojami šie kintamieji:

- finansiniai rodikliai;
- statistiniai kintamieji;
- variaciniai kintamieji;

- nefinansiniai kintamieji;
- rinkos kintamieji;
- finansinius rinkos kintamieji.

Autorius išskyrė finansinius rodiklius kaip dažniausiai naudojamus įmonių bankroto prognozavimo modeliuose. Tomas Klietk, Maria Misankova, Katarina Valaskova, Lucia Svabova, kurdami modelį bankrotui prognozuoti, naudojo Slovakijos įmonių finansinių ataskaitų duomenis, autoriai nusprendė naudoti kintamuosius, atsižvelgę į jų populiarumą bankroto tyrimuose, ir išsirinko 11 populiariausių bankroto rodiklių, kuriuos pateikė lentelėje. [5].

**4 lentelė.** Modelio sudarymui naudojami kintamieji ir santykiniai rodikliai [5].

Kintamieji	Santykinis rodiklis
Bendrasis likvidumo koeficientas	$\frac{\textit{Trumpalaikis turtas}}{\textit{Trumpalaikiai įsipareigojimai}}$
Absolutos likvidumo rodiklis	$\frac{\textit{Pinigai ir jų ekvivalentai}}{\textit{Trumpalaikiai įsipareigojimai}}$
Turto pelningumo rodiklis	$\frac{\textit{Grynasis pelnas}}{\textit{Turtas}}$
Nuosavo kapitalo pelningumo rodiklis	$\frac{\textit{Grynasis pelnas}}{\textit{Nuosavas kapitalas}}$
Įsiskolinimo rodiklis	$\frac{\textit{skolos}}{\textit{turtas}}$
Skolos – nuosavybės rodiklis	$\frac{\textit{skolos}}{\textit{nuosavas kapitalas}}$
Gautinų sumų dienų skaičius	$\frac{\textit{Gautinos sumos}}{\textit{Pardavimai}/360}$
Mokėtinų dienų sumų skaičius	$\frac{\textit{Trumpalaikiai įsipareigojimai}}{\textit{Pardavimai}/360}$
Inventoriaus apyvartumas	$\frac{\textit{Inventorius}}{\textit{Pardavimai}/360}$
Grynasis turtas	$\frac{\textit{Grynasis apyvartinis kapitalas}}{\textit{Turtas}}$
Nepaskirstytojo kapitalo viso turto santykis	$\frac{\textit{Nepaskirstytas kapitalas}}{\textit{Turtas}}$

Rafael'is Becerra-Vicario, David'as Alaminos, Eva Aranda, Manuel'is A. Fernández-Gámez, kurdami giliojo mokymosi modelį įmonių bankrotui prognozuoti, nusprendė naudoti 28 kintamuosius, remdamiesi prieš tai atliktų tyrimų rekomendacijomis [4]. Kintamuosius autoriai suskirstė į 6 grupes:

- ❖ Įmonės dydis:
  - bendras įmonės turtas.

- ❖ Efektyvumo rodikliai:
  - pajamų ir ilgalaikio turto santykis,
  - pajamų ir bendro turto santykis,
  - pardavimų savikainos ir vidutinių atsargų santykis.
- ❖ Likvidumo ir pinigų srautų rodikliai:
  - išdo, trumpalaikių finansinių investicijų, įsiskolinimų ir trumpalaikių įsipareigojimų santykis.
  - trumpalaikio turto ir trumpalaikių įsipareigojimų santykis,
  - EBIT ir trumpalaikių įsipareigojimų santykis,
  - apyvartinio kapitalo ir viso turto santykis,
  - laisvų pinigų srautų, finansinių išlaidų ir visų įsipareigojimų santykis.
  - laisvų pinigų srautų, dividendų ir visų įsipareigojimų santykis,
  - veiklos pinigų srautų ir bendrų įsipareigojimų santykis.
- ❖ Pelningumo rodikliai:
  - grynojo pelno ir pajamų santykis,
  - grynojo pelno ir grynosios nuosavybės santykis,
  - grynojo pelno ir viso turto santykis,
  - EBIT ir viso turto santykis,
  - bendroji pelno marža.
- ❖ Mokumo rodikliai:
  - ilgalaikių skolų ir viso turto santykis,
  - EBIT ir bendrų įsipareigojimų santykis,
  - EBIT ir finansinių išlaidų santykis,
  - EBITDA ir bendrų įsipareigojimų santykis,
  - grynojo nuosavo kapitalo ir ilgalaikių įsipareigojimų santykis,
  - viso turto ir grynojo nuosavo kapitalo santykis,
  - visų įsipareigojimų ir grynojo nuosavo kapitalo santykis,
  - visų įsipareigojimų ir viso turto santykis.
- ❖ Ne finansiniai rodikliai:
  - Įmonės amžius,
  - binarinis kintamasis nurodantis ar įmonė priklauso tinklui,
  - kokybės rodiklis, nurodantis ar įmonė turi kokybės sertifikatą.

Pateiktiems kintamiesiems, [4] tyrimo autoriai atliko statistinę kintamųjų analizę. Atliktos statistinės analizės tikslas, buvo ištirti bankrutavusių ir nebankrutavusių įmonių kintamųjų pokyčius likus vieniems, dvejiems ir trejiems metams iki bankroto. Šiam tikslui įgyvendinti, buvo sukurti bankrutavusių ir nebankrutavusių įmonių poaibiai ir tiriama paskutiniai treji įmonių veiklos metai. Kintamiesiems, pamečiui, buvo apskaičiuoti šie įverčiai: vidurkis, mediana, standartinis nuokrypis, minimumas, maksimumas ir M-W testas (angl. *Mann–Whitney*). Iš statistinės analizės, buvo pastebėta, kad didžiausius pokyčius bankrutavusių įmonių rodikliuose, lyginant su ne bankrutavusių įmonių rodikliais, galima buvo stebėti likus vieniems metams iki bankroto, tačiau pokyčiai buvo stebimi jau dveji metai iki bankroto.

Mario Hernandez Tinoco, Nick'as Wilson, kurdami bankroto prognozės modelį, naudojo Jungtinės karalystės įmonių duomenis [7]. Autoriai naudojo finansinius, makroekonominius ir



rinkos kintamuosius. Šio tyrimo tikslas buvo iširti kintamųjų įtaką bankroto prognozavimui. Toliau pristatysime, kintamuosius, naudotus [7] tyrime.

- ❖ Finansiniai apskaitos kintamieji:
  - veiklos pajamų ir įsipareigojimų santykis,
  - įsiskolinimo koeficientas,
  - apyvartinio kapitalo ir dienos išlaidų santykis,
  - palūkanų padengimo koeficientas.
- ❖ Makroekonominiai kintamieji:
  - mažmeninės kainos indeksas,
  - trumpalaikių (3 mėnesių) Jungtinės Karalystės obligacijų diskonto norma.
- ❖ Rinkos kintamieji.
  - Įmonės akcijų kaina
  - Pavėlinta (angl. *lagged*) kaupiamoji vertybinių popierių likutinė grąža.
  - Įmonės dydis.
  - Rinkos kapitalizacijos ir bendros skolos santykis.

Šiems kintamiesiems, autoriai atliko multikolinearumo analizę ir neradę multikolinearių kintamųjų nusprendė į modelį įtraukti visus kintamuosius.

Tadaaki's Hosaka, kurdamas sąsūkų neuroninį tinklą įmonių bankrotui prognozuoti, naudojo kintamuosius gautus iš įmonės balanso, bei pelno nuostolių ataskaitų [9]. Autorius nevykdė kintamųjų atrankos, tačiau atliko duomenų tvarkymo žingsnius, pašalindamas nereikšmingus įrašus, taip pat atliko duomenų transformaciją, taip pritaikydamas kintamuosius sąsūkų neuroninio tinklo modeliui.

### 1.3. Giliojo mokymosi taikymas bankroto prognozavime

Neuroniniai tinklai bankrotui prognozuoti pradėti taikyti 20 a. pabaigoje. 1990m. jau buvo sukurtas neuroninių tinklų modelis – įmonių bankrotui prognozuoti [18], sukurtas modelis buvo palygintas su tiesinės diskriminantinės analizės modeliu, šio tyrimo rezultatai parodė, kad neuroninių tinklų modelis prognozavo geriau. Nepaisant to, giliojo mokymosi algoritmai vis dar yra retesnis pasirinkimas bankroto prognozavimo uždaviniui spręsti, lyginant su kitais klasifikavimo algoritmais. Tačiau, didėjant duomenų kiekiui pasaulyje ir spartėjant programinei įrangai, įmonių bankrotui prognozuoti išbandoma vis daugiau algoritmų. Rafael'is Becerra-Vicario, David'as Alaminos, Eva Aranda, Manuel'is A. Fernández-Gámez įmonių bankrotui prognozuoti taikė giliuosius neuroninius tinklus, tyrimo metu autoriai sukūrė modelius, kurie prognozavo įmonių bankrotą po vienerių, dvejų ir trejų metų [4]. Gautus giliojo mokymosi modelius, autoriai palygino su logistinės regresijos modeliais ir pastebėjo, kad giliųjų neuroninių tinklų klasifikavimo rezultatai buvo geresni. Shekar'as Shetty, Mohamed'as Musa, Xavier'as Brédart Belgijos įmonių bankrotui prognozuoti, taikė daugiasluoksnio perceptrono modelį su šešiais paslėptaisiais sluoksniais, atraminių vektorių metodą ir XGBoost modelį ir pastebėjo, kad lyginant šių modelių klasifikavimo metrikas, daugiasluoksnis perceptronas įmonių bankrotą prognozavo prasčiausiai, tuo tarpu XGBoost ir atraminių vektorių metodas, turėjo panašų tikslumą [11]. Flavio Barboza, Herbert'as Kimura, Edward'as Atlman JAV ir Kanados įmonių bankrotui prognozuoti, taikė daugiasluoksnį perceptroną, atsitiktinio miško, atraminių vektorių, logistinės regresijos, daugianarės

diskriminantinės analizės, bagging, boosting modelius ir pastebėjo, kad atsitiktinio miško, bagging ir boosting modeliai pralenkė daugiasluoksnių perceptrono modelį [3]. Félix'as J.López Iturriaga, Iván'as Pastor Sanz įmonių bankrotui prognozuoti taikė diskriminantinės analizės, logistinės regresijos, atsitiktinio miško, daugiasluoksnių perceptrono, atraminių vektorių ir saviorganizuojančio žemėlapių – daugiasluoksnių perceptrono modelį [33]. Tyrimo metu autoriai sukūrė modelius įmonių bankrotui prognozuoti po vienerių, dvejų ir trejų metų ir įvertinę modelių tikslumo metrikas, pastebėjo, kad geriausiai įmonių bankrotą prognozavo - daugiasluoksnių perceptronų modeliai.

Nepaisant to, kad sąsūkų neuroniniai tinklai rodo puikius rezultatus vaizdų klasifikavime, šie modeliai yra daug rečiau pasirenkami įmonių bankrotui prognozuoti, lyginant su daugiasluoksnių perceptronų modeliais. Tačiau, jau yra atlikta tyrimų ir sąsūkų neuroninių tinklų taikyme įmonių bankrotui prognozuoti. Tadaaki's Hosaka, finansinius įmonių rodiklius išreiškęs nespaltotų vaizdų pavidalu, įmonių bankrotui prognozuoti, pritaikė sąsūkų neuroninį tinklą, sudarytą iš 27 sluoksnių ir pastebėjo, kad sąsūkų neuroninių tinklų modelis, klasifikavimo tikslumu, pralenkė šiuos modelius: daugiasluoksnių perceptroną, AdaBoost, atraminių vektorių metodą, tiesinę diskriminatinę analizę [9].

#### **1.4. Hiperparametrų paieškos metodai**

Tinkamas hiperparametrų įvedimas yra itin svarbus modelio tikslumui. Yra daugybė hiperparametrų paieškos metodų, pradedant nuo atsitiktinės paieškos iki sudėtingesnių metodų. Tačiau, pastebėsime, tai, kad neuroninių tinklų atveju, norint rasti geriausią modelį, taip pat turime rasti ir geriausią tinklo architektūrą, todėl ieškant geriausių hiperparametrų, šie turi būti išbandomi ir skirtingoms architektūroms, vadinasi susidaro didelis kiekis skirtingų modelių, kuriuos, visus reikia apmokyti ir ištestuoti, o tai lemia didelius laiko resursus, todėl yra svarbu rasti tokį hiperparametrų paieškos metodą, kuris rastų geriausią modelį, sunaudodamas mažiausiai resursų. Literatūroje, dėl savo lankstumo ir gebėjimo tirti neapibrėžtas funkcijas, kaip vienas iš optimaliausių hiperparametrų paieškos metodų, išskiriamas Bajeso optimizavimas [13, 36, 37, 38]. Šio metodo privalumas yra tai, kad Bajeso optimizavimas, skirtingai, nei dauguma kitų paieškos metodų, parinkdamas modelio parametrus, įvertina prieš tai gautus rezultatus. Lichao Wu<sup>1</sup>, Guilherme Perin, Stjepan Picek, daugiasluoksnių perceptrono ir sąsūkų neuroninio tinklo hiperparametrų paieškai taikė Bajeso optimizavimą ir atsitiktinės paieškos metodą, tyrimo metu, metodams buvo nustatytas maksimalus 50 iteracijų skaičius, gauti rezultatai parodė, kad Bajeso optimizavimo metodas per nurodytą iteracijų skaičių, rado geresnius modelio hiperparametrus, nei atsitiktinės paieškos metodas [36]. Jia Wu, Xiu-Yun Chen, Hao Zhang, Li-Dong Xiong, Hang Lei, Si-Hao Deng, taikydami Bajeso optimizavimą, ieškojo geriausių hiperparametrų šiems modeliams: atsitiktiniam miškui, sąsūkų neuroniniam tinklui, rekurentiniam neuroniniam tinklui, ieškodami geriausių hiperparametrų atsitiktinio miško modeliui, autoriai, šiam modeliui, taip pat pritaikė ir tinklo paieškos metodą ir pastebėjo, kad tiek Bajeso optimizavimas, tiek tinklo metodas rado hiperparametrus, su kuriais sudaryti modeliai turėjo beveik vienodą tikslumą, tačiau Bajeso optimizavimo metodas geriausių hiperparametrus rado 10 kart greičiau nei tinklo metodas, tuo tarpu neuroninių tinklų modeliams, autoriai taikė tik Bajeso optimizavimo metodą, kuriam nustatė maksimalų iteracijų skaičių lygu 50, sudaryti neuroninių tinklų modeliai su rastais hiperparametrais, turėjo didesnius nei 97% tikslumus [38].

## 1.5. Klasių disbalanso poveikis neuroninių tinklų apmokymui.

Dažnu atveju, sprendžiant klasifikavimo uždavinius, susiduriama su klasių disbalanso problema. Mateusz Buda, Atsuto Maki, Maciej A. Mazurowsk atliko tyrimą, tiriantį klasių disbalanso poveikį sąsūkų neuroninių tinklų modeliams [19]. Autoriai išskyrė duomenų perrinkimo ir duomenų klasifikavimo metodus, kurie gali padėti išspręsti klasių disbalanso problemą.

### ❖ Duomenų perrinkimo metodai.

- Dominuojančios klasės duomenų išmetimo (angl. *Undersampling*) metodas. Šis metodas atsitikusiai pašalina įrašus iš dominuojančios klasės.
- Mažumos klasės duomenų priauginimo (angl. *Oversampling*) metodas. Šis metodas atsitiktinai atrinka mažumų klasių įrašus ir juos pakartoja.
- Dirbtinė mažumos sukūrimo technika. (angl. *Smote*) metodas. Šis metodas sukuria sintetinius duomenis, naudodamas interpoliavimą.

### ❖ Klasifikavimo metodai.

- Klasifikavimo tikimybių slenksčio perkėlimas. (angl. *Threshold moving*). Šis metodas taikomas modelio testavimo etape. Metodo idėja – priskiriant gautas klasifikavimo tikimybės, išbandyti įvairius klasifikavimo slenksčius.
- Baudomis grįsti metodai (angl. *Cost sensitive learning*). Metodo idėja – neteisingai suklasifikuotoms klasėms priskirti baudas, didesnę baudą suteikiant mažųjų klasių reikšmėms.
- Vienos klasės klasifikavimas (angl. „*One – class classification*“). Neuroninių tinklų atveju, šis metodas vadinamas naujumo aptikimo metodu. Metodas idėja – atpažinti teisingai suklasifikuotus atvejus, o ne atskirti klases.
- Hibridinis metodas. Tai metodas, kuris sujungia kelis prieš tai paminėtus metodus.

Literatūroje [34, 29] teigiama, kad standartiniai klasifikavimo algoritmai yra sukurti taip, kad maksimizuotų bendrą teisingų prognozių skaičių. Šis kriterijus, grindžiamas prielaida, kad kiekvienoje klasėje klaidingų prognozių svarba yra vienoda. Todėl, kai turime duomenų aibę su dideliu klasių disbalansu, klasifikavimo algoritmai teikia pirmenybę didesnei klasei. Todėl dažnu atveju, didžiosios klasės prognozavimo tikslumas būna aukštas, o mažosios žemas.

Apibendrinus, galime teigti, kad tiriant klasių disbalanso įtaką giliojo mokymosi metodams [34, 19, 29, 30, 39] buvo pastebėta, kad:

- klasių disbalansas turi poveikį modelio tikslumui;
- klasių disbalanso įtaką klasifikavimo našumui, didėja kartu su užduoties sudėtingumu;
- esant ekstremaliai dideliame klasių disbalansui, modeliai apmokyti su duomenimis subalansuotais mažumos klasės duomenų priauginimo ir dominuojančios klasės duomenų išmetimo metodais, turėjo vienodai gerą tikslumą, todėl, norint sumažinti modelio apmokymo laiką, geresnis pasirinkimas duomenų subalansavimui - dominuojančios klasės duomenų išmetimo metodas;
- norint pasiekti geriausią modelio klasifikavimo tikslumą, reikėtų naudoti klasifikavimo slenksčio perkėlimo metodą;

- naudojant mažumos klasės duomenų priauginimo metodą, duomenys turėtų būti subalansuoti, taip, kad būtų visiškai panaikintas klasių disbalansas;
- naudojant dominuojančios klasės duomenų išmetimo metodą, turėtų būti atsižvelgta į esamą klasių disbalanso dydį;
- didėjantis klasių disbalansas apmokymo imtyje, daro neigiamą poveikį modelio klasifikavimo rezultatams modelio testavimo metu.

## 1.6. Tikslumo metrikos.

Klasifikavimo tikslumo rodikliai yra labai svarbūs vertinant modelių kokybę. Literatūroje išskiriami šie metrikų tipai [20, 21] :

- metrikos vertinančios paklaidas;
- metrikos pagrįstos tikimybine paklaida;
- metrikos vertinančios modelio gebėjimą klasifikuoti.

Viena iš populiariausių klasifikavimo metrikų, tai sumaišymo matrica, kuri parodo teisingai ir neteisingai suklasifikuotų duomenų atvejų skaičių. Toliau remiantis [21], pateiksime sumaišymo matricos pavyzdį, binarinio klasifikavimo atveju.

**5 lentelė.** Sumaišymo matrica [21]

Klasė		Tikrosios klasės	
		Teigiama (1)	FN
Prognozuojama klasė	Teigiama (1)	TP	FN
	Neigiama (0)	FP	TN

Toliau pateikiamos 5 lentelėje esančios santrumpos.

- TP - teisingai suklasifikuotų teigiamų atvejų skaičius.
- FP - neteisingai suklasifikuotų teigiamų atvejų skaičius.
- FN - neteisingai suklasifikuotų neigiamų atvejų skaičius.
- TN - teisingai suklasifikuotų neigiamų atvejų skaičius.

Pateikti sumaišymo matricų rodikliai, naudojami modelių tikslumo metrikų apskaičiavimui. Tyrėjai, [29, 30, 34] apžvelgę tikslumo metrikas vertinant klasifikavimo modelius su dideliu klasių disbalansu, išskiria toliau pateikiamas tikslumo metrikas.

- Jautrumas (angl. *sensitivity*) =  $\frac{TP}{TP+FN}$ . Įvertina, kokia dalis teigiamos klasės įvykių buvo priskirti teigiamai klasei.
- Specifiškumas (angl. *specificity*) =  $\frac{TN}{TN+FP} = 1 - FPR$ . Įvertina, kokia dalis neigiamos klasės įvykių buvo priskirti neigiamai klasei.
- Preciziškumas (angl. *precision*) =  $\frac{TP}{TP+FP}$ . Įvertina, kokia dalis teigiamos klasės prognozių yra teisingos.
- Bendras modelio tikslumas (angl. *accuracy*) =  $\frac{TP+TN}{TP+TN+FN+FP}$ . Įvertina, kokia dalis atvejų buvo suklasifikuoti teisingai. Kuo šis įvertis arčiau vieneto, tuo modelis yra geresnis. Remiantis [19, 21], galime teigti, kad šis rodiklis nėra tinkamiausias pasirinkimas, vertinti modelio tikslumą, duomenims su dideliu klasių disbalansu. Esant didelei daugumos klasės

persvarai, modelis gali turėti aukštą bendrą modelio tikslumą, vien todėl, kad gerai atpažįsta daugumos klasę, tačiau gali visiškai neatpažinti mažumos klases. Tačiau, bendras modelio tikslumas, gali būti naudojamas modelio hiperparametrų paieškos metu, ieškant modelio su didžiausiu bendru tikslumu.

- Klaidingai suklasifikuotų įvykių rodiklis - FPR (angl. *false positive rate*) =  $\frac{FP}{TN+FP}$ . Įvertina, kokia dalis prognozių buvo klaidingos.
- Geometrinis jautrumo ir specifiškumo vidurkis =  $\sqrt{jautrumas \cdot specifiškumas}$ . Šis įvertis įgyja maksimalią reikšmę, tuomet, kai *jautrumas* = *specifiškumas*. Šis įvertis literatūroje, siūlomas naudoti, kaip alternatyva bendram modeliui tikslumui, tiriant, klasifikavimo rezultatus, duomenų aibėje su dideliu klasių disbalansu [29].
- F1 rodiklis (angl. *f1 score*) =  $\frac{(1+\beta^2) \cdot jautrumas \cdot preciziškumas}{\beta^2 \cdot preciziškumas + jautrumas}$  - preciziškumo ir jautrumo svorinis geometrinis vidurkis. Koeficientas  $\beta$  – vertina jautrumo ir preciziškumo rodiklių svarbumą. Jeigu  $\beta > 1$ , tuomet F1 rodiklio vertinimas, daugiau atsižvelgia į jautrumą, jei  $\beta < 1$ , svarbesnis rodiklis yra preciziškumas, jei  $\beta = 1$ , sakoma, kad jautrumas ir preciziškumas yra vienodai svarbūs [29].

Modelio gebėjimą klasifikuoti, galima vertinti ir grafiškai. Norint įvertinti modelio klasifikavimo tikslumą prie skirtingų klasifikavimo tikimybių slenksčių, naudojama ROC kreivė (angl. *Receiver operating characteristic*). ROC kreivė vertina jautrumo ir klaidingai suklasifikuotų įvykių (angl. *false positive rate*) rodiklius, kiekvienam galimam klasifikavimo slenksčiui [30]. Iš gautos, ROC kreivės apskaičiuojama AUC metrika, rodanti plotą po ROC kreive, remiantis [30], galime teigti, kad modelis geba atskirti klases kai  $AUC > 0.5$ , o sakome, kad modelis yra idealus klasifikatorius, kai  $AUC = 1$ . Tačiau, literatūroje, pastebima, kad tiriant nesubalansuotą duomenų rinkinį, dažnai gaunama aukšta AUC metrikos reikšmė [30]. Modelis gali puikiai klasifikuoti didžiąją klasę, bet negebėti atpažinti mažosios klases, didelis klasių disbalansas, gali lemti gaunamą aukštą AUC įvertį, net ir tokiems modeliams, kurie prastai klasifikuoja mažumos klasę. Todėl, vertinant modelius, skirtus klasifikuoti duomenis su dideliu klasių disbalansu, šalia ROC kreivės siūloma naudoti PRC kreivę (angl. *Precision Recall Curve*), ši kreivė padeda įvertinti, modelio gebėjimą klasifikuoti mažumos klasę [40]. Norint vertinti klaidų aptikimo lygį, naudojama EER metrika, tai toks ROC kreivės taškas, kuris atitinka vienodą tikimybę klaidingai suklasifikuoti tiriamas klases, kuo šis įvertis mažesnis, tuo modelis geresnis [40].

## 1.7. Tyrimo uždaviniai.

Atlikus literatūros analizę, buvo pastebėta, kad iš giliojo mokymosi metodų, įmonių bankrotui prognozuoti, dažniausiai naudojami daugiasluoksniai perceptronai, tuo tarpu sąsūkų neuroniniai tinklai, yra itin retas pasirinkimas įmonių bankrotui prognozuoti, tačiau įvertinus, tai, kad tyrėjai pritaikę sąsūkų neuroninius tinklus įmonių bankroto prognozavimo uždaviniui spręsti, gavo gerus klasifikavimo rezultatus, buvo iškeltas tikslas, naudojant Lietuvos įmonių duomenis sudaryti daugiasluoksnio perceptrono ir sąsūkų neuroninio tinklo modelius.

Atsižvelgiant į literatūros apžvalgą, dėl gebėjimo vertinti praeities informaciją ir galimybės sunaudojant mažiau laiko resursų, rasti modelį su didžiausiu tikslumu, neuroninių tinklų hiperparametrų paieškai, buvo pasirinktas Bajeso optimizavimo metodas. Pastebėjus, tai, kad tiriamoje duomenų aibėje yra didelis klasių disbalansas, buvo nuspręsta prieš atliekant

hiperparametrų paiešką, įvertinti koks klasių balansas, būtų optimaliausias pasirinkimas modelio apmokymui. Tačiau atsižvelgiant į faktą, kad neuroninių tinklų modelių apmokymas užima daug laiko ir įvertinus, tai, kad apžvelgtuose tyrimuose, atsitiktinio miško modelio klasifikavimo rezultatai prilygo arba pralenkė neuroninių tinklų modelius, o atsitiktinio miško modelio apmokymas užima mažiau laiko, buvo nuspręsta, atsitiktinio miško modelį apmokyti naudojant apmokymo duomenų poaibius su skirtingais klasių balansais ir gautus modelius ištestuoti su testavimo poaibiu, kuriame išlaikomas pradinio duomenų rinkinio klasių disbalansas, o gautus rezultatus palyginti ir hiperparametrų paieškai naudoti tokį klasių balansą, su kuriuo atsitiktinio miško modelis išmoko geriausiai atpažinti bankroto atvejus, duomenų aibėje su dideliu klasių disbalansu.

Įvertinus, tai, kad klasių disbalansas daro įtaką neuroninių tinklų modelių apmokymui, buvo nuspręsta iširti klasių disbalanso įtaką modelių apmokymo metu ir modelius apmokyti su subalansuota ir nesubalansuota duomenų aibe.

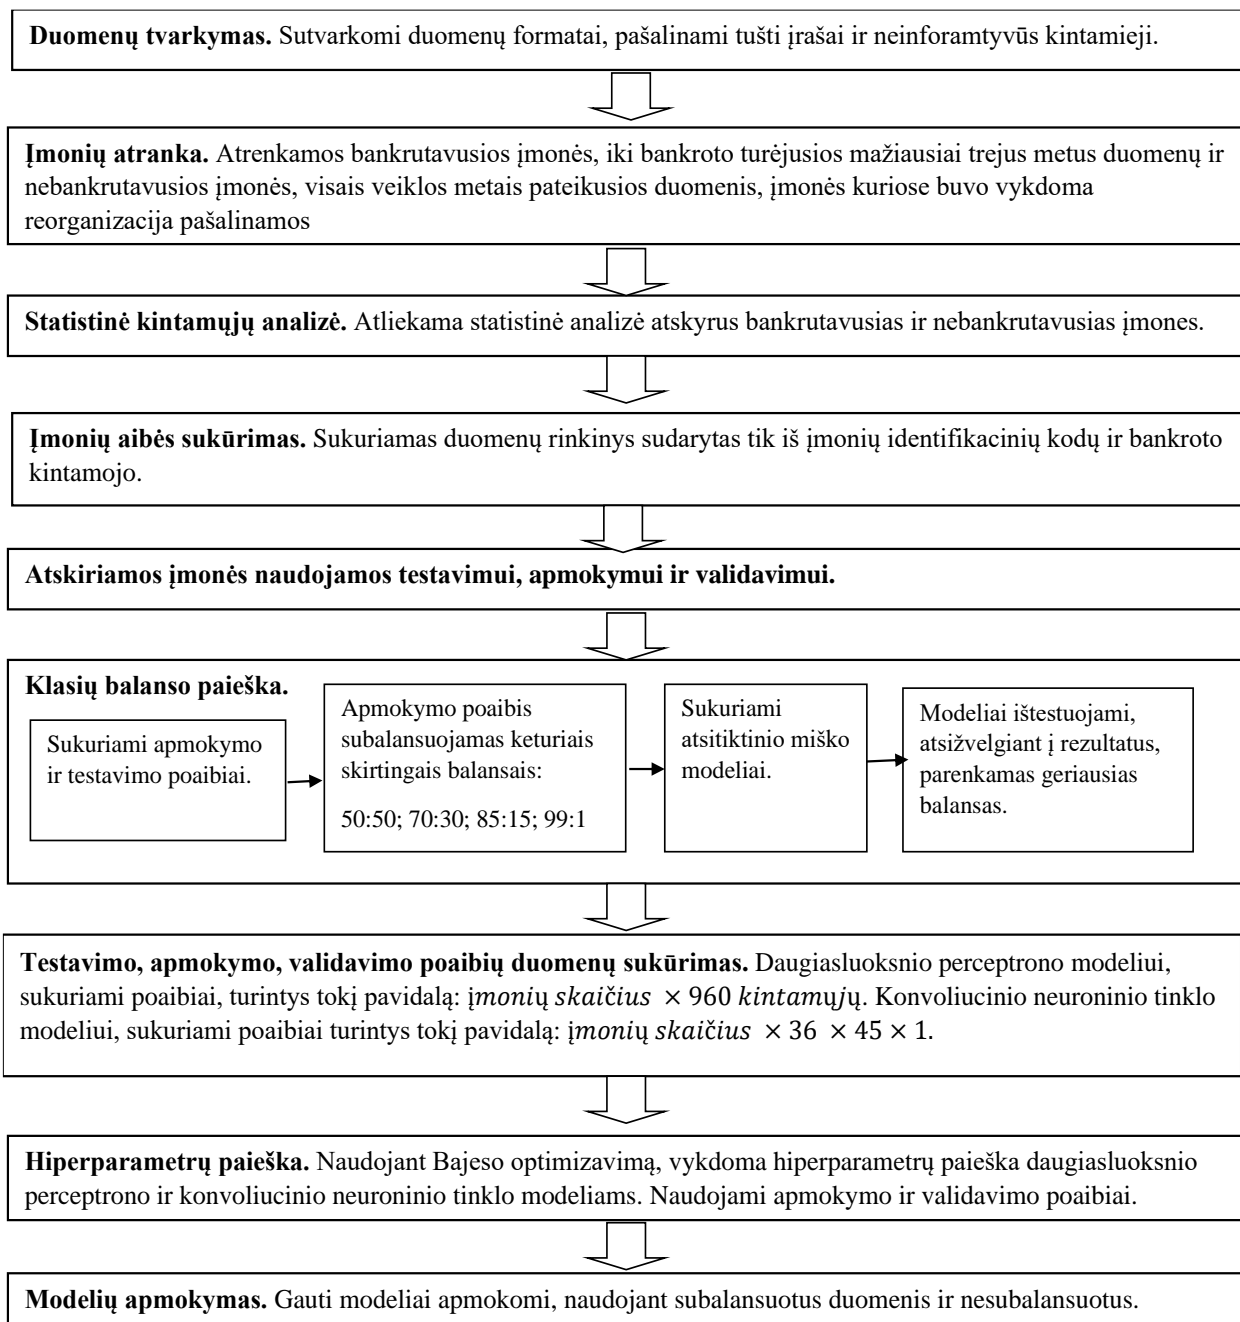
Atsižvelgiant į tai, kad modeliai kuriami naudojant realius Lietuvos įmonių duomenis, o šiuose duomenyse buvo pastebėtas didelis klasių disbalansas, buvo iškeltas tikslas, sukurti tokius modelius, kurie gebėtų atpažinti bankroto atvejus, duomenų aibėje su dideliu klasių disbalansu. Šiam tikslui pasiekti modeliai buvo testuojami su duomenų rinkiniu, kuriame buvo išlaikytas pradinio duomenų rinkinio klasių disbalansas.

Iš literatūros analizės, taip pat buvo pastebėta, kad norint įvertinti neuroninių tinklų modelių klasifikavimo tikslumą, tikslinga modelius palyginti su kitais klasifikavimo metodais. Dažniausiai, neuroninių tinklų modeliai buvo lyginami su logistinės regresijos, bei atraminių vektorių metodais. Taip pat pastebėjus, kad atsitiktinio miško metodas, klasifikavimo tikslumu, gali pralenkti neuroninių tinklų modelius, buvo nuspręsta į lyginamąją analizę traukti ir šį modelį.

Dėl savo didelės spartos ir pritaikymo giliųjų neuroninių tinklų mokymuisi, tyrime nuspręsta naudoti atvirojo kodo „Python“ programavimo kalbą ir šios įrangos biblioteka TensorFlow, kuri buvo sukurta 2015m. „Google“ komandos, tam, kad palengvintų giliojo mokymosi modelių modeliavimą.

## 2. Tyrimo metodai.

Siekiant pritaikyti giliojo mokymosi metodus įmonių bankrotui prognozuoti, buvo atliekamas tyrimas sudarytas iš kelių etapų. 1 pav. pateikiamas tyrimo planas.



1 pav. Tyrimo planas.

### 2.1. Tyrime naudojami duomenys

Pradinę duomenų imtį sudaro Lietuvos įmonių duomenys nuo 2013-01-01 iki 2018-12-01. Duomenys surinkti iš valstybinės mokesčių inspekcijos ir Sodros. Duomenų aibėje pateikiami įmonių veiklos rodikliai iš įmonių pelno – nuostolių ataskaitų, bei metinių deklaracijų. Visos įmonės yra nuasmenintos.

Pradinio duomenų rinkinio dydis 8,17 GB. Iš viso yra 64 kintamieji. Kintamųjų grupės:

- ❖ Bendra įmonės informacija:
  - įmonės amžius – 1 kintamasis,
  - ekonominė veiklos rūšis – 3 kintamieji,
  - geografinė įmonės informacija – 2 kintamieji,
  - teisinis statusas ir kodas – 5 kintamieji,
  - mokesčių mokėtojo informacija – 5 kintamieji,
- ❖ Kintamieji iš metinių deklaracijų:
  - įmonės veiklos rodikliai. – 13 kintamųjų,
  - finansiniai išvestiniai rodikliai – 9 kintamieji.
- ❖ Kintamieji iš mėnesinių deklaracijų:
  - įmonių veiklos rodikliai iš pvm deklaracijų- 13 kintamųjų,
  - informacija apie darbuotojus - 9 kintamieji,
  - darbo užmokesčio rodikliai - 2 kintamieji,
  - informacija apie įmonių nepriemokas - 2 kintamieji.

### **2.1.1. Duomenų tvarkymas**

Pradinė duomenų imtis yra pakankamai didelė, todėl natūralu, kad ne visi duomenys yra informatyvūs. Todėl prieš pradėdant kitus etapus yra atliekami šie žingsniai:

1. pašalinami tušti įrašai;
2. pašalinamos įmonės, kurios tiriamu laikotarpiu neegzistavo;
3. pašalinami kintamieji, kurie visu tiriamu laikotarpiu įgijo tą pačią reikšmę;
4. pašalinami kintamieji, kurių reikšmės visoje duomenų aibėje buvo tuščios;
5. pašalinamos įmonės, kurios tiriamu laikotarpiu nedeklaravo duomenų;
6. finansiniai rodikliai 2013 -2014m. laikotarpiu konvertuojami iš litų į eurus, naudojant nustatytą, fiksuotą Lietuvos banko valiutos kursą.

### **2.1.2. Įmonių atranka**

Tam, kad galėtume sukurti modelį bankrotui prognozuoti, turime pasirinkti tinkamas nebankrutavusias ir bankrutavusias įmones. Šiam tikslui pasiekti, sukuriame du poaibius: bankrutavusių ir nebankrutavusių įmonių. Nebankrutavusioms įmonėms priskiriamos įmonės, kurios visu tiriamu laikotarpiu vykdė veiklą, vadinasi turėjo pilnus penkerių metų veiklos duomenis. Bankrutavusioms įmonėms, priskiriamos įmonės kurioms tiriamu laikotarpiu buvo pradėta bankroto procedūra. Tačiau, mūsų nedomina, bankrutavusių įmonių duomenys po bankroto procedūros pradžios.


Įmonės, praėjusių metų veiklos duomenis, deklaruoja kiekvienų metų birželio mėnesį, todėl tariama, kad jeigu įmonei bankroto procedūra buvo pradėta iki birželio mėnesio (imtinai), tuomet paskutiniai bankrutavusių įmonių veiklos metai yra laikomi užpraeiti metai, jeigu bankroto procedūra buvo pradėta po birželio mėnesio, tuomet paskutiniai įmonės veiklos metai yra laikomi praeiti metai.

Bankrutavusių įmonių atveju, įmonės vykdė veiklą iki bankroto, įvairių laikotarpi. Atlikus literatūros analizę, pastebėjome, kad įmonių rodikliai gali pradėti rodyti pokyčius dveji metai iki



bankroto. Todėl, tam, kad galėtume stebėti bankrutavusių įmonių rodikliuose pokyčius, nusprendėme į modelių kūrimą, įtraukti bankrutavusias įmones, turinčias mažiausiai trejus metus veiklos duomenų.

Bankrutavusių įmonių skaičius, pagal veiklos metus



**2 pav.** Bankrutavusių įmonių skaičius, pagal vykdytus veiklos metus iki bankroto.

Iš 2 pav. galime pastebėti, kad įmonių vykdyusių veiklą mažiausiai trejus metus iki bankroto turime trigubai daugiau nei įmonių vykdyusių veiklą daugiau nei keturis ar penkis metus. Įvertinę, tai, kad bankrutavusių įmonių duomenų yra daug mažiau negu nebankrutavusių, nusprendėme į tyrimą įtraukti įmones, vykdyusias veiklą iki bankroto mažiausiai trejus metus.

### 2.1.3. Statistinė kintamųjų analizė


Atlikus duomenų tvarkymą, paliekami 45 kintamieji.

- ❖ Bendra įmonės informacija:
  - įmonės amžius – 1 kintamasis;
  - ekonominė veiklos rūšis – 3 kintamieji;
  - geografinė įmonės informacija – 1 kintamasis;
  - teisinis statusas ir kodas – 1 kintamasis;
  - mokesčių mokėtojo informacija – 1 kintamasis.
- ❖ Kintamieji iš metinių deklaracijų:
  - įmonės veiklos rodikliai. – 11 kintamųjų;
  - finansiniai išvestiniai rodikliai – 9 kintamieji.
- ❖ Kintamieji iš mėnesinių deklaracijų:
  - įmonių veiklos rodikliai iš pvm deklaracijų - 6 kintamieji;
  - informacija apie darbuotojus - 8 kintamieji;
  - darbo užmokesčio rodikliai – 2 kintamieji;
  - informacija apie įmonių nepriemokas – 2 kintamieji.

Norint įsitikinti, kad trejų metų duomenų gali pakakti modelių kūrimui, kintamiesiems atliekama statistinė kintamųjų analizė. Tiek bankrutavusioms, tiek nebankrutavusioms įmonėms, pamečiui,


nagrinėjami treji paskutiniai įmonių veiklos metai. Apskaičiuojami metiniai maksimumo, minimumo, vidurkio ir standartinio nuokrypio įverčiai. Visos rodiklių reikšmės yra pateikiamos 1 - 8 prieduose.

Atlikus statistinę analizę, pastebėjome, kad kai kurie nebankrutavusių įmonių rodikliai, rodė reikšmingus pokyčius jau dveji metai iki bankroto, o vieneri metai iki bankroto, dauguma rodiklių rodė neįprastas reikšmes. Vertinant metinių kintamųjų vidurkius, daugiausiai pokyčių pastebėjome, išvestinių finansinių rodiklių vidurkiuose. Toliau pateiksime bankrutavusių ir nebankrutavusių įmonių, finansinių išvestinių rodiklių diagramas.




3 pav. Pardavimo rodiklių vidurkiai.

Iš bankrutavusių ir nebankrutavusių įmonių pardavimo pajamų pardavimo savikainos vidurkių pateiktą 3pav., galime pastebėti, bankrutavusių įmonių pardavimų savikainos kritimą, kai nebankrutavusių įmonių atveju šis rodiklis išlieka stabilus.



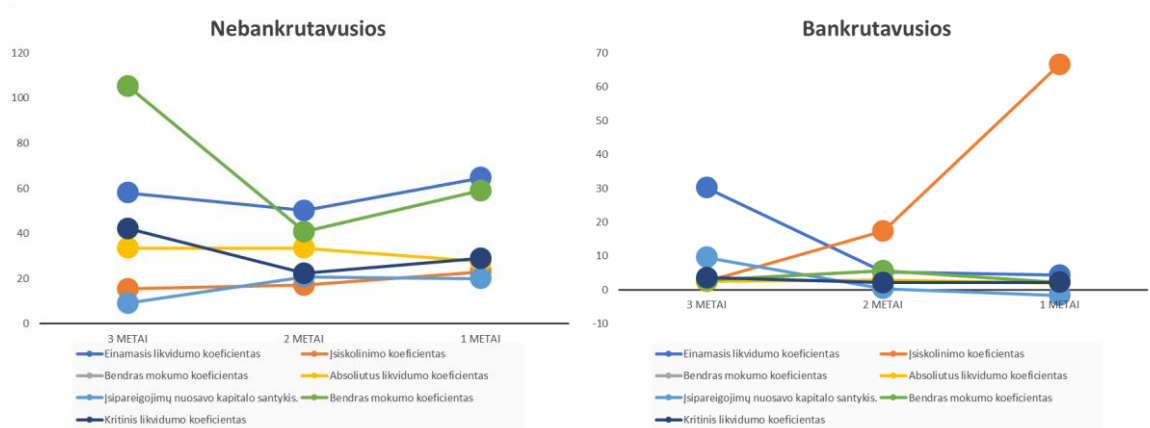
4 pav. Pelno ir pinigų rodiklių vidurkiai.

4 pav. galime matyti, tai, kad nebankrutavusių įmonių pelnas prieš mokesčius ir grynasis pelnas išlieka stabilus visais trejais metais, tuo tarpu bankrutavusių įmonių atveju, abu šie rodikliai rodo sumažėjimą antraisiais metais, ir staigų kritimą paskutiniais įmonių veiklos metais. Taip pat galime pastebėti, kad bankrutavusių įmonių atveju, paskutiniais veiklos metais išauga pinigų ir pinigų ekvivalentų reikšmė.




**5 pav.** Turto, atsargų, kapitalo ir trumpalaikių įsipareigojimų vidurkiai.

Vertinant turto, atsargų, kapitalo ir įsipareigojimų vidurkius 5 pav. galime išskirti, tai, kad bankrutavusių įmonių atveju, paskutiniais veiklos metais nuosavo kapitalo vidurkis tapo neigiamas.



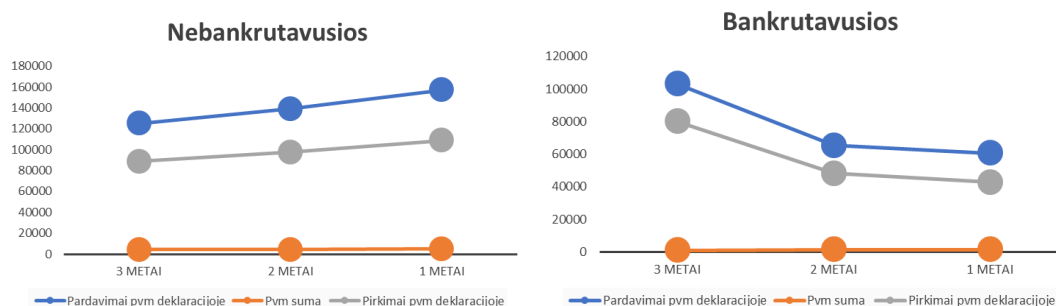
**6 pav.** Einamojo likvidumo, įsiskolinimo, bendro mokumo, absoliutaus likvidumo, kritinio likvidumo, įsipareigojimų ir nuosavo kapitalo santykio koeficientų vidurkiai.

Iš 6 pav. galime pastebėti, tai, kad visi nebankrutavusių įmonių rodikliai išskyrus įsiskolinimo koeficientą buvo didesni nei bankrutavusių įmonių. Taip pat galime išskirti, tai kad bankrutavusių įmonių įsiskolinimo koeficientas nuolatos augo, o einamojo likvidumo koeficientas sumažėjo ir tapo artimas nuliui, likus dvejiems metams iki bankroto.



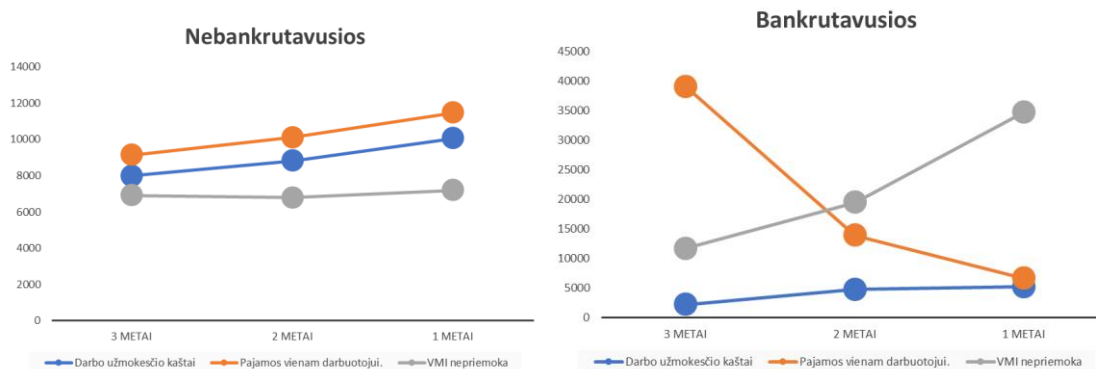
**7 pav.** Apyvartinio kapitalo ir įsipareigojimų vidurkiai.

Vertinant apyvartinio kapitalo ir įsipareigojimų vidurkius, galime išskirti tai, kad bankrutavusių įmonių apyvartinis kapitalas buvo artimas nuliui, o likus vieniems metams iki bankroto tapo neigiamas.



8 pav. Pvm rodiklių vidurkiai.

Vertinant pvm rodiklius 8pav. galime pastebėti, kad bankrutavusių įmonių pardavimai ir pirkimai krito, o didžiausias sumažėjimas matomas antraisiais metais.




9 pav. Darbo užmokesčio, pajamų vienam darbuotojui ir VMI nepriemokų vidurkiai.

Vertinant darbo užmokesčio, pajamų tenkančių vienam darbuotojui ir VMI nepriemokų vidurkius 9 pav., pastebėjome, tai, kad bankrutavusių įmonių atveju – darbo užmokesčio kaštai, buvo ženkliai mažesni nei nebankrutavusių įmonių. Taip pat matome, kad bankrutavusių įmonių atveju, pajamos vienam darbuotojui stipriai krenta antraisiais metais ir dar šiek paskutiniaisiais įmonių veiklos metais, kai tuo tarpu nebankrutavusių įmonių atveju – išlieka stabilios. Iš VMI nepriemokų vidurkių, galime pastebėti, kad bankrutavusių įmonių atveju, įmonių nepriemokos auga, kai nebankrutavusioms įmonėms išlieka stabilios.

## 2.2. Įmonių aibės sukūrimas. Įmonių skirtų testavimui, apmokymui ir validavimui atskyrimas.

Atrinkus įmones ir atlikus kintamųjų statistinę analizę, sukuriama bendra modelio duomenų imtis, kurią sudaro 80058 įmonės. Sukuriamas naujas binarinis kintamasis rodantis ar įmonei buvo pradėta bankroto procedūra. Bankrutavusioms įmonėms priskiriamas vieneto reikšmė, nebankrutavusioms nulinė reikšmė. Įvertinus, tai, kad daugiasluksniam perceptronui ir sąsūky neuroniniam tinklui, naudojami skirtingų formatų duomenys, norėdami modelius apmokyti, testuoti ir validuoti su jų

pačių įmonių duomenimis, nusprendėme sukurti duomenų rinkinį sudarytą iš dviejų kintamųjų: įmonės identifikacinio kodo ir kintamojo rodančio ar įmonė priklauso bankroto klasei. Siekiant įvertinti modelių gebėjimą atskirti bankroto atvejus nesubalansuotoje duomenų aibėje, prieš atliekant duomenų subalansavimo žingsnį, iš įmonių aibės atskiriama 15% įmonių, kurios bus naudojamos modelių testavimui, iš viso testavimui atskiriama 12023 įmonių. Likusios įmonės bus naudojamos kuriant apmokymo ir validavimo poaibius, pažymėsime, kad bus sudaromi dveji skirtingai apmokymo ir validavimo poaibių variantai: išlaikant klasių disbalansą ir subalansavus klases. Nebalansuojant duomenų, poaibiuose bus išlaikomas klasių disbalansas, vaizduojamas 10 pav., subalansuojant duomenis, bus naudojamas dominuojančios klasės išmetimo metodas (angl. *undersampling*).



**10 pav.** Bankrutavusių ir nebankrutavusių įmonių klasių disbalansas, tiriamoje duomenų aibėje

### 2.3. Klasių balanso paieška

Geriausio neuroninio tinklo hiperparametrų paieška, naudoja daug atminties resursų ir laiko. Ieškant modelio hiperparametrų, kiekvieną kart sukuriamas neuroninių tinklų modelis, gautas modelis apmokomas ir testuojamas. Todėl, hiperparametrų paieškos taikymas, naudojant skirtingus apmokymo poaibius (poaibius su skirtingais klasių balansais), užimtų daug laiko. Atlikus literatūros apžvalgą, pastebėjome, kad atsitiktinio miško modelis įmonių bankroto prognozavime, dažnu atveju tikslumu prilygdavo arba pranokdavo neuroninių tinklų modeliams. Įvertinus tai, kad atsitiktinio miško apmokymas užima mažiau laiko nei neuroninių tinklų modeliai, buvo nuspręsta, ieškant geriausio klasių subalansavimo, apmokyti atsitiktinio miško modelį su skirtingais klasių balansais ir ištestuoti su nesubalansuota duomenų aibe, įvertinus gautus rezultatus, naudoti tokį klasių balansą, kuris geriausiai apmokė modelį atpažinti bankroto atvejus. Buvo nuspręsta modelį apmokyti su šiais klasių balansais:

- 50% bankrutavusių įmonių, 50% ne bankrutavusių;
- 70% bankrutavusių įmonių, 30% ne bankrutavusių;
- 85% bankrutavusių įmonių, 15% ne bankrutavusių;

- Nesubalansuotoje duomenų aibėje, kur 99% nebankrutavusių įmonių, 1% bankrutavusių.

### 2.3.1. Apmokymo, validavimo ir testavimo poaibių sukūrimas

Tam, kad galėtume sukurti neuroninių tinklų modelius, duomenis turime konvertuoti į modeliams tinkamus pavidalus. Daugiasluoksniui perceptronui, kiekviena įmonė turi būti pateikiama kaip vienmatis vektorius, tai yra visame duomenų rinkinyje, vienos įmonės duomenys, turi užimti, vieną eilutę. Tuo tarpu sąsūkų neuroninio tinklo atveju, duomenys turi būti pateikiami matricų pavidalu, kur viena įmonė, pateikiama kaip viena matrica. Toliau pateiksime duomenų konvertavimą, kiekvienam modeliui atskirai. Pristatomi duomenų konvertavimo metodai, yra atliekami testavimo, validavimo ir apmokymo duomenims. Jeigu kuriami subalansuoti poaibiai, prieš tai yra subalansuojamos įmonės naudojamos apmokymui ir validavimui.

Daugiasluoksnių perceptrono modelio duomenų konvertavimo metu atliekami šie žingsniai:

- iš modelio duomenų aibės, atrenkami tiriamų įmonių duomenys (atininkamai testavimo, apmokymo, validavimo įmonių);
- atskiriami bankrutavusių ir nebankrutavusių įmonių poaibiai;
- bankrutavusioms įmonėms, sukuriamas kintamasis, kiekvienos įmonės įrašui, rodantis kelintas, tai įmonės periodas (mėnesis) iki bankroto;
- nebankrutavusioms įmonėms, sukuriamas, naujas kintamasis, rodantis kelintas tai įmonės periodas (mėnesis) iki paskutinio įmonės veiklos įrašo;
- bankrutavusioms ir nebankrutavusioms įmonėms, paliekami paskutinių trejų metų duomenys, kitaip tariant 36 paskutiniai periodai;
- bankrutavusioms įmonėms sukuriami nauji kintamieji, naudojant suvestinės lentelės funkciją (angl. *pivot table*), kaip indeksą imant kintamąjį rodantį kelintas, tai įmonės periodas iki bankroto;
- nebankrutavusioms įmonėms sukuriami nauji kintamieji, naudojant suvestinės lentelės funkciją (angl. *pivot table*), kaip indeksą imant kintamąjį rodantį kelintas, tai įmonės periodas iki paskutinio įmonės veiklos įrašo;
- sujungiami bankrutavusių ir nebankrutavusių įmonių duomenys;
- ištrinami kintamieji, kurių reikšmėms visoms įmonėms buvo tuščios, kitaip tariant metiniams kintamiesiems, paliekami tik trys kintamieji, kiekvieniems metams imant po vieną;
- gaunamas duomenų rinkinys, sudarytas iš 959 kintamųjų.

Atliekamas duomenų konvertavimas vaizduojamas 11 pav.

Data	Įmonės identifikacinis kodas	Kintamasis A	Kintamasis B
2015-01	Įmonė X	1	4
2015-02	Įmonė X	2	5
2015-03	Įmonė X	3	6
2015-01	Įmonė Y	0	-3
2015-02	Įmonė Y	-1	-4
2015-03	Įmonė Y	-2	-5

Pritaikome suvestinės lentelės funkciją (angl. *pivot*)

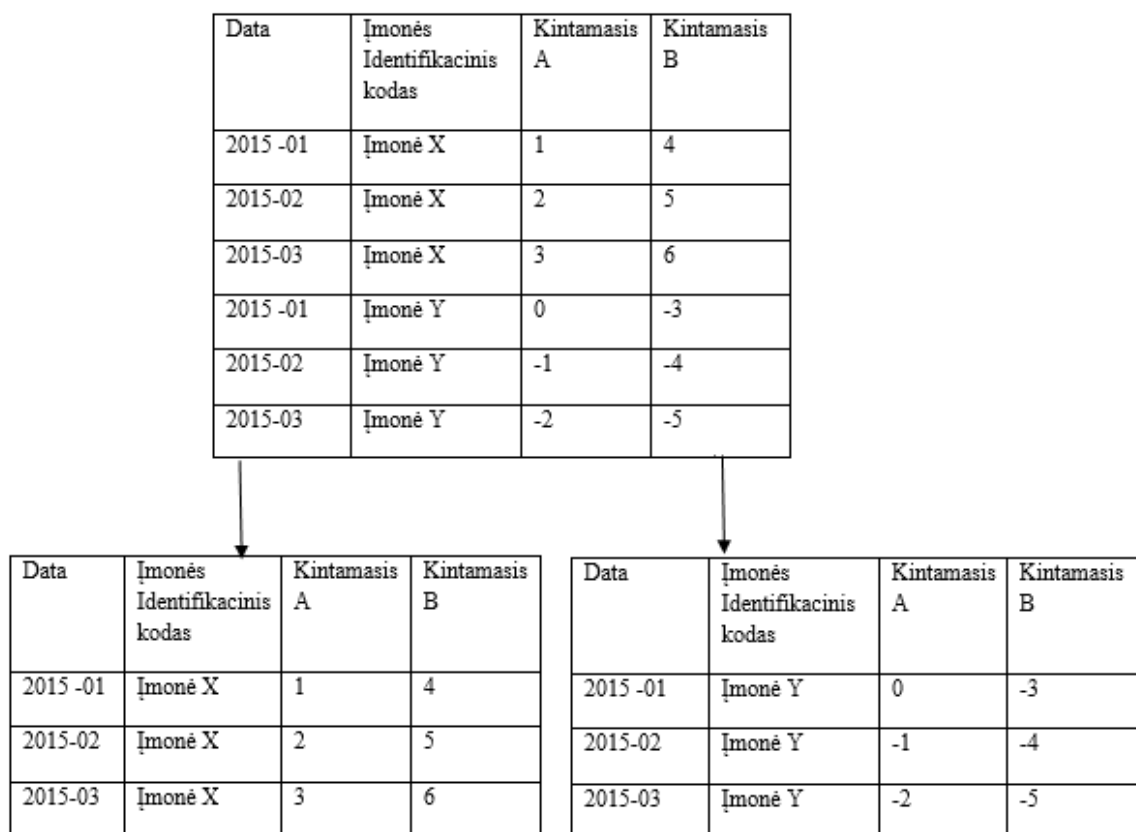
Data	Įmonės identifikacinis kodas	Kintamasis A -1	Kintamasis A-2	Kintamasis A-3	Kintamasis B -1	Kintamasis B-2	Kintamasis B-3
2015-01	Įmonė X	3	2	1	6	5	4
2015-02	Įmonė Y	-2	-1	0	-5	-4	-3

**11 pav.** Įmonių duomenų konvertavimas daugiasluoksnio perceptrono modeliui

Sąsūkų neuroninio tinklo duomenų konvertavimo metu atliekami šie žingsniai:

- iš modelio duomenų aibės, atrenkami tiriamų įmonių duomenys (atininkamai testavimo, apmokymo, validavimo įmonių);
- kiekvienai įmonei paliekami paskutinių trejų metų duomenys, kitaip tariant 36 paskutiniai periodai;
- tuščios reikšmės užpildomos nuliais,
- gauta duomenų aibė yra konvertuojama į trimatę erdvę, kur kiekviena įmonė yra paverčiama į matricą, kurios pavidalas yra:  $36 \times 45 \times 1$ . Gautos duomenų aibės pavidalas tuomet yra toks: *įmonių skaičius*  $\times 36 \times 45 \times 1$ .

Atliekamas duomenų konvertavimas, vaizduojamas 12 pav.




12 pav. Įmonių duomenų konvertavimas sąsūkų neuroniniams tinklams

## 2.4. Giliojo mokymosi modeliai.

Tyrimo metu yra naudojami šie modeliai: daugiasluoksnis perceptronas ir sąsūkų neuroninis tinklas. Abu šie modeliai priskiriami tiesioginio sklidimo dirbtinių neuroninių tinklų modeliams.

### 2.4.1. Dirbtiniai neuroniniai tinklai.

Dirbtiniai neuroniniai tinklai – tai informacijos apdorojimo sistemos, paremtos biologinio neurono veikimo principu. Kaip ir žmogaus smegenų atveju, dirbtiniai neuroniniai tinklai yra pagrįsti tarpusavyje sujungtais neuronais. Kiekvienai jungčiai priskirti koeficientai, vadinami neuronų svoriais. Toliau, 13 pav. pateikiama dirbtinio neurono schema, sudaryta, remiantis [25].



13 pav. Dirbtinio neurono schema




Pirmasis neuroninio tinklo sluoksnis, vadinamas įvesties sluoksniu. Įvestys – tai duomenys perduodami tinklui. Išeinančios jungtys, vadinamos išvestimis. Neuronų išvesties reikšmė, gaunama susumuojant įvesčių ir jų svorių sandaugas ir pritaikant aktyvacijos funkciją. Dažnu atveju neuronai turi poslinkius, poslinkio reikšmė yra padauginama iš vieneto ir pridedama prie bendros įvesčių ir svorių sandaugos. Išvesties reikšmę, pateiktą 13 pav. galime apibrėžti taip: tarkime turime  $n$  įvesčių, ir neuroną su svoriais  $w_1, w_2, \dots, w_n$ , bei poslinkiu  $b$ . Tuomet neuronų išvesties reikšmė  $y_i$  bus lygi:

$$y_i = f\left(\sum_{i=1}^n w_i x_i + b\right).$$

Sukombinavus du ar daugiau neuronų, sudaromas dirbtinis neuroninis tinklas.

### 2.4.2. Tiesioginio sklidimo neuroniniai tinklai

Tiesioginio sklidimo neuroniniuose tinkluose, neuronai yra grupuojami į sluoksnius, o sluoksniai sujungiami taip, kad tinkle nesudarytų ciklai. Šių neuroninių tinklų atveju, kiekvienais dirbtinis neuronas iš esamo sluoksnio yra sujungtas su kiekvienu dirbtiniu neuronu iš praeities sluoksnio. Šiame tinkle duomenys negali būti siunčiami į praeitus sluoksnius. Tiesioginio sklidimo neuroniniai tinklai, vadinami giliaisiais, tuomet, kai turi daugiau nei vieną paslėptąjį sluoksnį. Toliau 14 pav., pavaizduosime gilų daugiasluoksnio perceptrono modelį, remiantis [25]:



14 pav. Daugiasluoksnio perceptrono modelis

Pirmasis neuroninio tinklo sluoksnis, vadinamas įvesties sluoksniu, paskutinis – išvesties, o sluoksniai esantys tarp įvesties ir išvesties sluoksnių – paslėptieji sluoksniai. Sluoksnių išsiskirstymas, skaičiavimams, leidžia naudoti matricų operacijas. Jeigu  $W_i$  yra į  $i$ -ąjį sluoksnį įeinančių jungčių svorių matrica,  $h_{i-1}$  prieš tai einančio sluoksnio išvestis, tai  $i$ -ojo sluoksnio išvestis  $h_i$ , apskaičiuojama taip:

$$h_i = f(W \cdot h_{i-1}),$$

Toliau pavaizduosime, kaip yra apskaičiuojamos neuronų reikšmės iš vieno sluoksnio į kitą. Tarkime turime įvesties sluoksnį su keturiomis įvesties reikšmėmis:  $x_1, x_2, x_3, x_4$ . Iš įvesties sluoksnio, duomenys perduodami į paslėptąjį sluoksnį, su trimis neuronais, kiekvienas neuronas turi

po keturias svorių reikšmes  $w_{i1}, w_{i2}, w_{i3}, w_{i4}$  ir tris poslinkių reikšmes  $b_i$ , čia  $i$  žymi neurono eilę. Pažymėkime aktyvacijos funkciją  $f$ .

Tuomet sekančio sluoksnio įvestys yra apskaičiuojamos taip:

$$\begin{bmatrix} w_{11} & w_{12} & w_{13} & w_{14} \\ w_{21} & w_{22} & w_{23} & w_{24} \\ w_{31} & w_{32} & w_{33} & w_{34} \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ x_3 \\ x_4 \end{bmatrix} + \begin{bmatrix} b_1 \\ b_2 \\ b_3 \end{bmatrix} = \begin{bmatrix} w_{11}x_1 + w_{12}x_2 + w_{13}x_3 + w_{14}x_4 + b_1 = a_1 \\ w_{21}x_1 + w_{22}x_2 + w_{23}x_3 + w_{24}x_4 + b_2 = a_2 \\ w_{31}x_1 + w_{32}x_2 + w_{33}x_3 + w_{34}x_4 + b_3 = a_3 \end{bmatrix} = \begin{bmatrix} f(a_1) = y_1 \\ f(a_2) = y_2 \\ f(a_3) = y_3 \end{bmatrix}$$

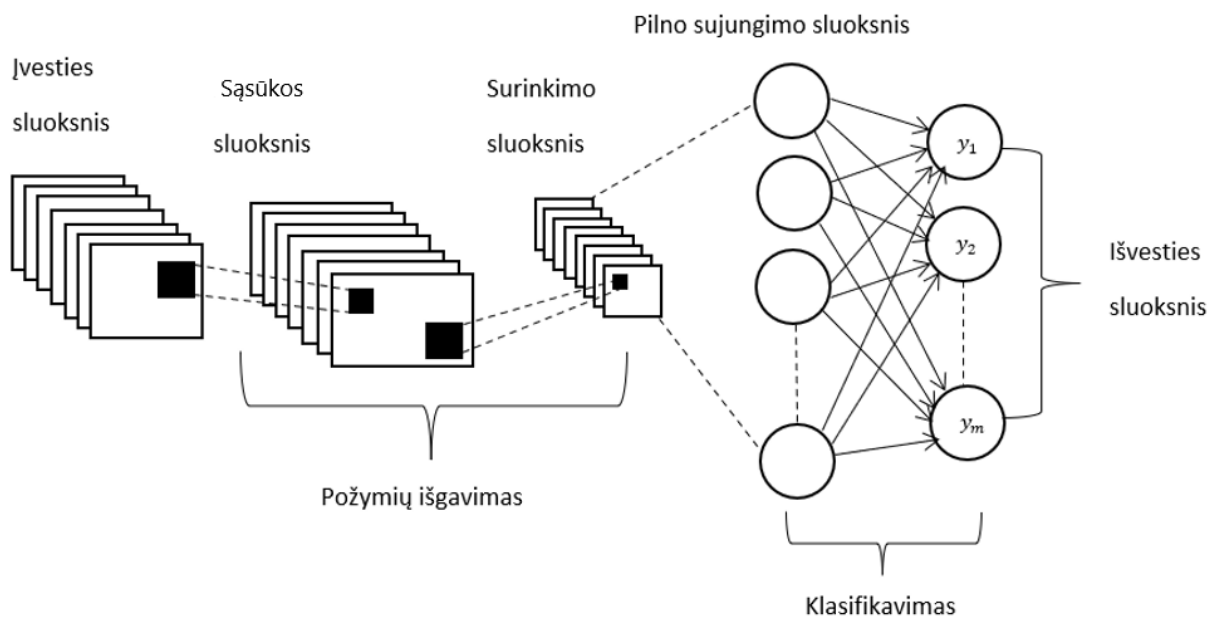
Čia  $y_1, y_2, y_3$  – gautos paslėptojo sluoksnio reikšmės.

### 2.4.3. Sąsūkų neuroniniai tinklai

Sąsūkų neuroniniai tinklai yra plačiai taikomi vaizdų analizėje. Trys pagrindiniai sąsūkų neuroninių tinklų sluoksniai:

- sąsūkos sluoksnis,
- surinkimo sluoksnis (angl. *pooling*),
- pilnai sujungtas sluoksnis.

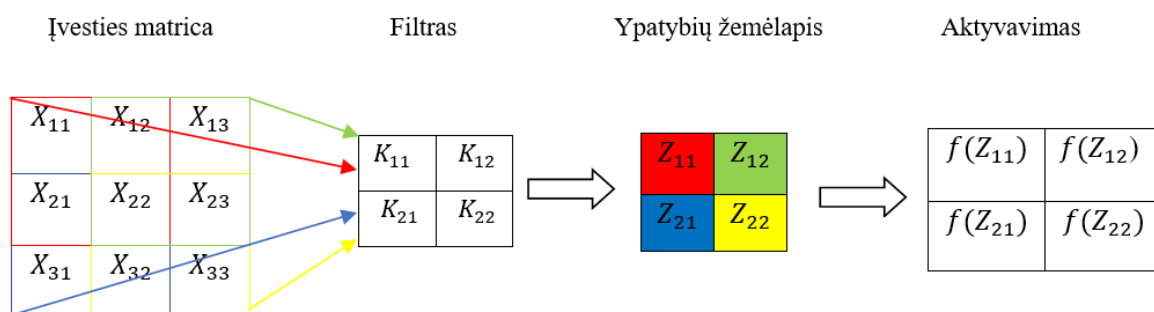
Toliau yra pateikiama schema, rodanti, kaip įvestis yra perduodama į sąsūkų neuroninį tinklą su trimis paslėptaisiais sluoksniais. Sąsūkų neuroniniame tinkle, neuronai sluoksniuose išdėstyti trijose dimensijose: plotis, aukštis, gylis. Toliau aptarsime pagrindinius sąsūkų neuroninio tinkle sluoksnius, vaizduojamus 15 pav., kuris sudarytas remiantis [22].



15 pav. Sąsūkų neuroninio tinklo schema

### Sąsūkos sluoksnis.

Pagrindinis sąsūkos sluoksnio tikslas, naudojant apmokomus filtrus (angl. *kernels*), išgauti duomenų ypatybes. Kaip ir neuronai, taip ir filtrai yra išdėstyti trijose dimensijose. Filtrų plotis ir aukštis, lyginant su įvesties duomenimis, beveik visuomet būna mažesni, o filtro gylis yra lygus prieš jį einančio sluoksnio gyliui. Sąsūkos sluoksnyje yra atliekama sąsūkos operacija, kurią toliau apibrėšime. Tarkime turime įvesties matricos elementus -  $X_{ij}$ , kur  $i$  -eilutės numeris,  $j$  – stulpelio, tarkime, kad  $i, j = 1, 2, \dots, N$  ir filtro matricos elementus -  $Y_{ij}$ , kur  $i$  -eilutės numeris,  $j$  – stulpelio, tarkime, kad  $i, j = 1, 2, \dots, M$ . Tuomet sąsūkos operacijos metu atliekama daugybos operacija, kuri yra apibrėžiama taip:  $\sum_{i=1}^N \sum_{j=1}^M X_{ij} \cdot Y_{ij}$ . Sąsūkos operacija yra atliekama, filtrams slenkant (angl. *convolve*) per įvesties duomenų matricą. Sąsūkos sluoksnį nusako šie hiperparametrai: filtro dydis, filtrų skaičius, filtro slinkimo žingsnis (angl. *stride*). Rezultatas, kuris gaunamas atlikus sąsūkos operaciją, vadinamas ypatybių žemėlapiu. (angl. *feature map*). Galutinė sąsūkų neuroninio tinklo išvestis, gaunama ypatybių žemėlapio reikšmėms pritaikius aktyvacijos funkciją. Toliau pavaizduosime sąsūkos sluoksnio metu vykstančias operacijas. Tarkime turime įvestį, kuri yra  $3 \times 3$  matrica, filtrą kuris yra  $2 \times 2$  matrica, poslinkį  $B$  ir aktyvacijos funkciją  $f$ . Matricos elemento reikšmę apibrėžkime  $X_{ij}$ , čia  $i, j = 1, 2, 3$ , filtro elemento reikšmę, apibrėžkime-  $K_{ln}$ , čia  $l, n = 1, 2$ . Pavaizduokime sąsūkos sluoksnio metu atliekamas operacijas, kai turim vieną filtrą. 16 pav. pateikiama schema, sudaryta remiantis [22].



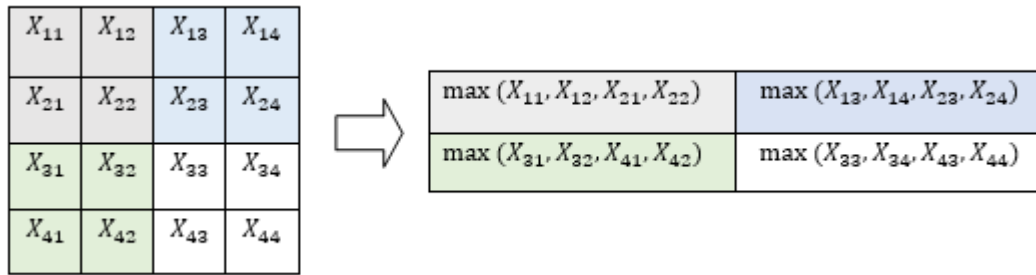
16 pav. Sąsūkos sluoksnis.

Pavaizduokime atliktus skaičiavimus,  $Z_{11}$  elementui:

$$\begin{bmatrix} X_{11} & X_{12} \\ X_{21} & X_{22} \end{bmatrix} \begin{bmatrix} K_{11} & K_{12} \\ K_{21} & K_{22} \end{bmatrix} + B = X_{11}K_{11} + X_{12}K_{12} + X_{21}K_{21} + X_{22}K_{22} + B = Z_{11}$$

### Surinkimo sluoksnis.


Surinkimo sluoksnyje yra sumažinamas kiekvienos įvesties dydis. Pagrindinis šio sluoksnio tikslas, kontroliuoti modelio persimokymą ir sumažinti tinklo parametrų kiekį, taip pagreitinant tinklo apmokymą. Šiame sluoksnyje taip pat yra slenkama per duomenų matricą, pritaikant surinkimo sluoksnio funkciją. Šį sluoksnį nusako žingsnio dydis ir surinkimo funkcija. Populiariausios surinkimo funkcijos, tai maksimumo arba vidurkio apskaičiavimas. Tarkime turime duomenų matricą,  $4 \times 4$  pavidalo, surinkimo žingsnį lygų dviem, surinkimo funkciją - maksimumo. Toliau, remiantis [22], pavaizduosime, surinkimo sluoksnio metu atliekamas operacijas.



17 pav. Surinkimo sluoksnis

*Pilno sujungimo sluoksnis.*

Pilno sujungimo sluoksnyje, gauti duomenys, konvertuojami į vienmatę erdvę, kitaip tariant šiam sluoksniui perduodamos įvestys yra paverčiamos į vektorių. Tuomet gautoms reikšmėms pritaikoma aktyvacijos funkcija. Pavaizduosime, pilno sujungimo sluoksnio metu atliekamus veiksmus. Tarkime turime  $2 \times 2$  įvesties matricą, tuomet šio sluoksnio metu bus atliekama tokia operacija:



18 pav. Pilnai sujungtas sluoksnis

Reikšmės  $Y_1, Y_2, Y_3, Y_4$  yra gaunamos analogiškai kaip ir daugiasluoksnio perceptrono atveju.

*Sąsūkų neuroninio tinklo išvesties sluoksnis.*

Išvestis yra gaunama pritaikius pasirinktą aktyvacijos funkciją, dažnu atveju yra naudojama „softmax“ arba „sigmoid“ funkcijos. Šiame sluoksnyje yra gaunamos klasifikavimo tikimybės, vėliau parinkus norimą slenksį, gauti rezultatai yra klasifikuojami.

**2.5. Dirbtinių neuroninių tinklų apmokymas.**

Sprendžiant vis ambicingesnes problemas, naudojami modeliai tampa vis sudėtingesni. Tinkamas hiperparametrų įvedimas yra itin svarbus modelio tikslumui. Yra daugybė hiperparametrų paieškos metodų, pradedant nuo atsitikinės paieškos iki sudėtingesnių algoritmų. Šie metodai, padeda surasti

tinkamiausią neuroninio tinklo architektūrą ir nustatyti optimaliausius neuroninio tinklo hiperparametrus. Tyrimo metu, yra ieškomos optimaliausios šių hiperparametrų reikšmės:

- sluoksnių skaičius,
- aktyvacijos funkcija,
- optimizavimo algoritmas,
- neuronų pašalinimas,
- neuronų normalizavimas,
- mokymosi greitis,
- epochų skaičius,
- partijos dydis.

### **2.5.1. Bajeso optimizavimas.**

Tyrimo metu, hiperparametrų paieškai, naudojamas Bajeso optimizavimas. Bajeso optimizavimas, tai globalaus optimizavimo metodas, galintis optimizuoti sudėtingas, triukšmingas juodųjų dėžių funkcijas. Literatūroje, šis metodas yra išskiriamas iš kitų paieškos metodų, dėl savo lankstumo ir gebėjimo tirti neapibrėžtas funkcijas [13]. Dažniausiai naudojamas Bajeso optimizavimo metodas - paremtas Gauso procesu. Tarkime turime parametrų aibę  $x$  ir tikslo funkciją  $f$  kurios pavidalo nežinome. Akivaizdu, kad  $f$  yra sudėtinga įvertinti, nes nežinome šios funkcijos formos, struktūros ir ypatybių. Taigi galime teigti, kad  $f$  yra juodoji dėžė. Tuomet kaip pakaitinis modelis yra naudojamas Gauso procesas. Pakaitinis modelis optimizuojamas tol kol yra patenkinama sustojimo sąlyga arba pasiekiamas konvergavimas. Bajeso optimizavimas kaip ir kiti paieškos metodai, daug kartų apskaičiuoja modelį su skirtingomis hiperparametrų reikšmėmis, tačiau šio metodo pranašumas yra tai, kad vykdoma paieška nėra atsitiktinė, o paremta ankstesnės informacijos vertinimu, o tai leidžia atrasti modelį su didžiausiu tikslumu, sunaudojant mažiau resursų.

### **2.5.2. Atgalinės sklaidos metodas**

Prieš tai aptartų neuroninių tinklų apmokymui, yra naudojamas atgalinės sklaidos metodas. Daugiasluoksniui perceptronui apmokymo metu, keičiami jungčių svoriai, sąsūkų neuroniniam tinklui, keičiami jungčių ir filtrų svoriai. Keičiant jungčių svorius, naudojamas atgalinės sklaidos metodas [23]. Šio metodu metu, pirmiausiai atsitiktinai sugeneruojami viso tinklo svoriai, tuomet iš apmokymo duomenų imties, parenkamas vienas elementas, kuris pateikiamas neuroniniam tinklui kaip įvesties sluoksnis. Atlikus neuroninio tinklo skaičiavimus, gaunamas išvesties sluoksnis, su pasirinkta klaidos funkcija apskaičiuojama klaidos reikšmė tarp gauto ir norimo rezultato. Tuomet, pasluoksniui, pradedant nuo išvesties sluoksnio, grįžtama atgal ir naudojant atgalinės sklaidos metodą, apskaičiuojami lokalūs gradientai. Pasirinktu optimizavimo metodu, ieškoma klaidos funkcijos minimumo.

### **2.5.3. Optimizavimo algoritmai.**

Tyrimo metu, ieškant geriausio optimizavimo algoritmo, buvo išbandyti septyni skirtingai variantai. Toliau bus pristatoma, tyrimo metu naudoti optimizavimo algoritmai.

1. Adam (angl. *Adaptive Moment Estimation*) algoritmas. Stochastinis optimizavimo metodas, kuris naudoja tik pirmos eilės gradientų reikšmes, taip sunaudodamas mažiau atminties resursų.

Šis algoritmas, pirmojo ir antrojo gradientų įverčių skirtingiems parametrams, taiko skirtingus mokymosi greičius. Adam algoritmas, sujungia dviejų kitų optimizavimo algoritmų privalumus: AdaGrad algoritmo, kuris rodo gerus rezultatus retiems gradientams ir RMSProp, kuris rodo gerus rezultatus nestacionariems gradientams [27, 16]. Šis algoritmas, mokymosi greitį, kiekvienam parametru pritaiko atskirai, todėl ir yra priskiriamas prie adaptivių metodų. Adam išsaugo eksponentiškai mažėjančius praeities kvadratinius gradientų vidurkius, tačiau skirtingai nei Adadelta ir RMSprop, šis algoritmas, taip pat išsaugo ir eksponentiškai mažėjančią praeities gradientų vidurkį [28].

2. Stochastinis gradientinis nusileidimas. Iteracinis optimizavimo metodas, kuris atlieka parametru atnaujinimą kiekvienam mokymo poaibiui.
3. RMSProp (angl. *Root mean squared propagation*) algoritmas. Gradientinio nusileidimo algoritmas su impulsu. RMSProp algoritmas, buvo sukurtas, tam, kad išspręsti radikaliai mažėjančio mokymo greičio, problemą [28]. Šis algoritmas padalija mokymosi greitį iš eksponentiškai mažėjančio gradientų kvadratų vidurkio.
4. Adadelta (angl. *An Adaptive Learning Rate*) algoritmas. Stochastinis optimizavimo algoritmas, mažinantis monotoniškai mažėjančią mokymosi greitį. Adadelta algoritmas, užuot neefektyviai kaupęs ankstesnius kvadratinius gradientus, rekursiškai susumuoja ankstesnius mažėjančius kvadratinius gradientų vidurkius [28].
5. Adagrad (angl. *Adaptive Gradient Algorithm*) algoritmas. Gradientinio nusileidimo algoritmas, kuris taiko didesnius atnaujinimus retiems parametrams ir mažesnius dažniems parametrams, tokiu būdu, šis metodas skirtingiems parametrams pritaiko skirtingą mokymosi greitį. Šio metodo privalumas yra tai, kad jis rodo gerus rezultatus, retai išsidėsčiusiems duomenims [28].
6. AdaMax (angl. *Adaptive Moment Maximum*) algoritmas. Adam algoritmo plėtinys, kurio metu metodas apibendrinamas iki begalinės normos (maksimumo) ir gali padėti efektyviau optimizuoti kai kurias problemas [28].
7. Nadam (angl. *The Nesterov-accelerated Adaptive Moment*). Adam algoritmo plėtinys, kurio metu yra pridodamas Nesterovo momentas. Pridėtas Nesterovo momentas, leidžia atlikti tikslesnį žingsnį, pasirenkant gradiento kryptį [28].

#### 2.5.4. Mokymosi greitis

2.3.3 skyrelyje aptartiems optimizavimo algoritmams, taip pat svarbu rasti ir optimaliausią mokymosi greitį. Didesnis mokymosi greitis, lemia greitesnį modelio apmokymą, tačiau parinkus per didelį mokymosi greitį, optimizavimo metu, algoritmas vietoj klaidos funkcijos minimumo, gali rasti vieną iš funkcijos nuolydžio taškų. Tuo tarpu, mažesnis mokymosi greitis suteikia daugiau galimybių rasti tikslo funkcijos optimumą, bet reikalauja daugiau epochų, o tai reiškia ilgesnį modelio mokymosi laiką ir daugiau atminties resursų. Todėl labai svarbu rasti tinkamiausią mokymo greitį, kuris užtikrintų efektyvią paiešką ir naudotų mažiau resursų.

#### 2.5.5. Aktyvacijos funkcijos.

Daugiasluoksniame perceptrone, aktyvacijos funkcija, naudojama kiekviename neuroninio tinklo sluoksnyje, tuo tarpu sąsūkų neuroninių tinklų atveju, aktyvacijos funkcija naudojama sąsūkos ir pilno sujungimo sluoksniuose.

Neuroninio tinklo apmokymo metu, gautos neuronų reikšmės gali įgyti visas skaitinės reikšmės, todėl nenaudojant aktyvacijos funkcijų, tinklo išvesties sluoksnio reikšmės būtų išsidėsčiusios intervale  $(-\infty, +\infty)$ , o tai reikštų, kad neuronų reikšmės neturėtų jokių apibrėžtų reikšmių rėžių. Viena iš aktyvacijos funkcijos paskirčių, nuspręsti ar neuronas turėtų būti aktyvuotas [24]. Aktyvavimo metu yra randama svorinė neuronų jungčių suma ir pridamas neurono poslinkis, gautam rezultatui pritaikoma pasirinkta aktyvacijos funkcija, remiantis gauta aktyvacijos reikšme, neuroninio tinklo viduje yra nusprendžiama ar neuronas yra reikšmingas modeliui, ir ar turėtų būti siunčiamas toliau. Aktyvacijos funkcija, neuroniniam tinklui, taip pat reikalinga, tam, kad būtų įvestas netiesiškumas [26].

Pradėjus taikyti dirbtinių neuroninių tinklų modelius, kaip aktyvacijos funkcijos buvo naudojamos sigmoidinė ir hiperbolinio tangento funkcijos. Tačiau, sudėtingėjant užduotims, buvo pastebėta, kad naudojant minėtas funkcijas, susiduriama su nykstančių gradientų problema, dėl kurios sulėtėja arba visiškai sustoja neuroninio tinklo mokymasis. Todėl buvo pasiūlytos ir kitos aktyvacijos funkcijos. Šiame tyrime yra išbandomos šios aštuonios aktyvacijos funkcijos:

1. ReLU (angl. *Rectified linear unit*) funkcija, apibrėžiama:  $f(x) = \max(0, x)$ .

2. Softsign funkcija, apibrėžiama:  $f(x) = \frac{x}{1+|x|}$ .

3. Softplus funkcija, apibrėžiama:  $f(x) = \ln(1 + e^x)$ .

4. Leaky ReLU (angl. *Leaky Rectified Linear unit*) funkcija, apibrėžiama:  
 $f(x) = \max(0.1 \cdot x, x)$ .

5. Sigmoidinė funkcija, apibrėžiama:  $f(x) = \frac{1}{1+e^{-x}}$ .

6. Hiperbolinio tangento funkcija, apibrėžiama:  $\tan(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$ .

7. ELU (angl. *Exponential Linear Unit*) funkcija, apibrėžiama:

$$f(x) = \begin{cases} x & x > 0 \\ \alpha(e^x - 1) & x \leq 0 \end{cases}$$

Čia  $\alpha < 0$ .  $\alpha$  tai funkcijos hiperparametras, kuris kontroliuoja neigiamas įvestis. Ši funkcija mažina nykstančio gradiento efektą, taip pagreitindama giliųjų neuroninių tinklų mokymąsi ir gali užtikrinti didesnę klasifikavimo tikslumą [14].

8. SELU (angl. *Scaled Exponential Linear Unit*) funkcija, apibrėžiama:

$$f(x) = \lambda \begin{cases} x & x > 0 \\ \alpha e^x - \alpha & x \leq 0 \end{cases}$$

Ši funkcija, gali padėti gauti išvestis, pasiskirsčiusias pagal normalųjį skirstinį [26]. Čia  $\lambda$  – standartizavimo konstanta, ši konstanta yra lygi 1.0507,  $\alpha$  taip yra apibrėžta ir yra lygi 1.6732.

### **2.5.6. Sluoksnių ir neuronų skaičius.**

Neuroninio tinklo paslėptųjų sluoksnių ir neuronų skaičius, taip pat daro įtaką rezultatams. Kiekviename neuroninio tinklo sluoksnyje duomenys yra perskaičiuojami - taip neuroninis tinklas gali atpažinti įvairius duomenų signalus. Paprastesnei problemai spręsti užtenka mažesnio sluoksnių skaičiaus ir mažiau neuronų, tačiau norint sukurti modelį, skirtą spręsti sudėtingesniems uždaviniams gali prireikti didesnio sluoksnių ir neuronų skaičiaus. Tačiau svarbu rasti, optimaliausią variantą, nes per didelis sluoksnių ir neuronų skaičius gali lemti tinklo persimokymą,

### **2.5.7. Epochų skaičius ir partijos dydis.**

Apmokymo metu, duomenys per neuroninį tinklą į priekį ir atgal yra perduodami ne vieną kartą. Skaičius nurodantis kiek kartų apmokymo duomenys bus perduoti tinklui, vadinamas epocha. Parinkus per mažą epochų skaičių, neuroninis tinklas, gali nepakankamai gerai apsimokyti. Per didelis epochų skaičius, gali lemti neuroninio tinklo persimokymą. Taip pat, neuroninio tinklo apmokymo laikui, įtaką daro ir apmokymo imties dydis, todėl norint pagreitinti tinklo apmokymą, vienos epochos metu, tinklui galime paduoti ne visą apmokymą imtį, tačiau tam tikrą įrašų skaičių, partijos dydis, tai parametras, nurodantis, kokio dydžio poaibis bus perduodamas tinklui apmokymo metu, kitaip tariant kiek įvesčių bus perduodama vienos epochos apmokymo metu.

### **2.5.8. Neuronų pašalinimas ir normalizavimas.**

Dažnu atveju, neuroninio tinklo sluoksniuose ne visi neuronai yra reikalingi, tačiau sunku įvertinti, kiek ir kuriuos neuronus reikėtų pašalinti, todėl tyrimo metu į neuroninio tinklo apmokymą įtraukiamas hiperparametras, kuris kiekviename sluoksnyje tiria, ar reikėtų neuronų pašalinimo ir koks neuronų kiekis turėtų būti pašalintas. Taip pat, sunku įvertinti ir tai, ar neuronų normalizavimas galėtų pagerinti modelio tikslumą, todėl įtraukiamas ir hiperparametras, po kiekvieno sluoksniu tiriantis, ar reikėtų neuronų normalizavimo.

## **2.6. Kiti klasifikavimo metodai**

Tam, kad galėtume įvertinti gautų modelių tikslumus, modelius palyginsime su kitais klasifikavimo metodais. Atlikus literatūros analizę, pastebėjome, kad dažniausiai, modeliai skirti bankroto prognozavimui, lyginami su logistine regresija ir atraminių vektorių metodų. Tačiau, įvertinę, tai, kad tyrimuose, kuriuose buvo lyginama atsitiktinio miško ir neuroninio tinklo modeliai, atsitiktinio miško klasifikavimo rezultatai, buvo geresni, nusprendėme į lyginamąją analizę, įtraukti ir šį metodą. Toliau trumpai pristatysime šiuos algoritmus.

### **2.6.1. Atsitiktinis miškas**

Atsitiktinis miškas, tai ansamblinio mokymosi metodas, kurį sudaro daugybė sprendimų medžių. Kiekvienam sprendimų medžiui iš duomenų imties yra priskiriama atsitiktinė dalis imties ir atsitiktinai parinkti kintamieji. Sudaryti medžiai apsimoko ir klasifikuoja. Atsitiktinio miško klasifikavimo rezultatas, tai visų medžių bendras įvertis, pasirenkant tą klasę, kurią dažniausiai pasirinkdavo medžiai [41].



### 2.6.2. Logistinė regresija.

Logistinė regresija, tai statistinis klasifikavimo modelis, kurio metu yra gaunama tikimybė. Logistinė regresija, gali būti dvinarė ir daugianarė, bankroto prognozavimo atveju, naudojama dvinarė logistinė regresija. Dvinarės logistinės regresijos modelis sudaromas ne pačiam priklausomam kintamajam, o jo tikimybių santykių logaritmui. Tarkime,  $Y_i$  – atsitiktinis dydis galintis įgyti reikšmes 0 arba 1 su tikimybėmis  $P(Y_i = 1) = p_i$   $P(Y_i = 0) = 1 - p_i$ . Tuomet tikimybė  $p_i$  randama iš formulės [41]:

$$p_i = \frac{e^{z_i}}{1 + e^{z_i}} \quad z_i = a + b_1x_1 + b_2x_2 + \dots + b_kx_{ki}$$

### 2.6.3. Atraminių vektorių metodas.

Atraminių vektorių metodas, tai mašininio mokymosi algoritmas, kuris pirmą kartą buvo aprašytas 1995m. [42]. Šis metodas, priskiriamas prie netiesinių klasifikavimo modelių. Klasifikuojami duomenys atskiriami hiperplokštuma. Metodas, ieško tokios hiperplokštumos, kad atstumas tarp atraminių vektorių būtų didžiausias.

### 3. Tiriamoji dalis


Konkrečiam uždaviniui spręsti tam, kad rasti geriausiai tinkantį neuroninio tinklo modelį, reikia rasti labiausiai tinkančią tinklo architektūrą ir tinkamiausius modelio hiperparametrus. Sudarius apmokymo, testavimo ir validavimo duomenų poaibius, kuriami neuroninių tinklų modeliai. Modelių apmokymui naudojami apmokymo, hiperparametrų validavimui – validavimo, modelių testavimui – testavimo, duomenys. Geriausios neuroninio tinklo architektūros paieškai buvo sukurta funkcija, kuri sudaro neuroninio tinklo modelį. Ieškant geriausios tinklo architektūros, sukurta funkcija yra perduodama Bajeso optimizavimo metodui. Bajeso optimizavimo metu yra ieškoma maksimalaus modelio tikslumo - validavimo metu. Daugiasluoksniui perceptronui tiriami šie hiperparametrai: sluoksnių skaičius, neuronų skaičius, aktyvacijos funkcija, optimizavimo algoritmas, mokymosi greitis, neuronų išmetimo sluoksnis ir išmetamų neuronų dydis, epochų skaičius, partijos dydis, sluoksnių normalizavimas. Sąsūkų neuroniniam tinklui tiriami šie hiperparametrai: sąsūkos sluoksnių skaičius, filtrų dydis, filtrų skaičius, aktyvacijos funkcija, neuronų išmetimo sluoksnis ir išmetimo dydis, neuronų normalizavimas, neuronų skaičius, optimizavimo algoritmas. Daugiasluoksniui perceptronui išvesties sluoksnyje naudojama sigmoidinė aktyvacijos funkcija, sąsūkos neuroninio tinklo modeliui – softmax funkcija.

#### 3.1. Klasių disbalansas modelio hiperparametrų paieškos metu

Ieškant geriausio klasių balanso, buvo apmokytas atsitiktinio miško modelis, subalansavus apmokymo aibę, keturiais skirtingais būdais:

- 50/50 - 50% ne bankroto atvejų, 50% bankroto atvejų;
- 70/30 - 70% ne bankroto atvejų, 30% bankroto atvejų;
- 85/15 - 85% ne bankroto atvejų, 15% bankroto atvejų;
- 99/1 – 99% ne bankroto atvejų, 1% bankroto atvejų.

Gauti modeliai buvo ištestuoti, su testavimo poaibiu, kuriame išlaikytas pradinės duomenų imties klasių disbalansas. 19 pav. pateikiama diagrama, kurioje matome, gautus atsitiktinių miškų klasifikavimo įverčius, duomenys naudoti šiai diagramai sudaryti, pateikiami 9 priede.



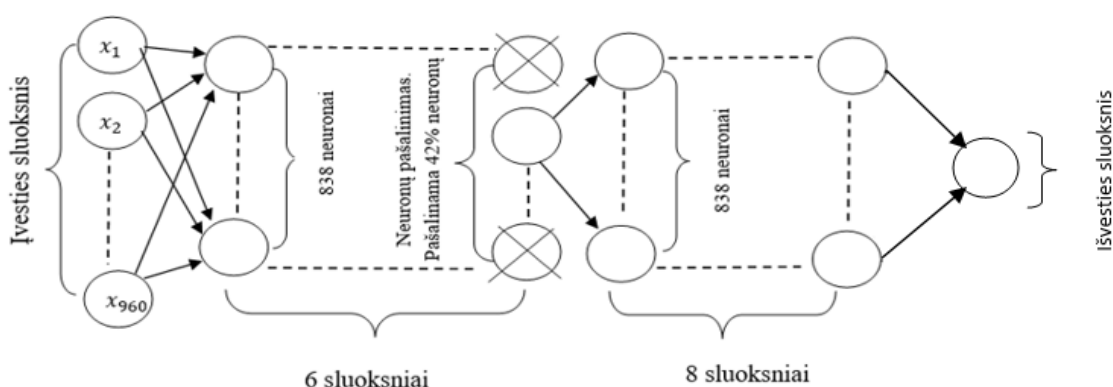
19 pav. Atsitiktinio miško klasifikavimo rezultatai

Iš gautų preciziškumo ir jautrumo įverčių 19 pav. galime pastebėti, kad apmokant atsitiktinio miško modelius su skirtingais klasių balansais, visais atvejais modeliai gerai atskyrė ne bankroto klasę. Vertinant bankroto klasę, pastebėsime, kad kai modelis buvo apmokytas su 50/50 balansu, buvo gautas aukštas jautrumo įvertis, tačiau žemas preciziškumo, o tai rodo, kad modelis didžiąją dalį bankroto atvejų priskyrė bankroto klasei, tačiau dažnai klydo ne bankroto atvejus priskirdamas bankroto klasei, o tai rodo, kad modelis blogai atskyrė klases. Modelis apmokytas, su 70/30 balansu, šiek tiek geriau atskyrė bankroto ir ne bankroto klases, tačiau iš preciziškumo įverčio bankroto klasei, pastebėsime, kad tik 37% bankroto prognozių buvo teisingos. Geriausiai klases atskyrė modeliai apmokyti su 85/15 ir 99/1 balansais. Modelis, apmokytas su nesubalansuota apmokymo imtimi, 50% visų bankroto atvejų priskyrė bankroto klasei, o bankroto prognozių tikslumas buvo 100%, taigi galime sakyti, kad šis modelis, išmoko puikiai atpažinti ne bankroto atvejus, nes nei vieno ne bankroto atvejo nepriskyrė bankrotui, tačiau prognozuodamas bankrotą, 50% bankroto atvejų priskyrė ne bankrotui. Modelis subalansuotas 85/15 balansu, bankroto atvejus atpažino didesniu tikslumu ir 73% bankroto atvejų priskyrė bankroto klasei, o 65% bankroto prognozių buvo teisingos. Kadangi, mums svarbiau yra tai, kaip modelis atpažįsta bankroto atvejus, nusprendėme modelių hiperparametrų paieškai naudoti apmokymo aibę subalansuota 85/15 balansu, subalansavimui naudojant dominuojančios klasės duomenų išmetimo (angl. „*Undersampling*“) metodą.

### 3.2. Daugiasluoksnio perceptrono modelio rezultatai

#### 3.2.1. Gautas modelis

Atlikus hiperparametrų paiešką daugiasluoksniui perceptronui, buvo gautas neuroninis tinklas sudarytas iš 14 paslėptųjų sluoksnių. Paslėptuosius sluoksnius sudarė 838 neuronai, šeštame sluoksnyje pašalinama 42% neuronų. 20 pav. pateikiama gauto daugiasluoksnio perceptrono modelio schema.




20 pav. Gautas daugiasluoksnio perceptrono modelis

20 pav. pateikto modelio schemeje, paslėptuosiuose sluoksniuose taikoma SELU aktyvacijos funkcija. Modelio apmokymo metu taikomas Adadelta optimizavimo algoritmas su 0.047

apmokymo greičiu. Apmokymo metu duomenys į priekį ir atgal yra perduodami 206 kartus (epochų skaičius), o vienos epochos metu pateikiama 417 įvesčių (partijos dydis).

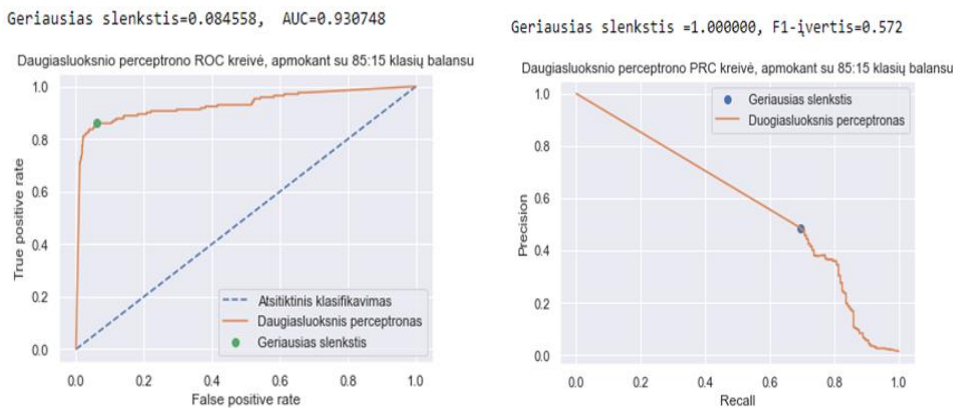
### 3.2.2. Modelio rezultatai, apmokant modelį su subalansuota apmokymo imtimi

Apmokius modelį, vaizduojamą 18 pav. su apmokymo imtimi, kurioje buvo 85% ne bankroto atvejų ir 15% bankroto atveju, apmokymo metu buvo gautas 97% tikslumas, validavimo metu 95%, toliau yra pateikiamas modelio apmokymo grafikas.



**21 pav.** Daugiasluksnio perceptrono apmokymas, naudojant 85/15 klasių balansą

Iš 21 pav. galime daryti prielaidą, kad modelis apmokymo metu nepersimokė, nes tiek validavimo tiek apmokymo tikslumai išlieka panašūs ir nėra stebimas validavimo tikslumo kritimas. Toliau pateiksime, gauto modelio ROC ir PRC kreives.

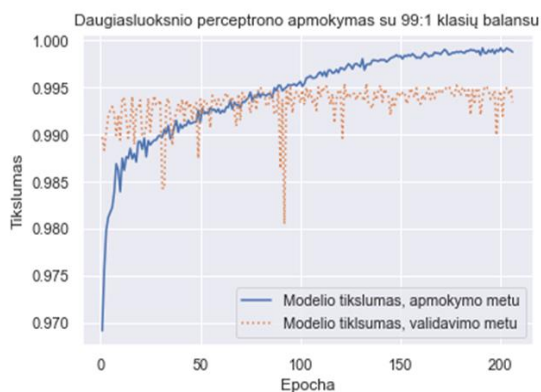


**22 pav.** Daugiasluksnio perceptrono ROC ir PRC kreivės, apmokant modelį su 85/15 balansu

Iš 22 pav. gautų ROC ir PRC kreivių, galime teigti, kad modelis atskiria klases, tačiau nepaisant gauto pakankamai didelio AUC įverčio, negalime teigti, kad tai yra idealus modelis. ROC kreivėje siūlomas klasifikavimo slenkstis yra 0.0846, šis įvertis, tai toks klasifikavimo slenkstis, su kuriuo buvo gautas maksimalus TPR ir FPR rodiklių geometrinis vidurkis, taigi šiuo atveju siūloma įmones priskirti bankroto klasei, kai gaunama bankroto tikimybė yra ne mažesne nei 0.0846. PRC kreivėje siūlomas klasifikavimo slenkstis yra 1, šis įvertis, tai toks klasifikavimo slenkstis, su kuriuo buvo gautas maksimalus F1 įvertis, arba kitaip tariant maksimalus preciziškumo ir jautrumo svorinis geometrinis vidurkis, tariant, kad preciziškumas ir jautrumas yra vienodai svarbūs.


### 3.2.3. Modelio rezultatai, apmokymo metu naudojant imtį su pradinio duomenų rinkinio klasių disbalansu

Apmokius modelį, vaizduojamą 20 pav. su apmokymo imtimi, kurioje buvo 99% ne bankroto atvejų ir 1% bankroto atveju, apmokymo metu buvo gautas 99% tikslumas, validavimo metu 99.4% tikslumas, toliau yra pateikiamas modelio apmokymo grafikas.



23 pav. Daugiasluksnio perceptrono apmokymas, naudojant 99/1 klasių balansą.

Iš 23 pav. galime daryti prielaidą, kad modelis apmokymo metu nepersimokė, nes tiek validavimo tiek apmokymo tikslumai išlieka panašūs ir nėra stebimas validavimo tikslumo kritimas. Tačiau įvertinę, faktą, kad modelis buvo apmokytas su dideliu klasių disbalansu, turime atsižvelgti į tai, kad modelis galėjo gauti didelius tikslumus, vien dėl to, kad visus atvejus priskyrė ne bankroto klasei. Toliau pateiksime, gauto modelio ROC ir PRC kreives.



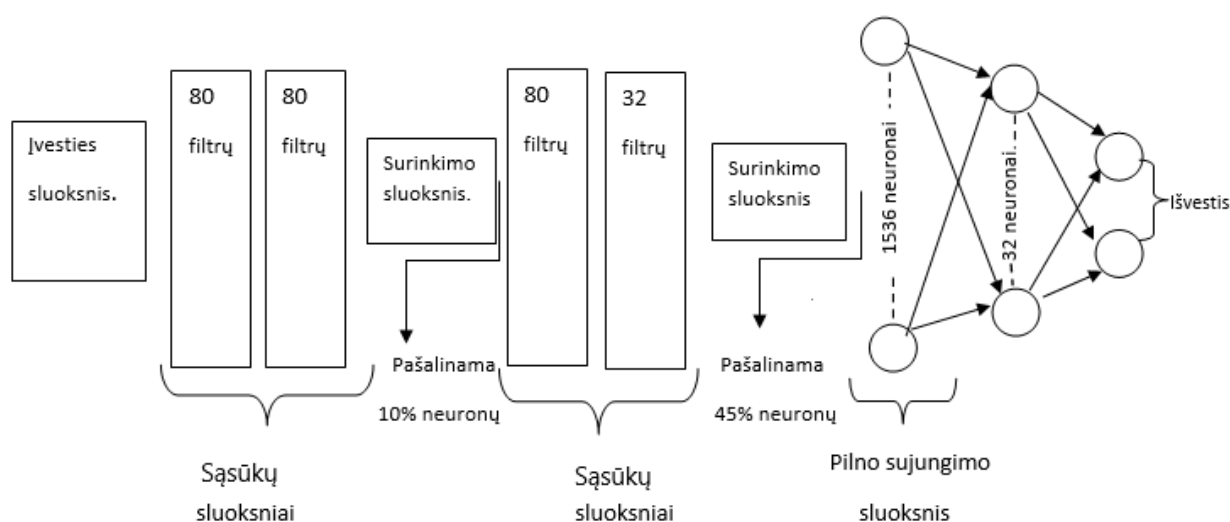
24 pav. Daugiasluksnio perceptrono ROC ir PRC kreivės, apmokant modelį su 99/1 balansu.

Iš 24 pav. gautų ROC ir PRC kreivių, galime teigti, kad modelis atskiria klases, lyginant su gautomis kreivėmis 20 pav., iš gautų ROC kreivių, atrodytų, kad modelių rezultatai panašūs, tačiau vertinant gautas PRC kreivės, matome, kad visgi modelis geriau atskyrė klases ir atpažino bankroto atvejus, kai buvo apmokomas su apmokymo imtimi, kurioje buvo išlaikomas pradinio duomenų rinkinio klasių disbalansas. Iš gautų slenksčių matome, kad ROC kreivėje siūloma įmones priskirti bankroto atvejams, kai gaunama bankroto tikimybė yra ne mažesne nei 0.00004, o iš PRC kreivės,

bankrotui siūloma priskirti tas įmones, kurioms buvo gaunama bankroto tikimybė, buvo ne mažesnė nei 0.979

### 3.3. Sąsūkų neuroninio tinklo rezultatai

Atlikus hiperparametrų paiešką sąsūkos neuroninio tinklo atveju, buvo gautas neuroninis tinklas sudarytas iš 8 paslėptųjų sluoksnių. Toliau pateiksime gautą sąsūkos neuroninio tinklo schemą.



25 pav. Gautas sąsūkų neuroninio tinklo modelis

25 pav. pateikto modelio sąsūkų sluoksniuose, naudojama softsign aktyvacijos funkcija ir  $3 \times 3$  filtrai. Surinkimo sluoksniuose, naudojama maksimumo surinkimo funkcija, o surinkimo žingsnis lygus 2. Pilno sujungimo sluoksnyje, naudojama ELU aktyvacijos funkcija, išvesties sluoksnyje softmax funkcija. Sąsūkų tinklo apmokymui, naudojamas RMSprop optimizavimo algoritmas su 0.0016 apmokymo greičiu. Apmokymo metu duomenys į priekį ir atgal yra perduodami 206 kartus (epochų skaičius), o vienos epochos metu pateikiama 417 įvesčių (partijos dydis).

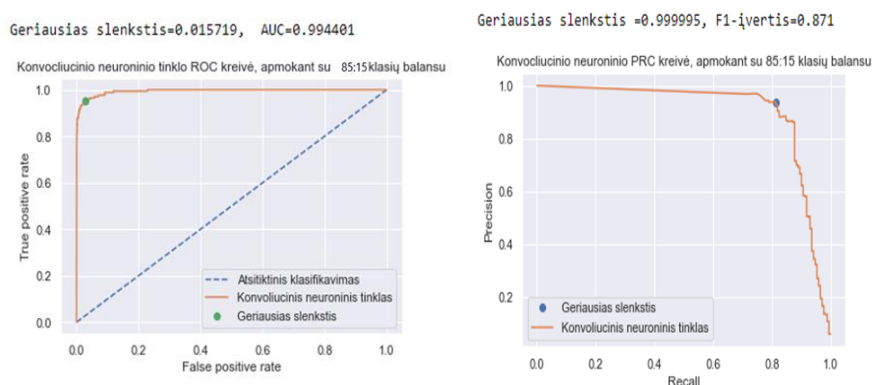
#### 3.3.1. Modelio rezultatai, apmokant modelį su subalansuota apmokymo imtimi

Apmokius modelį, vaizduojamą 25 pav. su apmokymo imtimi, kurioje buvo 85% ne bankroto atvejų ir 15% bankroto atveju, apmokymo metu buvo gautas 99% tikslumas, validavimo metu 97%, toliau yra pateikiamas modelio apmokymo grafikas.



**26 pav.** Šaškų neuroninio tinklo apmokymas, naudojant 85/15 klasių balansą

Iš 26 pav. galime daryti prielaidą, kad modelis apmokymo metu nepersimokė, nes tiek validavimo tiek apmokymo tikslumai išlieka panašūs ir nėra stebimas validavimo tikslumo kritimas. Toliau pateiksime, gauto modelio ROC ir PRC kreives.




**27 pav.** Šaškų neuroninio tinklo ROC ir PRC kreivės, apmokant modelį su 85/15 balansu

Iš 27 pav. gautų ROC ir PRC kreivių, galime teigti, kad modelis gerai atskyrė klases ir yra mažai nutolęs nuo idealaus klasifikavimo modelio, tai patvirtina ir gautas AUC įvertis labai artimas vienetui, tačiau įvertinus faktą, kad testuojamoje aibėje yra 99% ne bankroto atvejai, aukštas AUC įvertis gali būti gaunamas tik atsižvelgus į puikų ne bankroto klasės klasifikavimą, tačiau iš PRC kreivės, galime teigti, kad modelis geba atpažinti bankroto atvejus. Iš gautų slenksčių matome, kad ROC kreivėje siūloma įmones priskirti bankroto atvejams, kai gaunama bankroto tikimybė yra ne mažesne nei 0.0157, o iš PRC kreivės, bankrotui siūloma priskirti tas įmones, kurių gaunama bankroto tikimybė buvo ne mažesnė nei 0.999.


### 3.3.2. Modelio rezultatai, apmokymo metu naudojant imtį su pradinio duomenų rinkinio klasių disbalansu

Apmokius modelį, vaizduojamą 25 pav. su apmokymo imtimi, kurioje buvo 99% ne bankroto atvejų ir 1% bankroto atveju, apmokymo ir validavimo metu buvo gauti 99% tikslumai, toliau yra pateikiamas modelio apmokymo grafikas.



**28 pav.** Šašūkų neuroninio tinklo apmokymas, naudojant 99/1 klasių balansą

Iš 28 pav. galime daryti prielaidą, kad modelis apmokymo metu nepersimokė, nes tiek validavimo tiek apmokymo tikslumai išlieka beveik vienodi ir nėra stebimas validavimo tikslumo kritimas. Toliau pateiksime, gauto modelio ROC ir PRC kreives.



**29 pav.** Šašūkų neuroninio tinklo ROC ir PRC kreivės, apmokant modelį su 99/1 balansu

Iš gautų kreivių 29 pav. Galime teigti, kad modelis gerai atskiria klases. Iš gautų slenksčių matome, kad ROC kreivėje siūloma įmones priskirti bankroto atvejams, kai gaunama bankroto tikimybė yra ne mažesne nei 0.000033, o iš PRC kreivės, bankrotui siūloma priskirti tas įmones, kurių gaunama bankroto tikimybė buvo ne mažesnė nei 0.162525. Pastebėsime, kad lyginant gautus rezultatus, su pateikiamais 25 pav. matome, kad apmokant šašūkų neuroninį tinklą su nesubalansuota imtimi, PRC kreivėje 27 pav., gauname daug mažesnę slenkstį, tačiau su šiuo slenkščiu yra gaunamas didesnis F1 įvertis, tai galėtų reikšti, kad apmokant modelį su nesubalansuota duomenų aibe, modelis geba geriau atskirti bankroto atvejus, prie mažesnių slenksčių, lyginant su modeliu gautu apmokymu metu naudojant subalansuota duomenų aibę.

### 3.4. Giliojo mokymosi modelių palyginimas su kitais klasifikavimo modeliais


Norėdami įvertinti gautų giliojo mokymosi modelių rezultatus, taip pat sudarėme atraminių vektorių, logistinės regresijos ir atsitiktinio miško modelius. Modeliai buvo apmokomi su




subalansuota apmokymo imtimi, kurioje buvo 85% ne bankroto atvejų ir 15% bankroto atvejų ir su nesubalansuota apmokymo imtimi, kurioje buvo 99% ne bankroto atvejų ir 1% bankroto atvejų. Modeliai buvo testuojami su testavimo poaibių, kuriame išlaikomas pradinio duomenų rinkinio klasių disbalansas, kuriame buvo 99% ne bankroto atvejų ir 1% bankroto atvejų. Gautų modelių rezultatų atskirai nedetalizuosime, tačiau pateiksime visų modelių ROC, PRC kreives ir palyginsime gautus rezultatus.

### 3.4.1. ROC, PRC kreivės, apmokant modelius su subalansuota apmokymo aibe

Toliau yra pateikiama modelių ROC ir PRC kreivės ir modelių tikslumo metrikos, modelius apmokant su apmokymo imtimi, kurioje buvo 85% ne bankroto atvejų ir 15% bankroto atvejų.



30 pav. Visų modelių ROC kreivės, apmokant modelius 85/15 klasių balansu



31 pav. Visų modelių PRC kreivės, apmokant modelius 85/15 klasių balansu

**6 lentelė.** Modelių metrikos, apmokant su 85/15 klasių balansu

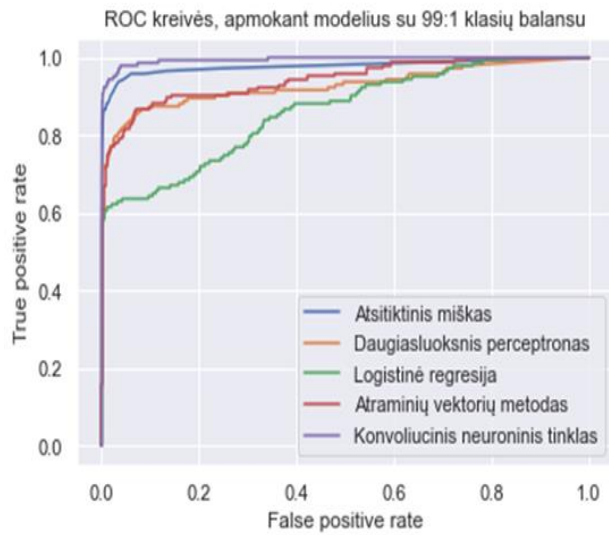
Modelis	AUC	EER	Geriausias slenkstis ROC kreivėje	Geriausias slenkstis PRC kreivėje	F1 įvertis, su geriausiu PRC slenksčiu
Atsitiktinis miškas	0.985	0.0496	0.29	0.62	0.715
Daugiasluoksnis perceptronas	0.93	0.1229	0.0846	1	0.572
Logistinė regresija	0.939	0.1578	0.543	0.977	0.657
Atraminių vektorių metodas	0.889	0.1754	0.131	0.339	0.302
Sąsūkų neuroninis tinklas	0.994	0.0409	0.0157	0.999	0.871

Iš gautų ROC kreivių, pateikiamų 30 pav. matome, kad sąsūkų neuroninio tinklo ir atsitiktinio miško modelių ROC kreivės yra artimos idealaus klasifikavimo modelio ROC kreivei, tai rodo ir gauti 6 lentelėje pateikiami AUC įverčiai artimi vienetui. Iš EER įverčių, pateiktų 6 lentelėje, galime teigti, kad mažiausiai klaidingai įmones klasifikavo sąsūkų neuroninio tinklo ir atsitiktinio miško modeliai. Daugiasluoksnio perceptrono ir logistinės regresijos ROC kreivės yra labai panašios, gauti AUC įverčiai šiems modeliams taip pat yra beveik identiški, tačiau iš EER reikšmių, galime pastebėti, kad klasifikuodamas įmones, šiek tiek mažiau klydo daugiasluoksnio perceptrono modelis. Vertinant PRC kreives, pateikiamas 31 pav. galime teigti, kad geriausiai klases atskyrė sąsūkų neuroninis tinklas, daugiasluoksnis perceptronas klases atskyrė prasčiau nei atsitiktinis miškas, tačiau pralenkė atraminių vektorių metodą.


6 lentelėje pateikiami geriausi klasifikavimo slenksčiai, gauti iš ROC kreivės, yra parenkami tokie, kad modelių TRP ir FPR rodiklių geometriniai vidurkiai būtų didžiausi. Galime pastebėti, kad šiuo atveju, giliojo mokymo modelių siūlomi slenksčiai yra pakankamai maži ir siūloma įmones priskirti bankroto atvejams, kai gaunama bankroto tikimybė yra ne mažesne nei: sąsūkų neuroninio tinklo atveju – 0.0157, daugiasluoksnio perceptrono – 0.0846. Tačiau iš pateiktų geriausių klasifikavimo slenksčių, gautų iš PRC kreivės, kurie yra parenkami taip, kad būtų gaunamas maksimalus F1 įvertis, kuris yra pateikiamas 6 lentelėje, matome, kad giliojo mokymo modelių siūlomi geriausi slenksčiai yra dideli ir artimi arba lygus vienam, tai reikštų, kad įmones priskirtume bankrotui, jei gauta bankroto tikimybė būtų ne mažesnė nei 0.999 arba lygi 1.

### 3.4.2. ROC, PRC kreivės, apmokant modelius su nesubalansuota apmokymo aibe

Toliau yra pateikiama modelių ROC ir PRC kreivės ir modelių tikslumo metrikos, modelius apmokant su apmokymo imtimi, kurioje buvo išlaikytas pradinio rinkinio klasių disbalansas, vadinasi buvo 99% ne bankroto atvejų ir 1% bankroto atvejų.



32 pav. Visų modelių ROC kreivės, apmokant modelius su 99/1 klasių balansu



33 pav. . Visų modelių PRC kreivės, apmokant modelius su 99/1 klasių balansu

7 lentelė. Modelių metrikos, apmokant su 99/1 klasių balansu

Modelis	AUC	EER	Geriausias slenkstis ROC kreivėje	Geriausias slenkstis PRC kreivėje	F1 Įvertis, su geriausiu PRC slenkščiu
Atsitiktinis miškas	0.977	0.0454	0.06	0.21	0.819
Daugiasluoksnis perceptronas	0.928	0.1259	0.00004	0.979	0.769
Logistinė regresija	0.862	0.2517	0.49	0.64	0.651
Atramiųjų vektorių metodas	0.942	0.1189	0.015	0.0163	0.65
Sąsūkių neuroninis tinklas	0.995	0.0349	0.000033	0.1625	0.905

Iš gautų ROC kreivių, pateikiamų 32 pav. matome, kad geriausias modelis yra sąsūkų neuroninis tinklas, atsitiktinis miškas minimaliai nutolęs nuo šio modelio, tai rodo ir gauti AUC ir EER įverčiai, pateikiami 7 lentelėje, tačiau iš PRC kreivių, pateiktų 33 pav. galime teigti, kad sąsūkų neuroninis tinklas klases atskyrė geriau nei atsitiktinis miškas. Taip pat galime pastebėti, kad šiuo atveju daugiasluoksnis perceptronas pralenkia logistinės regresijos modelį, iš gautų daugiasluoksnio perceptrono ir atraminių vektorių AUC ir EER įverčių, pateiktų 7 lentelėje, matome, kad visgi atraminių vektorių metodo įverčiai buvo didesni nei daugiasluoksnio perceptrono, tačiau vertinant PRC kreives, pateiktas 33 pav. matome, kad daugiasluoksnis perceptronas klases atskyrė geriau nei atraminių vektorių metodas.

Vertinant gautus, siūlomus slenksčius, pateiktos 7 lentelėje, matome, kad slenksčiai gaunami iš ROC kreivių, giliojo mokymo modeliams yra dar mažesni nei siūlomi 6 lentelėje, ir yra artimi nuliui, tuo tarpu slenksčiai gauti iš PRC kreivių yra mažesni nei 6 lentelėje, o su šiais slenksčiais gaunami F1 įverčiai – didesni, vadinasi, šiuo atveju, neuroninių tinklų modeliai, atskyrė klases geriau su mažesnėmis bankroto tikimybėmis.

### 3.4.3. Modelių rezultatai, testavimo metu

Įvertinę 3.4.1 ir 3.4.2 skyreliuose gautus rezultatus ir pastebėję, kad iš modelių naudotų lyginamajai analizei, geriausias modelis buvo atsitiktinis miškas, todėl toliau nagrinėsime sąsūkų neuroninio tinklo, daugiasluoksnio perceptrono ir atsitiktinio miško modelių rezultatus, gautus testavimo metu. Priskirdami gautus rezultatus klasėms, naudosime visiems modeliams tą patį slenkstį. Iš gautų PRC ir ROC kreivių, pastebėjome, kad vertinant siūlomus slenksčius giliojo mokymosi modeliams, ROC kreivėse, gaunami slenksčiai yra pakankamai maži, tuo tarpu PRC kreivėse pakankamai dideli ir yra artimi maksimaliam galimam slenkščiui (vienetui). Didesnis slenkstis, mažintų prognozuojamų bankroto atvejų skaičių, o mūsų atveju, mums yra svarbiau identifikuoti bankroto atvejus, todėl yra geriau daugiau įmonių, kurioms negresia bankrotas, priskirti bankroto klasei, nei nepriskirti įmonių kurioms gresia bankrotas - bankroto klasei. Atsižvelgę į tai ir įvertinę, kitų modelių gautus slenksčius, nusprendėme modelių klasifikavimo įverčių palyginimui, naudoti klasifikavimo slenkstį – 0.5. Vadinasi, sakysime, kad įmonė bankrutuos, jeigu jos bankroto tikimybė bus didesnė nei 0.5.

Toliau pateksime gautus jautrumo, preciziškumo ir F1 įverčius, modelius apmokant su subalansuota ir nesubalansuota apmokymo imtimi, pasirinkome vertinti šias metrikas, nes testavimo metu, naudojama duomenų aibė, kurioje išlaikomas pradinio duomenų rinkinio klasių disbalansas, kuriame yra tik 1 procentas bankroto atveju, o šios metrikos parodo kaip modelis atskiria klases, atsižvelgdamos į kiekvieną klasę atskirai.

**8 lentelė.** Modelių testavimo metrikos, apmokant su 85/15 klasių balansu

Modelis	Klasė	Preciziškumas	Jautrumas	F1
Daugiasluoksnis perceptronas	Ne Bankroto	1	0.97	0.98
	Bankroto	0.28	0.82	0.42
Sąsūkų neuroninis tinklas	Ne Bankroto	1	0.99	0.99
	Bankroto	0.53	0.92	0.67
Atsitiktinis miškas	Ne Bankroto	1	0.99	1
	Bankroto	0.65	0.73	0.68

Iš 8 lentelėje pateikiamų preciziškumo ir jautrumo įverčių, gautų vertinant modelius, apmokytus su subalansuota duomenų aibe, tačiau testuojant su testavimo imtimi, kurioje išlaikomas pradinio duomenų rinkinio klasių disbalansas, kuriame yra tik 1% bankroto atveju, galime teigti, kad:

- daugiasluoksnis perceptronas 82% visų bankroto atvejų, priskyrė bankroto klasei, tačiau tik 28% gautų bankroto prognozių buvo teisingos;
- sąsūkų neuroninis tinklas 53% visų bankroto atvejų priskyrė bankroto klasei ir 92% gautų bankroto prognozių buvo teisingos;
- atsitiktinis miškas, 65% visų bankroto atvejų priskyrė bankroto klasei ir 73% gautų bankroto prognozių buvo teisingos.

Vertinant F1 įverčius, pateiktus 8 lentelėje, galime teigti, kad apmokius modelius su subalansuota apmokymo imtimi, geriausiai klases atskyrė sąsūkų neuroninio tinklo ir atsitiktinio miško modeliai.

Atsitiktinis miškas

Daugiasluoksnis perceptronas

Sąsūkų neuroninis tinklas



**34 pav.** Modelių sumaišymo matricos, apmokant su 85/15 balansu

Iš 34 pav. pateiktų sumaišymo matricių, matome, kad apmokius modelius su subalansuota imtimi, sąsūkų neuroninis tinklas daugiausiai bankroto atvejų priskyrė bankroto klasei, tačiau atsitiktinis miškas mažiausiai ne bankroto atvejų priskyrė bankroto klasei. Taip pat galime pastebėti, kad daugiasluoksnis perceptronas daugiau bankroto atvejų priskyrė bankroto klasei, nei atsitiktinis miškas, tačiau daugiausiai klydo ne bankroto atvejus priskirdamas bankrotui.

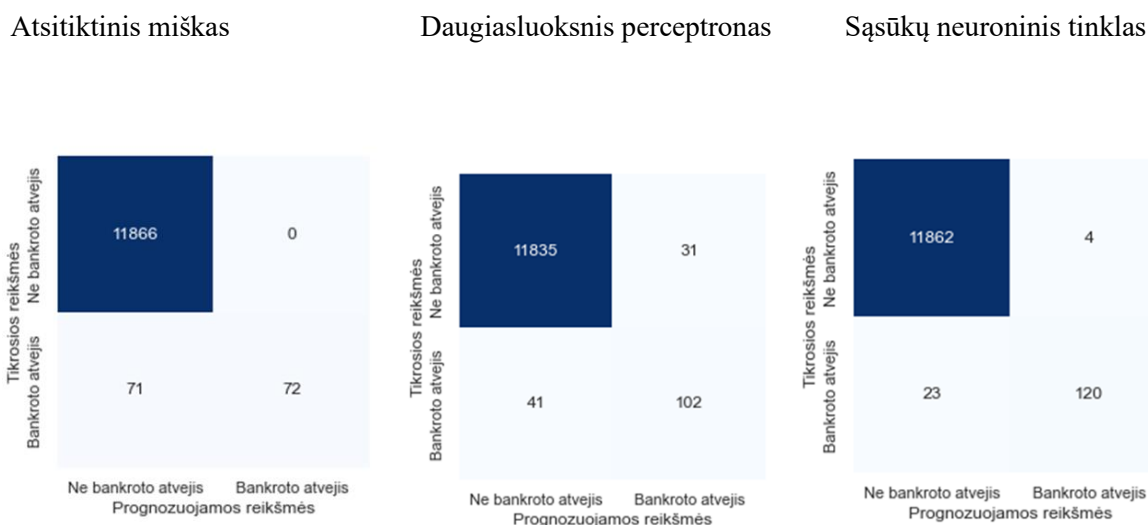
**9 lentelė.** Modelių tikslumo metrikos, apmokant su 99/1 klasių balansu

Modelis	Klasė	Preciziškumas	Jautrumas	F1
Daugiasluoksnis perceptronas	Ne Bankroto	1	1	1
	Bankroto	0.77	0.71	0.74
Sąsūkų neuroninis tinklas	Ne Bankroto	1	1	1
	Bankroto	0.97	0.84	0.9
Atsitiktinis miškas	Ne Bankroto	0.99	1	1
	Bankroto	1	0.5	0.67

Iš 9 lentelėje pateikiamų preciziškumo ir jautrumo įverčių, gautų vertinant modelius, apmokytus ir ištestuotus su duomenų imtimis, kuriose išlaikomas pradinio duomenų rinkinio klasių disbalansas, kuriame yra tik 1% bankroto atveju, galime teigti, kad:

- daugiasluoksnis perceptronas 77% visų bankroto atvejų, priskyrė bankroto klasei ir 71% gautų bankroto prognozių buvo teisingos;
- sąsūkų neuroninis tinklas 97% visų bankroto atvejų priskyrė bankroto klasei ir 84% gautų bankroto prognozių buvo teisingos;
- atsitiktinis miškas, visus bankroto atvejų priskyrė bankroto klasei, tačiau tik 50% gautų bankroto prognozių buvo teisingos.

Vertinant F1 įverčius, pateiktus 8 lentelėje, galime teigti, kad apmokus modelius su duomenų imtimi su dideliu klasių disbalansu, geriausiai klases atskyrė sąsūkų neuroninio tinklo modelis.



**35 pav.** Modelių sumaišymo matricos, apmokant su 99/1 balansu

Iš 35 pav. pateiktų sumaišymo matricių, matome, kad apmokus modelius su nesubalansuota imtimi, atsitiktinis miškas geriausiai atskyrė ne bankroto klasę, tačiau prasčiausiai – bankroto, nes 50% bankroto atvejų priskyrė ne bankrotui. Tuo tarpu giliojo mokymosi modeliai bankroto atvejus atskyrė geriau, pastebėsime, kad sąsūkų neuroninis tinklas, priskirdamas ne bankroto atvejus, bankrotui, klaidingai priskyrė tik 4 įmones. Lyginant sumaišymo matricas su matricomis gautomis 34 pav. galime teigti, kad giliojo mokymosi modeliai išmoko klases geriau atskirti, kai buvo apmokomi su apmokymo imtimi, kurioje buvo išlaikytas pradinio duomenų rinkinio klasių disbalansas.

## Išvados

1. Išanalizavus gautus duomenis, buvo pastebėta, kad iš 64 kintamųjų, tik 45 kintamieji buvo informatyvūs. Atskyrus bankrutavusias ir nebankrutavusias įmones, gautiems poaibiams buvo atlikta statistinė kintamųjų analizė, paskutiniams trejiems įmonių veiklos metams. Lyginant bankrutavusių ir nebankrutavusių įmonių veiklos rodiklių statistinius įverčius, buvo pastebėta, kad bankrutavusių įmonių duomenyse, signalus apie artėjantį įmonių bankrotą, galima aptikti jau dveji metai iki bankroto. Pritaikant duomenis giliojo mokymosi modeliams, buvo atliekamas duomenų konvertavimas. Duomenys buvo konvertuojami dvejais formatais:
  - Daugiasluoksnio perceptrono atveju kuriami kintamieji periodams atgal, tokiu būdu vienos įmonės duomenis, pateikiant kaip vieną vektorių. Šiuo atveju, metiniai kintamieji, kurių reikšmės visoms įmonėms buvo tuščios, buvo ištrinami. Šio modelio duomenų formatas turėjo tokį pavidalą: *įmonių skaičius* × 960. Šis duomenų konvertavimas, buvo sudėtingesnis ir reikalavo daugiau pakeitimų duomenyse, lyginant su duomenų konvertavimu, taikytu sąsūkų neuroniniam tinklui.
  - Sąsūkų neuroninio tinklo atveju, vienos įmonės duomenys buvo pateikiami vienos matricos pavidalu, šiuo atveju metinių kintamųjų reikšmės, kurios visoms įmonėms buvo tuščios yra pakeičiamos nuliais. Šio modelio duomenų formatas turėjo tokį pavidalą: *įmonių skaičius* × 36 × 45 × 1.
2. Atlikus hiperparametrų paiešką naudojant Bajeso optimizavimą ir subalansuotus duomenis (85% ne bankroto atvejų ir 15% bankroto atvejų), buvo gauti tokie modeliai:
  - Daugiasluoksnio perceptrono atveju, modelį sudarė 14 paslėptųjų sluoksnių, visi sluoksniai išskyrus šeštąjį buvo sudaryti iš 838 neuronų, šeštame paslėptajame sluoksnyje buvo pašalinama 42% neuronų. Paslėptuosiuose sluoksniuose taikoma SELU aktyvacijos funkcija, išvesties sluoksnyje - sigmoidinė aktyvacijos funkcija. Modelio apmokymo metu taikomas Adadelta optimizavimo algoritmas su 0.047 mokymosi greičiu. Apmokymo metu duomenys į priekį ir atgal yra perduodami 206 kartus (epochų skaičius), o vienos epochos metu pateikiama 417 įvesčių (partijos dydis). Hiperparametrų paieškos metu, gauto modelio tikslumas apmokymo metu buvo 97%, validavimo metu 95%.
  - Sąsūkų neuroninio tinklo atveju, buvo gautas modelis sudarytas iš 4 sąsūkos sluoksnių, 2 surinkimo sluoksnių, vieno pilno sujungimo sluoksnio, vieno paslėptojo sluoksnio. Pirmi trys sąsūkų sluoksniai buvo sudaryti iš 80 filtrų, ketvirtasis iš 32, sąsūkos sluoksniuose taikoma ELU aktyvacijos funkcija. Surinkimo sluoksniuose taikoma maksimumo funkcija, po pirmojo surinkimo sluoksnio pašalinama 10% neuronų, po antrojo 45%. Pilno sujungimo sluoksnis sudarytas iš 1536 neuronų, po jo einantis paslėptasis sluoksnis sudarytas iš 32 neuronų, šiuose sluoksniuose taikoma softsign aktyvacijos funkcija, išvesties sluoksnyje taikoma softmax funkcija. Hiperparametrų paieškos metu, gauto modelio tikslumas apmokymo metu buvo 99%, validavimo metu 97%.
3. Modeliai buvo apmokyti su skirtingais balansais (85% ir 15%, 99% ir 1%), o testuojami su duomenų poaibiui, kuriame išlaikomas pradinio duomenų rinkinio klasių disbalansas. Vertinant bankroto klasę, testuodami modelius gavome tokius rezultatus:

- Daugiasluoksnio perceptrono modelis, apmokytas su subalansuota duomenų imtimi, testavimo metu, 82% visų bankroto atvejų, priskyrė bankroto klasei, tačiau tik 28% gautų bankroto prognozių buvo teisingos. Tačiau apmokius šį modelį su nesubalansuotais duomenimis, šis modelis testavimo metu, 77% visų bankroto atvejų priskyrė bankroto klasei ir 71% gautų bankroto prognozių buvo teisingos.
- Sąsūkų neuroninis tinklas, apmokytas su subalansuota duomenų imtimi, 53% visų bankroto atvejų priskyrė bankroto klasei ir 92% gautų bankroto prognozių buvo teisingos. Apmokius šį modelį su nesubalansuotais duomenimis, šis modelis testavimo metu, 97% visų bankroto atvejų priskyrė bankroto klasei ir 84% gautų bankroto prognozių buvo teisingos.

Taigi, galime daryti išvadą, kad giliojo mokymosi modeliai, geriau atskiria klases, kai yra apmokomi su duomenų aibe, kurioje išlaikomas pradinio duomenų rinkinio klasių disbalansas.

4. Palyginus giliojo mokymosi modelius su atsitiktinio miško, logistinės regresijos ir atraminių vektorių metodais, galime teigti, kad šiuo atveju geriausias modelis buvo sąsūkų neuroninis tinklas. Įvertinę PRC kreives pastebėjome, kad apmokant modelius su subalansuota duomenų imtimi, geriausiai klases atskyrė sąsūkų neuroninis tinklas ir atsitiktinis miškas, daugiasluoksnis perceptronas pralenkė atraminių vektorių metodą, tačiau prilygo logistinei regresijai. Apmokant modelius su duomenų imtimi, kurioje išlaikomas pradinio duomenų rinkinio klasių disbalansas, giliojo mokymosi modeliai bankroto atvejus prognozavo geriausiai, tuo tarpu atsitiktinis miškas geriausiai prognozavo ne bankroto klasę.
5. Pastebėję, tai, kad giliojo mokymosi modeliai, klases atskyrė geriau, kai buvo apmokomi su duomenų imtimi, kurioje buvo išlaikytas pradinio duomenų rinkinio klasių disbalansas, sekančiuose tyrimuose, siūlome, hiperparametrų paieškos metu naudoti duomenų aibę, kurioje išlaikomas pradinis klasių disbalansas.



## Literatūros sąrašas

1. Altman E., (1968). Financial ratios discriminant analysis and the prediction of corporate bankruptcy. *Journal of Finance* 23(4) 589–609.
2. Ohlson J. A. (1980). Financial ratios and the probabilistic prediction of bankruptcy. *Journal of Accounting Research*, Spring Vol. 18, No.1
3. Flavio Barboza, Herbert Kimura, Edward Altman, (2017). Machine learning models and bankruptcy prediction. *Expert Systems with Applications*, Volume 83, Pages 405-417, ISSN 0957-4174. Prieiga per internetą: <https://doi.org/10.1016/j.eswa.2017.04.006>.
4. Becerra-Vicario R., Alaminos, D., Aranda E., Fernández-Gómez M.A. (2020). Deep Recurrent Convolutional Neural Network for Bankruptcy Prediction: A Case of the Restaurant Industry. *Sustainability*, 12, 5180. Prieiga per internetą: <https://doi.org/10.3390/su12125180>
5. Klietnik Tomas, Misankova Maria, Valaskova Katarina, Svabova, Lucia (2018). Bankruptcy Prevention: New Effort to Reflect on Legal and Social Changes. *Science and Engineering Ethics* 24 (2) 791-803.
6. Ashraf, Sumaira, Elisabete G. S. Félix, and Zélia Serrasqueiro, (2019). Do Traditional Financial Distress Prediction Models Predict the Early Warning Signs of Financial Distress. *Journal of Risk and Financial Management* 12, no. 2: 55. Prieiga per internetą: <https://doi.org/10.3390/jrfm12020055>
7. Mario Hernandez Tinoco, Nick Wilson, Financial distress and bankruptcy prediction among listed companies using accounting, market and macroeconomic variables, (2013). *International Review of Financial Analysis*, Volume 30, Pages 394-419, ISSN 1057-5219. Prieiga per internetą: <https://doi.org/10.1016/j.irfa.2013.02.013>.
8. Nazemi, Abdolreza & Rezazadeh, Hani & Fabozzi, Frank J. & Höchstötter, Markus, 2022. "Deep learning for modeling the collection rate for third-party buyers," *International Journal of Forecasting*, Elsevier, vol. 38(1), pages 240-252.
9. Tadaaki Hosaka, Bankruptcy prediction using imaged financial ratios and convolutional neural networks. (2019). *Expert Systems with Applications*, Volume 117, 2019, Pages 287-299, ISSN 0957-4174. Prieiga per internetą: <https://doi.org/10.1016/j.eswa.2018.09.039>.
10. Chong E, Han C, Park F C. (2017). Deep learning networks for stock market analysis and prediction: Methodology data representations and case studies[J]. *Expert Systems with Applications* 83: 187-205.
11. Shetty, Shekar, Mohamed Musa, and Xavier Brédart. (2022). "Bankruptcy Prediction Using Machine Learning Techniques" *Journal of Risk and Financial Management* 15, no. 1: 35. Prieiga per internetą: <https://doi.org/10.3390/jrfm15010035>.
12. du Jardin, P., (2009), Bankruptcy prediction models: How to choose the most relevant variables? *Bankers, Markets & Investors*, issue 98, January-February, pp. 39–46. Prieiga per internetą: <http://www.revue-banque.fr/article/bankruptcy-prediction-models-how-choose-most-relev>
13. Jasper Snoek Oren Rippel Kevin Swersky Ryan Kiros Nadathur Satish Narayanan Sundaram Md. Mostofa Ali Patwary Prabhat Ryan P. Adams (2015). Scalable Bayesian Optimization Using Deep Neural Networks. the Natural Sciences and Engineering Research Council of Canada. NSF IIS-1421780.
14. Clevert, Djork-Arné, Unterthiner, Thomas, Hochreiter, Sepp. (2015). Fast and Accurate Deep Network Learning by Exponential Linear Units (ELUs). Under Review of ICLR2016 (1997).

15. Andrew L. Awni Y. Andrew Y. Ng. (2013). Rectifier Nonlinearities Improve Neural Network Acoustic Models . roceedings of the 30 th International Conference on Machine Learning, Atlanta, Georgia, USA, JMLR: W&CP volume 28.
16. Kingma, Diederik P., and Jimmy Ba.(2014). Adam: A method for stochastic optimization. arXiv preprint arXiv:1412.6980.
17. Korol, Tomasz (2017). Evaluation of the factors influencing business bankruptcy risk in Poland, e-Finanse: Financial Internet Quarterly, ISSN 1734-039X, University of Information Technology and Management, Rzeszów, Vol. 13, Iss. 2, pp. 22-35. Prieiga per internetą: <http://dx.doi.org/10.1515/fiqf-2016-0020>
18. Odom, Marcus & Sharda, Ramesh. (1990). A Neural Network Model for Bankruptcy Prediction. IEEE International Joint conference on Neural Networks. 2. 163 - 168 vol.2. 10.1109/IJCNN.1990.137710.
19. Mateusz Buda, Atsuto Maki, Maciej A. Mazurowski. (2018). A systematic study of the class imbalance problem in convolutional neural networks, Neural Networks, Volume 106, , Pages 249-259, ISSN 0893-6080. Prieiga per internetą: <https://doi.org/10.1016/j.neunet.2018.07.011>.
20. C. Ferri, J. Hernández-Orallo, R. Modroiu. (2009). An experimental comparison of performance measures for classification, Pattern Recognition Letters, Volume 30, Issue 1, Pages 27-38, ISSN 0167-8655. Prieiga per internetą: <https://doi.org/10.1016/j.patrec.2008.08.010>.
21. Vujovic, Zeljko. (2021). Classification Model Evaluation Metrics. International Journal of Advanced Computer Science and Applications. Volume 12. 599-606.
22. Kiranyaz, Avci, O., Abdeljaber, O., Ince, T., Gabbouj, M., & Inman, D. J. (2021). 1D convolutional neural networks and applications: A survey. Mechanical Systems and Signal Processing, 151, 107398. Prieiga per internetą: <https://doi.org/10.1016/j.ymssp.2020.107398>.
23. Amardeep. (2017). Training Feed forward Neural Network With Backpropogation Algorithm. International Journal of Engineering and Computer Science. Prieiga per internetą: <https://doi.org/10.18535/ijecs/v6i1.03>.
24. Agostinelli, Forest.(2018). Learning activation functions to improve deep neural networks. arXiv preprint arXiv:1412.6830 (2014).
25. Priddy, Kevin L, & Keller, Paul E. (2005). Artificial neural networks: an introduction (p. 1). Preiga per internetą: <https://doi.org/10.1117/3.633187>
26. Nguyen, A., Khoa Pham, Dat Thanh Ngo, Thanh Ngo and Lam Dang Pham. (2021). An Analysis of State-of-the-art Activation Functions For Supervised Deep Neural Network. International Conference on System Science and Engineering (ICSSE) 215-220.
27. Kingma, Diederik P. and Ba, Jimmy. Adam: A Method for Stochastic Optimization., CoRR abs/1412.6980 (2014).
28. Ruder, Sebastian. (2016). An overview of gradient descent optimization algorithms. arXiv preprint arXiv:1609.04747.
29. Wei-Jiun Lin, James J. Chen. (2013). Class-imbalanced classifiers for high-dimensional data, Briefings in Bioinformatics, Volume 14, Issue 1, January 2013, Pages 13–26. Prieiga per internetą: <https://doi.org/10.1093/bib/bbs006>
30. Mazurowski, M. A., Habas, P. A., Zurada, J. M., Lo, J. Y., Baker, J. A., & Tourassi, G. D. (2008). Training neural network classifiers for medical decision making: the effects of imbalanced datasets on classification performance. Neural networks : the official journal of the International Neural Network Society, 21(2-3), 427–436. Prieiga per internetą: <https://doi.org/10.1016/j.neunet.2007.12.031>

31. Li, Y. and Wang, Y. (2018) Machine Learning Methods of Bankruptcy Prediction Using Accounting Ratios. *Open Journal of Business and Management*, 6, 1-20. doi: 10.4236/ojbm.2018.61001.
32. Hanxu Chang. 2019. The Application of Machine Learning Models in Company Bankruptcy Prediction. In *Proceedings of the 2019 3rd International Conference on Software and e-Business (ICSEB 2019)*. Association for Computing Machinery, New York, NY, USA, 199–203. Prieiga per internetą: <https://doi.org/10.1145/3374549.3374550>
33. Félix J. López Iturriaga, Iván Pastor Sanz, Bankruptcy visualization and prediction using neural networks: A study of U.S. commercial banks, *Expert Systems with Applications*, Volume 42, Issue 6, 2015, Pages 2857-2869, ISSN 0957-4174, <https://doi.org/10.1016/j.eswa.2014.11.025>.
34. Shaza M. Abd Elrahman1 ,Ajith Abraham. A Review of Class Imbalance Problem. *Journal of Network and Innovative Computing* . ISSN 2160-2174, Volume 1 (2013) pp. 332-340© MIR Labs.
35. Khalilia, M., Chakraborty, S. & Popescu, M. (2011). Predicting disease risks from highly imbalanced data using random forest. *BMC Med Inform Decis Mak* 11, 51. Prieiga per internetą: <https://doi.org/10.1186/1472-6947-11-51>.
36. Wu, L., Perin, G., & Picek, S. (2020). I Choose You: Automated Hyperparameter Tuning for Deep Learning-based Side-channel Analysis. *IACR Cryptol. ePrint Arch.*, 2020, 1293.
37. Hutter, F., Lücke, J. & Schmidt-Thieme, L. Beyond Manual Tuning of Hyperparameters. *Künstl Intell* 29, 329–337 (2015). Prieiga per internetą: <https://doi.org/10.1007/s13218-015-0381-0>
38. Jia Wu, Xiu-Yun Chen, Hao Zhang, Li-Dong Xiong, Hang Lei, Si-Hao Deng, Hyperparameter Optimization for Machine Learning Models Based on Bayesian Optimization, *Journal of Electronic Science and Technology*, Volume 17, Issue 1, 2019, Pages 26-40, ISSN 1674-862X. Prieiga per internetą: <https://doi.org/10.11989/JEST.1674-862X.80904120>.
39. Zhi-Hua Zhou and Xu-Ying Liu, "Training cost-sensitive neural networks with methods addressing the class imbalance problem," in *IEEE Transactions on Knowledge and Data Engineering*, vol. 18, no. 1, pp. 63-77, Jan. 2006, doi: 10.1109/TKDE.2006.17.
40. Jan Brabec, Lukas Machlica (2018). Bad practices in evaluation methodology relevant to class-imbalanced problems. *CoRR*, abs/1812.01388.
41. Couronné, Probst, P., & Boulesteix, A.-L. (2018). Random forest versus logistic regression: a large-scale benchmark experiment. *BMC Bioinformatics*, 19(1), 270–270. Prieiga per internetą: <https://doi.org/10.1186/s12859-018-2264-5>
42. Cortes C., Vapnik V. Support-vector networks. *Machine learning*, Vol. 20, No. 3, 1995, pp. 273–297

## Priedai

### 1 Metiniai kintamieji, maksimumų reikšmės.

Kintamasis	3 metai		2 metai		1 metai	
	Nebank. Maks.	Bank. Maks.	Nebank. Maks.	Bank. Maks.	Nebank. Maks.	Bank. Maks.
Pardavimo pajamos	321615800	57270486	398696200	34770307	1638384000	89912102
Pelnas prieš mokesčius	214234000	1012210.5	238328000	2084483	395003000	2086650
Grynasis pelnas	95155000	945890.65	105914000	2084483	335753000	2086650
Pardavimų savikaina	10174880	56486298	6493115	17692879	0	751319
Sąnaudos	40690	4555055.85	3546738	4384858		
Visas turtas	139836100	32584225.2	250091500	34402950	4655376000	27815000
Pinigai ir pinigų ekvivalentai	99045000	6666403	353843000	6193487	91687970	12201000
Trumpalaikis turtas	578608000	9756307	934350000	8986614	369860000	6684328
Atsargos	424411000	5450438.52	611135000	6130831	190435000	6035134
Nuosavas kapitalas	129761300	4277854	134377500	4114325	1734696000	2671972
Trumpalaikiai įsipareigojimai	547776400	10444732	995001000	9387101	1558909000	8887452
Einamasis likvidumo koeficientas	350993	26078.19	253355.2	3036.25	358776.5	1270.52
Kritinis likvidumo koeficientas	350993	858.08	52600	235.04	231095	1173.45
Absolūtus likvidumo koeficientas	318990	609.66	252415.8	1757.25	107702	34.3
Apyvartinis kapitalas	210560000	6319889	297136000	5847482	265178100	1634518
Apyvartino kapitalo apyvartumas	2236	13.39	1477.27	118.63	2197	6.16
Įsipareigojimai	572207800	30739096.78	151248600	35211200	2920680000	26735000
Įsiskolinimo koeficientas	142871	745.5	100893	5892	249649.7	1071.82
Įsipareigojimų nuosavo kapitalo santykis.	184763.3	6923	606352.7	327.63	477724	511.72
Bendras mokumo koeficientas	3258738	626.16	124121.7	3035.25	380614.2	65.57

### 2 Mėnesiniai kintamieji. Maksimumų reikšmės.

Kintamasis	3 metai		2 metai		1 metai	
	Nebank. maksimumas	Bank. maksimumas	Nebank. maksimumas	Bank. maksimumas	Nebank. maksimumas	Bank. maksimumas
Įmonės amžius	26	19	27	20	28	21
Pardavimai pvm deklaracijoje	395039300	10388558	483460900	8360382	536948100	13071201
Pvm suma	17198910	174864	23853650	861000	32504790	2118789
Pirkimai pvm deklaracijoje	360084300	7342923.8	413527200	6745755.1	575701100	8884576.19
vidut_parduot_pvm	395039300	10388558	483460900	8360382	536948100	13071201
Įmonės adresų skaičius	2	2	2	2	2	2
Darbuotojai, gaunantis atlyginimą.	16530	424	15301	391	14323	267

Darbuotojai, esantys neapmokamose atostogose.	502	29	410	20	754	34
Darbuotojų skaičius.	18086	446	16801	413	15660	293
Darbuotojų skaičius, pagal dirbtų dienų skaičių.	15531.61	311.93	14076.43	346.14	13543.48	233.84
Darbo užmokesčio kaštai	13343220	154589.84	12367130	137187.85	12105870	111105.06
Darbuotojų dirbusių bent vieną dieną skaičius.	16746	436	15516	409	14470	273
Darbo sutarčių skaičius.	18086	446	16801	413	15660	293
Darbo užmokesčio kaštų ir pardavimų santykis.	14379.09	796.37	9499.65	3316.81	40218.32	415.1
Pajamos vienam darbuotojui.	11496760	7343011	17941390	7687500	14444260	2104000
Proc. darbuotojų neapmokamose atostogose	1	1	1	1	1	1
Fizinių asmenų valdoma dalis.	1	1	1	1	1	1
VMI nepriemoka	19270690	2585489.6	19271340	2951089.2	19263840	5369917.15

### 3 Metiniai kintamieji. Minimumo reikšmės.

Kintamasis	3 metai		2 metai		1 metai	
	Nebank. minimumas	Bank. minimumas	Nebank. minimumas	Bank. minimumas	Nebank. minimumas	Bank. minimumas
Pardavimo pajamos	-3071885	0	-915854	-4999	-1109904	0
Pelnas prieš mokesčius	-23777000	-1230633	-111830000	-2377240	-91215000	-4208741
Grynasis pelnas	-23777000	-1046695	-111830000	-2377240	-91215000	-4208741
Pardavimų savikaina	-2.857E+09	-1921	-3.589E+09	-33229984	-1.529E+09	-89030401
Sąnaudos	-113660000	13028	-84786000	2780		
Visas turtas	-671034	-28839.82	-310219	-59262	-136715	-16420
Pinigai ir pinigų ekvivalentai	-642745	-67962	-140681	-50550	-803002	-14734
Trumpalaikis turtas	-701448	-46379.73	-340633	-75562	-248411	-16607
Atsargos	-34894	-48396.21	-59014	-83617	-104657	0
Nuosavas kapitalas	-38827480	-8253931.9	-583104000	-8546320	-674319000	-8742575
Trumpalaikiai įsipareigojimai	-666651	-1128.57	-406740	-2200	-222669	0
Einamasis likvidumo koeficientas	-14120.5	-8.06	-17579.5	-645.74	-30672	-0.57
Kritinis likvidumo koeficientas	-12488.07	-6.55	-17568	-147.59	-30672	-2.41
Absoliutus likvidumo koeficientas	-14119.5	-6.41	-15240	-16.38	-30672	-0.03
Apyvartinis kapitalas	-247749400	-8398732.5	-583375000	-8691130	-1.504E+09	-8887385
Apyvartino kapitalo apyvartumas	-55965	-744.5	-55965	-5891	-55965	-694.78
Įsipareigojimai	-664750	-40653	-367212	-41245	-110578	-20371
Įsiskolinimo koeficientas	-8274.33	-14.79	-2895	-115.49	-4154.1	-7.89
Įsipareigojimų nuosavo kapitalo santykis.	-102911	-132.19	-260646	-1893.6	-229915	-29590
Bendras mokumo koeficientas	-14121.5	-6.04	-14121.5	-50.53	-266247	-1.76

#### 4 Menesiniai kintamieji. Minimumo reikšmės

Kintamasis	3 metai		2 metai		1 metai	
	Nebank. Minimumas	Bank. minimumas	Nebank. minimumas	Bank. minimumas	Nebank. minimumas	Bank. minimumas
įmonės amžius	1	1	2	2	3	3
Pardavimai pvm deklaracijoje	-6068180	-44816	-32715026	-163762	-2093482	-139996
Pvm suma	-11404752	-860654	-16137769	-480992	-9921784	-402699
Pirkimai pvm deklaracijoje	-5203128.6	-91985.71	-2532914.3	-687266.67	-871230.76	-117966.67
vidut_parduot_pvm	-6068180	-44816	-32715026	-163762	-2093482	-139996
Įmonės adresų skaičius	1	1	1	1	1	1
Darbuotojai, gaunantis atlyginimą.	0	0	0	0	0	0
Darbuotojai, esantys neapmokamose atostogose.	0	0	0	0	0	0
Darbuotojų skaičius.	1	1	1	1	1	1
Darbuotojų skaičius, pagal dirbtų dienų skaičių.	0	0	0	0	0	0
Darbo užmokesčio kaštai	0.23	0.51	0.18	1	0	1.48
Darbuotojų dirbusių bent vieną dieną skaičius.	0	0	0	0	0	0
Darbo sutarčių skaičius.	0	1	1	1	0	1
Darbo užmokesčio kaštų ir pardavimų santykis.	-101.19	-1.84	-6769.51	-17.81	-1315.79	-11.55
Pajamos vienam darbuotojui.	-465267.75	-18681.05	-2403732	-59030.49	-348913.67	-16728.67
Proc. darbuotojų neapmokamose atostogose	0	0	0	0	0	0
Fizinių asmenų valdoma dalis.	0	0	0	0	0	0
VMI nepriemoka	0.01	0	0.01	0	0.01	0.01

#### 5 Metiniai kintamieji. Standartiniai nuokrypiai.

Kintamasis	3 metai		2 metai		1 metai	
	Nebank. std.nuokrypis	Bank. std.nuokrypis	Nebank. std.nuokrypis	Bank. std.nuokrypis	Nebank. std.nuokrypis	Bank. std.nuokrypis
Pardavimo pajamos	16352282	3090625.2	20687902	1985570.1	13626531	4034144.9
Pelnas prieš mokesčius	1474999.9	88876.32	1624203.7	155306.18	2233868.5	291179.89
Grynasis pelnas	825963.97	82108.46	906069.37	147947.89	1640661.1	251311.12
Pardavimų savikaina	18154934	3147370.6	23110595	2113208.3	15097757	4793732.8
Sąnaudos	13831193	806336.45	9695854.6	872594.1		
Visas turtas	10719136	1669947.7	18996137	1851930.9	19743865	1621612.8
Pinigai ir pinigų ekvivalentai	951991.42	229653.66	2085363.3	359225.14	1008597.6	810514.74
Trumpalaikis turtas	3502109.3	679579.38	6569358	638653.74	3961186.6	618397.62
Atsargos	2127063.2	402877.69	4059690.5	387254.76	1797310.5	336037.7
Nuosavas kapitalas	7234920.3	364069.8	10354040	427456.06	8580045.5	479623.78
Trumpalaikiai įsipareigojimai	3587630.5	716151.01	7253529.5	719782.53	8155042.2	868071.12

Einamasis likvidumo koeficientas	2157.09	820.77	1529.05	110.62	2672.05	61.01
Kritinis likvidumo koeficientas	1951.2	38.73	493.89	12.55	1201.32	53.6
Absoliutus likvidumo koeficientas	1644.06	26.36	1393.46	68.45	847.79	2.71
Apyvartinis kapitalas	2104444.5	435490.85	3743810.9	474336.44	6916464.5	555747.24
Apyvartino kapitalo apyvartumas	361.76	29.37	405.91	209.91	352.08	39.04
Įsipareigojimai	4988057	1570659.1	10496219	1785625.5	12765990	1616569
Įsiskolinimo koeficientas	706.33	29.11	707.86	208.72	1478	67.34
Įsipareigojimų nuosavo kapitalo santykis.	1068.06	220.82	3302.18	69.02	2341.33	1215.59
Bendras mokumo koeficientas	12506.21	25.87	1191.88	142.63	3374.23	4.92

## 6 Mėnesiniai kintamieji. Standartiniai nuokrypiai.

Kintamasis	3 metai		2 metai		1 metai	
	Nebank. std.nuokrypis	Bank. std.nuokrypis	Nebank. std.nuokrypis	Bank. std.nuokrypis	Nebank. std.nuokrypis	Bank. std.nuokrypis
Imonės amžius	6.22	5.35	6.22	5.35	6.22	5.35
Pardavimai pvm deklaracijoje	1808054.8	534312.25	2107869.1	280179.73	2472661.4	343419.15
Pvm suma	102101.72	18889.12	123746.21	22630.28	152471.4	38100.25
Pirkimai pvm deklaracijoje	1564794.2	467889.46	1820288.2	248669.91	2195990.4	239825.74
vidut_parduot_pvm	1804857	533930.89	2103922.2	280109.72	2467868.8	343021.83
Įmonės adresų skaičius	0.03	0.05	0.02	0.05	0.02	0.04
Darbuotojai, gaunantis atlyginimą.	97.85	22.32	91.22	22.41	89.06	19.88
Darbuotojai, esantys neapmokamose atostogose.	3.17	0.97	2.98	1.04	5.1	1.21
Darbuotojų skaičius.	105.07	23.29	98.21	23.53	95.83	20.94
Darbuotojų skaičius, pagal dirbtų dienų skaičių.	92.99	19.86	86.68	20.23	84.31	17.99
Darbo užmokesčio kaštai	71974.99	7053.31	73641.13	10691.26	76517.21	10375.11
Darbuotojų dirbusių bent vieną dieną skaičius.	99.08	22.76	92.41	22.94	90.4	20.32
Darbo sutarčių skaičius.	105.07	23.28	98.21	23.53	95.83	20.94
Darbo užmokesčio kaštų ir pardavimų santykis.	30.57	14.93	25.51	39.85	70.76	6.78
Pajamos vienam darbuotojui.	65046.73	343981.49	65919.31	191096.1	85821.62	41001.39
Proc. darbuotojų neapmokamose atostogose	0.14	0.14	0.14	0.16	0.16	0.21
Fizinių asmenų valdoma dalis.	0.36	0.3	0.35	0.31	0.36	0.34
VMI nepriemoka	225368.36	126039.1	211954.09	140791.1	199772.58	217624.72

## 7 Metiniai kintamieji. Vidurkiai.

Kintamasis	3 metai		2 metai		1 metai	
	Nebank. vidurkis	Bank. vidurkis	Nebank. vidurkis	Bank. vidurkis	Nebank. vidurkis	Bank. vidurkis
Pardavimo pajamos	981882.06	649160.98	1156468.5	609887.37	1197472.6	694472.79

Pelnas prieš mokesčius	80912.52	1752.47	82284.51	-12143.84	82419.78	-52153.46
Grynasis pelnas	46690.88	473.23	47055.23	-13289.26	52803.66	-42903.26
Pardavimų savikaina	-1155291.4	601239.93	-1382514.9	268195.02	-1432026	778724.97
Sąnaudos	-4542148.3	510864.25	-3414770.5	606915.88		
Visas turtas	772803.53	375941.53	1069169.6	433874.9	965862.08	426803.45
Pinigai ir pinigų ekvivalentai	87187.68	28125.88	120541.28	47476.33	107073.29	77566.14
Trumpalaikis turtas	312355.01	208859.94	438287.86	226663.83	408693.51	218205.63
Atsargos	126621.37	103056.44	187389.11	106672.59	163084.47	92843.16
Nuosavas kapitalas	369354.53	38211.19	495057	36812.05	422384.66	-11737.03
Trumpalaikiai įsipareigojimai	231594.47	211722.28	338670.3	239646.23	327511.75	296746.05
Einamasis likvidumo koeficientas	58.05	30.17	50.1	7.46	64.63	5.77
Kritinis likvidumo koeficientas	42.13	3.57	22.28	2	28.97	3.68
Absoliutus likvidumo koeficientas	33.41	2.61	33.42	4.7	27.5	0.54
Apyvartinis kapitalas	106596.6	3375.21	133764.22	-8210.67	112620.65	-70258.91
Apyvartinio kapitalo apyvartumas	-8.23	-1.88	-8.66	-9.88	-7.97	-4.95
Įsipareigojimai	396811.52	337730.34	563247.58	397397.24	531615.06	438540.48
Įsiskolinimo koeficientas	15.41	2.52	17.11	11.78	22.98	8.68
Įsipareigojimų nuosavo kapitalo santykis.	9.07	9.54	20.84	0.27	19.92	-48.64
Bendras mokumo koeficientas	105.22	2.84	40.78	9.58	59.02	0.91

## 8 Mėnesiniai kintamieji. Vidurkiai.

Kintamasis	3 metai		2 metai		1 metai	
	Nebank. vidurkis	Bank. vidurkis	Nebank. vidurkis	Bank. vidurkis	Nebank. vidurkis	Bank. vidurkis
Įmonės amžius	8.85	6.33	9.85	7.33	10.85	8.33
Pardavimai pvm deklaracijoje	125110.14	102971.32	139152.41	65347.14	156938.13	60588.06
Pvm suma	4152.48	948.76	4454.93	1442.81	4858.07	1498.27
Pirkimai pvm deklaracijoje	88655.96	79976.15	97686.08	48099.94	108844.43	42729.72
vidut_parduot_pvm	124665.88	102818.77	138629.53	65312.61	156328	60443.49
Įmonės adresų skaičius	1	1	1	1	1	1
Darbuotojai, gaunantis atlyginimą.	12.24	10.94	12.25	11.28	12.5	10.72
Darbuotojai, esantys neapmokamose atostogose.	0.17	0.21	0.18	0.26	0.24	0.34
Darbuotojų skaičius.	12.93	11.54	12.96	11.99	13.25	11.58
Darbuotojų skaičius, pagal dirbtų dienų skaičių.	11.66	10.02	11.69	10.33	11.9	9.79
Darbo užmokesčio kaštai	7984.67	2218.79	8815.36	4768.32	10054.28	5198.68
Darbuotojų dirbusių bent vieną dieną skaičius.	12.43	11.14	12.45	11.51	12.72	10.99
Darbo sutarčių skaičius.	12.93	11.54	12.96	11.99	13.25	11.58
Pajamos vienam darbuotojui.	9144.17	39087.53	10101.83	13939.36	11466.72	6654
Proc. darbuotojų neapmokamose atostogose	0.02	0.03	0.03	0.04	0.03	0.06
Fizinių asmenų valdoma dalis.	0.84	0.88	0.84	0.87	0.84	0.84
VMI nepriemoka	6914.32	11701.95	6792.38	19489.91	7189.56	34785.53



## 9 Atsitiktinio miško klasifikavimo rezultatai, apmokant modelį su skirtingais balansais.

Atsitiktinio miško klasifikavimo įverčiai, apmokant su 50:50 balansu.

	precision	recall	f1-score	support
0.0	1.00	0.94	0.97	11838
1.0	0.19	0.94	0.31	171
accuracy			0.94	12009
macro avg	0.59	0.94	0.64	12009
weighted avg	0.99	0.94	0.96	12009

Atsitiktinio miško klasifikavimo įverčiai, apmokant su 70:30 balansu.

	precision	recall	f1-score	support
0.0	1.00	0.98	0.99	11838
1.0	0.37	0.87	0.52	171
accuracy			0.98	12009
macro avg	0.68	0.92	0.75	12009
weighted avg	0.99	0.98	0.98	12009

Atsitiktinio miško klasifikavimo įverčiai, apmokant su 85:15 balansu.

	precision	recall	f1-score	support
0.0	1.00	0.99	1.00	11838
1.0	0.65	0.73	0.68	171
accuracy			0.99	12009
macro avg	0.82	0.86	0.84	12009
weighted avg	0.99	0.99	0.99	12009

---

Atsitiktinio miško klasifikavimo įverčiai, apmokant su 99:1

	precision	recall	f1-score	support
0.0	0.99	1.00	1.00	11866
1.0	1.00	0.50	0.67	143
accuracy			0.99	12009
macro avg	1.00	0.75	0.83	12009
weighted avg	0.99	0.99	0.99	12009