



Kauno technologijos universitetas
Matematikos ir gamtos mokslų fakultetas

Europos šalių investicinio patrauklumo vertinimas dirbtiniais neuroniniais tinklais

Baigiamasis magistro studijų projektas

Mantas Lukauskas
Projekto autorius

Doc. dr. Tomas Ruzgas

Vadovas

Prof. dr. Jurgita Bruneckienė

Vadovė

Kaunas, 2019



Kauno technologijos universitetas
Matematikos ir gamtos mokslų fakultetas

Europos šalių investicinio patrauklumo vertinimas dirbtiniais neuroniniais tinklais

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

Mantas Lukauskas

Projekto autorius

Doc. dr. Tomas Ruzgas

Vadovas

Lekt. dr. Mindaugas

Kavaliauskas

Recenzentas

Prof. dr. Jurgita Bruneckienė

Vadovė

Doc. dr. Vilda Gižienė

Recenzentė

Kaunas, 2019



Kauno technologijos universitetas

Matematikos ir gamtos mokslų fakultetas

Mantas Lukauskas

Europos šalių investicinio patrauklumo vertinimas dirbtiniais neuroniniais tinklais

Akademinio sąžiningumo deklaracija

Patvirtinu, kad mano, Manto Lukausko, baigiamasis projektas tema „Europos šalių investicinio patrauklumo vertinimas dirbtiniais neuroniniais tinklais“ yra parašytas visiškai savarankiškai ir visi pateikti duomenys ar tyrimų rezultatai yra teisingi ir gauti sąžiningai. Šiame darbe nei viena dalis nėra plagijuota nuo jokių spausdintinių ar internetinių šaltinių, visos kitų šaltinių tiesioginės ir netiesioginės citatos nurodytos literatūros nuorodose. Įstatymų nenumatytų piniginių sumų už šį darbą niekam nesu mokėjęs.

Aš suprantu, kad išaiškėjus nesąžiningumo faktui, man bus taikomos nuobaudos, remiantis Kauno technologijos universitete galiojančia tvarka.

(vardą ir pavardę įrašyti ranka)

(parašas)

Lukauskas, Mantas. Europos šalių investicinio patrauklumo vertinimas dirbtiniais neuroniniais tinklais. Magistro krypties studijų baigiamasis projektas / vadovai doc. dr. Tomas Ruzgas ir prof. dr. Jurgita Bruneckienė; Kauno technologijos universitetas, Matematikos ir gamtos mokslų fakultetas.

Studijų kryptis ir sritis (studijų kryptių grupė): Fiziniai mokslai, Matematika (G100)

Reikšminiai žodžiai: dirbtiniai neuroniniai tinklai, tiesioginės užsienio investicijos, rekurentiniai neuroniniai tinklai, ilgalaikės-trumpalaikės atminties neuroniniai tinklai, mašininis mokymasis.

Kaunas, 2019. 76 p.

Santrauka

Baigiamasis magistro projektas yra skirtas Europos šalių tiesioginėms užsienio investicijoms prognozuoti dirbtiniais neuroniniais tinklais. Mokslinėje literatūroje dažniausiai yra nagrinėjami tik veiksniai, lemiantys tiesiogines užsienio investicijas į šalį, tačiau TUI prognozavimas nėra atliekamas. Tiesioginės užsienio investicijos yra reikšmingos kiekvienai šaliai, todėl jų prognozavimas gali padėti planuoti šalies biudžetą. Atlikta mokslinės literatūros analizė leido išskirti penkis pagrindinius TUI patrauklumo elementus. Šios analizės metu buvo sudarytas teorinis tiesiogines užsienio investicijas į šalį lemiančių veiksnių grupių modelis, kurį sudaro 16 veiksnių grupių (41 veiksnys). Tyrime naudojami dirbtinių neuroninių tinklų modeliai: RNN, LSTM, GRU ir ELM, kurie plačiau aptariami šio darbo metodų aprašyme. Tyrime buvo sukurti daugiau nei 140 tūkst. dirbtinių neuroninių tinklų modeliai. Šių modelių rezultatai parodė, kad didžiausias tikslumas yra pasiekiamas naudojant ELM metodus. Sukurtų modelių palyginimas su kitų mokslininkų naudojamais tiesinės regresijos modeliais patvirtino, kad dirbtinių neuroninių tinklų modeliai yra tikslesni tiesioginių užsienio investicijų į šalį prognozavime. Pritaikyti geriausi dirbtinių neuroninių tinklų modeliai parodė, kad, lyginant su 2017 metais, 13-oje iš 29 tyrime naudotų šalių 2018 metais prognozuojamas tiesioginių užsienio investicijų mažėjimas. Likusiose 16-oje šalių, remiantis geriausiai prognozavimo modeliais, prognozuojamas TUI didėjimas. Didžiausias TUI didėjimas (įvertinant procentinį TUI pokytį) yra numatomas Islandijoje – 282 %. O didžiausias TUI mažėjimas (įvertinant procentinį TUI pokytį) yra numatomas Suomijoje. Verta pastebėti ir tai, kad didžiausias TUI turinčioje šalyje, Nyderlanduose, TUI didėjimas sieks tik 0,18 %. Tyrimo metu sudaryti dirbtinių neuroninių tinklų klasifikavimo modeliai patvirtino, kad didžiausią reikšmę teigiamoms TUI turi infliacijos lygis šalyje, eksporto didėjimo tempas, nuosavo kapitalo pelningumo rodiklis ir kt. Tyrimo metu buvo išskirti dvidešimt didžiausių reikšmę turintys rodikliai, kurie plačiau yra pristatomi šiame darbe.

Lukauskas, Mantas. Evaluation of investment attractiveness of European countries by artificial neural networks. Master's Final Degree Project / supervisors assoc. prof. Tomas Ruzgas and prof. Jurgita Bruneckienė; Faculty of Mathematics and Natural Sciences, Kaunas University of Technology.

Study field and area (study field group): Physical sciences, Mathematics (G100)

Keywords: artificial neural networks, foreign direct investment, recurrent neural networks, long-short term memory neural networks, machine learning.

Kaunas, 2019. 76 p.

Summary

This project focuses on the topic of Europe countries foreign direct investment modelling by artificial neural networks. Foreign direct investment is significant for each country, so forecasting can help to plan the country's budget. In the scientific literature, only the factors that determine foreign direct investment are considered, but FDI forecasting is not performed. The analysis of the scientific literature made it possible to distinguish five main elements of attractiveness of FDI. In this analysis, a theoretical model of the groups of factors determining foreign direct investment was formed, consisting of 16 groups of factors (total of 41 factors). The study uses models of artificial neural networks: RNN, LSTM, GRU, and ELM, which are discussed in more detail in the description of methods. In this study, more than 140,000 models of artificial neural networks were created. The results of these models have shown that maximum accuracy is achieved using ELM techniques. Comparison of the developed models with the linear regression models used by other scientists confirmed that the models of artificial neural networks are more accurate in forecasting foreign direct investment. The best models of artificial neural networks applied showed that, compared to 2017, in 13 out of 29 countries used in the study in 2018, foreign direct investment is projected to decline. In the remaining 16 countries, based on best forecasting models, FDI growth is projected. The largest increase in FDI (considering the percentage change in FDI) is expected in Iceland - 282%. Meanwhile, the largest decline in FDI (considering the percentage change in FDI) is expected in Finland. It is also worth noting that the largest FDI country in the Netherlands, the increase in FDI will be only 0.18%. Arranged models for the classification of artificial neural networks have confirmed that inflation rates in the country, export growth rates, return on equity, and so on are of the greatest importance to positive FDI. The study identified twenty most important indicators that are more widely presented in the study.

Turinys

Lentelių sąrašas	7
Paveikslų sąrašas	8
Santrumpų ir terminų sąrašas	10
Įvadas	11
1. Literatūros apžvalga	13
1.1. Investicinio patrauklumo ir tiesioginių užsienio investicijų sampratos.....	13
1.2. Investicinio patrauklumo vertinimo indeksai	14
1.3. Tiesiogines užsienio investicijas sąlygojantys veiksniai	18
1.3.1. Ekonominis patrauklumas	18
1.3.2. Socialinis ir kultūrinis patrauklumas	21
1.3.3. Technologinis patrauklumas	23
1.3.4. Politinis patrauklumas	24
1.3.5. Aplinkos patrauklumas	25
1.3.6. Apibendrinti tiesiogines užsienio investicijas šalyje lemiantys veiksniai ir jų modelis. 26	
1.4. Tiesioginių užsienio investicijų dinamika 2000-2017 metais	28
2. Metodų analizė	31
2.1. Mašininis mokymasis	31
2.2. Dirbtiniai neuroniniai tinklai, jų samprata, veikimas, tipai ir naudojimas	32
2.2.1. Rekurentiniai neuroniniai tinklai	35
2.2.2. Ilgalaikės-trumpalaikės atminties neuroniniai tinklai.....	37
2.2.3. Sulaikomo pasikartojančio vieneto neuroniniai tinklai	41
2.2.4. Saviorganizuojantys neuroniniai tinklai	42
2.2.5. Ekstremalaus mokymosi mašinos.....	43
2.3. Aktyvacijos funkcijos samprata ir naudojimas.....	44
2.4. Klasterinė analizė.....	45
2.5. Duomenų dimensijų mažinimas	48
2.6. Metodų tikslumo vertinimo metrikos	50
3. Empirinis tyrimas	52
3.1. Duomenys	52
3.2. Tiesioginių užsienio investicijų kintamojo apžvalga.....	53
3.3. Išorinių kintamųjų apžvalga	54
3.4. Klasterizavimo analizės rezultatai	56
3.5. Saviorganizuojančių neuroninių tinklų rezultatai	59
3.6. Tiesioginių užsienio investicijų prognozavimo rezultatai	60
3.6.1. Geriausiai tiesiogines užsienio investicijas prognozuojantys modeliai.....	60
3.6.2. Geriausiai tiesiogines užsienio investicijas prognozuojančių modelių palyginimas.....	62
3.6.3. Skirtingų neuroninių tinklų konfigūracijų palyginimas.....	63
3.6.4. Tiesioginių užsienio investicijų 2018 metais prognozavimas	65
3.7. Tiesioginių užsienio investicijų klasifikavimo rezultatai	66
Išvados	68
Rekomendacijos	70
Literatūros sąrašas	71
Priedai	77

Lentelių sąrašas

1.1 lentelė. Tiesiogines užsienio investicijas lemiantys veiksniai ir veiksmų grupės.....	26
2.1 lentelė. Aktyvacijos funkcijos, jų lygtys ir grafinis vaizdavimas	44
2.2 lentelė. Metriniai atstumo matai.....	48
2.3 lentelė. Regresinių modelių paklaidos funkcijos	50
2.4 lentelė. Klasifikavimo modelių paklaidos funkcijos.....	51
3.1 lentelė. Kiekvienos tyrime naudotos šalies geriausių modelių, remiantis MAPE metrika charakteristikos.....	61
3.2 lentelė. Geriausiai prognozuojančiu dirbtinių neuroninių tinklų modelių palyginimas su tiesinės regresijos ir „Naive“ modeliais, remiantis MAPE metrika	62
3.3 lentelė. Tiesioginės užsienio investicijos 2017 metais ir prognozuojamos geriausiai modeliais 2018 TUI	65

Paveikslų sąrašas

1.1 pav. Pasaulinio patrauklumo tiesioginėms užsienio investicijoms indekso (GFICA) struktūra.	15
1.2 pav. Pasaulinio patrauklumo tiesioginėms užsienio investicijoms Europos šalių indekso reikšmės 2018 metais.....	15
1.3 pav. Rizikos ir privataus kapitalo šalies patrauklumo indekso (VCPE) struktūra	16
1.4 pav. Rizikos ir privataus kapitalo šalies patrauklumo (VCPE) Europos šalių indekso reikšmės 2018 metais.....	16
1.5 pav. Regionų investicinį patrauklumą, sumanaus vystymosi kontekste, lemiančių veiksnių modelis (2).....	17
1.6 pav. Tiesioginėms užsienio investicijoms patrauklumą šalyje lemiančių veiksnių modelis	28
1.7 pav. Pasaulio, aukštų, vidutinių ir žemų pajamų šalių tiesioginių užsienio investicijų dinamika 2000-2017 metais	29
1.8 pav. Euro zonos, OECD ir ES šalių tiesioginių užsienio investicijų dinamika 2000-2017 metais	29
2.1 pav. Neuroninio tinklo schema: a) neuroninio tinklo perceptronas; b) neuroninis tinklas su vienu paslėptuoju sluoksniu	33
2.2 pav. Gradientinio nusileidimo (angl. <i>gradient descent</i>) metodas	34
2.3 pav. Rekurentinių neuroninių tinklų schemas: a) rekurentinių neuroninių tinklų struktūra; b) rekurentinių neuroninių tinklų ciklas.....	35
2.4 pav. Išskleistas rekurentinis neuroninis tinklas.....	36
2.5 pav. Rekurentinių neuroninio tinklų veikimo schema	36
2.6 pav. RNN tinklas esant nedideliam atotrūkiui tarp informacijos ir jos panaudojimo.....	36
2.7 pav. RNN tinklas esant dideliame atotrūkiui tarp informacijos ir jos panaudojimo.....	37
2.8 pav. Ilgalaikės-trumpalaikės atminties neuroninis tinklas	37
2.9 pav. Ilgalaikės-trumpalaikės atminties neuroninių tinklų struktūra.....	38
2.10 pav. Pagrindinis ilgalaikės-trumpalaikės atminties neuroninių tinklų elementas	38
2.11 pav. LSTM veikimo schema – 1 žingsnis: užmiršimo vartų sluoksniu (angl. <i>forget gate layer</i>) panaudojimas	39
2.12 pav. LSTM veikimo schema – 2 žingsnis: atnaujinamų reikšmių parinkimas	39
2.13 pav. LSTM veikimo schema – 3 žingsnis: būsenos atnaujinimas.....	40
2.14 pav. LSTM veikimo schema – 4 žingsnis: išvesties ir naujos būsenos išvedimas.....	40
2.15 pav. Sulaikomo pasikartojančio vieneto (GRU) neuroninis tinklas.....	41
2.16 pav. Sulaikomo pasikartojančio vieneto (GRU) (angl. <i>gated recurrent unit</i>) veikimo schema	42
2.17 pav. Ekstremalaus mokymosi mašinų (angl. <i>Extreme learning machines</i>) veikimo schema ...	43
2.18 pav. K-vidurkių algoritmo veikimo principas	46
2.19 pav. Pirmosios ir antrosios pagrindinių komponentų kryptys.....	49
3.1 pav. Empirinio tyrimo duomenų paruošimo schema	52
3.2 pav. Tyrimo duomenų modeliavimo programos beta versijos saityno vartotojo sąsaja (angl. <i>web user interface</i>).....	53
3.3 pav. Europos šalių tiesioginių užsienio investicijų stačiakampės diagramos	54
3.4 pav. Europos šalių BVP tenkančių vienam gyventojui stačiakampės diagramos.....	54
3.5 pav. Europos šalių prekybos atvirumo (% BVP) stačiakampės diagramos	55
3.6 pav. Europos šalių nedarbo lygio (%) stačiakampės diagramos	56
3.7 pav. TUI ir BVP sklaidos diagramos: a) naudojant tikrąsias reikšmes b) naudojant logaritmines reikšmes.....	56

3.8 pav. TUI ir prekybos atvirumo (% BVP) sklaidos diagramos: a) naudojant tikrąsias reikšmes b) naudojant logaritmines reikšmes	57
3.9 pav. Hierarchinio klasterizavimo rezultatai panaudojant visus rodiklius	57
3.10 pav. Hierarchinio klasterizavimo panaudojant visus rodiklius rezultatų žemėlapis	58
3.11 pav. Hierarchinio klasterizavimo rezultatai panaudojant pagrindines komponentes (k = 14)..	59
3.12 pav. Saviorganizuojančių neuroninių tinklų rezultatai panaudojant pagrindinius TUI rodiklius	59
3.13 pav. Saviorganizuojančių neuroninių tinklų rezultatai panaudojant visus kintamuosius	60
3.14 pav. Skirtingų giluminio mokymosi karkasų efektyvumo įvertinimas 2018 metais.....	66
3.16 pav. Reikšmingiausi šalių tiesioginių užsienio investicijų tendencijų klasifikavimo kintamieji (n = 20).....	67

Santrumpų ir terminų sąrašas

Santrumpos:

ANN – dirbtiniai neuroniniai tinklai (angl. *artificial neural networks*)

BVP – bendras vidaus produktas (angl. *gross domestic product*)

ELM – ekstremalaus mokymosi mašinos (angl. *extreme learning machines*)

GRU – sulaikomo pasikartojančio vieneto (angl. *gated recurrent unit*) neuroniniai tinklai;

ICA – nepriklausomų komponentų analizė (angl. *independent components analysis*)

LSTM – ilgalaikės-trumpalaikės atminties neuroniniai tinklai (angl. *long-short term memory networks*);

OECD - ekonominio bendradarbiavimo ir plėtros organizacija (angl. *organisation for economic co-operation and development*)

PCA – pagrindinių komponentų analizė (angl. *principal components analysis*)

RNN – rekurentiniai neuroniniai tinklai (angl. *recurrent neural network*);

SOM – saviorganizuojantys neuroniniai tinklai (angl. *self-organizing map*)

TUI – tiesioginės užsienio investicijos (angl. *foreign direct investments (FDI)*)

Įvadas

Darbo problematika ir aktualumas. Globalizacija, ketvirtoji pramonės revoliucija, technologijų pažanga, sparčiai besikeičianti aplinka ir vartotojų poreikiai lemia didėjančią konkurenciją tarp įvairių įmonių ir organizacijų. Organizacijos konkuruoja dėl idėjų, produktų ar paslaugų, vartotojų, darbuotojų, technologijų, projektų, rinkų ir kt. Siekdamos išlikti konkurencingomis, įmonės ir organizacijos turi ieškoti naujų ir sumanių būdų, kaip konkuruoti ir išlaikyti savo konkurencingumą nacionaliniu ir (ar) tarptautiniu lygmeniu ilguoju laikotarpiu. Moksliniai tyrimai patvirtina, kad tiesioginės užsienio investicijos yra viena iš įmonės ir organizacijos konkurencingumo didinimo priemonių. Jos laikomos viena iš saugiausių bei naudingiausių kapitalo srauto formų [1]. Naujausi tiek užsienio, tiek ir lietuvių mokslininkų darbai išryškina tendenciją, kad tose šalyse, kuriose pritraukiama daugiau tiesioginių užsienio investicijų, įmonės pasižymi aukštesniu konkurencingumo lygiu ir plėtros tempu. Šis ryšys tarp tiesioginių užsienio investicijų ir įmonių konkurencingumo tik patvirtina, kad pačios šalys, formuojančios investicinį patrauklumą, prisideda prie įmonių konkurencingumo didinimo. Be to, tiesioginės užsienio investicijos tiesiogiai prisideda prie visos šalies ekonomikos plėtros skatindamos žinių, technologijų ir inovacijų pritraukimą, infrastruktūros kūrimą, susijusių ir aptarnaujančių verslų atsiradimą. Teigiamas tiesioginių užsienio investicijų poveikis parodo tai, kad svarbu strateginiame šalies lygmenyje sumaniai formuoti šalies investicinį patrauklumą ir teisingai prognozuoti į šalį ateinančias tiesiogines užsienio investicijas. Šalys, gebančios prognozuoti ateities tiesiogines užsienio investicijas, gali tiksliau planuoti savo biudžetą, formuoti strateginio vystymosi kryptis, diversifikuoti ir efektyviau valdyti su tiesioginių užsienio investicijų išėjimu susijusias rizikas ir neigiamas pasekmes.

Mokslininkai analizuodami tiesioginių užsienio investicijų tendencijas ar ypatumus ir vertindami šalies investicinio patrauklumo koncepciją bei jos įtaką tiesioginėms užsienio investicijoms, dažniausiai tiria ryšį tarp atskirų investicinį patrauklumą lemiančių veiksnių ir tiesioginių užsienio investicijų, panaudodami tiesinės regresijos modelius, kurie yra tinkami ne visais atvejais. Be to, dažniausiai yra atliekamas tik tiesiogines užsienio investicijas veikiančių veiksnių vertinimas, o ne tiesioginių užsienio investicijų prognozavimas. Mokslinėje literatūroje, dėl didelės tiesiogines užsienio investicijas šalyje lemiančių veiksnių sąveikos ir kiekio, prognozavimas tampa kompleksišku uždaviniu ir dideliu iššūkiu tiek mokslininkams dėl pačių rezultatų patikimumo, tiek ir strategams dėl skaičiavimo ir prognozavimo rezultatais paremtų išvadų priėmimo ir sprendimų teisingumo. Esant dideliems duomenų srautams ir komplikuotiems ryšiams tarp jų, dirbtinio intelekto panaudojimas yra vienas iš galimų būdų mokslininkui, ekonomistui, strategui sumaniai spręsti ekonomines problemas. Tai leidžia rasti greitą, savalaikį ir teisingą (išvengiant žmogiškosios klaidos) atsakymą (pagrindimą) ekonominėms išvadoms (sprendimams). Tai sustiprina priimamų išvadų įžvalgumą ir priimamų sprendimų operatyvumą. Dėl šios priežasties, dirbtinio intelekto panaudojimas ekonomikoje tampa ne tik svarbiu, bet ir būtinu aspektu. Taigi, šiame darbe tiesioginėms užsienio investicijoms prognozuoti bus naudojami dirbtiniai neuroniniai tinklai, suteikiantys galimybę prognozuoti reikšmes, remiantis net ir dideliu kiekiu kokybinių ir kiekybinių rodiklių. Taip pat bus kuriama modeliavimo programa, leidžianti pastoviai atnaujinti, susisteminti, atrinkti svarbiausius rodiklius ir surūšiuoti, sumodeliuoti ir prognozuoti, pagal užduotus parametrus ekonominę informaciją.

Tyrimo objektas – Europos šalių tiesioginės užsienio investicijos.

Tyrimo tikslas – palyginti skirtingos struktūros dirbtinius neuroninius tinklus, naudojamus tiesioginėms užsienio investicijoms prognozuoti.

Tyrimo uždaviniai:

1. išanalizuoti investicinio patrauklumo ir tiesioginių užsienio investicijų sampratas, jų tarpusavio ryšį ir identifikuoti pagrindinius tiesiogines užsienio investicijas šalyje lemiančius veiksniai;
2. sudaryti tiesioginėms užsienio investicijoms patrauklumą šalyje lemiančių veiksmų modelį ir išskirti veiksniai charakterizuojančius rodiklius;
3. aptarti dirbtinių neuroninių tinklų modelius, naudojamus šalies investiciniam patrauklumui prognozuoti;
4. atlikti šalių klasterinę ir saviorganizuojančių neuroninių tinklų analizę, išskiriant šalis, turinčias panašius tiesiogines užsienio investicijas į šalį lemiančius rodiklius;
5. sudaryti tiesiogines užsienio investicijas prognozuojančius neuroninių tinklų modelius kiekvienai tyrime naudojamai šaliai ir atlikti TUI prognozavimą, remiantis geriausiais atrinktais modeliais;
6. parengti tiesioginių užsienio investicijų tendencijų klasifikavimo modelius ir išskirti pagrindinius rodiklius, lemiančius klasifikavimo rezultatus.

Tyrimo metodai. Mokslinės literatūros analizė, statistinių duomenų analizė, duomenų klasterinė analizė, dirbtinių neuroninių tinklų modeliai.

Darbo struktūra. Šis darbas yra sudarytas iš trijų atskirų dalių. Pirmoje dalyje (1 skyrius) pateikiama investicinio patrauklumo ir tiesiogines užsienio investicijas į šalį lemiančių veiksmų literatūros analizė. Šio skyriaus pabaigoje sudaromas teorinis tiesiogines užsienio investicijas į šalį lemiančių veiksmų modelis. Antrame šio darbo skyriuje pateikiama informacija apie tyrime naudotus klasterinės analizės, duomenų dimensijų mažinimo ir dirbtinių neuroninių tinklų modelius. Trečiame šio darbo skyriuje pateikiama informacija apie empiriniame tyrime naudojamų duomenų gavimą, klasterinės ir dirbtinių neuroninių tinklų analizės rezultatai. Šiame skyriuje pateikiamas skirtingų dirbtinių neuroninių tinklų modelių palyginimas, siekiant išsiaiškinti geriausiai veikiančių dirbtinių neuroninių tinklų struktūrą.

1. Literatūros apžvalga

1.1. Investicinio patrauklumo ir tiesioginių užsienio investicijų sampratos

Didėjanti konkurencija tarp įvairių organizacijų lemia tai, kad jos turi ieškoti naujų būdų, kaip tapti konkurencingesnėmis. Vienas iš būdų siekiant didinti savo konkurencingumą – investavimas naujose rinkose. Tiesioginės užsienio investicijos (angl. *foreign direct investment*) yra laikomos viena iš saugiausių ir didžiausią naudą investuotojui teikiančių investicijų formų [1]. Dėl šios priežasties nagrinėjant investicinį patrauklumą tampa svarbu apibrėžti ir tiesiogines užsienio investicijas. Remiantis ekonominio bendradarbiavimo ir plėtros organizacijos (angl. *Organization for Economic Co-operation and Development*) pateikiamu tiesioginių užsienio investicijų apibrėžimu, šios investicijos yra apibūdinamos, kaip finansiniai srautai, kurie parodo, kokia yra investicinių sandorių vertė įvykusi tarp atskirų valstybių. Remiantis šia organizacija tiesioginės užsienio investicijos yra dviejų tipų. Pirmasis tipas yra gaunamos tiesioginės užsienio investicijos (angl. *foreign direct investment inflow*), tuo tarpu antrasis – išeinančios tiesioginės užsienio investicijos (angl. *foreign direct investment outflow*). Pirmuoju atveju tiesioginės užsienio investicijos yra gaunamos iš užsienio investuotojų, kurie plečia savo veiklą ir (ar) pradeda naują veiklą šalyje. Antruoju – pačios šalies investuotojai investuoja į kitas šalis. Remiantis kita tarptautine organizacija – Tarptautiniu valiutos fondu (angl. *International Monetary Fund*), tiesioginės užsienio investicijos yra apibrėžiamos, kaip vienos šalies investuotojo susidomėjimas kitos šalies (investicijų gavėjo) ekonomika. Susidomėjimas taip pat gali būti suprantamas, kaip tam tikrų ekonominių santykių palaikymas tarp šalių. Lietuvos Respublikoje galiojantys įstatymai taip pat apibrėžia tiesiogines užsienio investicijas. Remiantis Lietuvos Respublikos investicijų įstatymo, įsigaliojusiu 1999 metais, 1 skirsnio, 3 straipsniu investicijų rūšys gali būti skirstomos pagal tai, kokią įtaką ūkio subjektui daro šios investicijos. Remiantis šiuo skirstymu yra išskiriamos dvi investicijų rūšys:

1. Tiesioginės investicijos – investicijos, kurios daro tiesioginę įtaką subjekto kapitalui. Šios investicijos gali būti skirtos įregistruoti ūkio subjekto kapitalui ar jo daliai įsigyti. Jos suteikia teisę investuotojui kontroliuoti ar daryti įtaką ūkio subjektui.
7. Netiesioginės investicijos – tai investicijos, kurios nesuteikia investuotojui galimybės daryti įtaką ūkio subjektui į kurį yra investuojama.

Galimas ir investicijų išskyrimas atsižvelgiant į tai, kur yra įsikūrusi nuolatinė investuotojo buveinė:

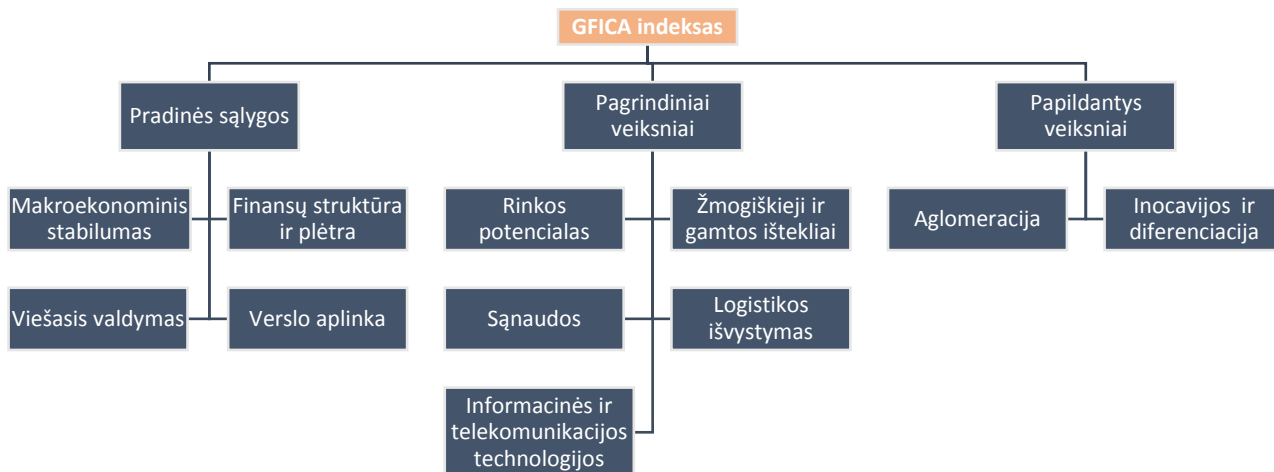
1. Vidaus investicijos – tai investicijos, gaunamos iš valstybės fizinių ar juridinių asmenų;
2. Užsienio investicijos – tai investicijos, gaunamos iš užsienio fizinių ar juridinių asmenų.

Kaip buvo minėta anksčiau, tiesioginės užsienio investicijos yra viena iš saugiausių ir didžiausią naudą teikiančių investavimo formų, tačiau įmonės norėdamos investuoti ir rasti sau priimtinausią ir didžiausią naudą galintį suteikti investavimo sprendimą turi atsižvelgti į didelį kiekį skirtingų veiksnių, lemiančių jų sprendimą. Organizacijų (investuotojų) sprendimą, į kurią šalį turi būti nukreiptas jų tiesioginių investicijų srautas, gali lemti daugelis skirtingų veiksnių: darbo jėgos kaina, šalies politinis stabilumas, šalyje esanti konkurencija ir kt. Remiantis investicijų pasirinkimo veiksniais, apibendrinant galima teigti, kad šalies investicinis patrauklumas tiesioginėms užsienio investicijoms gali būti apibūdinamas, kaip įvairių socialinių, ekonominių, teisinių, politinių, technologinių, geografinių, infrastruktūrinių veiksnių rinkinys suteikiantis organizacijai pranašumą prieš savo konkurentus [2]. Tuo tarpu kitų autorių nuomone, šalies investicinis patrauklumas nėra vien tam tikri veiksniai apibūdinantys vietovę, tačiau yra ir pats vietovės sugebėjimas pritraukti

naujas investicijas, pateikiant savo pranašumą prieš kitas vietas [3]. Nagrinėjant tiesiogines užsienio investicijas ir šalių investicinį patrauklumą, svarbu atsižvelgti į tai, kad šalies investicinis patrauklumas yra dinaminis procesas. Dėl patrauklumo dinamiškumo sprendimai, kurie šiuo metu leidžia pritraukti dideles tiesiogines užsienio investicijas ir atrodo logiški ar geriausi artimoje ateityje gali prarasti savo pranašumą. Dėl pakitusių sąlygų šalyje, organizacijos plėtodamos savo verslą gali persikelti kitur, pakeisti savo sprendimą dėl investicijų dydžio arba atsisakyti investavimo suplanuotoje vietoje. Pasitraukus investicijoms iš vietovės gali kilti problemų dėl ekonominės bei socialinės gerovės užtikrinimo. Dėl šios priežasties pastovus ir (ar) pakartotinis investicinis šalies patrauklumo vertinimas tampa strateginiu šalies ir (ar) vietovės tikslu, kadangi tik šiuo atveju vietovė gali tinkamai įvertinti savo investicinį patrauklumą ir imtis atitinkamų veiksmų šiam patrauklumo išlaikyti ir (ar) jam didinti. Tiesioginių užsienio investicijų planavimas ir prognozavimas leidžia planuoti šalies biudžetą bei kitus rodiklius, priklausančius būtent nuo tiesioginių užsienio investicijų. Taigi, apibendrinant galima teigti, kad tiesioginės užsienio investicijos tiesiogiai prisideda prie visos šalies ekonomikos plėtros, skatindamos žinių, technologijų ir inovacijų pritraukimą, infrastruktūros kūrimą, susijusių ir aptarnaujančių verslų atsiradimą. Teigiamas tiesioginių užsienio investicijų poveikis parodo tai, kad svarbu strateginiame šalies lygmenyje sumaniai formuoti šalies investicinį patrauklumą ir teisingai prognozuoti į šalį ateinančias tiesiogines užsienio investicijas.

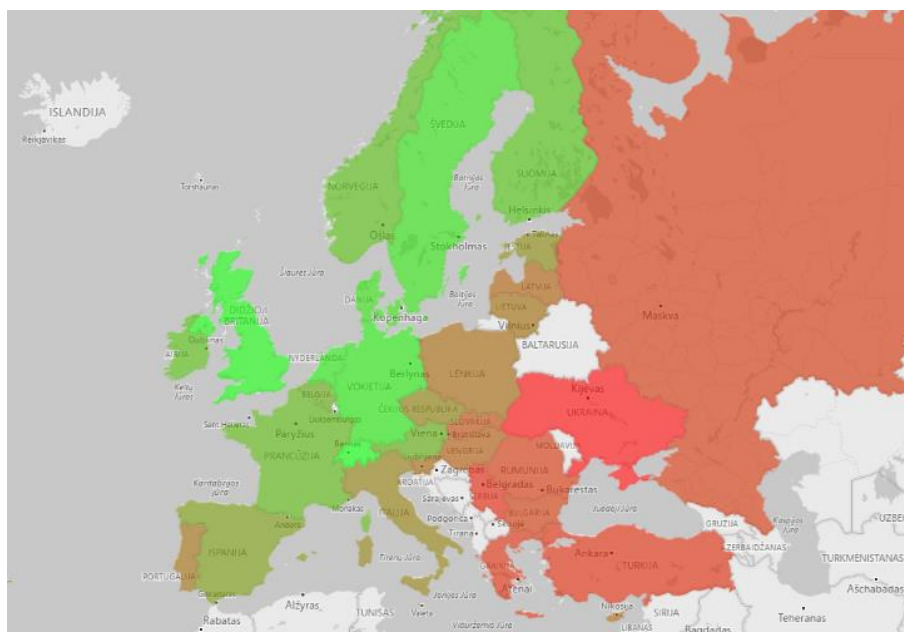
1.2. Investicinio patrauklumo vertinimo indeksai

Galima pastebėti, kad tiesioginių užsienio investicijų vertinime dažniausiai yra panaudojami įvairūs indeksai, taip išreiškiant investicinį patrauklumą viena reikšme. Investicinio patrauklumo išreiškimas indeksu suteikia galimybę didelį skaičių kiekybinių ir kokybinių rodiklių išreikšti dažniausiai vienu skaičiumi ar keliomis tarpinių indeksų reikšmėmis. Investicinio patrauklumo vertinime visi turimi rodikliai dažniausiai yra sugrupuojami į tam tikras veiksmų grupes, iš kurių yra gaunamos tarpinių indeksų reikšmės. Dažniausiai naudojami ir pastebimi mokslinėje literatūroje investicinio patrauklumo indeksai yra GFCI, VCPE ir A.T.Kearney'io FDICI. A.T.Kearney'io tiesioginių užsienio investicijų pasitikėjimo indeksas (angl. *foreign direct investment confidence index*) savo ataskaitose įvertina tik 25 šalis ir jų investicinį patrauklumą, tuo tarpu kiti 2 indeksai įvertina daugiau nei 100 šalių. Atsižvelgiant į mažą ataskaitoje pateikiamų šalių skaičių, šis indeksas toliau plačiau nebus aptariamas. Vienas iš dažniausiai literatūroje sutinkamų investicinio patrauklumo vertinimo indeksų yra pasaulinis patrauklumo tiesioginėms užsienio investicijoms indeksas (angl. *global foreign direct investment country attractiveness index (GFICA)*). Šis indeksas pateikia informaciją apie 109 pasaulio šalių investicinį patrauklumą. Indeksas yra paremtas trimis pagrindiniais indekso elementais: pradinės investicijų sąlygos, pagrindiniai veiksniai skatinantys TUI ir papildantys veiksniai. Kiekvienas iš šių elementų yra sudarytas iš dar smulkesnių elementų, kurie yra sudaryti iš kiekybinių ar kokybinių rodiklių. Toliau pateikiamas paveikslas, vaizduojantis GFICA indekso sudarymo struktūrą (žr. 1.1 pav.).




1.1 pav. Pasaulinio patrauklumo tiesioginėms užsienio investicijoms indekso (GFICA) struktūra

Skaičiuojant galutinę šio indekso reikšmę yra panaudojamas minimalios ir maksimalios reikšmės standartizavimas. Didžiausią reikšmę šiam rodikliui turi pagrindiniai veiksniai (rinkos potencialas, sąnaudos, žmogiškieji ir gamtos išteklių, logistikos išvystymas bei informacinės ir telekomunikacijų technologijos), kadangi šiai veiksmių grupei suteikiamas didžiausias svoris. Tuo tarpu apskaičiuojant pradinių sąlygų, pagrindinių ir papildančių veiksmių reikšmes yra priskiriami vienodi svoriai. Remiantis naujausia indekso reikšme – 2018 metų, galima pastebėti, kad didžiausią investicinio patrauklumo reikšmę turi Jungtinės Amerikos valstijos, tuo tarpu antrąją vietą pagal šį indeksą užima Šveicarija, o trečiąją Jungtinė Karalystė. Žemiau pateikiamame paveiksle (žr. 1.2 pav.) pavaizduotas Europos šalių GFICA investicinio patrauklumo indeksas (žalia spalva reiškia didesnę indekso reikšmę).



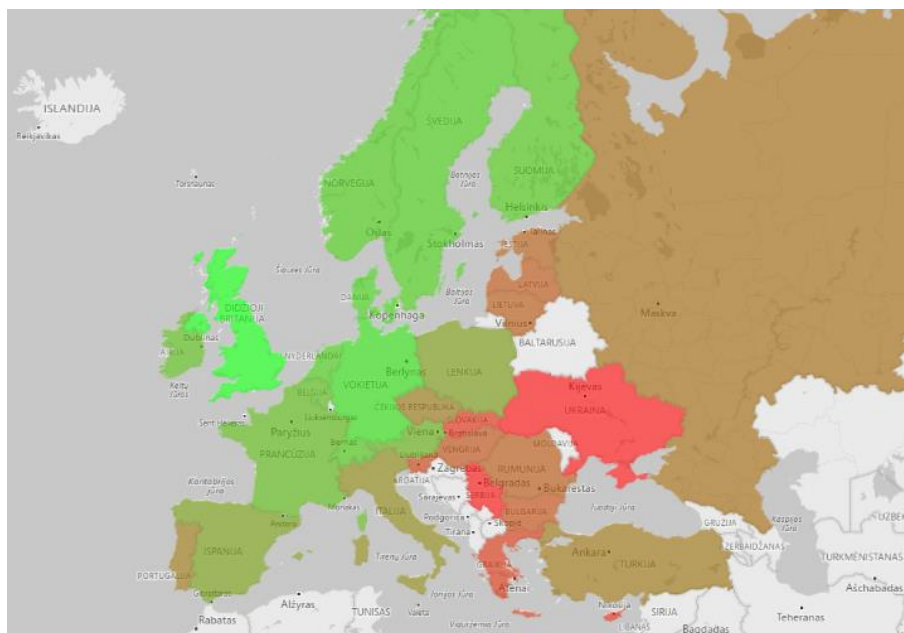
1.2 pav. Pasaulinio patrauklumo tiesioginėms užsienio investicijoms Europos šalių indekso reikšmės 2018 metais

Be GFICA investicinio patrauklumo vertinimo indekso taip pat dažnai tyrimuose yra naudojamas ir Alexander Groh'o bei kitų sukurtas rizikos ir privataus kapitalo šalies patrauklumo indeksas (angl. *The Venture Capital & Private Equity Country Attractiveness Index*). Šis indeksas įvertina net 125 skirtingas šalis ir jų patrauklumą investicijoms. Šis investicinio patrauklumo indeksas yra sudarytas iš 6 pagrindinių veiksnių grupių, lemiančių investicinį patrauklumą: ekonominis aktyvumas, rinkos dydis, mokestinė aplinka, investuotojų apsauga ir įmonių valdymas, žmogiškojo kapitalo ir socialinė aplinka, verslumo galimybės (angl. *entrepreneurial opportunities*). Toliau pateikiamas paveikslas, vaizduojantis VCPE indekso sudarymo struktūrą (žr. 1.3 pav.).



1.3 pav. Rizikos ir privataus kapitalo šalies patrauklumo indekso (VCPE) struktūra

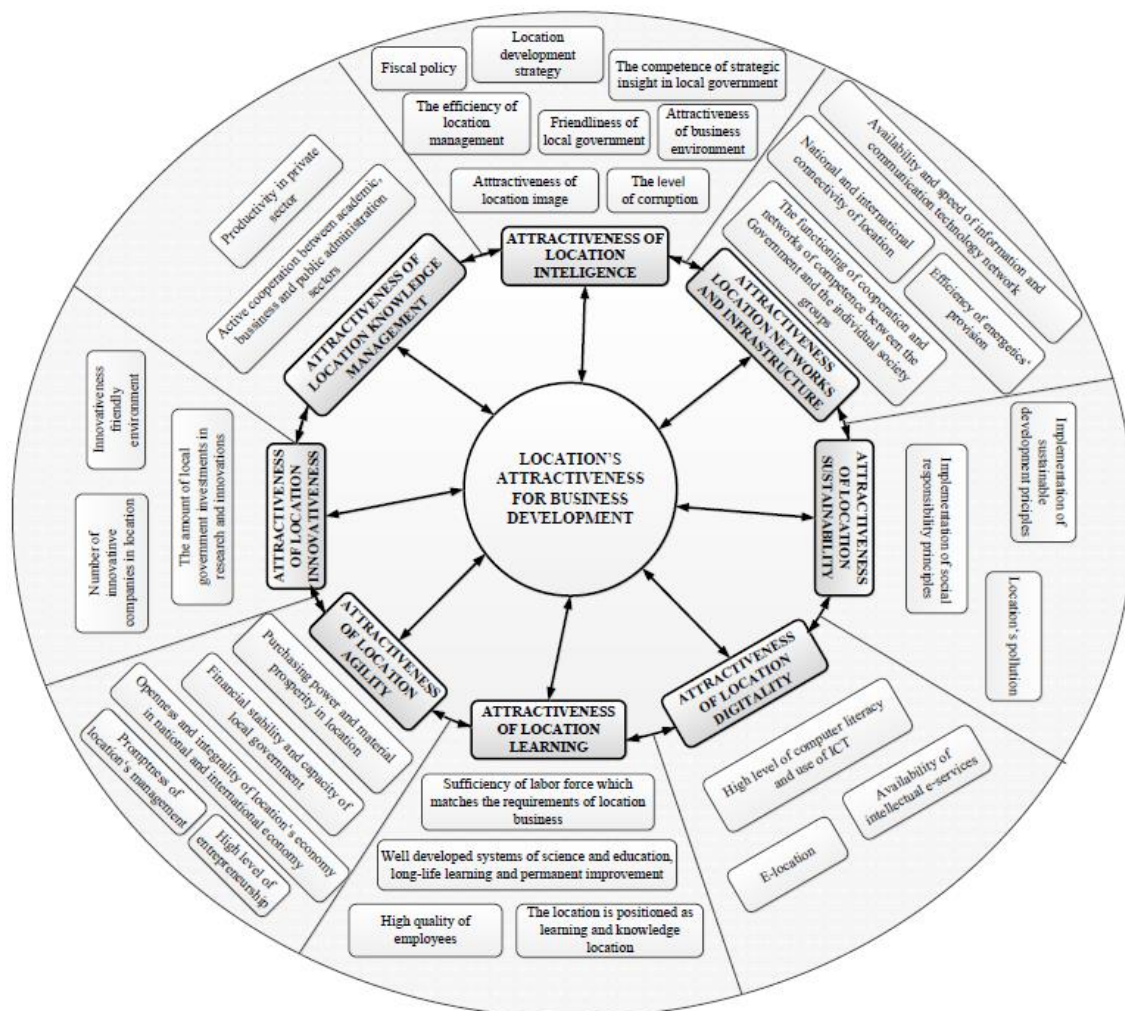
Remiantis naujausia, 2018 metų, indekso reikšme, galima pastebėti, kad didžiausią investicinio patrauklumo reikšmę turi Jungtinės Amerikos valstijos, tuo tarpu antrąją vietą užima Jungtinė Karalystė. Didžiausią investicinį patrauklumą turinti šalis tiek naudojant GFICA indeksą, tiek VCPE sutampa, tačiau VCPE indeksas Šveicarijai suteikia tik penkioliktą reitingą, kai GFICA indeksas Šveicarijai suteikia antrąjį reitingą. Žemiau pateiktame paveiksle pateikiami Europos šalių VCPE investicinio patrauklumo indeksai (žalia spalva reiškia didesnę indekso reikšmę).



1.4 pav. Rizikos ir privataus kapitalo šalies patrauklumo (VCPE) Europos šalių indekso reikšmės 2018 metais

Lietuvių autorių mokslinėje literatūroje investicinio patrauklumo indeksai nėra taip dažnai sutinkami ar taip gerai žinomi, kaip anksčiau minėti pasaulyje naudojami investicinio patrauklumo indeksai. Vienas iš naujausių Lietuvoje sukurtų indeksų, įvertinančių investicinį patrauklumą, yra sukurtas

I. Zykienės. Šis indeksas buvo apžvelgtas šios autorės daktaro disertacijoje „Vietovės patrauklumo verslo plėtrai sumanaus vystymosi kontekste vertinimas“ (angl. „*Evaluation of location's attractiveness for business growth in the context of smart development*“). Didžiausias dėmesys, kuriant šį indeksą, buvo skiriamas sumaniam vystymuisi. Šios autorės investicinio patrauklumo indeksas yra taikomas ne atskirų šalių, o Lietuvos regionų investiciniam patrauklumui įvertinti. Indekso reikšmė, kaip ir prieš tai buvusių indeksų atveju, yra sudaroma iš atskirų veiksmų grupių (žr. 1.5 pav.).



1.5 pav. Regionų investicinį patrauklumą, sumanaus vystymosi kontekste, lemiančių veiksmų modelis [2]

I. Zykienės moksliniame darbe regionų investicinis patrauklumas sumanaus vystymosi kontekste yra priklausomas nuo 8 pagrindinių grupių: 1) faktorių grupė apibūdinanti infrastruktūros išvystymo lygį, 2) faktorių grupė apibūdinanti regiono tvarumą, 3) faktoriai apibūdinantys skaitmenizacijos lygį, 4) faktoriai apibūdinantys regiono mokymosi gebėjimus, 5) faktoriai apibūdinantys regiono galimybes greitai reaguoti į rinkos pokyčius, 6) faktoriai apibūdinantys regionų inovacijų lygį, 7) faktoriai apibūdinantys regiono žinių išsivystymo lygį, 8) faktoriai apibūdinantys regiono sumanumo išsivystymo lygį. Šis modelis buvo sukurtas siekiant įvertinti vietovių gebėjimą naudotis turimais veiksniais, kurie nulemia verslo plėtos patrauklumą vietovėje. Šių faktorių įvertinimas leidžia pritraukti naujas organizacijas į vietovę ir (ar) išlaikyti turimas investicijas.

1.3. Tiesiogines užsienio investicijas sąlygojantys veiksniai

Šiuolaikinėmis ekonomikos sąlygomis kapitalas tampa vis lankstesnis ir mobilesnis, todėl tiesioginės užsienio investicijos (TUI) yra laikomos viena iš saugiausių bei naudingiausių kapitalo srauto formų [1]. Atsižvelgiant į tiesiogines užsienio investicijas priimančios šalies padėtį, jos sukuria daugybę teigiamų poveikių priimančios šalies ekonomikai. Priimančios šalies ekonomikoje yra sukuriama naujos darbo vietos, perduodamos įvairios technologijos, plėtojama infrastruktūra ir kita. Dėl šių priežasčių visos šalys stengiasi sukurti tokį investicijų pritraukimo mechanizmą, kad būtų patrauklesnės, lyginant su kitomis šalimis [4; 5]. Be to, tiesioginės užsienio investicijos padeda mobilizuoti ekonominę veiklą mažiau išsivysčiusiose šalyse, gerindamos ekonominį efektyvumą juose [6]. Šie teigiami aspektai lemia tai, kad mažiau išsivystę šalys konkuruoja dėl TUI siūlydami investuotojams palankias vietas sąlygas ar net jas pritaikydami prie investuotojų poreikių [1]. Bruno ir Camposo (2013) atliktoje literatūros apžvalgoje pastebima, kad 50 procentų tyrimų rodo, kad TUI turi teigiamą poveikį ekonomikos augimui [7]. Šiame tyrime taip pat pateikiama ir tai, kad 39 procentai tyrimų rodo, kad augimas yra nepriklausomas nuo TUI, todėl TUI ir ekonomikos augimo sąryšis nėra vertinamas vienareikšmiškai. Kemeny'is (2010) taip pat nustatė, kad TUI įplaukos teigiamai veikia technologijų atnaujinimą šalyje, todėl TUI yra svarbios ir dėl žinių perdavimo šaliai [8]. Nors šalys ir konkuruoja dėl tiesioginių užsienio investicijų ir stengiasi pagerinti savo investicinių patrauklumą, tampa svarbu suvokti, kas šį patrauklumą nulemia. Investicinių patrauklumą vertinančių rodiklių mokslinėje literatūroje pateikiama gana daug, tačiau šių rodiklių suskirstymas į veiksnius ir veiksmų grupes yra sudėtingas ir daug laiko užimantis procesas, kurį kiekvienas autorius pateikia savaip. Toliau šiame poskyryje esančiuose skyreliuose pateikiama įvairių investicinių patrauklumą lemiančių rodiklių apžvalga ir šių rodiklių skirstymas į veiksmų grupes. Veiksmų grupės, siekiant paprastesnio veiksmų aprašymo, buvo suskirstytos į politinio, ekonominio, socialinio ir kultūrinio, technologinio ir aplinkos patrauklumo grupes. Remiantis šiuo skirstymu toliau yra aprašomos veiksmų grupės, lemiančios tiesiogines užsienio investicijas į šalį ir naudojamos šiame darbe.

1.3.1. Ekonominis patrauklumas

Ekonominis patrauklumas tiesioginėms užsienio investicijoms gali būti apibūdinamas, kaip makroaplinkos elementas, nurodantis tam tikras ūkio raidos tendencijas, kurios turi reikšmę investuotojų sprendimams. Ekonominis patrauklumas gali būti susiejamas ir su nagrinėjamos šalies, ir su tarptautinio ūkio tendencijomis ar jų kryptimi. Investuotojams, investuojant į naują rinką, svarbu tai, kad šios rinkos perkamoji galia atitiktų investuotojų lūkesčius. Aukštesnė šalies perkamoji galia leidžia didinti investicijų atsiperkamumą ir gaunamas pajamas [9]. Didesnės namų ūkio pajamos reiškia tai, kad rinkos vartotojai gali nupirkti daugiau produkcijos, todėl organizacijoms yra sudaromos galimybės, išnaudojant masto ekonomiją, didinti savo pranašumą prieš konkurentus, tiesiogines užsienio investicijas nukreipusius į kitas rinkas [10]. Ši pati išvada gali būti prieinama ir vertinant rinkos namų ūkio išlaidas, tačiau šiuo atveju yra atsižvelgiama ne į gaunamas namų ūkio pajamas, tačiau į išlaidas, kurios įvertina ir namų ūkio taupymo lėšas. Rinkos namų ūkio išlaidos yra potencialios investuotojo pajamos, kurios gali būti gaunamos šioje rinkoje. Šio veiksmo nagrinėjimas leidžia investuotojams įvertinti tikimybę, kad investicijos atsipirks.

Sparčių globalizacijos procesų kontekste, investuotojai investuodami į naujas rinkas siekia didinti pajamas ne tik iš rinkos į kurią yra investuojama. Tuo pačiu yra siekiama, kad šios rinkos (į kurias yra nukreiptos investicijos) padės pritraukti ir pajamas iš aplinkinių ar susietų rinkų. Ekonomikos gebėjimą pritraukti pajamas iš kitų rinkų ir jos ryšį su kitomis rinkomis galima vadinti ekonomikos

atvirumu. Ekonomikos atvirumas leidžia investuotojams įvertinti ar rinka yra orientuota į eksportą, ar tai yra uždara ekonomika (ar su mažu atvirumo laipsniu). Investuotojai rinkdamiesi investavimo kryptį pasirenka rinkas su dideliu atvirumo laipsniu, kadangi tokiu atveju yra gaunamos didesnės pajamos nei uždaroje ekonomikoje [11]. Ekonomikos atvirumas gali būti apibūdinamas ekonomikos integralumo su užsienio rinkomis, turistinio patrauklumo ir socialinės globalizacijos veiksniais. Ekonomikos integralumą su užsienio rinkomis galima vertinti, pasinaudojant eksporto (arba importo) verte bendro vidaus produkto atžvilgiu [12] taip pat eksporto ir importo sumos padalintos iš bendro vidaus produkto atžvilgiu [11; 13]. Abu šie ekonomikos integralumo vertinimai pateikia informaciją apie tai, koku laipsniu ekonomika yra atvira, o tuo pačiu kokios pajamos iš kitų rinkų yra pritraukiamos. Ne mažiau svarbus veiksnys, įvertinantis ekonomikos integralumą, yra ekonomikos integracija įvairiose sąjungose ar prekybos susitarimuose. Rinkos integracija su Europos Sąjungos struktūromis gali paspartinti šalies plėtrą ir didinti patrauklumą TUI [1]. Investuotojams rinkos integracija su ES leidžia paprasčiau vykdyti savo prekybą, palengvina kapitalo perkėlimą iš vienos šalies į kitą, leidžia lengviau pasiekti ES šalių rinkas [14; 15]. Taip pat svarbų vaidmenį ekonomikos integralume su užsienio rinkomis atlieka įvairūs laisvosios prekybos susitarimai bei laisvosios prekybos zonos [16; 17]. Buthe ir Milner'is (2008) teigia, kad tarptautiniai prekybos susitarimai (GATT ir PPO) ir lengvatiniai prekybos susitarimai įtikina investuotojus ir didina jų investicijas. Be to, prisijungimas prie tarptautinių prekybos susitarimų gali būti ypač svarbus besivystančioms šalims [18]. Ekonomikos atvirumas gali būti vertinamas ne tik per šios ekonomikos integralumą su kitomis rinkomis, tačiau ir vertinant turistinį rinkos patrauklumą. Investuotojams, kurių pajamos yra gaunamos iš vartojimo šalyje, didesnis turistinis patrauklumas reiškia ir didesnes pajamas, todėl šis veiksnys gali lemti ir investicinį šalies patrauklumą. Investuotojai nukreipdami tiesiogines užsienio investicijas į turistams patrauklias šalis, šias šalis gali išnaudoti savo prekės ženklo reklamai, pardavimams ir kt. [19]. Galiausiai, ekonomikos atvirumo veiksmų grupėje svarbus ir socialinės globalizacijos veiksnys, leidžiantis investuotojams įvertinti vartotojų elgseną. Aukštos socialinės globalizacijos šalys yra kur kas patrauklesnės TUI, kadangi tokių šalių vartojimas yra panašesnis į globalias tendencijas, o investuotojams tai yra skatinantis veiksnys. Aukšta socialinė globalizacija leidžia investuotojams sumažinti įvairias rėmimo išlaidas, taip didinant savo gaunamas pajamas.

Šiuolaikinio investavimo sąlygomis didelę reikšmę investuotojų šalies pasirinkimui turi finansų rinkos išvystymas. Alfaro ir kt. (2004) teigia, kad investuotojai investuoja į šalis tik tada, kai šių finansų rinka yra išvystyta ir tenkina jų poreikius [20]. Finansų rinkos išvystymo lygį pirmiausiai galima apibūdinti, remiantis pačios finansų sistemos išvystymo lygiu šalyje. Žemas finansinių įstaigų ir visos sistemos išvystymas yra didelė kliūtis užsienio bankų, investicinių fondų kapitalui ir tarptautinių organizacijų investicijoms [21]. Aukštas šios sistemos lygis leidžia investuotojams lengviau gauti kreditus [22], taip pat lemia didesnę finansų rinkos dalį šalyje [23], geresnę akcijų rinkos vertinimą [24], geresnę finansinių įmonių situaciją [25] bei didesnes investicijas į naujas finansų rinkų technologijas. Aukštas finansų sistemos išvystymo lygis leidžia šaliai sumažinti finansinę riziką, kuri reiškia ne gebėjimą grąžinti savo užsienio įsipareigojimus. Užsienio investuotojai yra labai jautrūs finansinėms rizikoms, todėl šalys su didele finansine rizika negali lygiaverčiai konkuruoti dėl TUI [26]. Investuotojai yra linkę rinktis šalis su žema finansine rizika ir (ar) aukštu finansų sistemos lygio išvystymu. Vertinant finansų rinkos išvystymą, ne ką mažiau nei finansų sistemos išvystymas yra svarbus ir šalies bankų sistemos stabilumas. Stabilūs šalies bankai gali užtikrinti tinkamas kredito sąlygas investuotojams bei sumažinti investuotojų patiriamą finansinę riziką, kuri, kaip buvo minėta, yra labai reikšminga. Bankų nestabilumas verčia investuotojus ieškoti kitų finansavimo šaltinių bei apsunkina investavimo procesą [27; 28]. Finansinių šaltinių paieška ar

apsunkintas investavimo procesas lemia tai, kad investuotojai pasirenka investuoti į šalis, kuriose bankų sistema yra stabilesnė. Galiausiai finansų rinkos išvystymo lygį gali apibūdinti ir finansų laisvė šalyje. Finansinė laisvė investuotojams suteikia galimybę nebeskirti papildomų investicijų siekiant palaikyti savo verslo funkcionavimą, kadangi gaunamos pajamos viršija patiriamas išlaidas [29]. Didelę reikšmę vertinant finansų laisvę šalyje turi palūkanų norma, kuri turi reikšmingą ryšį su tiesioginėmis užsienio investicijomis. Didesnė palūkanų norma reiškia didesnes sąnaudas dėl skolinimosi, todėl ir mažesnę grynąją pelną iš investicijų. Šalies pasirinkimą dėl TUI investavimo gali lemti tai, kokios išlaidos bus patiriamos dėl palūkanų normos ar jos kitimo.

Pritraukiant naujas tiesiogines užsienio investicijas svarbus veiksnys, lemiantis šio proceso sėkmingumą, yra šalies ekonominis gyvybingumas. Ekonominis gyvybingumas gali būti apibrėžiamas įvairiai, todėl kai kurie autoriai nagrinėja šalies eksporto ir importo apimtį, bendrą vidaus produktą tenkantį vienam gyventojui ar kt. Dauguma ekonomistų teigia, kad tiesioginės užsienio investicijos turi tiesioginį sąryšį su investicijas priimančios šalies ekonomikos augimu. Empiriniai tyrimai rodo, kad šis ryšys egzistuoja tiek išsivysčiusiose, tiek besivystančiose šalyse, todėl jo reikšmingumas yra vertinamas vienareikšmiškai. Taip pat galima pastebėti tai, kad šalys gaunančios daugiau TUI, turi ir didžiausią ekonomikos augimą [30]. TUI veikia kaip ekonomikos augimo stiprinimo elementas ir todėl didina užimtumą, ir pajamas atsirandančias dėl įvairių užsienio investicinių projektų priėmimo šalyje [31]. Be šių elementų TUI padeda atkurti BVP augimą taip aktyvinant papildomų TUI pritraukimą [32]. Kaip matoma, TUI augimas skatina ir ekonominį šalies augimą, pritraukiantį didesnes tiesiogines užsienio investicijas, kurios ir vėl gerina ekonominį gyvybingumą [33; 34]. Ekonominis šalies gyvybingumas tyrimuose dažnai vertinamas ir remiantis infliacijos lygiu. Infliacijos lygis gali būti apibūdinamas, kaip kainų lygio kilimas, dėl kurio krinta perkamoji galia, kuri paveikia pajamų generavimo galimybes [35]. Infliacija yra tradicinis veiksnys parodantis, kaip vyriausybė sugeba apriboti pinigų pasiūlą ir subalansuoti biudžetą. TUI įplaukos šiuo atžvilgiu yra glaudžiai susijusios su mažu infliacijos lygiu, todėl mažesnis infliacijos lygis reiškia didesnes TUI įplaukas [36; 37]. Mokslinėje literatūroje galima pastebėti, kad padidėjęs prekybos atvirumas ir užsienio investicijos turi teigiamą įtaką ekonominiam gyvybingumui [38]. Dėl šios priežasties vertinant tiesiogines užsienio investicijas ir veiksnius, lemiančius jų kiekį šalyje, svarbu atsižvelgti ir į esamą investavimo lygį. Didesnis esamas investavimo lygis gerina šalies sąlygas pritraukti daugiau investicijų į šalį, kadangi teigiamas investicijų pavyzdys yra svarbus veiksnys investuotojams, pasirenkant investavimo šalį. Taip pat siekiant didesnių TUI yra svarbu ir valdžios sektoriaus veiklos tikslingumas, didinant šalies investicinį patrauklumą. Valdžios priimanamos reformos, priklausomai nuo priimamų sprendimų, gali didinti ar mažinti TUI kiekį šalies ekonomikoje. Todėl ypač svarbu yra institucinės sistemos kokybė ir valdymo, kaip veiksnio lemiančio TUI svarba [39; 40; 41; 42]. Geras valdymas, be viso ko, reiškia ekonominę laisvę, saugias nuosavybės teises. Sąžiningas ir veiksmingas viešasis sektorius ir minimalūs prekybos apribojimai lemia teigiamą įtaką TUI [43]. Visi šie veiksniai: ekonominis gyvybingumas, esamas investavimo lygis ir valdžios sektoriaus veiklos tikslingumas, didinant šalies investicinį patrauklumą, apibendrintai gali būti vadinami šalies ekonomine pažanga.

Investuotojai pasirinkdami šalį savo verslo vystymui didelį dėmesį atkreipia į šalies verslo aplinką. Teigiamą verslo aplinką didina galimybę šaliai sulaukti tiesioginių užsienio investicijų [44; 45]. Verslo aplinka gali būti vertinama, remiantis skirtingais veiksniais: verslo laisvė, verslo pradžios ar pabaigos sudėtingumu, mokesčių našta ir kt. Verslo laisvė yra veiksnys atspindintis, kaip laisvai investuotojai gali vykdyti savo veiklą šalyje. Desai ir Dharmapala (2009) pažymi, kad silpna

investuotojų apsauga užsienio šalyse gali didinti kontrolės vertę, sukurdamos paskatas naudoti TUI [46]. Investuotojams, vertinant investicijas, yra svarbu ir verslo pradžios sudėtingumas, kadangi būtent verslo pradžia lemia ir tolimesnės veiklos efektyvumą. Siekiama įvertinti laiką per kiek verslas gali būti pradėtas, kokios išlaidos bus patiriamos verslo pradžioje, taip pat įvairios apsaugos taisyklės. Vertinant verslo pradžios sudėtingumą, jis vertinamas dviprasmiškai, kadangi nors verslo pradžios išlaidos gali būti labai svarbus veiksnys, tačiau užsienio investuotojai gali daugiau dėmesio kreipti į prekybos paprastumą [47]. Investuotojams svarbi ne tik verslo pradžia, tačiau ir verslo uždarymas, kadangi lengvesnis verslo uždarymas leidžia investuotojams sumažinti riziką verslo nesėkmės atveju. Investuotojai investuodami į šalis ir siekdami vykdyti savo veiklą dažnai didelę dalį investicijų skiria būtent statyboms. Šalys yra ypač suinteresuotos, kad investicijos būtų skirtos „plyno lauko“ investicijoms, kadangi šiuo atveju šalis sulaukia didesnio skatinančio poveikio [48]. Paprastos verslo statybos ir turto registravimas skatina TUI investavimą į „plyną lauką“, todėl šie veiksniai taip pat yra svarstyliniai investicinio patrauklumo vertinime. Svarbus verslo elementas yra ir verslo mokestinė našta, todėl investuotojai investuodami į naujas šalis tam skiria didelį dėmesį [49; 50]. Mažesnė verslo mokestinė našta leidžia investuotojams tikėtis didesnio organizacijos pelningumo, kadangi gaunamas pelnas nėra naudojamas padengti mokestinę našta. Verslo mokestinė našta gali būti sumažinama, sudarant palankias sąlygas investuoti šalyje [51], steigiant pramoninius parkus [52] ar panaudojant kitas investicines paskatas [53; 54].

Užsienio investuotojams didelę reikšmę turi šalies socialinės atsakomybės išsivystymo lygis, kadangi šis išsivystymo lygis parodo nusikalstamumo lygį, pajamų nelygybę ar nelaimingus atsitikimus darbe. Nusikalstamumo lygis šalyje leidžia investuotojams įvertinti galimas verslo rizikas joje, tuo tarpu pajamų nelygybė investuotojams parodo tai, kaip šalis sugeba tvarkytis su savo finansais. Galiausiai nelaimingų atsitikimų darbe šalyje lygis leidžia organizacijai įvertinti šalyje galiojančius darbo saugos įstatymus.

1.3.2. Socialinis ir kultūrinis patrauklumas

Be ekonominio patrauklumo siekiant įvertinti tiesioginių užsienio investicijų patrauklumą investuotojai vertina socialinio ir kultūrinio patrauklumo aspektus. Socialinis ir kultūrinis patrauklumas gali būti apibūdinamas, kaip demografinių ir žmonių kultūros veiksnių visuma. Kiekvienam investuotojui, nesvarbu, kokia veikla jis užsiimtų, investuojant kitoje šalyje, yra reikalinga ir darbo jėga, todėl didelę reikšmę, renkantis šalį, turi darbo rinkos patrauklumas. Darbo rinkos patrauklumą investuotojui galima vertinti, remiantis darbo vietos kaina, darbo jėgos kvalifikacija ir darbo jėgos pasiekiamumu. Savaimė suprantama, kad darbo vietos kaina lemia investuotojų patiriamas išlaidas, vykdant veiklą investicijas priimančioje šalyje. Mažesnės sąnaudos darbo jėgai leidžia investuotojui uždirbti didesnę pelną, o tuo pačiu ir didina investuotojo investicijų atsiperkamumą [55; 56; 57; 58]. Pigi darbo jėga ypač domina investuotojus, kurių veikla yra vykdoma aukšto darbo užmokesčio šalyse, kadangi organizacijos investuodamos siekia sumažinti savo patiriamas veiklos vykdymo išlaidas. Mažesni atlyginimai gali pritraukti įmones vykdančias sąnaudų mažinimo strategiją, tačiau gali būti ir taip, kad dideli darbuotojų atlyginimai rodo aukštos kvalifikacijos darbuotojus, kurie savo ruožtu pritraukia didesnės pridėtinės vertės investicijas [59; 60]. Aukštos kvalifikacijos darbuotojai yra svarbus veiksnys, naudingas investuotojui jei tiesioginių užsienio investicijų objektas reikalauja turėti aukštos kvalifikacijos personalą. Taip dažnai būna nes tiesioginės užsienio investicijos paprastai įgyvendina pažangias technologijas [61]. Geresnė darbo jėgos kokybė leidžia pritraukti aukštesnio lygio investuotojus, kurie investuoja į aukštesnias technologijas. Kvalifikuotas žmogiškasis kapitalas suteikia investuotojams konkurencinį pranašumą,

todėl tai dar labiau traukia TUI [62]. Manoma, kad aukštos kvalifikacijos personalas gali greičiau išmokti ir priimti naujas technologijas, taip pat aukštesnės kvalifikacijos darbuotojams yra reikalingos mažesnės išlaidos jiems persikvalifikuojant. Darbo jėgos kvalifikacija ir darbo jėgos kaina nėra vieninteliai veiksniai, lemiantys darbo rinkos patrauklumą investuotojui. Darbo rinkos patrauklumą lemia ir darbo jėgos pasiekiamumas, kadangi svarbu ne tik pigi darbo jėga ar aukšta šios jėgos kvalifikacija, tačiau ir tai ar ši darbo jėga gali būti pasiekta. Lengvas darbo jėgos pasiekiamumas investuotojams suteikia galimybę rinktis organizacijos personalą, taip pat greitai pradėti vykdyti veiklą ir vėliau lengvai plėsti savo veiklos mastus. Darbo jėgos pasiekiamumui įvertinti dažniausiai yra naudojamas gyventojų ekonominės veiklos lygio rodiklis, rodantis ekonomiškai aktyvių gyventojų dalį šalyje tam tikru laiko momentu. Vertinant darbo jėgos pasiekiamumą, didelę reikšmę jam turi ir darbo jėgos reguliavimas šalyje. Pernelyg didelis darbo rinkos reguliavimas gali trukdyti mokyti naujus darbuotojus tarptautinėse įmonėse, o tai savo ruožtu sudaro trukdžius darbo našumui didėti ir mažina užsienio investuotojų susidomėjimą šalimi [63].

Svarbus aspektas socialiniame ir kultūriniame patrauklume yra ne tik darbo jėgos patrauklumas, bet ir bendra šalies demografinė aplinka, kurios pagrindiniai veiksniai yra rinkos dydis ir demografinė gyventojų sudėtis. Rinkos dydis lemia tai, kad investuotojams yra suteikiama galimybė išnaudoti masto ekonomiją, sumažinti logistikos išlaidas, taip pat labiau orientuotis į eksportavimą į kaimynines šalis [64]. Didelės turtingos rinkos leidžia organizacijoms specializuotis, pasinaudoti rinkos segmentacija ir masto ekonomika [65; 66]. Empiriniai tyrimai taip pat įrodo tai, kad egzistuoja teigiamas ryšys tarp rinkos dydžio ir (arba) rinkos augimo bei tiesioginių užsienio investicijų įplaukų šalyje [67; 68]. Rinkos dydis taip pat dažniausiai yra siejamas su horizontaliosiomis TUI, kai investuojanti įmonė tikisi užimti atitinkamą vidaus rinkos dalį [69]. Be rinkos dydžio, šalyje investicinio patrauklumo demografinė aplinka gali būti įvertinama ir remiantis demografinės gyventojų sudėties veiksniais. Demografinė gyventojų sudėtis investuotojams leidžia įvertinti potencialių vartotojų skaičių bei galimų gauti pajamų dydį. Taip pat demografinė gyventojų sudėtis gali būti siejama ir su žmogiškaisiais ir (ar) darbo ištekliais, kadangi suteikia informaciją apie darbingo amžiaus gyventojų skaičių šalyje. Kuo didesnė darbingo amžiaus gyventojų dalis yra šalyje, tuo paprasčiau investuotojams yra surasti darbuotojus savo organizacijai. Taip pat didelis jaunų asmenų skaičius šalyje užtikrina investuotojams ateities žmogiškąjį kapitalą.

Plečiantis įvairioms technologijoms ir sudėtingėjant verslo procesams bei esant dideliame kvalifikuotų darbuotojų poreikiui, svarbų vaidmenį investicijų pritraukime turi švietimo ir mokymo sistemos kokybė [70]. Šalys paskutiniaisiais metais ypač aktyviai kovoja dėl aukštos kvalifikacijos darbo jėgos, todėl labai svarbu, išlaikyti šiuos darbuotojus savo rinkoje bei apsaugoti nuo „protų nutekėjimo“ [71]. Aukštas švietimo ir mokslo sistemos išvystymo lygis užtikrina reikiamo kiekio aukštos kvalifikacijos specialistų paruošimą darbo rinkai. Taip pat tik aukštas mokslo sistemos lygis, leidžia šaliai pateikti patentus, kurie gali būti vertinami, kaip dar vienas investuotojų traukos objektas [72]. Efektyvi švietimo sistema gali pagerinti studento gebėjimą mokytis ir perkelti šalį į aukštesnio išsilavinimo lygį. Būtent mokymasis yra vienas iš svarbiausių asmenų, firmų ir šalių elementų, siekiant diegti įvairias inovacijas [73]. Greitai besimokantis asmuo gali prisitaikyti prie pokyčių vykstančių aplinkoje, naujų technologijų ir sukurti naują produktą, remiantis turimomis žiniomis. Taip pat greitai besimokantis asmuo gali greitai suprasti naujas žinias, mokytis iš kitų specialistų ar organizacijos. Aukštas švietimo ir mokslo sistemos išvystymo lygis leidžia paruošti specialistus, gebančius priimti įmonei vertingus sprendimus ir skatinti novatorišką veiklą [74]. Darbuotojų papildomas ugdymas įmonėje dar labiau veikia įmonės inovatyvių sprendimų priėmimą [75]. Verslo

poreikius atitinkančių specialistų ugdymas nėra įsivaizduojamas be mokslo, verslo ir valdžios bendradarbiavimo. Šalies universitetų ir kitų mokymo įstaigų, privataus ir viešojo sektoriaus bendradarbiavimas, teigiamai veikia investicinį šalies patrauklumą per žmogiškojo kapitalo kokybės pokyčius. Remiantis verslo poreikiais modernizuojama vyriausybės politika sudaro galimybes kurti aukštųjų technologijų žmogiškąjį kapitalą, kuris yra ypač paklausus tarp investuotojų. Nekvalifikuota ar verslo poreikių neatitinkanti darbo jėga gali lemti perspektyviausių inovacijų ir investicinių projektų žlugimą. Atsižvelgiant į tai svarbu, kad būtų priimami politiniai sprendimai, leidžiantys tinkamai valdyti kvalifikuotą darbo jėgą bei sukurti žinių visuomenę, o tuo pačiu ir didinti tiesioginių užsienio investicijų pritraukimą į šalį.

Svarbus veiksnys investuotojų šalies pasirinkimui yra šalies darbo jėga ir jos lygis, todėl ne ką mažiau svarbu yra ir šalies sveikatos apsaugos sistemos išsivystymo lygis. Aukštas sveikatos apsaugos sistemos išsivystymo lygis užtikrina efektyvų darbą organizacijai. Žemas šios sistemos lygis gali reikšti papildomas investuotojų investicijas, siekiant apsaugoti savo organizacijos darbuotojų sveikatą, taip pat mažėjantį vartojimą rinkoje. Didelę reikšmę šios sistemos lygiui turi išlaidos sveikatos apsaugai, kadangi didesnės išlaidos reiškia geresnį rūpinimąsi šalies gyventojų sveikata. Taip pat sveikatos apsaugos sistemos išsivystymo lygį galima įvertinti ir remiantis bendru šalies gyventojų sveikatos lygiu. Gyventojų sveikatos lygis gali būti vertinamas, kaip tam tikra žmogiškojo kapitalo forma, kuri didina ekonomikos našumą tiek kiekvieno darbuotojo individualiai, tiek šalies mastu [76]. Taip pat aukštesnis šalies gyventojų sveikatos lygis užtikrina ir geresnį gyventojų pajamų augimą, kuris investuotojams gali suteikti aukštesnes pajamas [77].

1.3.3. Technologinis patrauklumas

Technologinis šalies patrauklumas gali būti apibūdinamas, kaip šalies technologinių naujovių skatinimas ir infrastruktūros plėtra šalyje. Infrastruktūra – neatsiejama nuo tiesioginių užsienio investicijų veiksnių grupė, kadangi tik tinkama infrastruktūra užtikrina sklandų tiesioginių investicijų pritraukimą. Infrastruktūra gali būti suprantama, kaip ekonominės veiklos sritys, kurios skatina ir palengvina kitų gamybos procesų vykdymą. Lynn'as (2007) pažymi, kad gerėjanti ryšių ir transporto infrastruktūra skatina urbanizacijos tempą, o tai savo ruožtu palaiko šalies ekonomikos vystymąsi [78]. Greitas ekonomikos vystymasis traukia tiesiogines užsienio investicijas, nes greitai besivystančiose rinkose yra pasiekiamas geresnis investicijų efektyvumas. Vertinant infrastruktūros išvystymo lygį, kaip investicinį patrauklumą lemiančių veiksnių grupę, dažniausia yra atsižvelgiama į pasiekiamumo išvystymo lygį ir informacinių ir komunikacijos technologijų (IKT) išvystymo lygį. Dauguma empirinių tyrimų patvirtina, kad IKT turi teigiamą poveikį ekonomikos augimui ir tiesioginių užsienio investicijų kiekiui šalyje [79; 80; 81; 82]. Puikus IKT potencialo išnaudojimo pavyzdys gali būti pastebimas besivystančios ekonomikos šalyse, pavyzdžiui, Singapūre, Honkonge ar Taivane. Visos šios šalys dėl IKT potencialo išnaudojimo yra aukštos pridėtinės vertės, kurioms reikalingos IKT, investicijų centras. Tačiau egzistuoja ir neigiamas IKT išsivystymo lygio poveikis šalies ekonomikai. Neturtingi žmonės turi mažiau išteklių šiuolaikinėms informacinėms technologijoms priimti dėl to atsiranda skurdas ir didesnis pajamų skirtumas tarp aukštas ir žemas pajamas gaunančių gyventojų. Dėl įvairių IKT technologijų (šviesolaidinis internetas, didieji verslo duomenys, bevielė telefonija ir daiktų internetas (angl. *IOT*)) organizacijos gali didinti savo produktyvumą išnaudodamos šias technologijas. IKT infrastruktūra taip pat gerokai pagerėjo dėl didelių investicijų į fiksuotojo ryšio ir belaidžio ryšio tinklus, interneto paslaugų teikėjus ir mobiliųjų telefonų tinklus. Tyrimai pateikia tai, kad Kinija ir Indija tampa sparčiausiai besivystančiomis IKT rinkomis pasaulyje [83]. Nors IKT infrastruktūra ir yra ypač svarbi, vertinant investicinį patrauklumą,

tačiau ne visos organizacijos yra paremtos vien informacinėmis technologijomis. Daugumai gamybos sektoriaus įmonių ne ką mažiau svarbus yra ir šalies pasiekiamumo išsivystymo lygis. Sėkmingai organizacijos veiklai didelę reikšmę turi ir šalyje teikiamos logistikos paslaugos ar transporto infrastruktūra [84]. Dėl tinkamos infrastruktūros šalyje mažėja investuotojų patiriamos išlaidos, kurios būtų patiriamos dėl investavimo į infrastruktūros gerinimą. Taip pat organizacijos investuodamos atsižvelgia į tai ar yra tinkamos infrastruktūros sąlygos ten, kur organizacijos investicijos nėra tokios reikšmingos, pavyzdžiui, jūrų uostai [85]. Apibendrinant infrastruktūros poveikį tiesioginėms užsienio investicijoms galima teigti, kad kuo labiau infrastruktūra šalyje yra išvystyta, tuo paprasčiau yra pritraukti tiesiogines užsienio investicijas. Taip pat dėl aukštesnio infrastruktūros išsivystymo lygio gerėja ekonomikos vystymasis, turistinis patrauklumas ir pačios šalies konkurencingumas [86; 87].

Šalies technologinis patrauklumas yra neatsiejamas nuo inovacijų, kurios yra vienos iš pagrindinių verslo varomųjų jėgų. Inovacijos gali būti apibrėžiamos, kaip “Produktų, paslaugų ir susijusių rinkų atnaujinimas ir padidinimas; naujų gamybos, tiekimo ir distribucijos metodų sukūrimas, pokyčių vadyboje, darbo aplinkoje ir darbuotojų kompetencijose įdiegimas” [88]. Aukštas inovacijų diegimo lygis šalyje leidžia pritraukti aukštesnės pridėtinės vertės investicijas, didinti bendrą TUI kiekį. Inovacijų diegimų lygis gali būti vertinamas, remiantis inovacijų sistemos funkcionalumo veiksmu. Tik aukštas inovacijų sistemos funkcionavimo lygis užtikrina, kad naujos inovacijos bus sėkmingai pritaikytos verslo ir (ar) investuotojų reikmėms. Žinių perdavimas ir naujų technologijų diegimas yra pateikiamas, kaip vienas iš pagrindinių TUI traukos objektų [89], todėl aukštas inovacijų sistemos funkcionavimas yra ypač reikšmingas. Šalys, kurios skiria didelį dėmesį stiprinamos inovacijų valdymą, turi galimybę pasiekti aukštesnį naujovių lygį šalyje. Atsižvelgiant į tai, kad sėkminga inovacijų valdymo sistema leidžia užtikrinti tinkamą turimų išteklių panaudojimą [90]. Kitas svarbus veiksnys, apibūdinantis inovacijų diegimo lygį, yra verslo produktyvumo lygis, leidžiantis įvertinti, kaip efektyviai yra panaudojami verslo turimi ištekliai. Aukštas darbo našumas leidžia investuotojams gauti didesnes pajamas su mažesnėmis išlaidomis, todėl šis veiksnys tampa labai svarbus, vertinant investicinį patrauklumą [91].

1.3.4. Politinis patrauklumas

Politis patrauklumas tiesioginėms užsienio investicijoms gali būti suprantamas, kaip vyriausybės sprendimų įtaka verslo aplinkai ir verslo priimamiems sprendimams. Šis patrauklumas gali apimti esamus ir būsimus teisės aktus, kurie dažniausiai yra susiję su darbo užmokesčio ir (ar) intelektinės nuosavybės įstatymais. Dėl tokių įstatymų priėmimo tiesioginėms užsienio investicijoms gali būti pritraukiamos arba priešingai „atstumiamos“. Didelę reikšmę investuotojams turi politiniai šalyje priimami sprendimai, kadangi būtent dėl šių sprendimų gali keistis visos valstybės požiūris į tiesiogines užsienio investicijas. Šį požiūrį galima apibendrintai pavadinti šalies politinio įvaizdžio veiksmų grupe, kurią galima vertinti, remiantis politinio stabilumo ir korupcijos lygio veiksniais. Politinis stabilumas yra vertinamas, kaip politinė rizika, kylanti dėl vyriausybės politikos stabilumo ar nestabilumo, kadangi įprastai tai parodo didelės rizikos tikimybę. Politinio stabilumo reiškiniai gali būti suskirstomi į mikro- ir makrolygmens rizikas. Makrolygmens rizika reiškia nenumatytus ir politiškai motyvuotus aplinkos pokyčius, kurie yra nukreipti į visas užsienio įmones investavusias šalyje. Tuo tarpu mikrolygmens rizika – apibūdina politinius pokyčius verslo aplinkoje ar vienoje verslo srityje. Politinis stabilumas (rizika) nėra veiksnys, kurio galima visiškai išvengti, todėl svarbu sumažinti šio veiksnio neigiamas pasekmes investicijoms bei numatyti sprendimus dėl iškilusios rizikos [26]. Politinis stabilumas gali būti apibrėžiamas ir kaip tikimybė, kad vyriausybė bus

destabilizuota arba nuversta [92]. Tačiau šis apibrėžimas dažniau tinka karo riziką patiriančioms šalims. Tarptautinės prekybos organizacijos palankiai vertina stabilias, patikimas ir sąžiningas vyriausybes [93], nes tuomet šios vyriausybės yra vertinamos, kaip teisėtos ir galinčios užtikrinti tinkamas sąlygas investicijoms [94]. Politinis nestabilumas daro šalį mažiau patrauklią investicijoms, nes šalies nestabilumas sukuria nenuspėjamą verslo aplinką, galinčią sutrikdyti verslo ir ekonominius šalies procesus [18]. Dėl šių priežasčių verslo pelningumas taip pat yra veikiamas neigiamai ar verslo vykdymas gali būti netgi sustabdytas. Pagal Ramcharran'ą (1999) politinis nestabilumas gali būti siejamas su pilietiniais karais, perversmais, neteisėtu kapitalo nutekėjimu, finansinių rinkų nestabilumu ir politine korupcija. Būtent šalyje vyraujanti korupcija yra kitas ypač svarbus veiksnys, lemiantis tiesioginių užsienio investicijų kiekį šalyje. Remiantis Kaufmann'u ir kt. (2009) korupcija gali būti apibrėžiama, kaip viešosios valdžios vykdoma veikla, siekiant privačios naudos [92]. Ši veikla apima kyšininkavimą, valdžios nusikalstamumą, nepotizmą, privataus sektoriaus globą ir įkalinimą. Investuotojus korupcija gali veikti keliais skirtingais aspektais. Pirmiausiai, didelė korupcija pasižyminčiose šalyse yra patiriama didesnė ekonominė rizika, kadangi ji mažina ekonominę laisvę, taip pat yra jaučiamas nesaugumas ir netikrumas tarp vyriausybės ir verslo dėl ekonominių santykių šalyje. Antra, korupcija sukuria papildomas išlaidas investuotojams, kadangi dalis uždirbamų pajamų turi būti skiriama kyšiams ar kitoms korupcijos priemonėms [95]. Taip pat yra pastebima ir tai, kad gali būti sudaromos sudėtingos sąlygos žaliavoms gauti [96]. Dažniausiai patiriamos išlaidos dėl korupcijos negali būti kompensuojamos pigesniais ištekliais, kurie yra gaunami aukšta korupcija pasižyminčioje šalyje. Konkurentai investuojantys į mažiau korumpuotas šalis patirs mažesnes sąnaudas, jiems bus sudarytas stabilus išteklių tiekimas [97]. Remiantis šiais aptartais veiksniais galima teigti, kad politinis įvaizdis yra reikšminga investicinio patrauklumo veiksmų grupė, turinti didelę įtaką šalies investiciniam patrauklumui.

Tačiau politinis šalies patrauklumas gali būti įvertinamas ir vertinant šalies valdymo efektyvumą. Šalis, kurių politinis įvaizdis yra panašus, o korupcija šalyse nėra galima, yra sudėtinga lyginti, remiantis politine aplinka, todėl šalies valdymo efektyvumo veiksmų grupė leidžia įvertinti tokių šalių valdymo skirtumus. Šalies valdymo efektyvumas gali būti suprantamas, kaip šalies politikos patikimumas ir valdžios sugebėjimas veiksmingai įgyvendinti įvairius pokyčius [98]. Globerman'as ir Shapiro (2002) teigia, kad egzistuoja teigiamas efektyvaus šalies valdymo poveikis TUI. Šie autoriai teigia, kad veiksmingas vyriausybės valdymas ir mažesnis reguliavimas, leidžia sukurti teigiamą investicinę aplinką, o tuo pačiu ir palankias sąlygas pritraukti TUI ir augti ekonomikai [93]. Apibendrinant šį skirsnį galima pastebėti, kad vertinant politinį įvaizdį svarbus atsižvelgti į politikos stabilumą, korupcijos lygį šalyje, o tuo pačiu ir šalies valdymo efektyvumo lygį, kadangi šis lygis leidžia palyginti išsivysčiusių šalių politinį įvaizdį.

1.3.5. Aplinkos patrauklumas

Aplinkos patrauklumas tiesioginėms užsienio investicijoms gali būti apibūdinamas, kaip faktorius apibūdinantis geografinius ir aplinkosauginius veiksnius, kurie turi reikšmę investuotojų sprendimams investuoti šalyje. Investuotojams priimant sprendimą, kuri šalis yra patrauklesnė tiesioginėms investicijoms, svarbus veiksnys šiame pasirinkime yra ir geografinė šalies aplinka. Geografinė šalies padėtis gali būti įvertinama, remiantis skirtingais aspektais: šalies geografinė padėtimi ir šalies gamtos išteklių potencialu. Tinkama šalies geografinė padėtis investuotojams gali padėti sumažinti logistikos išlaidas, taip pat paprasčiau pasiekti kitų šalių rinkas [99]. Johnson'o ir kt. (2001) teigimu, mažėjantis geografinis atstumas tarp šalių leidžia lengviau perduoti įvairias žinias iš vienos šalies į kitą [100]. Kuo arčiau besivystanti šalis yra prie inovatyvių šalių, tuo labiau tikėtina,

kad TUI gaunančios šalys turės pakankamą pajėgumą įdiegti naujus produktus ar procesus [90]. Taip pat svarbu ir tai, kad dideli šalių didmiesčiai leidžia pasiekti tiek vidines rinkas, tiek ir pasaulines rinkas [101]. Biurų naudojimas tokiuose didmiesčiuose gali būti vertinamas, kaip papildoma nauda, kurią gauna investuotojas dėl savo investicijų [102]. Tiesiogines užsienio investicijas gali traukti ir atskirų šalių turimi išskirtiniai gamtos ištekliai, kadangi tokių išteklių panaudojimas savo veikloje, jų paprastesnis gavimas, leidžia investuotojui įgyti konkurencinį pranašumą, lyginant su kitais konkurentais [103]. Taip pat tiesioginės užsienio investicijos nukreiptos į paklašius gamtos išteklius, leidžia investuotojams gauti pajamas, išnaudojant šalies priimančios investicijas gamtos išteklius. Atsižvelgiant į tai, vertinant tiesiogines užsienio investicijas svarbu įvertinti ir šalies gamtos išteklių potencialą. Investuotojai vertindami aplinkos patrauklumą didelį dėmesį skiria aplinkos užterštumui ir kitiems ekologiniams veiksniams, kurie gali būti apibendrinami, kaip ekologinė šalies aplinka. Šalies ekologinės aplinkos veiksnių grupė gali būti įvertinama, remiantis aplinkos užterštumu ir (ar) atsinaujinančios energetikos lygiu. Aplinkos užterštumas ir jį reguliuojantys įstatymai yra reikšmingi veiksniai, lemiantys tiesioginių užsienio investicijų srautą į šalį. Šalys turinčios griežtus aplinkos užterštumo standartus sulaukia mažiau investicijų iš didelę aplinkos taršą pasižyminčia veikla užsiimančių investuotojų. Šie investuotojai dėl griežtų įstatymų yra linkę perkelti savo investicijas į šalis, kur šie įstatymai yra palankesni jų veiklai, dažniausiai tai būna žemo išsivystymo šalys [104; 105]. Taip pat investuotojams vertinant ekologinę šalies aplinką svarbus yra iš šalies atsinaujinančios energetikos išvystymo lygis. Aukštas šalies atsinaujinančios energetikos išvystymo lygis užtikrina investuotojams ateities energijos šaltinį, taip pat skatina investicijas būtent šioje veikloje [106]. Apibendrinant šį skirsnį galima pastebėti, kad aplinkos patrauklumas turi reikšmę investuotojų priimamiems sprendimams dėl tiesioginių užsienio investicijų.

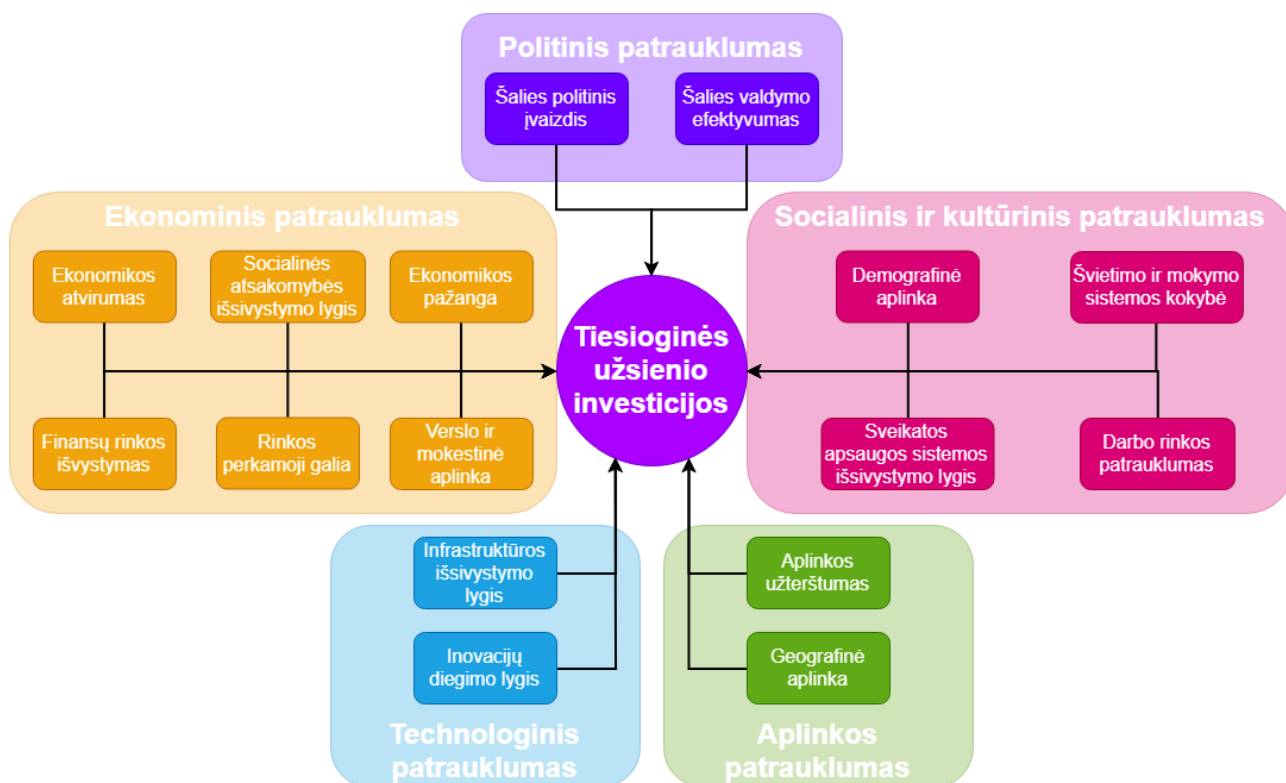
1.3.6. Apibendrinti tiesiogines užsienio investicijas šalyje lemiantys veiksniai ir jų modelis

Remiantis ankstesniuose skyreliuose atlikta tiesioginių užsienio investicijų patrauklumą lemiančių veiksnių analize buvo sudaryta lentelė, apibendrinanti šiuos veiksnius ir aptartų veiksnių modelis (žr. 1.6 pav.). Toliau esančioje lentelėje (žr. 1.1 lentelė) pateikiami apibendrinti veiksniai ir veiksnių grupės.

1.1 lentelė. Tiesiogines užsienio investicijas šalyje lemiantys veiksniai ir veiksnių grupės

Veiksnių grupė	Veiksniai	Autoriai
Ekonomikos pažanga	Ekonomikos gyvybingumas	J. Bruneckienė ir kt., (2016) [107],
	Esamas investavimo lygis	L. Nikolova ir E. Plotnikova (2013) [108], I. Zykienė ir V. Snieška (2011) [87]
Verslo ir mokesstinė aplinka	Verslo laisvė	J. Bruneckienė ir kt., (2016) [107], I. Zykienė ir V. Snieška (2011) [87], A. Corcoran ir R. Gillanders (2015) [109], J. Toskovič ir kt. (2016) [110]
	Verslo pradžios sudėtingumas	
	Verslo statybos sudėtingumas	
	Turto registravimo sudėtingumas	
	Verslo mokesčių našta	
	Verslo uždarymo sudėtingumas	
Darbo rinkos patrauklumas	Darbo vietos kaina	Belderbos ir kt. (2016) [111],
	Darbo jėgos kvalifikacija	L. Nikolova ir E. Plotnikova (2013) [108],
	Darbo jėgos pasiekiamumas	I. Zykienė ir V. Snieška (2011) [87]
Rinkos perkamoji galia	Namų ūkio pajamos	S. Adams (2009) [112],
	Namų ūkio išlaidos	S. Stankevičienė ir A. Lakštutienė (2012) [113]
Ekonomikos atvirumas	Ekonomikos integralumas su užsienio rinkomis	S. Adams (2009) [112],
	Turistinis patrauklumas	W. Strzelczyk (2014) [114]

	Socialinė globalizacija	
Demografinė aplinka	Rinkos dydis	Belderbos ir kt. (2016) [111],
	Gyventojų demografinė sudėtis	L. Nikolova ir E. Plotnikova (2013) [108]
Infrastruktūros išsivystymo lygis	IKT išsivystymas	J. Bruneckienė ir kt., (2016) [107],
	Šalies pasiekiamumas (oru, sausuma ir vandeniui)	I. Zykienė ir V. Snieška (2011) [87], N.Lucke ir S.Eichler (2016) [115]
Šalies politinis įvaizdis	Politinis stabilumas	P.Lv ir F.Spigarelli (2015) [116],
	Korupcijos lygis	F. Economou ir kt. (2017) [117], A.P.Groh ir M.Wich (2009) [118], B. A. Blonigen ir J. Piger (2014) [119]
Šalies valdymo efektyvumas	Vyriausybės išlaidos	A.P.Groh ir M.Wich (2009) [118],
	Vyriausybės vientisumas (angl. <i>government integrity</i>)	N.Lucke ir S.Eichler (2015) [98], M.Murat ir T. Pirotti (2010) [120],
	Valdžios efektyvumas	A.P.Groh ir K.Lieser (2013) [121]
Švietimo ir mokymo sistemos kokybė	Švietimo ir mokslo sistemos išvystymo lygis	Belderbos ir kt. (2016) [111], S.Stankevičienė ir A.Lakštutienė (2012) [113],
	Mokslo, verslo ir valdžios bendradarbiavimas	A.Groh (2018) [122], I.Jakusonoka ir K.Zarina (2018) [123]
Sveikatos apsaugos sistemos išvystymo lygis	Išlaidos sveikatos apsaugai	H. Birnleitner (2014) [124],
	Gyventojų sveikatos lygis	W. Strzelczyk (2014) [114]
Inovacijų diegimo lygis	Inovacijų sistemos funkcionalumas	T. Dorozynski ir A. Kuna-Marszalek (2016) [1],
	Verslo produktyvumo lygis	J. Villaverde ir A. Maza (2015) [125]
Finansų rinkos išvystymas	Finansų sistemos išsivystymo lygis	S. Poelhekke (2015) [126]
	Bankų sistemos stabilumas	V. Botric ir L. Škuflic (2006) [127]
	Finansinė laisvė	
Socialinės atsakomybės išsivystymo lygis	Nusikalstamumo lygis	G. Kharlamova (2014) [128],
	Pajamų nelygybė	A.A. Vershinina ir kt. (2015) [129],
	Nelaimingi atsitikimai darbe	A.Sabonienė ir I.Zykienė (2012) [130]
Geografinė aplinka	Geografinė padėtis	B. A. Blonigen ir J. Piger (2014) [119],
	Gamtos išteklių potencialas	J. Bruneckienė ir kt., (2016) [107], S.Stankevičienė ir A.Lakštutienė (2012) [113]
Ekologinė aplinka	Atsinaujinančioji energetika	L. Kwang-Hoon (2016) [131],
	Aplinkos užterštumas	G. Kharlamova (2014) [128], A.A. Vershinina ir kt. (2015) [129], G. O'Meara (2015) [132]



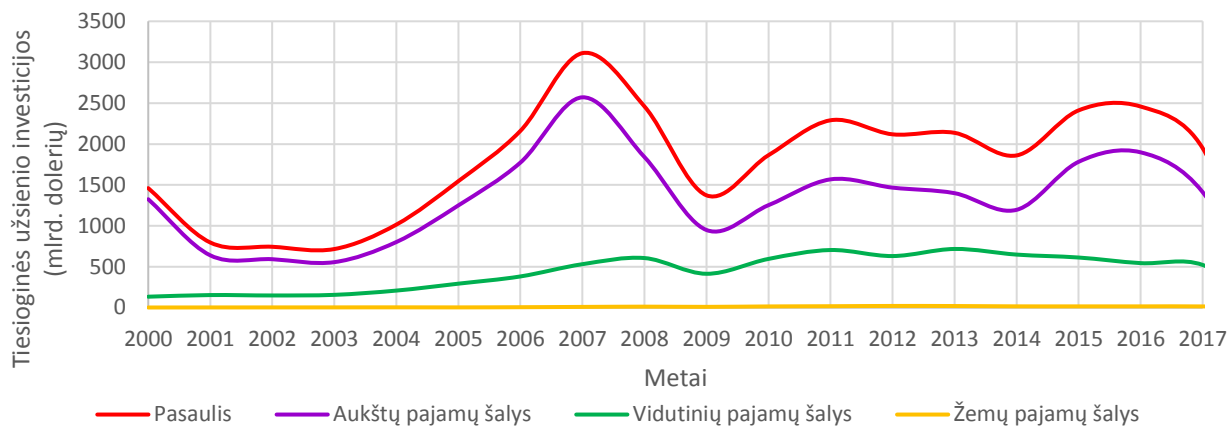
1.6 pav. Tiesioginėms užsienio investicijoms patrauklumą šalyje lemiančių veiksnių modelis

Aukščiau pateiktame paveiksle pateikiamas tiesioginių užsienio investicijos vertinimo modelis. Verta pastebėti tai, kad tiesiogines užsienio investicijas šalyje lemiantys veiksniai ne tik lemia tiesiogines užsienio investicijas, tačiau ir sąveikauja tarpusavyje (žr. 1.6 pav.). Tiesioginės užsienio investicijos savo ruožtu veikia veiksnių grupes, tačiau šiame darbe tai nėra aptariama plačiau. Šis modelis buvo suformuotas, remiantis išsamia mokslinės literatūros analize, didelį dėmesį skiriant dažniausiai mokslininkų minimiems patrauklumą lemiantiems veiksniams. Šio modelio naujumas, lyginant su kitais autorių darbais, yra tas, kad į modelį, kaip lygiavertis veiksnys, buvo įtrauktas socialinės atsakomybės išsivystymo lygio veiksnys, kuris pastaruoju metu formuoja ypatingą reikšmę investuotojams, renkantis šalis kaip investavimo objektą. Tiesiogines užsienio investicijas šalyje lemiančios veiksnių grupės, veiksniai ir rodikliai yra pateikiami 15 priede. Šis tiesioginėms užsienio investicijoms patrauklumą šalyje lemiančių veiksnių modelis yra universali metodologija, kuri gali būti naudojama skirtingoms šalims ir jų TUI prognozuoti. Nors šio darbo empirinėje dalyje šis modelis analizuotas Europos šalių pavyzdžiu, tačiau jis gali būti naudojamas ir kitų šalių tiesioginėms užsienio investicijoms analizuoti ir prognozuoti. 15 priede pateikiami kiekybiniai rodikliai gali būti pritaikomi skirtingų šalių poreikiams, atsižvelgiant į šalių statistinių duomenų prieinamumą.

1.4. Tiesioginių užsienio investicijų dinamika 2000-2017 metais

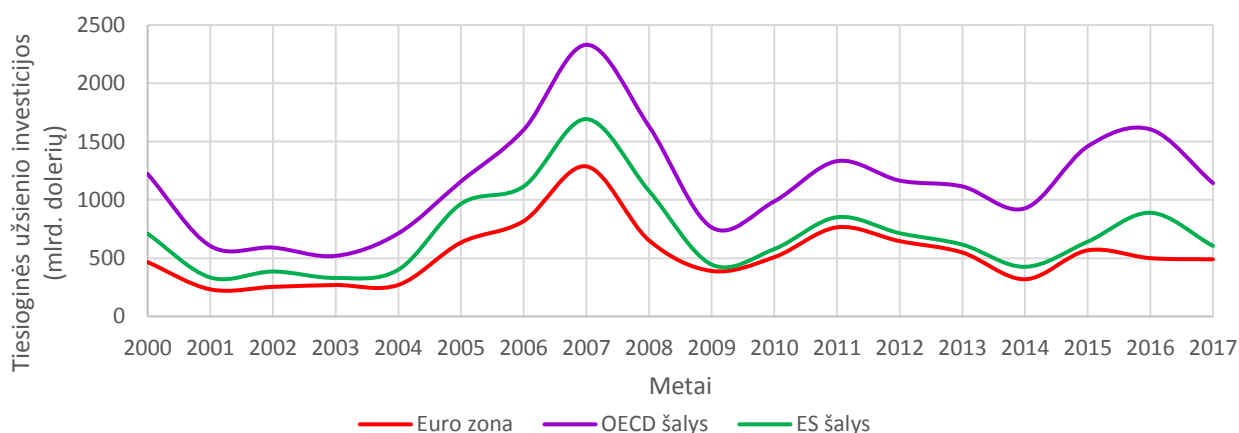
Oficialiuose statistinės informacijos puslapiuose pateikiama informacija apie tiesiogines užsienio investicijas tik iki 2017 metų, todėl tyrime yra naudojami būtent šie duomenys. Tyrimo metu atliekamas 2018 metų tiesioginių užsienio investicijų prognozavimas. Toliau pateiktame paveiksle (žr. 1.7 pav.) pateikiamos viso pasaulio, aukštų, vidutinių ir žemų pajamų šalių tiesioginių užsienio investicijų dinamika 2000-2017 metais. Remiantis šia dinamika galima pastebėti, kad bendros pasaulio tiesioginės užsienio investicijos stipriai priklauso nuo aukštų pajamų šalių tiesioginių užsienio investicijų, kadangi jų dinamika yra ypač panaši. Remiantis pateiktu grafiku galima

pastebėti, kad 2017 metais bendros pasaulio tiesioginės užsienio investicijos sumažėjo 26,1 procentais. Svarbu yra ir tai, kad 2017 metais, lyginant su 2016 metais, TUI aukštų pajamų šalyse sumažėjo net 34,4 %, todėl matoma, kad tai yra didesnis TUI mažėjimas nei vertinant pasaulio TUI. Vidutinių pajamų šalyse taip pat pastebimas TUI mažėjimas, kuris siekia 4,2 %, o žemų pajamų šalyse šis mažėjimas buvo 3,3 %.



1.7 pav. Pasaulio, aukštų, vidutinių ir žemų pajamų šalių tiesioginių užsienio investicijų dinamika 2000-2017 metais

Atsižvelgiant į darbo temą, kurios pagrindinis objektas yra Europos šalys buvo nuspręsta apžvelgti ir Euro zonos, ES šalių TUI dinamiką ir ją palyginti su OECD šalių TUI dinamika. Šių šalių tiesioginių užsienio investicijų dinamika 2000-2017 metais pateikiama 1.8 paveiksle. Remiantis šia pateikiama dinamika galima pastebėti, kad 2017 metais, lyginant su 2016 metais, OECD šalyse tiesioginės užsienio investicijos sumažėjo 40,4 %. Tuo tarpu apžvelgiant ES šalių TUI dinamiką pastebima tai, kad 2017 metais, lyginant su 2016 metais, TUI sumažėjo net 47,0 %. Galiausiai verta pastebėti tai, kad Euro zonos šalių tiesioginės užsienio investicijos sumažėjo tik 2,1 %, todėl tai yra pats mažiausias TUI sumažėjimas lyginant su kitomis paveiksle pateikiamomis šalių grupėmis. 2017 metais Euro zonos šalių TUI 2017 metais sudaro net 81 % ES šalių TUI, kai tuo tarpu 2016 metais Euro zonos šalių TUI sudarė tik 56,2 % ES TUI.



1.8 pav. Euro zonos, OECD ir ES šalių tiesioginių užsienio investicijų dinamika 2000-2017 metais

Tiesioginės užsienio investicijos tiesiogiai prisideda prie visos šalies ekonomikos plėtros skatindamos žinių, technologijų ir inovacijų pritraukimą, infrastruktūros kūrimą. Apibendrinant literatūros analizę, galima pastebėti, kad literatūroje yra pateikiama daug skirtingų nuomonių apie tai, kas lemia šalių investicinį patrauklumą ir šio patrauklumo rezultata – tiesiogines užsienio investicijas. Remiantis literatūros analizės metu sudarytu tiesiogines užsienio investicijas šalyje lemiančių veiksnių modelių tolimesniame darbe bus siekiama įvertinti skirtingų matematinių metodų tinkamumą TUI prognozuoti. TUI prognozavimas yra svarbus aspektas, kadangi tikslus prognozavimas gali leisti šalims planuoti savo biudžetą bei įvertinti tolimesnes TUI tendencijas. Atsižvelgiant į tai, kad mokslinėje literatūroje, vertinant TUI, yra atliekamas tik reikšmingų veiksnių vertinimas tiesinės regresijos modeliais tampa svarbu įvertinti ne tik reikšmingus veiksnius, bet ir atlikti TUI prognozavimą, panaudojant sudėtingesnius matematinius modelius. Tokių matematinių modelių panaudojimas leidžia rasti ne tik tiesinį ryšį tarp veiksnių ir TUI. Šis baigiamasis darbas ir jo empirinis tyrimas leis įvertinti TUI prognozavimo tikslumą įvairiais dirbtinių neuroninių tinklų metodais bei pasiūlyti praktinius sprendimus TUI prognozavimo srityje. Sukurtas veiksnių lemiančių TUI šalyje modelis gali būti taikomas ne tik Europos šalims, todėl ir kuriami dirbtiniai neuroninių tinklų modelių testavimo ir kūrimo algoritmai taip pat gali būti panaudojami kitų šalių TUI prognozuoti. Tyrimo rezultatai taip pat bus pritaikomi, kuriant taikomąją ekonominių rodiklių modeliavimo programą, kuri palengvins ekonominių rodiklių surinkimą ir analizavimą.

2. Metodų analizė

Šalių investicinio patrauklumo vertinime priklausomai nuo užduoties buvo naudojami įvairūs statistiniai ir mašininio mokymosi metodai. Šalims segmentuoti (grupuoti) pagal įvairius rodiklius buvo naudojama klasterinė analizė ir saviorganizuojantys neuroniniai tinklai. Šių metodų panaudojimas leidžia išskirti panašias šalis. Duomenų dimensijoms mažinti – koreliacinė, pagrindinių komponentų ir nepriklausomų komponentų analizės, kurios leidžia sutrumpinti algoritmų vykdymo laiką, kadangi sumažina didelių dimensijų duomenis. Šalies investiciniam patrauklumui modeliuoti – dirbtiniai neuroniniai tinklai. Regresijos uždaviniui, kai yra prognozuojamas investicijų kiekis, buvo naudojami rekurentiniai neuroniniai tinklai (RNN), ilgalaikės-trumpalaikės atminties neuroniniai tinklai (LSTM), sulaikomojo sluoksnio neuroniniai tinklai (GRU) ir ekstremalaus mokymosi mašinos (ELM). Klasifikacijos uždaviniui spręsti, kai yra vertinamas šalies investicijų didėjimas arba mažėjimas, buvo naudojami daugiasluoksniai dirbtiniai neuroniniai tinklai bei galingesnis *Python TensorFlow* paketas.

2.1. Mašininis mokymasis

Mašininis mokymasis (angl. *machine learning (ML)*) – tai kompiuterių mokslo (angl. *computer science*) sritis, kurioje siekiama „išmokyti“ kompiuterį atpažinti tam tikrus šablonus, rasti ryšius tarp atskirų duomenų. Klasikinio programavimo atveju kompiuteriui yra pateikiamos taisyklės ir duomenys, taip siekiant gauti galutinį atsakymą, panaudojant iš anksto apibrėžtus skaičiavimus. Lyginant su klasikiniu programavimu, mašininio mokymosi atveju yra gaunamas ne atsakymas, o tam tikros taisyklės, kurios gali būti taikomos naujiems duomenims. Mašininis mokymasis taip pat dažnai yra apibūdinamas, kaip dirbtinio intelekto sritis, kurios tikslas – pritaikant kompiuterinę techniką tobulinti veiklos vykdymą, didinti veiklos efektyvumą. Mašininio mokymosi algoritmai pasinaudodami turimais duomenimis iš jų kuria praktinėje veikloje taikomus modelius [133]. Dažniausiai yra išskiriamos trys mašininio mokymosi kategorijos: mokymasis be mokytojo (angl. *unsupervised learning*), mokymasis su mokytoju (angl. *supervised learning*) ir skatinamasis mokymasis (angl. *reinforcement learning*). Ketvirtoji mašininio mokymosi kategorija, kuri yra rečiau pastebima yra dalinis mokymasis su mokytoju (angl. *semi-supervised learning*). Šios mašininio mokymosi kategorijos pasižymi:

- **Mokymasis be mokytojo** (angl. *unsupervised learning*) – šis mokymas atliekamas su duomenimis, kurių klasė nėra iš anksto žinoma. Naudojant šiuos metodus bandoma atrasti „paslėptus“ ryšius tarp duomenų. Galima pastebėti tai, kad dėl iš anksto nežinomų duomenų klasių negalima įvertinti, koks yra gauto modelio tikslumas (priešingai nei mokymosi su mokytoju atveju) [134]. Mokymosi be mokytojo mašininio mokymosi metodus galima suskirstyti į dvi mažesnes metodų grupes: klasterizavimas ir dimensijų mažinimas ar asociacijos taisyklės. Dažniausiai naudojami neprižiūrimo mokymosi algoritmai yra klasterizavimo algoritmai ir vienas iš geriausiai žinomų klasterizavimo algoritmų yra *k*-vidurkių algoritmas (angl. *k-means clustering*) [135]. *K*-vidurkių klasterizavimas yra naudojamas suskirstyti duomenis į *k* iš anksto nustatytų grupių, tarp kurių yra atrandamas „paslėptas“ ryšys, kurio žmogus galbūt gali ir nepastebėti (plačiau apie klasterizacijos metodus pateikiama 2.4 poskyryje).
- **Skatinamasis mokymasis** (angl. *reinforcement learning*) – tai mašininio mokymosi sritis, kurioje modelis gauna informaciją apie aplinką ir išmoksta pasirinkti veiksmus, kurie maksimizuoja tikslo funkciją. Šis mokymasis yra gana retai sutinkamas sprendžiant realias

užduotis, tačiau teigiama, kad ateityje šis mokymo metodas gali rasti labai platų pritaikymą: autonominiai automobiliai, logistikos sprendimai ir kt. [136].

- **Mokymasis su mokytoju** (angl. *supervised learning*) – tai mašininio mokymosi sritis, kai modelis yra sukuriamas iš turimų praeities (mokymosi imties) duomenų. Mokymosi duomenų rinkinyje yra pateikiamos duomenų poros X (kintamieji / stebinių savybės) ir Y (klasės reikšmė) [137]. Šie metodai leidžia modeliams atpažinti paslėptus ryšius tarp duomenų ir remiantis naujais duomenimis gali prognozuoti Y reikšmes. Kaip pagrindinius prižiūravimo mokymosi metodus galima įvardinti regresijos, sprendimų medžių, klasifikavimo ir neuroninių tinklų metodus.
- **Mokymasis su daliniu mokytoju** (angl. *semi-supervised learning*) – tai mašininio mokymosi tipas, kai duomenų rinkinyje yra pateikiama tiek suženklinti duomenys, tiek ir nesuženklinti. Šio mokymosi tikslas yra duomenų klasifikavimo modelio kūrimas, kuris pasižymėtų geresniais rezultatais, nei panaudojant duomenų rinkinyje esančius tik suženklintus duomenis [138].

Kaip matoma iš pateikiamų mašininio mokymosi kategorijų aprašymo galima pastebėti, kad kiekviena iš šių kategorijų turi savo pritaikymą praktikoje. Dažnai praktikoje, o tuo pačiu ir šiame darbe, yra taikomas mokymosi su mokytoju metodas – dirbtiniai neuroniniai tinklai (angl. *artificial neural networks*), kurių aptarimas pateikiamas tolimesniame šio darbo poskyryje.

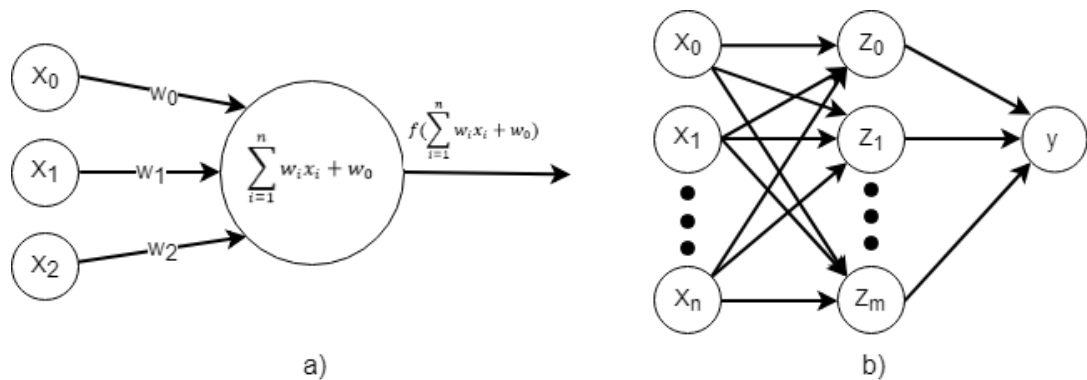
2.2. Dirbtiniai neuroniniai tinklai, jų samprata, veikimas, tipai ir naudojimas

Dirbtiniai neuroniniai tinklai (angl. *artificial neural networks*) – tai mašininio mokymosi metodas, kuris yra pagrįstas žmogaus smegenų veikla. Pažinimo mokslininkai ir neuromokslininkai siekia išsiaiškinti, kaip iš tiesų veikia žmogaus smegenys, todėl tokie modeliai padeda atlikti įvairias simuliacijas [139]. Inžinerijoje šiuo atveju tikslas yra ne suprasti, kaip veikia žmogaus smegenys, tačiau panaudojant šias žinias sukurti naudingus algoritmus ir (ar) modelius. Dirbtiniai neuroniniai tinklai yra viena iš sričių, galinčių padėti kurti geresnius kompiuterinius modelius. Smegenys yra neįtikėtinas informacijos apdorojimo įrenginys, turintis tokius neįtikėtinus sugebėjimus, kaip vaizdų atpažinimas, kalbos atpažinimas, mokymasis ir kt. Kadangi šios savybės gali būti ypač naudingos įvairiuose ekonominiuose procesuose, todėl dirbtinių neuroninių tinklų panaudojimas yra ypač aktualus. Taikant dirbtinius neuroninius tinklus kompiuterių moksle vienas iš pagrindinių elementų yra perceptronas¹ (angl. *perceptron*). Perceptrono įvesties reikšmės gali būti gaunamos iš aplinkos arba perduodamos iš kito perceptrono. Perceptrono gaunamos reikšmės yra dauginamos iš sinapsės svorio ir tuomet perceptrono išvestis paprasčiausiu atveju yra apskaičiuojama:

$$y = \sum_{i=1}^n w_i x_i + w_0; \quad (1)$$

čia y – išvesties reikšmė; n – įvesties reikšmių skaičius; w_i – i -tosios įvesties svoris; x_i – i -toji įvestis. Tada panaudojant šią išvesties reikšmę taip pat yra panaudojama ir aktyvacijos funkcija tam, kad mokomas neuroninius tinklas netaptų tiesiniu. Plačiau apie aktyvacijos funkcijas ir jų panaudojimą pateikiama „2.3 Aktyvacijos funkcijos samprata ir naudojimas“ poskyryje. Žemiau pateiktame paveiksle pavaizduotas perceptrono veikimo principas (žr. 2.1 pav.).

¹ Perceptronas (angl. *perceptron*; lot. *perceptio* - pažinimas + (elek)tronas) tai smegenų modelis, padedantis tirti natūralųjį intelektą fizikos ir matematikos priemonėmis [151].



2.1 pav. Neuroninio tinklo schema: a) neuroninio tinklo perceptronas; b) neuroninis tinklas su vienu paslėptuoju sluoksniu

Neuroniniuose tinkluose visuomet yra panaudojami paslėptieji sluoksniai (angl. *hidden layers*), kurie leidžia sudaryti tiesinę įvesties rodiklių kombinaciją. Vieno sluoksnio dirbtinis neuroninis tinklas yra sudarytas iš įvesties sluoksnio, vieno paslėptojo sluoksnio ir išvesties sluoksnio (žr. 2.1 pav.). Įvesties sluoksnyje pateikiamos stebimų rodiklių reikšmės, tuomet paslėptojo sluoksnio perceptronų reikšmės apskaičiuojamos pagal formulę, kuri atitinka anksčiau aptartą perceptrono formulę:

$$z_j = f \left(\sum_{i=1}^n w_{ij} x_i + w_0 \right); \quad (2)$$

čia z_j – j -tasis paslėptojo sluoksnio perceptronas; f – aktyvacijos funkcija; w_{ij} – i -tosios įvesties reikšmės į j -ąjį paslėptojo sluoksnio perceptroną svoris; x_i – i -toji įvesties reikšmė.

Tuomet šio neuroninio tinklo išvesties reikšmė (y) yra apskaičiuojama panaudojant iš ankstesnės formulėmis gautomis reikšmėmis:

$$y = f \left(\sum_{i=1}^n w_j z_j + w_0 \right); \quad (3)$$

čia y – išvesties reikšmė; f – aktyvacijos funkcija; w_j – j -ojo paslėptojo sluoksnio perceptrono svoris; z_j – j -ojo paslėpto sluoksnio perceptrono reikšmė.

Vieno sluoksnio dirbtiniai neuroniniai tinklai tinka paprastiems uždaviniams spręsti, tačiau esant sudėtingiems uždaviniams jie nebėra efektyvūs. Sudėtingų uždavinių atveju yra naudojami daugiasluoksniai neuroniniai tinklai, kurie turi daugiau paslėptųjų sluoksnių. Šiuo atveju paslėptuosiuose sluoksniuose esantys neuronai priima informaciją iš prieš tai buvusio paslėptojo sluoksnio neuronų.

Neuroninių tinklų svorių parinkimas yra vienas iš esminių dalykų šių modelių kūrimo procese. Dažniausiai naudojamas algoritmas, taikomas svoriams parinkti, yra klaidos skleidimas atgal (angl. *backpropagation* (BP)). Šis klaidos skleidimo atgal metodas yra iteratyvus, todėl pirminiai svoriai yra parenkami atsitiktinai. Neuroninio tinklo išvesties rezultatas yra lyginamas su realiu išvesties rezultatu ir remiantis tuo yra apskaičiuojama paklaidos funkcija. Pagrindinė klaidos skleidimo atgal idėja yra dalinių išvestinių $\partial C / \partial w$ ir $\partial C / \partial b$ minimizavimas. Šiuo atveju C yra modelio paklaidos funkcija, o w , kaip buvo minėta anksčiau, svoris.

Kvadratinė paklaidos funkcija yra užrašoma:


$$C = \frac{1}{2n} \sum_x \|y(x) - a^L(x)\|^2; \quad (4)$$

čia n – bendras stebinių skaičius; $y = y(x)$ – išvesties rezultatas; x – vienas individualus stebinys; L – sluoksnių skaičius tinkle; a^L – tinklo aktyvacijų išvestis, kai x yra įvestis.

Klaidos skleidimo atgal algoritmas yra vykdomas, remiantis šiais žingsniais:

1. Atsitiktinai parenkami neuroninio tinklo svoriai, kurie yra artimi nuliui, tačiau nėra jam lygūs.
2. Pirmas stebinys yra pateikiamas į neuroninio tinklo įvesties sluoksnį.
3. Vykdomas skleidimas į priekį (angl. *forward-propagation*), kai informacija neuroniniu tinklu juda iš kairės jo pusės (įvesties sluoksnio) į dešinę (išvesties sluoksnį), kol yra gaunamas rezultatas.
4. Apskaičiuojama gauta paklaida tarp realios reikšmės ir prognozuojamos reikšmės.
5. Vykdomas klaidos skleidimas atgal (angl. *back-propagation*) iš dešinės pusės (išvesties sluoksnio) į kairę pusę (įvesties sluoksnį). Šiame algoritmo žingsnyje yra atnaujinamos svorių reikšmės priklausomai nuo to, kaip šie svoriai lemia išvesties reikšmę.
6. Kartojamas 2–5 žingsnis.
7. Kada visas mokymo duomenų rinkinys pereina per šiuos žingsnius, pradeda nauja neuroninio tinklo mokymo epocha.

Taip pat svarbu pabrėžti tai, kad paklaidos funkcija šiuo atveju yra atskirų stebinių paklaidų funkcijų suma. Kaip buvo minėta anksčiau, tada, atsižvelgiant į gautas dalinių išvestinių reikšmes, yra keičiami svoriai, kad paklaida būtų minimizuota ir šis procesas yra vykdomas kol pasiekiamas minimumas ar artimas jam dydis. Tačiau geriausių svorių radimo procesas yra sudėtingas, nes egzistuoja labai didelis skaičius įvairių kombinacijų ir visų jų patikrinti nėra galimybių. Dėl šios priežasties dažniausiai klaidai minimizuoti yra naudojamas gradientinio nusileidimo (angl. *gradient descent*) metodas (žr. 2.2 pav.).



2.2 pav. Gradientinio nusileidimo (angl. *gradient descent*) metodas

Neuroninių tinklų modeliuose yra panaudojami du skirtingi gradientinio nusileidimo tipai:

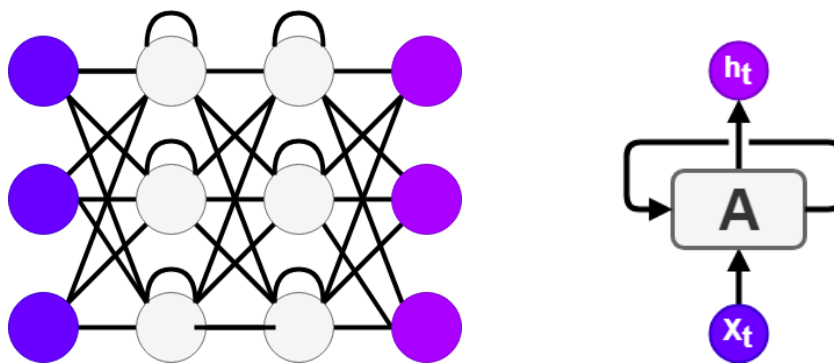
- Grupės (paketo) gradientinis nusileidimas (angl. *batch gradient descent*) – šiuo atveju modelyje naudojami svoriai yra atnaujinami, remiantis tam tikro nustatyto kiekio stebinių pagrindu. Modelis apskaičiuoja svorius, remiantis stebinių grupe, ir tik tuomet šiuos svorius atnaujina.

- Stochastinis² gradiento nusileidimas (angl. *stochastic gradient descent*) – šiuo gradientinio nusileidimo atveju svoriai yra atnaujinami po kiekvieno stebinio.

Nors neuroniniai tinklai yra panaudojami ypač dažnai, tačiau šie mašininio mokymosi modeliai turi ir tam tikrų trūkumų. Pirmiausiai, dėl didelių duomenų kiekio neuroniniai tinklai yra sudėtingai mokomi, nes yra patiriamos didelės laiko sąnaudos. Šią problemą, šiuo metu, dažniausiai bandoma spręsti su tam tikromis neuroninių tinklų modifikacijomis, tokiomis kaip ekstremalaus mokymosi mašinomis (angl. *extreme learning machines*). Taip pat vienas iš svarbių trūkumų, naudojant neuroninius tinklus ekonominiuose uždaviniuose, yra tai kad šie tinklai yra laikomi „juoda dėže“. Dėl šios priežasties tinklo parametrų interpretavimas yra sudėtingas ar tam tikrais atvejais išvis negalimas. Nagrinėjant ekonominius reiškinius kintančius laike, svarbiu faktoriumi tampa tai, kad šie reiškiniai yra kintantys laike ir tos pačios šalies rodiklių reikšmės yra susietos. Tokioms reikšmėms prognozuoti buvo sukurti rekurentiniai neuroniniai tinklai, kurie yra apžvelgiami tolimesniuose šio poskyrio skyreliuose.

2.2.1. Rekurentiniai neuroniniai tinklai


Įprastai naudojami tiesioginio sklidimo neuroniniai tinklai negali užfiksuoti tęstinio duomenų kitimo, todėl šiuo atveju jie negali būti panaudojami. Šiam tikslui įgyvendinti buvo sukurti rekurentiniai neuroniniai tinklai, leidžiantys užfiksuoti ne tik esamą būseną, tačiau ir praeities būseną [140]. To pavyzdys gali būti teksto vertimas į užsienio kalbą, kai priklausomai nuo sakinyje iš eilės einančių žodžių yra parenkamas tinkamas verčiamo žodžio linksnis ar pats žodis. Rekurentiniai neuroniniai tinklai, sprenddami šią užduotį, panaudoja ciklus, kurie leidžia išsaugoti anksčiau buvusias būsenas (žr. 2.3 pav.). 2.3 paveiksle pateikiama supaprastinta rekurentinių neuroninių tinklų schema.



2.3 pav. Rekurentinių neuroninių tinklų schemas: a) rekurentinių neuroninių tinklų struktūra; b) rekurentinių neuroninių tinklų ciklas


Pateiktoje rekurentinio neuroninio tinklo struktūroje (žr. 2.3 pav.) pateikiami žymėjimai: A – neuroninio tinklo dalis; X_t – neuroninio tinklo įvesties reikšmė laiko momentu t ; h_t – neuroninio tinklo išvesties reikšmė laiko momentu t . Atsižvelgiant į tai, kad pateiktas rekurentinis neuroninis tinklas yra suprantamas, kaip ciklas, jis gali būti atvaizduojamas ir kaip vientisas procesas, susidedantis iš kelių dalių (žr. 2.4 pav.)

² Stochastinis (gr. *stochasis* – nuspėjimas) – matematikos moksle įvykis, procesas ar reiškinys, kuris yra atsitiktinis, tikimybinis. Pvz. atsitiktinis procesas, kurio kitimas priklauso nuo atsitiktinumo [151].




2.4 pav. Išskleistas rekurentinis neuroninis tinklas

Kartais atliekant specifines užduotis rekurentiniai neuroniniai tinklai yra labai efektyvūs, atliekant tokias užduotis. Pavyzdžiui, jei rekurentiniai neuroniniai tinklai yra naudojami tekstui versti iš vienos kalbos į kitą, dažniausiai pakankama žinoti kelis prieš tai buvusius žodžius, kad būtų parenkamas teisingas žodžio linksnis ar pats žodis, turintis kelias skirtingas reikšmes. Toliau pateikiamame paveiksle (žr. 2.5 pav.) pateikiama šių neuroninių tinklų veikimo schema. Pereinant iš vienos neuroninio tinklo dalies į kitą, yra išsaugoma prieš tai buvusi reikšmė, kuri naujoje tinklo dalyje yra sujungiama su naujai gauta reikšme. Tuomet yra panaudojama hiperbolinio tangento funkcija ir gaunama išvesties reikšmė, kuri yra pateikiama toliau esančiai tinklo daliai.



2.5 pav. Rekurentinių neuroninio tinklų veikimo schema


Šiais atvejais skirtumas tarp pateikiamos įvesties informacijos ir vietos, kur ši informacija yra panaudojama, yra nedidelis, todėl rekurentiniai neuroniniai tinklai gali išmokti šią informaciją. Toliau esančiame paveiksle pateikta iliustracija, vaizduojanti mažą atotrūkį tarp įvesties reikšmių ir išvesties reikšmės (žr. 2.6 pav.).



2.6 pav. RNN tinklas esant nedideliui atotrūkiui tarp informacijos ir jos panaudojimo

Tačiau galimas atvejis, kada siekiant prognozuoti išvesties reikšmes, yra reikalingas didesnis kontekstas, leidžiantis tai padaryti. Šiuo atveju panaudojant paprastus rekurentinius neuroninius

tinklus tai įgyvendinti tampa sudėtinga. Žemiau esančiame paveiksle pateikta iliustracija, vaizduojanti didelį atotrūkį tarp įvesties reikšmių ir išvesties reikšmės (žr. 2.7 pav.).




2.7 pav. RNN tinklas esant dideliui atotrūkiui tarp informacijos ir jos panaudojimo

Dėl šios priežasties buvo sukurtas naujas neuroninių tinklų tipas, leidžiantis užfiksuoti ir tolimesnės praeities informacija. Šie neuroniniai tinklai yra vadinami ilgalaikės-trumpalaikės atminties neuroniniai tinklai (angl. *LSTM*), kurių aprašymas pateikiamas tolimesniame skyrelyje (žr. 2.2.2 skyrelis).

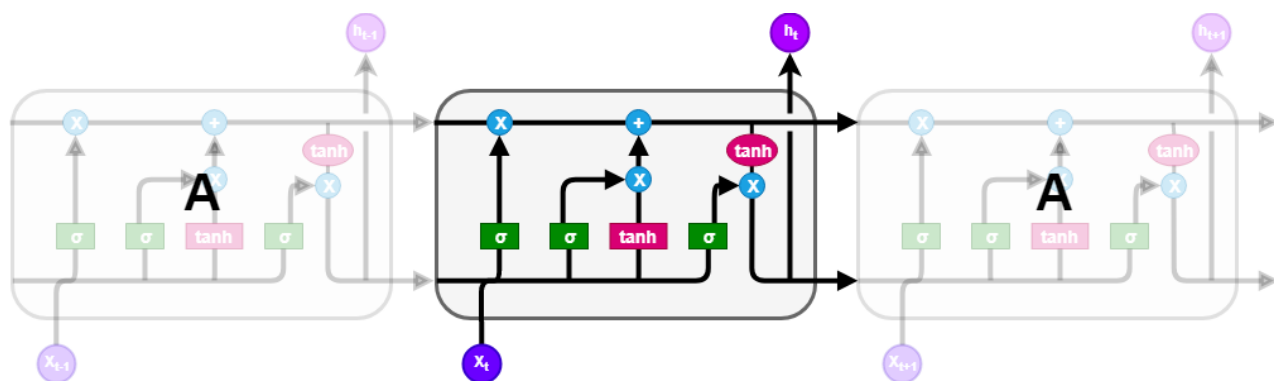
2.2.2. Ilgalaikės-trumpalaikės atminties neuroniniai tinklai

Ilgalaikės-trumpalaikė atminties neuroniniai tinklai (angl. *long-short term memory networks* (LSTM)) tai rekurentinių neuroninių tinklų tipas, leidžiantis užfiksuoti ne tik praeities duomenis, kai atotrūkis tarp įvesties informacijos ir išvesties yra nedidelis, tačiau ir tada, kai šis atotrūkis yra daug didesnis [141]. Panaudojant šiuos neuroninius tinklus yra siekiama išsaugoti ar kitaip sakant „atsiminti“ prieš tai buvusių būsenų reikšmes.




2.8 pav. Ilgalaikės-trumpalaikės atminties neuroninis tinklas

Šis neuroninių tinklų tipas pirmą kartą buvo pristatytas 1997 metais, kai tai padarė Hochreiter'is ir Schmidhuber'is. Paskutiniu metu dėl galimybės užfiksuoti ilgos praeities informaciją šie neuroniniai tinklai yra ypač dažnai panaudojami praktikoje. Šie neuroniniai tinklai taip pat turi „grandinės“ tipo struktūrą, tačiau jų pasikartojantis vienetas turi visiškai kitą struktūrą nei paprasti rekurentiniai neuroniniai tinklai. Vietoje vieno sluoksnio, kaip yra rekurentinių neuroninių tinklų atveju, LSTM turi net keturis sluoksnius, kurių sąryšis yra išskirtinis. Ilgalaikės-trumpalaikės atminties neuroninių tinklų struktūra pateikiama paveiksle esančiame toliau (žr. 2.9 pav.).



2.9 pav. Ilgalaikės-trumpalaikės atminties neuroninių tinklų struktūra

Aukščiau pateiktame paveiksle (žr. 2.9 pav.) naudojamas žymėjimas: žalias kvadratas – neuroninio tinklo sluoksnis, mėlynas apskritimas – operacijos atliekamos tarp atskirų vektorių (daugyba, sudėtis ir kt.). Šiame pateiktame paveiksle taip pat pateikiamos vektorių kryptys, dviejų rodyklių susikirtimas nurodo vektorių sujungimą, o vieno vektoriaus atskyrimas į du vektorius – šių vektorių kopijavimą. Pagrindinis šių neuroninių tinklų elementas yra horizontali linija, einanti per visą grandinę. Šio elemento iliustracija pateikiama toliau esančiame paveiksle (žr. 2.10 pav.).




2.10 pav. Pagrindinis ilgalaikės-trumpalaikės atminties neuroninių tinklų elementas

Toliau šiame skyrelyje pateikiama informacija apie ilgalaikės-trumpalaikės atminties neuroninių tinklų veikimo principą, apžvelgiant kiekvieną vykdomą žingsnį šiuose neuroniniuose tinkluose. Pirmajame LSTM neuroninių tinklų sluoksnyje (žr. 2.11 pav.) bandoma atrinkti, kuri informacija turi būti išmetama iš anksčiau surinktos informacijos. Tai yra atliekama panaudojant sigmoidinės funkcijos sluoksnį, kuris yra vadinamas užmiršimo vartų sluoksniu (angl. *forget gate layer*). Šiame sluoksnyje yra panaudojamos h_{t-1} ir x_t įvesties reikšmės ir gaunama išvesties reikšmė tarp 0 ir 1.

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f); \quad (5)$$

Šios reikšmės yra gaunamos kiekvienai jau anksčiau sukauptai būsenai C_{t-1} , kur 1 atspindi tai, kad būsena turi būti išsaugoma, o 0 kad nauja būsena turi būti atmetama ir neturi būti saugoma. Jei tai yra pritaikoma prognozuojant ekonominius rodiklius tai galima įsivaizduoti, kaip atmetamas tam tikrų anksčiau buvusių metų rodiklių reikšmes. Prognozuojant investicinį patrauklumą jis gali nepriklausyti nuo prieš 3 metus buvusių rodiklių reikšmių ir šiuo atveju tokių reikšmių išvestis šiame sluoksnyje būtų 0.



2.11 pav. LSTM veikimo schema – 1 žingsnis: užmiršimo vartų sluoksnio (angl. *forget gate layer*) panaudojimas


Antrajame šio algoritmo žingsnyje yra nusprendžiama, kuri informacija bus išlaikoma (žr. 2.12 pav.). Visa tai susideda iš dviejų dalių. Pirmą dalį – sigmoidinės funkcijos sluoksnis, kuris yra vadinamas įvesties vartų sluoksniu (angl. *input gate layer*). Šiame sluoksnyje yra nusprendžiama, kurios reikšmės bus atnaujintos.

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i); \quad (6)$$

Tada antrasis – hiperbolinio tangento sluoksnis, kuris sukuria naujas galimas reikšmes \tilde{C}_t , kurios gali būti pridamos prie būsenos reikšmės.

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C); \quad (7)$$

Tada sekančiame žingsnyje yra sudedamos šios reikšmės, kad būtų atnaujinta būseną. Pavyzdžiui, vertinant investicinį patrauklumą yra norima išsaugoti naują būseną, kuri gali būti narystė ES ir tada pamiršti, kokia būseną buvo anksčiau.




2.12 pav. LSTM veikimo schema – 2 žingsnis: atnaujinamų reikšmių parinkimas

Trečiajame žingsnyje yra atliekamas senosios būsenos C_{t-1} atnaujinimas į naują būseną C_t (žr. 2.13 pav.) Siekiant atnaujinti šią būseną visi skaičiavimai buvo atliekami ankstesniuose žingsniuose, todėl šiuo atveju lieka tik būsenos atnaujinimas.

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t; \quad (8)$$

Pirmiausiai yra sudauginama senoji būseną su f_t , kur šių narių sandauga leidžia pamiršti nereikalingą informaciją. Tada prie šios sandaugos yra pridėdama $i_t * \tilde{C}_t$ parodanti, kaip yra norima atnaujinti kiekvieną būseną. Šioje vietoje vyksta tikrasis informacijos pamiršimas. Kaip buvo pateikta anksčiau, to pavyzdys gali būti informacijos apie narystę ES pamiršimas t. y. informacijos apie šalies nebuvimą ES nare pakeitimas į šios šalies buvimą ES nare.



2.13 pav. LSTM veikimo schema – 3 žingsnis: būsenos atnaujinimas

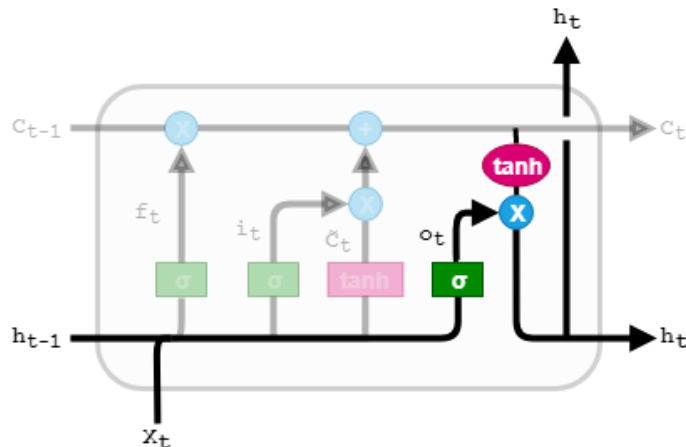
Paskutiniame žingsnyje yra nusprendžiama, kokia bus išvestis (žr. 2.14 pav.). Išvesties reikšmė šiuo atveju priklauso nuo būsenos reikšmės, tačiau yra filtruota šios reikšmės versija. Pirmiausiai yra panaudojama sigmoidinė funkcija, kuri nustato kokia dalis būsenos reikšmės bus išvesta.

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o); \quad (9)$$

Tuomet yra panaudojama hiperbolinio tangento funkcija tam, kad būsenos reikšmė būtų tarp -1 ir 1.

$$h_t = o_t * \tanh(C_t); \quad (10)$$


Ši gauta reikšmė yra sudauginama su anksčiau gauta sigmoidinės funkcijos reikšme, todėl išvesties reikšmė turi tam tikrą anksčiau nustatytą dalį būsenos reikšmės.



2.14 pav. LSTM veikimo schema – 4 žingsnis: išvesties ir naujos būsenos išvedimas

2.2.3. Sulaikomo pasikartojančio vieneto neuroniniai tinklai

Kita rekurentinių neuroninių tinklų modifikacija gana daug besiskirianti nuo LSTM modifikacijos yra sulaikomo pasikartojančio vieneto (GRU) (angl. *gated recurrent unit*) tinklai. Šis tinklas yra panašus į LSTM tipo tinklą, nes kaip ir LSTM yra panaudojami įvairūs loginiai elementai, kurie leidžia kontroliuoti informacijos pateikimą. Vienas iš pagrindinių skirtumų tarp LSTM ir GRU yra tai, kad GRU neturi atminties celių [142].



2.15 pav. Sulaikomo pasikartojančio vieneto (GRU) neuroninis tinklas

Šio tipo neuroniniai tinklai neišskiria užmiršimo vartų (angl. *forget gate*) ir įvesties vartų (angl. *input gate*), o juos sudeda į vienus atsinaujinimo vartus (angl. *update gate*). Taip pat šis neuroninių tinklų tipas sujungia celės būseną ir paslėptąją būseną. Pirmajame šių neuroninių tinklų žingsnyje yra apskaičiuojami atnaujinimo vartai z_t laiko momentu t :

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t]); \quad (11)$$

Šiame žingsnyje yra panaudojama nauja x_t reikšmė, taip pat ankstesniame periode buvusi būseną h_{t-1} . Abu šie rezultatai yra sudedami kartu, tada yra panaudojama sigmoidinė funkcija tam, kad reikšmės būtų pakeičiamos į 0 – 1 intervalą. Atnaujinimo vartai (angl. *update gate*) leidžia modeliui nustatyti, kiek praeities informacijos, iš praėjusių laiko periodų, modelyje turi būti paliekama ir panaudojama ateityje. Šis elementas yra ypač naudingas, kadangi padeda išvengti nykstančio gradiento (angl. *vanishing gradient*) problemos.

Antrame žingsnyje yra panaudojami atnaujinimo vartai (angl. *reset gate*). Šis žingsnis yra ypač reikšmingas šiame neuroninių tinklų tipe, kadangi nurodo kokią dalį praeities informacija reikia atmeti. Informacijos atmetimas yra apskaičiuojamas pagal:

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t]); \quad (12)$$

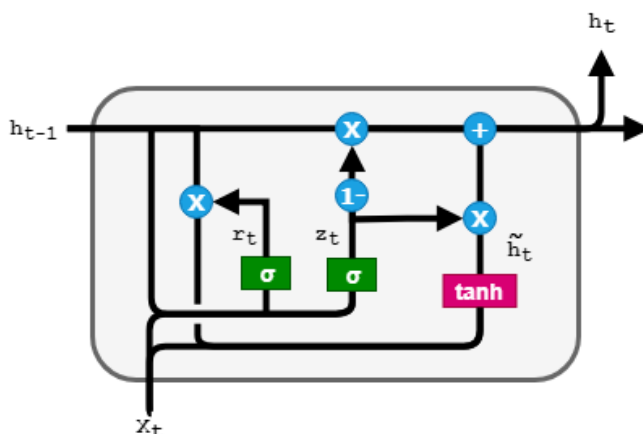
Galima pastebėti, kad šiame žingsnyje naudojama formulė yra lygiai tokia pati, kaip ir pirmajame žingsnyje naudota formulė. Skirtumas tarp šių formulių yra tik naudojami svoriai. Trečiame šio algoritmo žingsnyje yra apskaičiuojama dabartinė atminties būseną. Šiame etape yra panaudojami anksčiau apskaičiuoti atnaujinimo vartai (angl. *reset gate*). Yra panaudojama nauja informacija ir atnaujinimo vartai tam, kad būtų išsaugota reikalinga informacija iš praeities. Visa tai yra atliekama panaudojant formulę:

$$\tilde{h}_t = \tanh(W * [r_t * h_{t-1}, x_t]); \quad (13)$$

Pirmiausiai yra sudauginama x_t ir h_{t-1} su jų svoriais. Tuomet yra apskaičiuojama Hadamardo sandauga tarp atnaujinimo vartų (r_t) ir praeities būsenos (h_{t-1}). Ši sandauga leidžia nuspręsti, kuri informacija turi būti atmetama iš praėjusio periodo. Atnaujinimo vartų (r_t) reikšmė artima 0, leidžia atmesti praeities periodų informaciją ir naudoti tik naujesnę informaciją. Po šių operacijų, reikšmės yra sudedamos ir jų sudėties rezultatui yra pritaikoma netiesinė hiperbolinio tangento funkcija. Paskutiniame žingsnyje yra apskaičiuojamas h_t vektorius, kuris saugo informaciją dabartiniame tinklo vienetė ir šią informaciją perduoda kitam vienetui. Siekiant tai įgyvendinti yra panaudojami anksčiau minėti atnaujinimo vartai (angl. *update gate*). Ši neuroninio tinklo dalis nusprendžia, kuri informacija turi būti surenkama iš dabartinės informacijos, o kuri iš praeities. Visa tai atliekama pasinaudojant formule:

$$h_t = (1 - z_t) * h_{t-1} + z_t * \tilde{h}_t; \quad (14)$$

Pirmiausiai remiantis šia formule yra atliekama Hadamardo sandauga tarp $(1 - z_t)$ ir h_{t-1} , tuomet pasinaudojant ta pačią Hadamardo sandaugą tai atliekama ir tarp z_t , ir \tilde{h}_t . Galiausiai yra apskaičiuojama šių dviejų sandaugų suma ir gaunama laiko momento t informacija, kuri pateikiama tolimesniam neuroninio tinklo vienetui.



2.16 pav. Sulaikomo pasikartojančio vieneto (GRU) (angl. *gated recurrent unit*) veikimo schema

2.2.4. Saviorganizuojantys neuroniniai tinklai

Saviorganizuojantys neuroniniai tinklai ar saviorganizuojantys žemėlapiai (angl. *self-organizing map* (SOM)) tai mokymosi be mokytojo dirbtinių neuroninių tinklų tipas, leidžiantis didelės dimensijos duomenis atvaizduoti plokštumoje. Pagrindinis šio neuroninių tinklų tipo skirtumas, lyginant su kitais neuroniniais tinklais, yra tai, kad šiuose neuroniniuose tinkluose naudojamas konkurencinis mokymasis, o ne mokymasis atsižvelgiant į klaidos funkciją [143]. Saviorganizuojantys neuroniniai tinklai gali generuoti vaizdą šešiakampiame ar stačiakampiame tinkle. Šie neuroniniai tinklai yra panaudojami meteorologijoje, okeanografijoje, projektų prioretizavime, naftos ir dujų paieškoje. Saviorganizuojantys neuroniniai tinklai taip pat gali būti vadinami saviorganizuojančiais savybių žemėlapiai (angl. *self-organizing feature map* (SOFM)) arba Kohonen'o žemėlapiams. Saviorganizuojančių neuroninių tinklų kūrimas yra vykdomas, remiantis šiais žingsniais:

1. Saviorganizuojančio neuroninio tinklo neuronai atsitiktinai yra atvaizduojami duomenų erdvėje.
2. Atsitiktinai parenkamas vienas duomenų taškas.
3. Randamas neuronas, kuris yra arčiausiai pasirinkto duomenų taško. Toliau šis neuronas yra vadinamas geriausio atitikimo vienetu (angl. *Best Matching Unit* (BMU)).


4. Geriausio atitikimo vienetas yra perkeliamas arčiau 2 žingsnyje pasirinkto duomenų taško. Atstumo sumažėjimas tarp geriausio atitikimo vieneto ir pasirinkto duomenų taško priklauso nuo mokymosi greičio.
5. Geriausio atitikimo vieneto kaimynai taip pat yra perkeltami arčiau duomenų taško. Kuo toliau tinklo neuronai yra nuo BMU, tuo mažesnis yra atstumo iki duomenų taško pasikeitimas. Atstumas nuo neuronų iki BMU lemia BMU kaimynų pasirinkimą.
6. Atnaujinamas mokymosi greitis ir BMU spindulys ir tada kartojamas 2–4 žingsnis. Šis algoritmas yra vykdomas tol, kol tinklo neuronų pozicijos yra stabilios.

Nors saviorganizuojantys neuroniniai tinklai padeda supaprastinti duomenų rinkinius, turinčius didelį skaičių kintamųjų, ir paprastai juos atvaizduoti dvimatėje erdvėje, tačiau šis metodas turi ir apribojimus:

- **Negali būti naudojami kategoriniai kintamieji.** Saviorganizuojantys neuroniniai tinklai priima prielaidą, kad visi kintamieji duomenų rinkinyje yra tolydūs. Dėl šios priežasties kategoriniai kintamieji yra atvaizduojami, kaip tiesė ir nėra pastebimas duomenų pasiskirstymas. Kategorinių kintamųjų panaudojimas dėl to neleidžia gauti papildomos informacijos apie turimus duomenis.
- **Ilgas skaičiavimo laikas.** Duomenų rinkiniuose, turinčiuose daug kintamųjų, yra apskaičiuojama daug atstumų, todėl šis procesas yra ilgai trunkantis.

2.2.5. Ekstremalaus mokymosi mašinos

Ekstremalaus mokymosi mašinos (angl. *Extreme learning machines*) – tai dirbtiniai neuroniniai tinklai skirti duomenų klasifikacijai, regresijai, klasterizacijai, retų duomenų aproksimacijoms (angl. *sparse approximation*) ar duomenų suspaudimui, siekiant sumažinti duomenų dimensijas [144]. Priklausomai nuo duomenų ir sprendžiamo uždavinio gali būti naudojami skirtingos ekstremalaus mokymosi mašinos, kuomet yra naudojamas vienas sluoksnis, daugiau sluoksnių ar hierarchiniai tinklai. Paslėptajame sluoksnyje esantys neuronai, gali būti ne tik klasikiniai neuronai, tačiau gali būti panaudojamos ir bazinės funkcijos, ar šie neuronai gali būti sukuriami iš neuronų potinklio t.y. neuroną sudaro dar atskiras tinklas. Tyrimai rodo, kad ELM metodai vis dar yra panaudojami retai, tačiau dėl savo greičio paskutiniu metu jiems yra skiriamas didesnis dėmesys ir jų panaudojimo sritys nuolat yra išplečiamos [145]. Žemiau pateiktas paveikslas, kuris vaizduoja ekstremalaus mokymosi mašinų veikimo schemą (žr. 2.17 pav.).



2.17 pav. Ekstremalaus mokymosi mašinų (angl. *Extreme learning machines*) veikimo schema

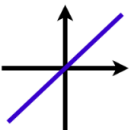
2.3. Aktyvacijos funkcijos samprata ir naudojimas

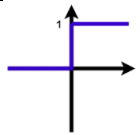
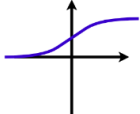
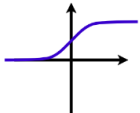
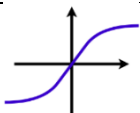
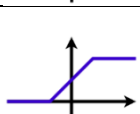
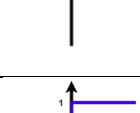
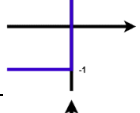
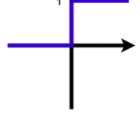
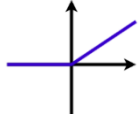
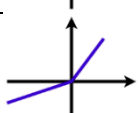

Aktyvacijos funkcija (angl. *activation function*) – tai funkcija, skirta pakeisti įvesties reikšmes į tam tikros funkcijos reikšmes, kurios vėliau yra panaudojamos sekančiame neuroninio tinklo sluoksnyje (paslėptajame arba išvesties). Aktyvacijos funkcijos neuroniniuose tinkluose yra naudojamos siekiant, kad tinklas nebūtų tiesiškas t. y. jis atitiktų ne tik tiesinę priklausomybę. Toliau yra apžvelgiamas aktyvacijos funkcijų panaudojimas skirtingų neuroninių tinklų atvejais.

Pilnai sujungto tiesioginio sklidimo (angl. *feed-forward*) neuroninio tinklo atvejis. Galima apibrėžti, kad Y_i apibūdina i -tojo sluoksnio neuroninio tinklo rezultatą, o Y_0 yra įvestis (angl. *input*). Pilnai sujungtas tiesioginio sklidimo neuroninis tinklas yra aprašomas lygtimi $Y_i = f(W_i L_{i-1})$, kai $i > 1$, kur šiuo atveju f yra anksčiau apibūdinta aktyvacijos funkcija. Tuomet remiantis prielaida, kad aktyvacijos funkcija šiuose neuroniniuose tinkluose nėra naudojama gaunama, kad $Y_T = W_T L_{T-1} = W_T W_{T-1} L_{T-2} = \dots = (W_T W_{T-1} \dots W_1) L_0$. Įvedus pasižymėjimą $W = W_T W_{T-1} \dots W_1$ yra gaunama $L_T = W L_0$. Ši lygtis apibūdina tik tiesinę transformaciją, kuri nėra naudinga, siekiant aprašyti sudėtingesnes priklausomybes duomenyse. Taigi, nenaudojant aktyvacijos funkcijos tiesioginio sklidimo neuroniniuose tinkluose tampa sudėtinga aprašyti duomenis ir siekiant tai padaryti yra reikalinga daugiau parametrų, kurie mažina neuroninio tinklo mokymo greitį.

Rekurentinių neuroninių tinklų atvejis. Aktyvacijos funkcijų svarbumą rekurentiniuose neuroniniuose tinkluose galima aprašyti, remiantis paprasčiausiu rekurentiniu neuroniniu tinklu, kurio paslėpta būsena gali būti aprašoma lygtimi: $h_t = f(W_{X_t} + R h_{t-1})$, kur X_t yra įvesties signalas t žingsnyje bei remiantis prielaida, kad $h_0 = 0$. Remiantis prielaida, kad aptariamuose neuroniniuose tinkluose nėra naudojama aktyvacijos funkcija, gaunama, kad neuroninis tinklas būtų aprašomas lygtimi: $h_t = W_{X_t} + R h_{t-1}$. Ši pati lygtis galiotų ir prieš tai buvusiai tinklo būsenai h_{t-1} , kur ši būsena gali būti aprašoma lygtimi $h_{t-1} = W_{X_{t-1}} + R h_{t-2}$. Tuomet galima pastebėti, kad $h_t = W_{X_t} + R(W_{X_{t-1}} + R h_{t-2}) = W_{X_t} + W R_{X_{t-1}} + R^2 h_{t-2}$, todėl dar vėlesniame žingsnyje viskas būtų išlaikoma pagal tą pačią logiką ir būtų aprašoma $h_t = W_{X_t} + W R_{X_{t-1}} + W R^2_{X_{t-2}} + R^3 h_{t-3}$. Ir visa tai būtų atliekama iki pat šios sekos pradžios, kurioje viskas būtų užrašoma $h_t = W(x_t + R x_{t-1} + R^2 x_{t-2} + \dots + R^{t-1} x_1) + R^{t-1} h_0$. Kadangi anksčiau buvo apibrėžiama, kad $h_0 = 0$, todėl ši lygtis gali būti užrašoma kur kas paprasčiau $h_t = W(x_t + R x_{t-1} + R^2 x_{t-2} + \dots + R^{t-1} x_1)$. Iš visos šios informacijos galima pastebėti, kad jei yra dvi sekos (x_1, x_2, \dots, x_T) ir $(x'_1, x'_2, \dots, x'_T)$, tuomet $h_t(ax + \beta x') = ah_t(x) + \beta h_t(x')$. Iš šio rezultato galima pamatyti, kad rekurentinių neuroninių tinklų sluoksnis pavirsta tiesine išraiška, o tai yra nepageidaujamas reiškinys. Šis reiškinys yra nepageidaujamas, kadangi paslėptas sluoksnis gali per daug fiksuoti praeities būsenas arba išvis neužfiksuoti šių būsenų. Aktyvacijos funkcijos bei jų apskaičiavimo lygtys ir grafinis vaizdavimas pateikiamas 2.1 lentelėje.

2.1 lentelė. Aktyvacijos funkcijos, jų lygtys ir grafinis vaizdavimas

Aktyvacijos funkcija	Lygtis	Grafikas
Tiesinė (angl. <i>identity</i>)	$f(x) = x$	

Binarinė (angl. <i>binary step</i>)	$f(x) = \begin{cases} 0, & \text{kai } x < 0 \\ 1, & \text{kai } x \geq 0 \end{cases}$	
Logistinė / Sigmoidinė (angl. <i>logistic / sigmoid</i>)	$f(x) = \frac{1}{1 + e^{-x}}$	
Gompertz'o	$f(x) = \alpha e^{-be^{-cx}}$	
Hiperbolinio tangento (angl. <i>hyperbolic tangent</i>)	$f(x) = \frac{e^x + e^{-x}}{e^x + e^{-x}}$	
Segmentuoti tiesinė (angl. <i>piece-wise linear</i>)	$f(x) = \begin{cases} 1, & \text{kai } x \geq \frac{1}{2} \\ x + \frac{1}{2}, & \text{kai } -\frac{1}{2} < x < \frac{1}{2} \\ 0, & \text{kai } x \leq -\frac{1}{2} \end{cases}$	
Ženklo (angl. <i>sign (signum)</i>)	$f(x) = \begin{cases} -1, & \text{kai } x < 0 \\ 0, & \text{kai } x = 0 \\ 1, & \text{kai } x > 0 \end{cases}$	
Vienpakopė (angl. <i>Unit step (Heaveside)</i>)	$f(x) = \begin{cases} 0, & \text{kai } x < 0 \\ 0.5, & \text{kai } x = 0 \\ 1, & \text{kai } x > 0 \end{cases}$	
Suglodinta tiesinė (angl. <i>Rectified Linear Unit (ReLU)</i>)	$f(x) = \begin{cases} 0, & \text{kai } x < 0 \\ x, & \text{kai } x \geq 0 \end{cases}$	
Parametrinė suglodinta tiesinė (angl. <i>Parametric Rectified Linear Unit (PReLU)</i>)	$f(x) = \begin{cases} \alpha x, & \text{kai } x < 0 \\ x, & \text{kai } x \geq 0 \end{cases}$	
Eksponentinė (angl. <i>Exponential Linear Unit (ELU)</i>)	$f(x) = \begin{cases} \alpha(e^x - 1), & \text{kai } x < 0 \\ x, & \text{kai } x \geq 0 \end{cases}$	
<i>SoftPlus</i>	$f(x) = \log_e(1 + e^x)$	


2.4. Klasterinė analizė

Klasterinė analizė – tai matematinis metodas, leidžiantis objektus ar stebinius suskirstyti į atskiras grupes. Stebiniai, esantys viename klasteryje, yra panašūs vienas į kita, kai tuo tarpu stebiniai tarp skirtingų klasterių pasižymi mažu panašumu. Ši analizė leidžia atrasti grupes, esančias duomenyse, kurios negali būti paprastai pastebimos pradiniuose duomenyse. Klasterinė analizė yra plačiai naudojama įvairiose mokslo srityse: verslo įžvalgose, paveikslų atpažinime, saityno paieškose ir kita. Priimant verslo sprendimus, klasterinė analizė yra panaudojama vartotojams segmentuoti bei šiems segmentams valdyti. Toks padalinimas leidžia priimti tinkamus sprendimus skirtingiems vartotojų segmentams. Klasterizavimas dažnai yra apibūdinamas kaip duomenų segmentavimas, kadangi

suteikiama galimybė atskirti stebinius labiausiai panašius vienas į kitą. Taip pat dėl šios priežasties klasterizavimas gali būti panaudojamas ir išskirtims atpažinti duomenyse. Atsižvelgiant į tai, kaip toli nuo rastų klasterių yra pavienės reikšmės, galima teigti, kad tokios reikšmės gali būti vertinamos kaip išskirtys. Šis išskirčių analizavimas yra puikiai pritaikomas bankiniame sektoriuje, beiėskant apgavystės požymių tarp atskirų klientų ar pinigų srautų. Analizuojant klasterinę analizę galima pastebėti, kad dažniausiai yra minima atstumu pagrįsta (*angl. distance-based*) klasterinė analizė. Šis klasterinės analizės tipas yra pagrįstas stebinių atstumu. Klasterinė analizė mašininio mokymosi kontekste yra laikoma mokymo be mokytojo metodu, kadangi kuriant šiuos modelius nėra žinoma, kokiam segmentui (klasteriui) kiekvienas objektas priklauso. Tuo tarpu klasifikacijos atveju mokant mašininio mokymosi algoritmą yra pateikiama objekto klasė, iš kurios šis modelis ir mokosi, todėl toks mokymas vadinamas su mokytoju.

Klasterinės analizės metodai ir (ar) algoritmai gali būti skirstomi įvairiai, kadangi yra sudėtinga apibrėžti, kokio būtent tipo tai yra algoritmas, nes dažnai jie yra persidengiantys. Tačiau vertinant metodus pagal jų veikimo principą, galima išskirti pagrindinius metodų tipus: padalinimo metodai, tankiu grįsti metodai ir hierarchiniai metodai. **Padalinimo metodai** padalina turimus duomenis į k grupių, kur kiekvienas stebinis priklauso būtent vienai grupei. Dauguma padalinimo metodų yra atstumu grįsti metodai. Pirmajame cikle duomenys yra padalinami į k grupių. Tuomet atliekant iteracijas bandoma atrasti tinkamiausią duomenų padalinimą, kad klasteryje esantys elementai būtų panašūs (atstumas tarp jų būtų mažiausias), o tuo tarpu stebiniai tarp atskirų klasterių skirtųsi (atstumas tarp jų būtų didžiausias). Dažniausiai naudojami padalinimo algoritmai yra k -vidurkių ir k -medoidų (*angl. k-medoids*), kurie naudodami iteracijas siekia rasti optimalią klasterių sudėtį. Šie metodai pasižymi tuo, kad puikiai atranda sferos formos klasterius, kai stebinių skaičius yra santykinai mažas ar vidutinis. K -vidurkių metodo esmė yra stebinių suskirstymas į k nurodytų klasterių, tačiau panaudojant šiuos metodus ir atsitiktinai iniciavus klasterių centrus, klasteriai gali būti skirtingi. Šis metodas gali būti aprašomas 5 pagrindiniais žingsniais (žr. 2.18 pav.):

1. Stebiniai atsitiktinai yra suskirstomi į k klasterių bei parenkami pradiniai šių klasterių centrai.
2. Perskaičiuojami klasterių centrai.
3. Apskaičiuojamas kiekvieno stebinio atstumas iki klasterių, remiantis atstumo matais.
4. Pagal atstumą iki klasterių centrų stebiniai yra priskiriami artimiausiam klasteriui.
5. Pakartotinai vykdomas 2–4 žingsnis tol, kol klasterių centrai nebekinta arba jų kitimas yra mažesnis už nurodytą tolerancijos ribą.



2.18 pav. K -vidurkių algoritmo veikimo principas

Šis klasterizavimo metodas pasižymi dideliu greičiu ir gana paprastu metodo pritaikymu. Didžiausią problemą kelia tai, kad iš anksto turi būti nustatomas klasterių skaičius. Išankstinis klasterių nustatymas yra sudėtingas uždavinys, kadangi klasterių skaičius imtyje ir visoje populiacijoje gali skirtis. Taip pat klasteriai gali būti sudaryti iš išskirčių. Be šių problemų pastebima ir k -vidurkių klasterizavimo problema dėl galinčių „užstrigti“ klasterių centrų.

Hierarchiniai metodai – sukuria hierarchinį stebinių išskaidymą. Šie metodai gali būti skirstomi į 2 mažesnius pogrupius: aglomeracijos (sudėties) ir suskaldymo. Aglomeracijos metodų atveju yra pradama nuo klasterių skaičiaus lygaus stebinių skaičiui. Tuomet panašiausios grupės sujungiamos į vieną grupę, o šios grupės – į dar didesnę grupę. Remiantis šia logika yra vykdomas duomenų grupių jungimas tol, kol visi duomenys priklauso vienai grupei (klasteriui). Padalinimo atveju klasterizavimas yra pradamas nuo visų stebinių vienoje grupėje ir šią grupę dalinant į mažesnes grupes, tol, kol yra sudaromas grupių skaičius, lygus stebinių skaičiui. Hierarchiniai metodai gali būti paremti tiek atstumu tarp klasterių, tiek klasterius sudarančių stebinių tankiu. Viena iš problemų panaudojant šiuos klasterizavimo metodus yra tai, kad atlikus stebinių padalinimą į grupes, jie negali būti sujungiami atgal į pradinę grupę. Dėl šios priežasties neteisingai suskirstyti stebiniai lieka priskirtuose klasteriuose [146]. Atliekant hierarchinį klasterizavimą ypač svarbų vaidmenį atlieka artumo mato nustatymas. Hierarchiniame klasterizavime galimi 5 pagrindiniai artumo matai:

1. Artimiausio kaimyno – remiantis šiuo artumo matu yra lyginami skirtinguose klasteriuose esantys artimiausi elementai.
2. Tolimiausio kaimyno – remiantis šiuo artumo matu yra lyginami skirtinguose klasteriuose esantys tolimiausi elementai.
3. Vidutinės jungties – remiantis šiuo artumo matu yra lyginami visi skirtinguose klasteriuose esantys elementai, įvertinant vidutinį atstumą tarp klasterių.
4. Sunkio metodas (centrodės metodas) – remiantis šiuo artumo matu atstumas tarp klasterių yra vertinamas pagal atstumą tarp klasterių centrų.
5. Vordo (Ward) metodas – remiantis šiuo artumo matu yra įvertinamas atstumas nuo centro iki į vieną klasterį sujungtų elementų ir lyginamas su atstumu iki atskirų dviejų klasterių elementų atstumu iki šių klasterių centrų.

Tankiu grįšti klasterizavimo metodai – šie metodai pasižymi tuo, kad priešingai nei kiti klasterizavimo metodai gali atrasti ne tik sferinius klasterius. Šie klasterizavimo metodai remiasi tuo, kad klasteriai yra plečiami tol, kol yra tenkinama tam tikra klasterio kaimynų sąlyga. Klasteriai yra kuriami remiantis tuo, kad tam tikru atstumu nuo klasterių būtų nustatytas minimalus stebinių skaičius. Šie metodai gali būti panaudojami siekiant iš duomenų atskirti išskirtis, kadangi išskirtys bus nutolusios didesniu atstumu nuo klasterių ir netenkins anksčiau aptartų sąlygų.

Klasterių panašumui įvertinti gali būti naudojami:

- Atstumo matai.
- Koreliacijos koeficientai.

Atstumo matai teikia informaciją apie tai, kaip stebiniai yra panašūs vienas į kitą, arba kaip skiriasi vienas nuo kito. Dažniausiai atstumui įvertinti yra naudojamas Euklido atstumas, tačiau taip pat naudojami ir Manheteno, Čebyšovo, Minkovskio atstumai. Minkovskio atstumas leidžia apibendrinti kitus tris atstumo matus. Minkovskio atstumo parametrui m esant lygiam 1, jis virsta Manheteno atstumu, esant 2 – Euklido, o kai $m = \infty$ – Čebyšovo. Toliau pateikiamoje lentelėje (žr. 2.2 lentelė) pateikiamos šių atstumo matų apskaičiavimo formulės.

2.2 lentelė. Metriniai atstumo matai

Atstumo matas	Formulė
Euklido	$d(x, y) = d(y, x) = \sqrt{\sum_{i=1}^n (x_i + y_i)^2}$
Manheteno	$d(x, y) = \sum_{i=1}^n x_i + y_i $
Čebyšovo	$d(x, y) = \max_i x_i + y_i $
Minkovskio	$d(x, y) = \sqrt[m]{\sum_{i=1}^n (x_i + y_i)^m}$

Skirtingų stebinių panašumą galima apibūdinti ir panaudojant koreliacijos koeficientus. Vienas iš dažniausiai naudojamų koreliacijos koeficientų yra Pirsono (tiesinės) koreliacijos koeficientas:

$$d(x, y) = 1 - \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}}; \quad (15)$$

Taip pat naudojamas Eiseno kosinuso koreliacijos koeficientas, kuris yra Pirsono koreliacijos koeficiento modifikacija, remiantis prielaida, kad \bar{x} ir \bar{y} yra lygūs nuliui [147]:

$$d(x, y) = 1 - \frac{|\sum_{i=1}^n x_i y_i|}{\sqrt{\sum_{i=1}^n x_i^2} \sqrt{\sum_{i=1}^n y_i^2}}; \quad (16)$$

Spirmano tvarkos skalės koreliacijos koeficientas, kuris leidžia įvertinti ryšį tarp X ir Y, remiantis monotoniškumu, todėl ryšys yra nebūtinai tiesinis ir didėjant X monotoniškai didėja ir Y:

$$d(x, y) = 1 - \frac{\sum_{i=1}^n (x'_i - \bar{x}')(y'_i - \bar{y}')}{\sqrt{\sum_{i=1}^n (x'_i - \bar{x}')^2} \sqrt{\sum_{i=1}^n (y'_i - \bar{y}')^2}}; \quad (17)$$

Kendalo koreliacijos koeficientas leidžia įvertinti ryšį tarp tvarkos skalės kintamųjų, šio koreliacijos koeficiento ženklas yra interpretuojamas taip pat kaip ir kitų koreliacijos koeficientų – teigiamas koeficientas reiškia tiesioginę priklausomybę, neigiamas – atvirkštinę priklausomybę tarp kintamųjų:

$$d = \frac{n_c - n_d}{\frac{1}{2}n(n-1)}; \quad (18)$$

čia n_c – suderintos poros; n_d – nesuderintos poros; $n - x$ ir y stebinių skaičius.

2.5. Duomenų dimensijų mažinimas


Duomenų dimensijų mažinimas (angl. *dimensionality reduction*) – tai duomenų kintamųjų sumažinimas, remiantis tam tikromis matematinėmis taisyklėmis. Duomenų matmenų mažinimas leidžia sutaupyti vietas atliekant skaičiavimus, taip pat yra greičiau atliekami skaičiavimai. Kai kurie algoritmai, esant dideliame duomenų dimensijų skaičiui, negali atlikti skaičiavimų, todėl duomenų matmenų mažinimas leidžia atlikti šiuos skaičiavimus. Duomenų dimensijų mažinimas leidžia atskirti nereikalingas stebinių savybes, sumažinant duomenų multikolinearumo problemą. Taip pat duomenų matmenų mažinimas leidžia paprasčiau vizualizuoti duomenis, kai dimensijos yra sumažinamos iki

dviejų ar trijų matmenų, kurios gali būtų atvaizduojamos vizualiai. Dimensijų mažinimas gali būti atliekamas dviem skirtingomis metodikomis:

- Atliekant duomenų matmenų mažinimą, paliekant tik svarbias stebinių savybes. Toks duomenų mažinimas yra vadinamas savybių atranka (angl. *feature selection*).
- Atliekant duomenų dimensijų mažinimą, randant sumažintą naują duomenų rinkinį, kurio savybės yra pradinio duomenų rinkinio savybių kombinacijos, išlaikančios tą pačią informaciją. Tai yra vadinama dimensijų mažinimu.

Pagrindiniai metodai, priskiriami duomenų dimensijų mažinimui, yra pagrindinių komponentių analizė ir nepriklausomų komponentių analizė.

Pagrindinių komponentių analizė (angl. *principal components analysis*) – tai matematinis metodas, leidžiantis sumažinti duomenų dimensijas, išsaugojant didžiąją dalį informacijos. Šis metodas leidžia išskirti galimai koreliuojančius kintamuosius į mažesnę skaičių nekoreliuotų kintamųjų, kurie ir yra vadinami pagrindinėmis komponentėmis [148]. Pagrindinių komponentių analizės metu pirmiausia yra randama pirmoji pagrindinė komponentė (PK1) – tai kryptis, kuria dispersija yra didžiausia. Ši pagrindinė komponentė eina per duomenų centrą – tašką, kuriame yra visų kintamųjų vidurkis. Tuomet antroji pagrindinė komponentė (PK2) eina per tą patį tašką ir yra statmena PK1. Visos kitos pagrindinės komponentės taip pat eina per šį tašką ir yra statmenos prieš tai buvusių pagrindinių komponentių (n-1)-matei plokštumai, todėl PK3 yra statmena dvimatei PK1 ir PK2 plokštumai. Toliau pateikiamas paveikslas, vaizduojantis dviejų pagrindinių komponentių – PK1 ir PK2 atvejį (žr. 2.19 pav.)



2.19 pav. Pirmosios ir antrosios pagrindinių komponentių kryptys

Galimas ir šio grafiko matematinis užrašymas. Jei stebiniai, kurie yra tiriami, turi n skirtingų savybių, tuomet jie gali būti užrašomi, kaip $X = (X_1, X_2, \dots, X_n)$. Tuomet, remiantis šiuo užrašymu, pirmąją pagrindinę komponentę bus vadinama tokia tiesine kombinacija $a_1^T X$, kai a_1 yra parenkamas taip, kad būtų gaunama didžiausia dispersija pagal visus vektorius. Remiantis šiuo pačiu principu, antroji pagrindinė komponentė yra užrašoma $a_2^T X$ ir a_2 parenkamas taip, kad šios komponentės dispersija būtų didžiausia pagal visus vektorius ortogonalius a_1 .

Nepriklausomų komponentių analizė (angl. *independent components analysis (ICA)*) – tai matematinis metodas, atrenkantis pagrindines komponentes, kurios nėra priklausomos viena nuo

kitos. Pagrindinis skirtumas tarp pagrindinių komponentų analizės (PKA) ir nepriklausomų komponentų analizės (NKA) yra tai, kad PKA remiasi nekoreliuotais faktoriais, o NKA nepriklausomais. Jei du kintamieji yra nekoreliuoti, tai reiškia, kad nėra tiesinio ryšio tarp šių kintamųjų. Jei kintamieji yra nepriklausomi, tuomet kintamieji nepriklauso vienas nuo kito. Pavyzdžiui, žmogaus amžius ir tai ką jis valgo gali būti laikomi kaip nepriklausomi kintamieji. NKA algoritmas remiasi prielaida, kad kintamieji yra tiesinės kombinacijos nežinomų paslėptųjų kintamųjų. Taip pat daroma prielaida, kad šie latentiniai kintamieji yra tarpusavyje nesusiję, t. y., šie kintamieji nepriklauso nuo kitų kintamųjų ir todėl jie vadinami nepriklausomais stebimų duomenų komponentais.

2.6. Metodų tikslumo vertinimo metrikos

Mašininio mokymosi modelių kūrime svarbus veiksnys yra šių modelių tikslumas, todėl yra reikalingos funkcijos galinčios įvertinti modelių tikslumą. Paklaidos funkcijos atlieka šią funkciją, lygindamos modelių prognozuojamas reikšmes ir tikrąsias reikšmes. Priklausomai nuo sprendžiamo uždavinio yra pritaikomos skirtingos paklaidos funkcijos. Žemiau esančioje lentelėje pateikiamos regresinių modelių paklaidos funkcijos (žr. 2.3 lentelė).

2.3 lentelė. Regresinių modelių paklaidos funkcijos

Pavadinimas	Formulė
R^2 – determinacijos koeficientas (<i>angl. coefficient of determination</i>)	$R^2 = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$
R_{adj}^2 – pataisytas determinacijos koeficientas (<i>angl. adjusted coefficient of determination</i>)	$R_{adj}^2 = 1 - \left[\frac{(1 - R^2)(n - 1)}{n - k - 1} \right]$
MAE – vidutinė absoliutinė paklaida (<i>angl. mean absolute error</i>)	$MAE = \frac{1}{n} \sum_{i=1}^n y_i - \hat{y}_i $
MSE – vidutinė kvadratinė paklaida (<i>angl. mean square error</i>)	$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$
RMSE – vidutinės kvadratinės paklaidos šaknis (<i>angl. rooted mean square error</i>)	$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}}$
MPE – vidutinė procentinė paklaida (<i>angl. mean percentage error</i>)	$MPE = \frac{100\%}{n} \sum_{i=1}^n \frac{y_i - \hat{y}_i}{y_i}$
MAPE – vidutinė absoliuti procentinė paklaida (<i>angl. mean absolute percentage error</i>)	$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left \frac{y_i - \hat{y}_i}{y_i} \right $
MASE – vidutinė absoliutinė normuota paklaida (<i>angl. mean absolute scaled error</i>)	$MASE = \frac{1}{n} \sum_{i=1}^n \frac{ y_i - \hat{y}_i }{\frac{1}{n-1} \sum_{i=2}^n y_{i-1} - y_i }$

Klasifikavimo modeliuose yra panaudojamos kitos paklaidos funkcijos, kadangi jomis yra siekiama įvertinti būtent klasifikavimo modelių paklaidą. Toliau esančioje lentelėje pateikiamos klasifikavimo modelių paklaidos funkcijos (žr. 2.4 lentelė). Kiekviena iš šių paklaidos funkcijų įvertina vis kitoki modelių tikslumą. Vienos įvertina teisingai prognozuojamų reikšmių kiekį, kitos įvertina teisingai prognozuojamų teigiamų reikšmių kiekį. Pavyzdžiui, Matthews'o koreliacijos koeficientas laikomas labiau informatyviu nei kitos sumaišymo matricos metrikos, tokios kaip tikslumas ar F1 metrika. Apskaičiuojant šį koreliacijos koeficientą yra įvertinamas sumaišymo matricos balansas tarp atskirų šios matricos elementų [149]. Taip pat dažnai naudojama klasifikavimo metrika yra AUC – plotas po

ROC kreivė (angl. *area under curve*). Ši metrika, kaip ir kitos, parodo kaip tiksliai yra klasifikuojamos klasės. Didesnė AUC vertė parodo tai, kad geriau prognozuojama pirmą klasę, kai iš tiesų yra pirmą ir klasifikuojama antrą klasę, kai iš tiesų yra antrą. Kadangi ši metrika yra apskaičiuojama, kaip plotas po ROC kreivę, todėl toliau esančioje lentelėje šios metrikos skaičiavimo formulė nėra pateikiama.

2.4 lentelė. Klasifikavimo modelių paklaidos funkcijos

Pavadinimas	Formulė
ACC – Tikslumas (<i>angl. accuracy</i>)	$ACC = \frac{(TP + TN)}{(TP + FP + TN + FN)}$
ERR – Klaidų lygis (<i>angl. error rate</i>)	$ERR = \frac{(FP + FN)}{(TP + FP + TN + FN)}$
Jautrumas (<i>angl. sensitivity arba recall</i>)	$Sensitivity = \frac{TP}{TP + FN}$
Ypatumas (<i>angl. specificity</i>)	$Specificity = \frac{TN}{TN + FP}$
Tikslumas (<i>angl. precision</i>)	$Precision = \frac{TP}{TP + FP}$
F1 metrika (<i>angl. F-1 measure</i>)	$F_1 = \frac{2 * Sensitivity * Specificity}{Sensitivity + Specificity}$
MCC – (<i>angl. Matthew's correlation coefficient</i>)	$MCC = \frac{(TP * TN) - (FN * FP)}{\sqrt{(TP + FN) * (TN + FP) * (TP + FP) * (TN + FN)}}$
GM – geometrinis vidurkis (<i>angl. geometric mean</i>)	$GM = \sqrt{Specificity * Sensitivity}$
ROC kreivė (<i>angl. receiver operating characteristic</i>)	$ROC = \frac{\sqrt{Sensitivity^2 + Specificity^2}}{\sqrt{2}} [150]$

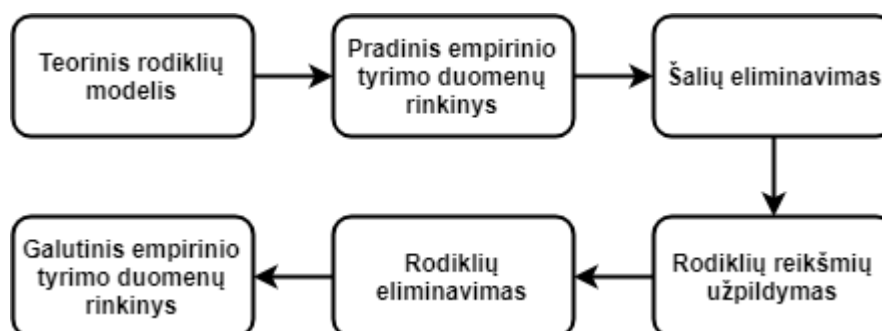
3. Empirinis tyrimas

3.1. Duomenys

Empiriniame šio darbo tyrime buvo naudojami įvairūs kiekybiniai ir kokybiniai duomenys, kurie buvo paremti 1.3 poskyryje apžvelgtu tyrimo modeliu. Kiekybiniams duomenims surinkti buvo naudojami trys pagrindiniai duomenų šaltiniai:

- **WorldBank** – pasaulio banko statistikos departamento duomenų bazė. Šioje duomenų bazėje pateikiama teminė daugelio pasaulio šalių statistinė informacija. Šis duomenų portalas atlieka duomenų mainus su Jungtinėmis tautomis, tarptautiniu valiutos fondu ir kitomis organizacijoms. Dėl šios priežasties šioje duomenų bazėje pateikiami savalaikiai ir tikslūs ekonominiai pasaulio šalių duomenys. Duomenys ir jų grafinis vizualizavimas šioje duomenų bazėje yra prieinamas laisvai.
- **Eurostat** – Europos sąjungos statistikos departamentas, pateikiantis kokybišką Europos ekonominių rodiklių informaciją. Šioje duomenų bazėje pateikiama ne tik Europos šalių, bet ir kaimyninių šalių ekonominių rodiklių informacija. Šios duomenų bazės rodikliai yra laisvai prieinami kiekvienam vartotojui.
- **TheGlobalEconomy** – pasaulio šalių ekonominių rodiklių duomenų bazė. Ši duomenų bazė yra tarp rekomenduojamų duomenų bazių, kurias rekomenduoja Amerikos Ekonomikos asociacijos. Šioje duomenų bazėje pateikiami daugiau nei 200 šalių duomenys, kurie yra surenkami iš anksčiau minėtos WorldBank duomenų bazės, Jungtinių tautų, UNESCO, Amerikos energetikos informacijos administracijos ir kitų duomenų bazių. Šios duomenų bazės duomenys yra laisvai prieinami, tačiau norint šiuos duomenis eksportuoti į „xls“ formatą tai yra apmokestinama už kiekvieną rodiklį reikšmę ar užsisakant mėnesinę duomenų paslaugą.

Pradiniame duomenų rinkinyje buvo analizuojamos 32 šalys ir daugiau nei 200 rodiklių. Po šių rodiklių analizės paaiškėjo, kad 3 šalių trūkstamų reikšmių skaičius sudaro didelę dalį visų reikšmių, todėl šios šalys buvo eliminuojamos iš tolimesnio tyrimo. Iš tolimesnio tyrimo buvo eliminuotos: Serbija, Bosnija ir Hercegovina bei Albanija. Po šios duomenų analizės buvo atsižvelgiama į rodiklių trūkstamas reikšmes ir šios trūkstamos reikšmės buvo užpildomos papildomų šaltinių reikšmėmis. Siekiant atlikti tokių reikšmių užpildymą, papildomas šaltinis galėjo būti tik toks, kurio metodika sutampa su pradinio šaltinio metodika. Paskutiniame duomenų paruošimo žingsnyje buvo atmesti visi kintamieji, kurių trūkstamos reikšmės negali būti užpildomos kitų šaltinių ar logiškais reikšmėmis.




3.1 pav. Empirinio tyrimo duomenų paruošimo schema

Didžiajai daliai tyrimo duomenų surinkti buvo naudojama tyrimo metu sukurta modeliavimo programa (žr. 3.2 pav.). Ši programa buvo sukurta panaudojant *R* programavimo kalbą. Programos saityno vartotojo sąsaja (angl. *web user interface*) buvo kuriama, naudojant *R shiny* paketą ir kitus papildomus paketus, leidžiančius kurti patogią vartotojo sąsają. Duomenims išgauti buvo naudojami paketai: *Worldbank* duomenims – *wbstats* ir *WDI*, *Eurostat* duomenims – *eurostat*.

3.2 pav. Tyrimo duomenų modeliavimo programos beta versijos saityno vartotojo sąsaja (angl. *web user interface*)

3.2. Tiesioginių užsienio investicijų kintamojo apžvalga


Atsižvelgiant į tyrimo temą, šiame skyrelyje pateikiama tyrime nagrinėjamų šalių tiesioginių užsienio investicijų apžvalga. Dėl didelio tyrime naudojamų šalių skaičiaus, jų vaizdavimas sklaidos diagrama yra komplikotas, todėl yra naudojamos stačiakampės diagramos (angl. *box plot*). Žemiau pateiktame paveiksle pateikiamos šalių stačiakampės diagramos (žr. 3.3 pav.). Šios diagramos leidžia nustatyti šalių vidutinį tiesioginių užsienio investicijų kiekį, jų pasiskirstymą ir išskirtines reikšmes. Remiantis pateiktu paveikslu galima pastebėti, kad didžiausias vidutinių investicijų kiekis 2000–2017 metų laikotarpiu buvo Nyderlanduose. Verta pastebėti ir tai, kad Nyderlandų tiesioginės užsienio investicijos turi vieną išskirtinę reikšmę – 2007 metais (734 mlrd. dolerių). Remiantis literatūros analize galima pastebėti, kad didžiausias investicijas nagrinėjamoje šalių imtyje turi Nyderlandai, kadangi ši šalis pasižymi aukštos kvalifikacijos darbuotojais, gera geografine padėtimi, palankiais verslo įstatymais. Iš tiriamos šalių imties vertinant tiesioginių užsienio investicijų kiekį taip pat galima išskirti Vokietiją ir Jungtinę Karalystę, kadangi šių šalių investicijos yra didžiausios po Nyderlandų. Vertinant šių šalių tiesiogines užsienio investicijas tarpusavyje galima pastebėti, kad Vokietijos TUI yra daug stabilesnės, kai tuo tarpu Jungtinės Karalystės TUI nėra stabilios ir turi didelį kitimą. Kitų tyrime naudojamų šalių tiesioginių užsienio investicijų kiekis yra santykinai mažas palyginus su šiomis šalimis. Pateiktame paveiksle (žr. 3.3 pav.) taip pat galima pastebėti ir tai, kad beveik visos šalys tam tikrame laikotarpyje pasižymi išskirtinėmis reikšmėmis. Dažniausiai šios išskirtinės reikšmės pastebimos prieš ekonominę krizę, kadangi nuo jos tiesioginių užsienio investicijų kiekis daugumoje šalių nėra pasiekęs aukščiausių reikšmių.



3.3 pav. Europos šalių tiesioginių užsienio investicijų stačiakampės diagramos

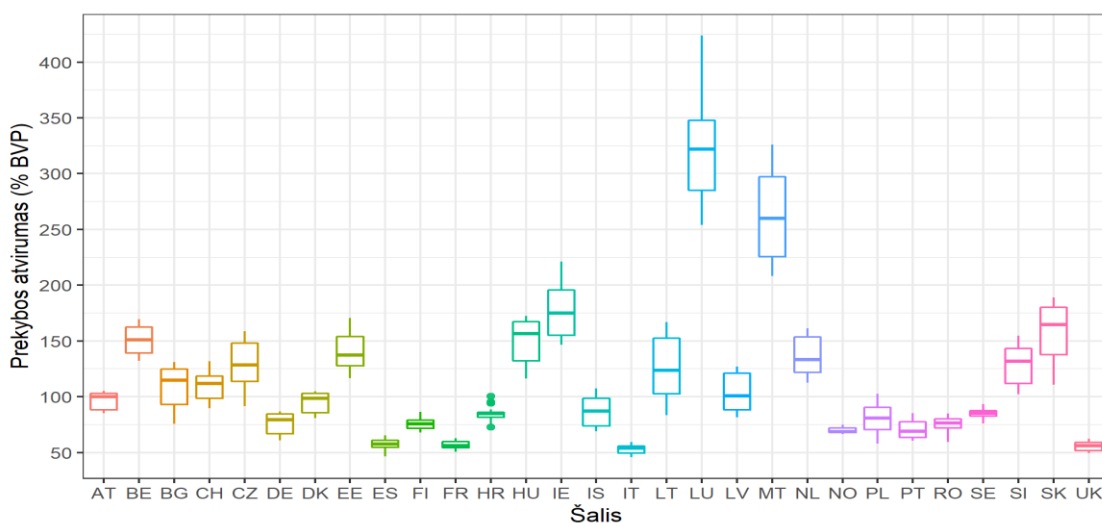
3.3. Išorinių kintamųjų apžvalga

Remiantis literatūros apžvalgos skyriuje sudarytu teoriniu veiksnių modeliu buvo surinkti išorinių kintamųjų duomenys. Atsižvelgiant į didelį skaičių išorinių kintamųjų šiame skyrelyje pateikiama tik dalies iš jų apžvalga. Vienas iš pagrindinių išorinių kintamųjų, kurį naudoja daugelis autorių, yra bendras vidaus produktas (BVP) ar BVP tenkantis vienam gyventojui. Vertinant tyrime nagrinėjamų šalių bendrą vidaus produktą tenkantį vienam gyventojui 2000–2017 metais galima pastebėti, kad didžiausią vidutinę jo reikšmę, šiame laikotarpyje, turi Liuksemburgas. Taip pat didelėmis BVP vienam gyventojui reikšmėmis pasižymi Norvegija, Šveicarija ir Danija. Remiantis toliau pateikiamomis šalių BVP vienam gyventojui stačiakampėmis diagramomis (žr. 3.4 pav.) galima pastebėti, kad didžiausią sklaidą turi anksčiau minėtos didžiausią BVP vienam gyventojui turinčios šalys. Taip pat galima pastebėti, kad Airija ir Islandija pasižymi keliomis išskirtinai didelėmis reikšmėmis. Tuo tarpu išskirtinai maža reikšmė pasižymi Ispanija, kurios mažiausia reikšmė buvo pastebėti tiriamo laikotarpio pradžioje t. y. 2000 metais.




3.4 pav. Europos šalių BVP tenkančių vienam gyventojui stačiakampės diagramos

Dažnai tiesioginių užsienio investicijų vertinime yra panaudojamas prekybos atvirumo rodiklis. Šis rodiklis dažniausiai yra apskaičiuojamas, kaip šalies importo ir eksporto sumos santykis su bendruoju šalies vidaus produktu. Vertinant šalių prekybos atvirumą 2000–2017 metų laikotarpyje yra pateikiamos šio rodiklio stačiakampės diagramos (žr. 3.5 pav.). Vertinant tyrime nagrinėjamų šalių prekybos atvirumą 2000–2007 metais galima pastebėti, kad didžiausią šio rodiklio vidutinę reikšmę turi Liuksemburgas, taip pat dideliu prekybos atvirumu pasižymi Malta. Be šių šalių kitos nagrinėjamos šalys nepasižymi dideliu prekybos atvirumu. Galima pastebėti, kad dalies šalių (Ispanija, Italija, Prancūzija ir kt.) prekybos atvirumas yra mažesnis nei 100 %. Taip pat remiantis stačiakampėmis diagramomis matoma, kad nė viena nagrinėjama šalis tiriamuoju laikotarpiu neturi nei išskirtinai didelių šio rodiklio reikšmių, nei išskirtinai mažų.



3.5 pav. Europos šalių prekybos atvirumo (% BVP) stačiakampės diagramos


Didelę reikšmę šalių investiciniam patrauklumui turi šalies nedarbo lygis, kuris parodo, kokia dalis šalies gyventojų neturi darbo. Vertinant šalių nedarbo lygį 2000–2017 metų laikotarpyje yra pateikiamos šio rodiklio stačiakampės diagramos (žr. 3.6 pav.). Atsižvelgiant į tyrime nagrinėjamų šalių nedarbo lygį 2000–2007 metais galima pastebėti, kad mažiausią šio rodiklio vidutinę reikšmę turi Islandija ir Norvegija. Remiantis tuo galima teigti, kad šiose šalyse yra mažiausias vidutinis nedarbo lygis. Remiantis stačiakampėmis diagramomis galima pastebėti ir tai, kad Ispanija pasižymi didžiausiu vidutiniu nedarbo lygiu nagrinėjamame laikotarpyje. Taip pat pastebima ir tai, kad Ispanija pasižymi ir didžiausia nedarbo lygio sklaida, o tai parodo, kad nedarbo lygis šioje šalyje pasižymi dideliu nestabilumu. Taip pat didelė nedarbo lygio rodiklio sklaida pasižymi Lenkija, tačiau vidutinis nedarbo lygis šioje šalyje palyginus su kitomis šalimis yra nedidelis. Stačiakampėse diagramose galima pastebėti, kad Liuksemburgas, Malta ir Rumunija turi išskirtinai mažų nedarbo lygio reikšmių nagrinėjamame laikotarpyje. Pavyzdžiui, Liuksemburgo išskirtinai maža nedarbo lygio reikšmė pastebima 2001 metais, kai nedarbo lygis šioje šalyje buvo tik 1,8 %.



3.6 pav. Europos šalių nedarbo lygio (%) stačiakampės diagramos


3.4. Klasterizavimo analizės rezultatai

Tyrimo metu, remiantis teoriniame modelyje išskirtais rodikliais, buvo atliekama klasterinė šalių analizė. Šios analizės tikslas – pagal tiesiogines užsienio investicijas lemiančius rodiklius atskirti šalių grupes. Šalys esančios viename klasteryje gali būti laikomos panašiomis pagal lemiančius veiksnius, o skirtingų klasterių šalys laikomos skirtingomis. Šalių klasterizavimas buvo atliekamas, remiantis vidutinėmis rodiklių reikšmėmis 2000–2017 metais. Šalių klasterizavimas remiantis dviem rodikliais gali būti atliekamas ir vizualiai, panaudojant sklaidos diagramas. Žemiau pateikiama tiesioginių užsienio investicijų ir BVP tenkančio vienam gyventojui sklaidos diagrama (žr. 3.7 pav.). Atsižvelgiant į tai, kad panaudojant tikrąsias rodiklių reikšmes šalys yra sudėtinga atskirti, naudojamos ir logaritminės rodiklių reikšmės. Remiantis sklaidos diagrama galima pastebėti, kad Nyderlandai išsiskiria pagal tiesiogines užsienio investicijas. Tuo tarpu pagal BVP tenkantį vienam gyventojui labiausiai pastebimas Liuksemburgo atsiskyrimas nuo kitų šalių. Taip pat galima pastebėti ir tai, kad Suomija, Danija, Islandija, Švedija ir Austrija sudaro naują klasterį, kadangi šių šalių tiesioginių užsienio investicijų ir BVP vienam gyventojui lygis yra panašus.




3.7 pav. TUI ir BVP sklaidos diagramos: a) naudojant tikrąsias reikšmes b) naudojant logaritmines reikšmes

Žemiau pateikiama tiesioginių užsienio investicijų ir šalies prekybos atvirumo sklaidos diagrama (žr. 3.8 pav.). Atsižvelgiant į tai, kad panaudojant tikrąsias rodiklių reikšmes šalis yra sudėtinga atskirti, yra naudojamos ir logaritminės rodiklių reikšmės. Remiantis sklaidos diagrama galima pastebėti, kad Nyderlandai išsiskiria pagal tiesiogines užsienio investicijas. Tuo tarpu pagal šalies prekybos atvirumą labiausiai pastebimas Liuksemburgo ir Maltos atsiskyrimas nuo kitų šalių. Taip pat galima pastebėti ir tai, kad Belgija ir Airija sudaro naują šalių klasterį, kadangi tiek jų tiesioginės užsienio investicijos, tiek prekybos atvirumas yra panašus. Taip pat iš šios sklaidos diagramos galima išskirti Jungtinės Karalystės, Prancūzijos, Ispanijos ir Italijos klasterį. Šiame klasteryje esančios šalys pasižymi mažu prekybos atvirumu ir didesnėmis nei vidutinėmis tiesioginėmis užsienio investicijomis.



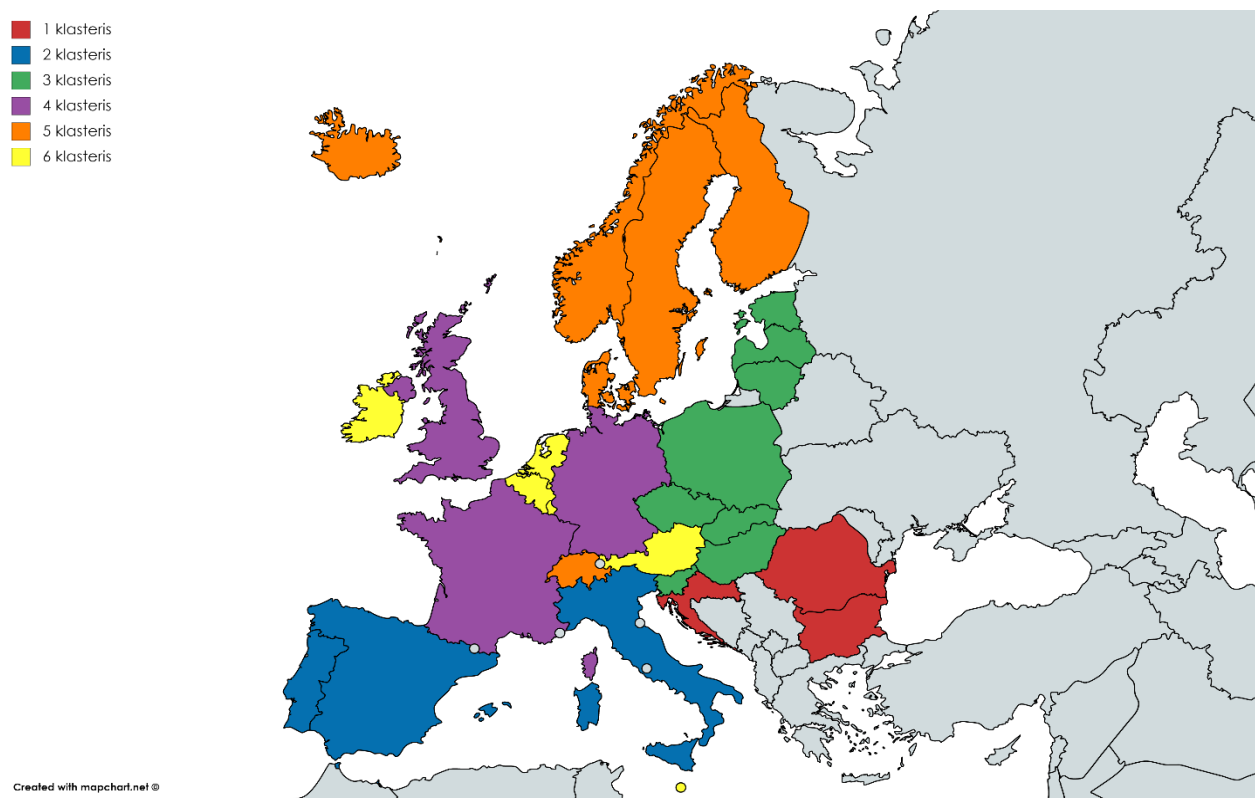
3.8 pav. TUI ir prekybos atvirumo (% BVP) sklaidos diagramos: a) naudojant tikrąsias reikšmes b) naudojant logaritmines reikšmes

Sklaidos diagramose negalima atvaizduoti daugiau nei trijų dimensijų duomenų, todėl klasterizavimo rezultatai remiantis visais tyrime naudojamais duomenimis negali būti atvaizduoti. Dėl šios priežasties klasterizavimo rezultatams pateikti vizualiai yra naudojamos dendogramos. Toliau pateikiami klasterizavimo pagal visus tyrime naudojamus išorinius rodiklius tyrimo rezultatai (žr. 3.9 pav.). Klasterizavimas buvo atliekamas hierarchiniais klasterizavimo metodais, panaudojant Euklido atstumo matą.



3.9 pav. Hierarchinio klasterizavimo rezultatai panaudojant visus rodiklius


Norint vizualiai atskirti klasterius ir interpretuoti rezultatus, šie klasterinės analizės rezultatai yra pateikiami žemėlapyje, kuriame skirtingomis spalvomis pateikiami atskiri klasteriai (žr. 3.10 pav.). Galima pastebėti, kad klasterizavimo rezultatai, remiantis visais išoriniais tiesiogines užsienio investicijas lemiančiais veiksniais, atskiria šalis pagal regionus. Pirmajam klasteriui yra priskiriamos: Kroatija, Bulgarija ir Rumunija. Antrajam klasteriui yra priskiriamos Pietų Europos šalys: Italija, Ispanija ir Portugalija. Verta pastebėti, kad Malta nors ir yra pietų Europos šalis, tačiau šiam klasteriui ji nėra priskiriama. Trečiajam klasteriui yra priskiriamos Baltijos regiono šalys ir Vengrija, Lenkija, Slovėnija, Slovakija ir Čekija. Verta pastebėti tai, kad remiantis hierarchinio klasterizavimo rezultatais šis klasteris galėtų būti padalinamas į du atskirus klasterius, kur vienam iš jų būtų priskiriamos tik Baltijos regiono šalys, o kitam klasteriui likusios Rytų Europos šalys. Ketvirtajam klasteriui yra priskiriamos: Jungtinė Karalystė, Vokietija ir Prancūzija. Penktajam klasteriui yra priskiriamos Šiaurės Europos šalys: Islandija, Norvegija, Suomija ir Danija. Taip pat verta pastebėti ir tai, kad šiam klasteriui yra priskiriama viena ne Šiaurės Europos šalis – Šveicarija. Paskutiniam klasteriui priskiriamos šalys negali būti įvardijamos, kaip tam tikro regiono šalys, kadangi šiam klasteriui yra priskiriamos: Belgija, Austrija, Nyderlandai, Airija, Liuksemburgas ir Malta. Remiantis hierarchinio klasterizavimo rezultatais Malta gali būti atskiriama į naują klasterį ir būti vertinama, kaip išskirtinė Europos šalis.



3.10 pav. Hierarchinio klasterizavimo panaudojant visus rodiklius rezultatų žemėlapis

Šalims klasterizuoti pagal tiesiogines užsienio investicijas šalyje lemiančius veiksnius buvo panaudojama ir pagrindinių komponentų analizė. Ši analizė leidžia sumažinti duomenų dimensijas ir pagreitina klasterizavimo procesą. Klasterizavimui pritaikant pagrindinių komponentų analizę buvo naudojamas toks pagrindinių komponentų skaičius, kad paaiškina dispersija būtų ne mažesnė nei 90 %. Žemiau pateikiami hierarchinio klasterizavimo rezultatai, kai yra naudojama pagrindinių

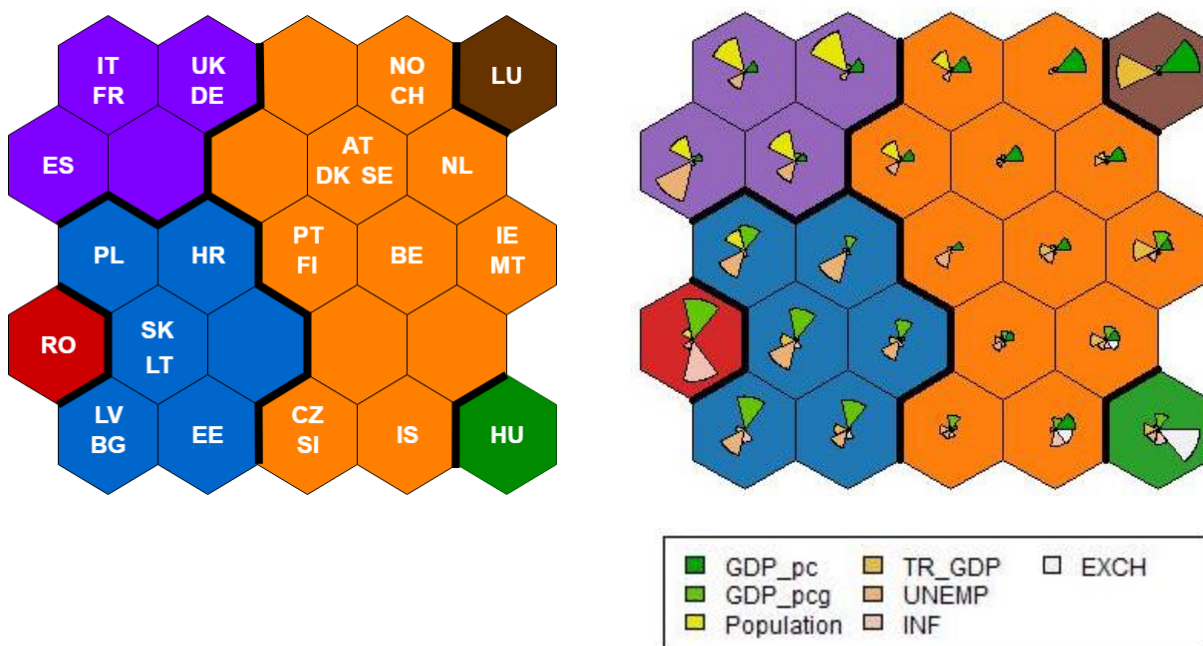
komponenčių analizė (žr. 3.11 pav.). Galima pastebėti, kad panaudojant keturiolika pagrindinių komponenčių klasterizavimo tyrimo rezultatai beveik nesiskiria nuo klasterizavimo rezultatų, kai yra naudojami visi išoriniai kintamieji. Šiuo atveju galima pastebėti, kad išskiriant 6 klasterius, Malta yra vertinama kaip išskirtinė šalis.



3.11 pav. Hierarchinio klasterizavimo rezultatai panaudojant pagrindines komponentes (k = 14)

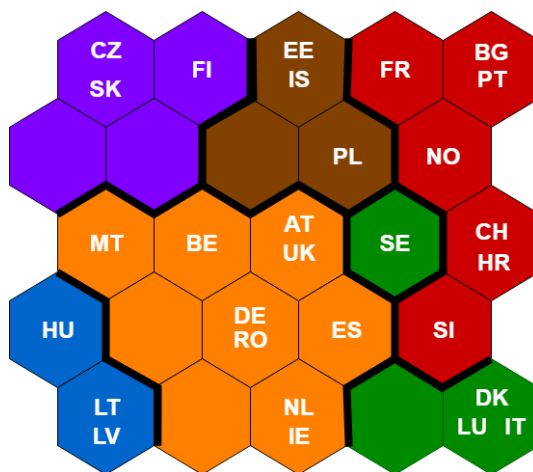
3.5. Saviorganizuojančių neuroninių tinklų rezultatai

Tyrimo metu šalia klasterinės analizės taip pat buvo pritaikomas ir saviorganizuojančių neuroninių tinklų metodas. Šis metodas leidžia didelės dimensijos duomenis atvaizduoti plokštumoje, todėl yra labai naudingas atskiriant šalis. Tyrimo metu, kadangi didelių dimensijų duomenys negali būti pateikiami, kaip žemėlapis, rodantis rodiklių reikšmes, buvo panaudojami pagrindiniai, kitų autorių nuomone, rodikliai lemiantys tiesiogines užsienio investicijas į šalį. Toliau pateiktame paveiksle galima pastebėti šalių atvaizdavimą plokštumoje, taip pat skirtingų rodiklių vizualizaciją atskirose saviorganizuojančio neuroninio tinklo celėse (žr. 3.12 pav.).



3.12 pav. Saviorganizuojančių neuroninių tinklų rezultatai panaudojant pagrindinius TUI rodiklius

Galima pastebėti, kad saviorganizuojančių dirbtinių neuroninių tinklų rezultatai rodo, kad pavyzdžiui dešinysis viršutinis kampas, kuriame yra Liuksemburgas pasižymi dideliu bendru vidaus produktu vienam gyventojui, taip pat dideliu prekybos atvirumu. Tuo tarpu pavyzdžiui kairysis viršutinis žemėlapių kampas pasižymi didele populiacija, o artėjant prie mėlynos srities žemėlapių celės pradeda pasižymėti ir didesniu nedarbo lygiu. Saviorganizuojantys dirbtiniai neuroniniai tinklai buvo pritaikyti ir panaudojant visus tyrime naudojamus rodiklius. Iš šio paveikslo galima pastebėti, kaip yra pasiskirstę šalys pagal šiuos rodiklius į atskirus klasterius. Iš paveikto paveikslo (žr. 3.13 pav.) matoma, kad pavyzdžiui, Lietuva ir Latvija yra priskiriamos vienai celei, todėl galima teigti, kad investicinį patrauklumą lemiantys rodikliai yra ypač panašūs šiose šalyse.



3.13 pav. Saviorganizuojančių neuroninių tinklų rezultatai panaudojant visus kintamuosius

3.6. Tiesioginių užsienio investicijų prognozavimo rezultatai

Prognozuojant tiesiogines užsienio investicijas buvo panaudojami skirtingos struktūros dirbtiniai neuroniniai tinklai: RNN, LSTM, GRU ir ELM. Tyrimo metu buvo ieškoma geriausių tinklų parametrų kiekvienai šaliai ir buvo atrenkamas geriausiai prognozuojantis dirbtinių neuroninių tinklų modelis (3.5.1 skyrelis). Geriausiai prognozuojančių modelių rezultatai buvo palyginti su dažniausiai mokslinėje literatūroje naudojamais tiesinės regresijos modeliais (3.5.2 skyrelis). Taip pat buvo palygintos skirtingos modelių konfigūracijos, įvertinant ar yra reikšmingas skirtumas tarp skirtingų modelių (3.5.3 skyrelis). Geriausiai prognozuojantys dirbtinių neuroninių tinklų modeliai buvo pritaikyti šalių tiesioginėms investicijoms prognozuoti 2018 metais (3.5.4 skyrelis).

3.6.1. Geriausiai tiesiogines užsienio investicijas prognozuojantys modeliai

Tyrimo metu buvo sukurti daugiau nei 125 tūkst. skirtingų RNN, LSTM ir GRU dirbtinių neuroninių tinklų modeliai ir daugiau nei 22 tūkst. ELM modeliai. RNN, LSTM ir GRU modeliai buvo sudaryti, esant skirtingiems neuronų skaičiams viename, dviejuose ar trijuose paslėptuose sluoksniuose. Naudojamas neuronų skaičius paslėptuose sluoksniuose buvo nuo 2 iki 10 (naudojamas žingsnis – 1). Taip pat buvo naudojamos skirtingos aktyvacijos funkcijos: logistinė, hiperbolinio tangento ir Gompertz'o. Modelių parametrai buvo derinami, remiantis keliais skirtingais atvejais:

6. Kiekvienai šaliai su visais tyrime naudojamais išoriniais kintamaisiais.
7. Kiekvienai šaliai su latentiniais kintamaisiais, gautais panaudojant pagrindines komponentes.
8. Kiekvienai šaliai su latentiniais kintamaisiais, gautais panaudojant nepriklausomas komponentes.

Pagrindinių komponentių skaičius buvo parenkamas, remiantis paaiškinama dispersija. Tyrime buvo naudojamas pagrindinių komponentių skaičius, paaiškinantis ne mažiau nei 90 % visos dispersijos. Tyrime taip pat buvo naudojamos 2, 3, 5 ir 10 nepriklausomos komponentės. Atsižvelgiant į tai, kad tyrime yra naudojamos trumpos laiko eilutės, buvo naudojamas kryžminis patikrinimas ateities reikšmėms. Laiko eilutės pradžia buvo naudojama modeliams mokytis, o tolimesnėms laiko eilutės reikšmės – patikrinti. Geriausi RNN modelių rezultatai yra pateikiami 2, 5 ir 8 priede. Geriausi LSTM modelių rezultatai yra pateikiami 3, 6 ir 9 priede. Geriausi GRU modelių rezultatai yra pateikiami 4, 7 ir 10 priede.

ELM modeliai buvo sudaryti esant skirtingiems neuronų skaičiams viename, dviejuose ar trijuose paslėptuose sluoksniuose. Naudojamas neuronų skaičius paslėptuose sluoksniuose buvo nuo 2 iki 10 (naudojamas žingsnis – 1). Trijų sluoksnių ELM modelių atveju viduriniame sluoksnyje neuronų skaičius buvo keičiamas nepriklausomai nuo pirmojo paslėptoje sluoksnio neuronų skaičiaus. Neuronų skaičius viduriniame sluoksnyje buvo nuo 2 iki 10 (naudojamas žingsnis – 1). ELM modeliuose išvesties sluoksnio svoriui įvertinti buvo naudojami skirtingi metodai: *Lasso* (angl. *Least Absolute Shrinkage and Selection Operator*), *Ridge*, žingsninė regresija (angl. *stepwise*) ir tiesinė regresija (angl. *linear regression*). Taip pat laiko eilutėms modeliuoti buvo naudojami ir modeliai be išorinių kintamųjų, siekiant įvertinti ar išoriniai kintamieji didina prognozavimo modelių tikslumą. Geriausi ELM modelių rezultatai yra pateikiami 11 priede.

Apibendrinant visų tyrime naudotų modelių rezultatus toliau esančioje lentelėje (žr. 3.1 lentelė) pateikiami geriausi šalių tiesioginių investicijų prognozavimo modeliai, remiantis MAPE paklaidos funkcija.

3.1 lentelė. Kiekvienos tyrime naudotos šalies geriausių modelių, remiantis MAPE metrika charakteristikos

Šalis	Metodas	Struktūra	DM	DM sk.	Akt. Funk.	RMSE	NRMSE	MAE	MPE	MAPE	MASE
AT	GRU	10	PCA	6	Tanh	459.77	140.60	383.04	60.75	67.16	0.67
BE	ELM	9;2;9	lm	-	-	15.57	50.10	11.64	26.15	40.07	0.43
BG	ELM	8;3;8	step	-	-	0.37	65.40	0.31	-8.80	18.22	0.34
CH	ELM	4;7;4	lasso	-	-	44.04	85.00	30.47	59.78	63.63	0.47
CZ	ELM	9;8;9	step	-	-	2.12	60.70	1.39	5.98	15.10	0.30
DE	ELM	6;4;6	lm	-	-	10.06	52.10	6.79	-6.61	12.39	0.31
DK	ELM	7;2;7	lm	-	-	6.73	69.70	4.72	64.05	64.05	0.56
EE	GRU	4	ICA	2	Gompertz	0.71	47.60	0.52	10.11	17.04	0.38
ES	ELM	3;5;3	lm	-	-	5.57	49.10	4.68	-13.67	15.42	0.27
FI	GRU	8;8;8	PCA	6	Tanh	163.77	258.80	154.33	85.74	85.74	1.93
FR	ELM	7;3;7	lm	-	-	6.23	39.80	4.91	-21.64	21.64	0.29
HR	GRU	9	ICA	2	Gompertz	2.26	109.90	1.45	17.09	17.23	0.60
HU	ELM	5;2;5	step	-	-	20.28	66.60	13.94	-40.97	66.35	0.45
IE	ELM	9;7;9	lasso	-	-	37.69	47.80	22.60	3.65	19.39	0.26
IT	ELM	8;6;8	lm	-	-	5.22	63.90	4.14	-46.98	59.47	0.52
LT	GRU	8;8;8	ICA	2	Gompertz	0.09	15.70	0.08	-7.95	9.98	0.08
LU	ELM	2;9;2	step	-	-	10.94	20.10	7.15	-10.09	30.78	0.17
LV	ELM	10;10;10	step	-	-	0.11	33.80	0.09	-7.56	10.09	0.41
NL	ELM	4;4	step	-	-	74.02	90.80	59.15	-27.53	30.35	0.62
NO	ELM	6;2;6	step	-	-	13.26	80.10	9.71	-38.33	68.98	0.63
PL	ELM	2;5;2	lm	-	-	2.51	31.40	2.01	-2.47	16.55	0.24
PT	ELM	10;10;10	step	-	-	6.73	95.60	4.24	1.27	37.06	0.54
RO	ELM	4;2;4	step	-	-	0.82	68.10	0.49	-7.90	9.32	0.61
SE	ELM	4;4	step	-	-	4.52	64.60	3.22	-0.74	49.50	0.42
SI	GRU	4	ICA	10	Logistic	1.15	81.00	0.60	12.46	17.97	0.28
SK	RNN	10;10;10	PCA	6	Tanh	14.06	133.10	10.70	47.55	47.55	0.57
UK	ELM	9;9;9	lm	-	-	32.12	33.40	16.45	6.05	9.80	0.27
MT	RNN	3;3;3	PCA	7	Tanh	118.91	90.50	62.69	36.40	36.40	0.59
IS	RNN	3	No	-	Gompertz	0.99	23.80	0.87	11.13	19.61	0.25

Remiantis aukščiau pateikta lentelė (žr. 3.1 lentelė) galima pastebėti, kad dažnai geriausių prognozavimo rezultatus parodė ELM modeliai. Nei vienas ELM modelis su vienu paslėptuoju sluoksniu nepateikė geriausių rezultatų. Taip pat verta pastebėti ir tai, kad tik prognozuojant Islandijos tiesiogines užsienio investicijas geriausių prognozavimo rezultatus parodė modeliai, kuriuose yra panaudojami visi kintamieji, o ne pagrindinės ar nepriklausomos komponentės. Visais kitais atvejais pagrindinės ar nepriklausomos komponentės pateikia geresnius prognozavimo rezultatus, todėl šių dimensijų mažinimo metodų panaudojimas tyrime pasitvirtino. Mažiausia vidutine absoliutine procentine paklaida (9,32 %) pasižymi Rumunijos tiesioginių užsienio investicijų modelis. Šis modelis – trijų paslėptųjų sluoksnių ELM modelis, kurio išvesties sluoksnių svoriams nustatyti yra naudojama žingsninė (angl. *stepwise*) regresija.

3.6.2. Geriausiai tiesiogines užsienio investicijas prognozuojančių modelių palyginimas

Ekonomikos srities mokslinėje literatūroje mokslininkai ieškodami ryšio tarp tiesiogines užsienio investicijas šalyje lemiančių rodiklių ir TUI dažniausiai naudoja paprastus tiesinės regresijos modelius. Tiesinės regresijos modeliai yra tinkami ne visuomet, todėl norint prognozuoti tiesiogines užsienio investicijas yra reikalingi sudėtingesni modeliai. Tuo tarpu laiko eilučių prognozavimo uždaviniuose modeliai dažnai yra lyginami su naiviu prognozavimo metodu. Šis laiko eilučių prognozavimo metodas kiekviename vėlesniame laikotarpyje prognozuoja praėjusio laikotarpio reikšmę. Teigiama, kad jei sukurtas modelis negali prognozuoti tiksliau, nei modelis, kartojantis paskutinę reikšmę, toks modelis negali būti naudojamas realioms uždaviniais spręsti. Toliau pateiktoje lentelėje (žr. 3.2 lentelė) pateikiamas tyrimo metu gautų geriausių prognozavimo modelių palyginimas su tiesinės regresijos ir „Naive“ modeliais.

3.2 lentelė. Geriausiai prognozuojančių dirbtinių neuroninių tinklų modelių palyginimas su tiesinės regresijos ir „Naive“ modeliais, remiantis MAPE metrika

Šalis	Dirbtinių neuroninių tinklų modeliai						Tiesinės regresijos modeliai	Naive modeliai
	Metodas	Struktūra	DM	DM sk.	Akt. Funk	MAPE	MAPE	MAPE
AT	GRU	10	PCA	6	Tanh	67,16	1267,71	331,88
BE	ELM	9;2;9	lm	-	-	40,07	274,31	74,53
BG	ELM	8;3;8	step	-	-	18,22	397,11	54,54
CH	ELM	4;7;4	lasso	-	-	63,63	124,77	163,10
CZ	ELM	9;8;9	step	-	-	15,10	149,46	124,34
DE	ELM	6;4;6	lm	-	-	12,39	104,54	78,48
DK	ELM	7;2;7	lm	-	-	64,05	345,57	731,38
EE	GRU	4	ICA	2	Gompertz	17,04	166,91	156,79
ES	ELM	3;5;3	lm	-	-	15,42	123,59	44,03
FI	GRU	8;8;8	PCA	6	Tanh	85,74	217,51	151,26
FR	ELM	7;3;7	lm	-	-	21,64	155,54	135,02
HR	GRU	9	ICA	2	Gompertz	17,23	822,38	649,76
HU	ELM	5;2;5	step	-	-	66,35	346,78	238,11
IE	ELM	9;7;9	lasso	-	-	19,39	105,28	80,22
IT	ELM	8;6;8	lm	-	-	59,47	260,67	43,71
LT	GRU	8;8;8	ICA	2	Gompertz	9,98	83,56	27,45
LU	ELM	2;9;2	step	-	-	30,78	333,11	204,62
LV	ELM	10;10;10	step	-	-	10,09	246,51	69,08
NL	ELM	4;4	step	-	-	30,35	250,56	63,35
NO	ELM	6;2;6	step	-	-	68,98	569,19	604,09
PL	ELM	2;5;2	lm	-	-	16,55	62,12	241,27
PT	ELM	10;10;10	step	-	-	37,06	173,69	155,12
RO	ELM	4;2;4	step	-	-	9,32	70,42	15,65

SE	ELM	4;4	step	-	-	49,50	591,38	136,97
SI	GRU	4	ICA	10	Logistic	17,97	126,72	55,14
SK	RNN	10;10;10	PCA	6	Tanh	47,55	149,13	161,85
UK	ELM	9;9;9	lm	-	-	9,80	157,28	33,63
MT	RNN	3;3;3	PCA	7	Tanh	36,40	1687,81	226,21
IS	RNN	3	No	-	Gompertz	19,61	200,26	99,13

Atsižvelgiant į tyrimo metu gautus rezultatus, kurie yra pateikiami 3.2 lentelėje, galima pastebėti, kad beveik visais atvejais dirbtinių neuroninių tinklų prognozavimo modeliai pateikia tikslesnius prognozavimo rezultatus, lyginant su tiesinės regresijos ir „Naive“ modeliais. Išskirtinis atvejis pastebimas Italijos tiesioginių užsienio investicijų prognozavime, kadangi Italijos tiesiogines užsienio investicijas geriausiai prognozuoja „Naive“ modelis. Remiantis tokiais rezultatais galima teigti, kad Italijos tiesioginių užsienio investicijų prognozavime nėra prasminga naudoti sudėtingus dirbtinių neuroninių tinklų modelius.

3.6.3. Skirtingų neuroninių tinklų konfigūracijų palyginimas

Skirtingų modelių ar modelių su skirtingais naudojamais parametrais statistinis palyginimas leidžia įvertinti ar sudėtingesnių modelių prognozavimo rezultatai yra tikslesni nei paprastesnių modelių. Remiantis palyginimo ir įvertinimo rezultatais galima parinkti geriausius modelius, o tai leidžia sutaupyti kompiuterio atmintį ar skaičiavimo laiką. Šiame skyrelyje pateikiamas skirtingų modelių statistinis palyginimas. Siekiant palyginti ar yra statistiškai reikšmingas skirtumas tarp skirtingų neuroninių tinklų modelių rezultatų buvo atliekama dispersinė analizė (angl. *analysis of variance* (ANOVA)). Modelių rezultatai, kurie netenkina ANOVA prielaidą, buvo tikrinami remiantis neparametriniais kriterijais. Atliekant vidurkių palyginimas tarp: RNN, LSTM ir GRU metodų, MAPE metrikos tikslumo, buvo pastebėta, kad Velčo heteroskedastiškumo Fišerio kriterijus pateikia rezultatus, kad tarp imčių dispersijų yra statistiškai reikšmingas skirtumas (statistikos vertė 1323,48, p vertė <0,05). Tokia pati išvada buvo gauta ir panaudojant normalumo nebuvimui atsparesnį Fligner-Killeen'o kriterijų (Chi statistika 1979,3, p < 0,05). Išanalizavus gautus rezultatus buvo pastebėta, kad naudojami duomenys netenkina ANOVA prielaidų, todėl buvo naudojami neparametriniai vidurkių palyginimo metodai. Kruskal-Wallis kriterijaus rezultatai parodė, kad Chi statistika yra 1945,3, p vertė yra mažesnė nei 0,05. Šie rezultatai parodo tai, kad yra statistiškai reikšmingas skirtumas tarp skirtingų dirbtinių neuroninių tinklų modelių. Siekiant patikrinti tarp kurių dirbtinių neuroninių tinklų tipų yra statistiškai reikšmingas skirtumas buvo naudojamas porinis Mano-Vitnio kriterijus. Šio kriterijaus rezultatai parodė tai, kad egzistuoja statistiškai reikšmingas skirtumas tarp kiekvienos iš porų. Verta pastebėti ir tai, kad atsižvelgiant į vidutinę MAPE reikšmę ir apžvelgtą statistiškai reikšmingą skirtumą geriausių tikslumą pateikia GRU modeliai. Atliekant vidurkių palyginimas tarp skirtingų duomenų dimensijų mažinimo metodų, MAPE metrikos tikslumo, buvo pastebėta, kad Velčo heteroskedastiškumo Fišerio kriterijaus rezultatai rodo, kad tarp imčių dispersijų nėra statistiškai reikšmingo skirtumo (statistikos vertė 0,274, p = 0,760). Tokia pati išvada buvo gauta ir panaudojant normalumo nebuvimui atsparesnį Fligner-Killeen'o kriterijų (Chi statistika 0,561, p = 0,755). Kruskal-Wallis kriterijaus rezultatai parodė, kad Chi statistika yra 2,264, o p reikšmė yra 0,323. Šie rezultatai parodo tai, kad nėra statistiškai reikšmingo skirtumo tarp skirtingų dimensijų mažinimo metodų. Atliekant vidurkių palyginimas tarp skirtingo dirbtinių neuroninių tinklų paslėptųjų sluoksnio skaičiaus, MAPE metrikos tikslumo, buvo pastebėta, kad Velčo heteroskedastiškumo Fišerio kriterijaus rezultatai rodo, kad tarp imčių yra statistiškai reikšmingas skirtumas (statistikos vertė 26,53, p vertė <0,05). Tą patį patvirtina ir Fligner-Killeen'o kriterijus (Chi statistika 709,16, p < 0,05). Kruskal-Wallis kriterijaus rezultatai parodė, kad Chi statistika yra 63,87,

p vertė yra mažesnė nei 0,05. Šie rezultatai parodo tai, kad yra statistiškai reikšmingas skirtumas tarp skirtingų dirbtinių neuroninių tinklų modelių. Siekiant patikrinti tarp kurių dirbtinių neuroninių tinklų sluoksnių skaičiaus yra statistiškai reikšmingas skirtumas buvo naudojamas porinis Mano-Vitnio kriterijus. Šio kriterijaus rezultatai parodė tai, kad egzistuoja statistiškai reikšmingas skirtumas tarp kiekvienos iš porų. Atliekant vidurkių palyginimas tarp skirtingų aktyvacijos funkcijų, MAPE metrikos tikslumo, buvo pastebėta, kad Velčo heteroskedastiškumo Fišerio kriterijus pateikia rezultatus, kad tarp imčių yra statistiškai reikšmingas skirtumas (statistikos vertė 686,27, p vertė <0,05), šią išvadą patvirtina ir Fligner-Killeen'o kriterijus (Chi statistika 11,383, p < 0,05). Kruskal-Wallis kriterijaus rezultatai parodė, kad Chi statistika yra 2118,7, p vertė yra mažesnė nei 0,05. Šie rezultatai parodo tai, kad yra statistiškai reikšmingas skirtumas tarp skirtingų aktyvacijos funkcijų. Siekiant patikrinti tarp kurių aktyvacijos funkcijų yra statistiškai reikšmingas skirtumas buvo naudojamas porinis Mano-Vitnio kriterijus. Šio kriterijaus rezultatai parodė tai, kad egzistuoja statistiškai reikšmingas skirtumas tarp hiperbolinio tangento aktyvacijos funkcijos ir Gompertz'o, logistinės aktyvacijos funkcijų. Tačiau rezultatai parodė, kad reikšmingas skirtumas tarp Gompertz'o ir logistinės aktyvacijos funkcijos nėra pastebimas. Geriausias rezultatus pateikia Gompertz'o ir logistinės aktyvacijos funkcijos, tuo tarpu naudojant hiperbolinio tangento funkciją yra gaunami blogiausi rezultatai. Atliekant vidurkių palyginimas tarp skirtingų mokymosi koeficientų (angl. *learning rate*), MAPE metrikos tikslumo, buvo pastebėta, kad Velčo heteroskedastiškumo Fišerio kriterijus pateikia rezultatus, kad tarp imčių yra statistiškai reikšmingas skirtumas (statistikos vertė 5,031, p vertė <0,05). Tokia pati išvada buvo gauta ir panaudojant normalumo nebuvimui atsparesnį Fligner-Killeen'o kriterijų (Chi statistika 113,14, p < 0,05). Išanalizavus gautus rezultatus buvo pastebėta, kad naudojami duomenys netenkina ANOVA prielaidų, todėl buvo naudojami neparimetriniai vidurkių palyginimo metodai. Kruskal-Wallis kriterijaus rezultatai parodė, kad Chi statistika yra 3,80, p vertė yra 0,150. Šie rezultatai parodo tai, kad nėra statistiškai reikšmingo skirtumo tarp skirtingų mokymosi koeficientų nėra. Apibendrinant gautus rezultatus galima teigti, kad geriausias dirbtinių neuroninių tinklų tipas tiesioginėms užsienio investicijoms prognozuoti yra sulaikomojo sluoksnio neuroniniai tinklai (GRU). Vertinant paslėptųjų sluoksnių skaičių galima teigti, kad geriausi rezultatai yra gaunami tada, kai yra naudojamas didesnis paslėptųjų sluoksnių skaičius. Siekiant parinkti tinkamą aktyvacijos funkciją buvo pastebėta, kad geriausias rezultatus pateikia Gompertz'o ir logistinė aktyvacijos funkcija. Atsižvelgiant į tai, kad šios funkcijos yra panašios tokio rezultato ir buvo tikimasi tyrimo pradžioje. Aptariant mokymosi koeficiento (angl. *learning rate*) reikšmę buvo pastebėta, kad reikšmingo skirtumo tarp šių reikšmių nėra, todėl dirbtinių neuroninių tinklų kūrimo metu galima naudoti ir didesnę šio parametro reikšmę taip sumažinant modelių kūrimo laiką ir taupant kompiuterio atmintį. Taip pat buvo pastebėta, kad nėra pastebimas statistiškai reikšmingas skirtumas tarp naudojamų duomenų dimensijų mažinimo metodų, todėl galima teigti, kad šiame prognozavime galima panaudoti pagrindines komponentes arba nepriklausomas komponentes. Šių metodų panaudojimas taip pat leidžia sutaupyti laiko ir atminties, kadangi yra naudojamas daug mažesnis kintamųjų skaičius.

ELM modeliai taip pat buvo įvertinti ar yra reikšmingas skirtumas tarp su skirtingais parametrais kuriamų modelių. Atliekant vidurkių palyginimas tarp skirtingo dirbtinių neuroninių tinklų paslėptųjų sluoksnio skaičiaus, MAPE metrikos tikslumo, buvo pastebėta, kad Velčo heteroskedastiškumo Fišerio kriterijaus rezultatai rodo, kad tarp imčių dispersijų yra statistiškai reikšmingas skirtumas (statistikos vertė 6,584, p vertė <0,05). Tokia pati išvada buvo gauta ir naudojant Fligner-Killeen'o kriterijų (Chi statistika 53,427, p < 0,05). Išanalizavus gautus rezultatus buvo pastebėta, kad naudojami duomenys netenkina ANOVA prielaidų, todėl buvo naudojami neparimetriniai vidurkių

palyginimo metodai. Kruskal-Wallis kriterijaus rezultatai parodė, kad Chi statistika yra 32,271, p vertė yra mažesnė nei 0,05. Šie rezultatai parodo tai, kad yra statistiškai reikšmingas skirtumas tarp skirtingų dirbtinių neuroninių tinklų modelių. Siekiant patikrinti tarp kurių dirbtinių neuroninių tinklų sluoksnio sk. yra statistiškai reikšmingas skirtumas buvo naudojamas porinis Mano-Vitnio kriterijus. Šio kriterijaus rezultatai parodė tai, kad egzistuoja statistiškai reikšmingas skirtumas tarp kiekvienos iš porų, tačiau tarp 1 ir 2 sluoksnių bei 2 ir 3 sluoksnių kriterijaus p reikšmė yra 0,047. Atliekant vidurkių palyginimas tarp skirtingų ELM išvesties sluoksnio svorių nustatymo metodų, MAPE metrikos tikslumo, buvo pastebėta, kad Velčo heteroskedastiškumo Fišerio kriterijaus rezultatai rodo, kad tarp imčių yra statistiškai reikšmingas skirtumas (statistikos vertė 45,600, p vertė <0,05). Tokia pati išvada buvo gauta ir panaudojant Fligner-Killeen'o kriterijų (Chi statistika 1833,9, p < 0,05). Išanalizavus gautus rezultatus buvo pastebėta, kad naudojami duomenys netenkina ANOVA prielaidų, todėl buvo naudojami nparametriniai vidurkių palyginimo metodai. Kruskal-Wallis kriterijaus rezultatai parodė, kad Chi statistika yra 859,65, p vertė yra mažesnė nei 0,05. Šie rezultatai parodo tai, kad yra statistiškai reikšmingas skirtumas tarp skirtingų dirbtinių neuroninių tinklų modelių. Siekiant patikrinti tarp kurių dirbtinių neuroninių tinklų sluoksnio sk. yra statistiškai reikšmingas skirtumas buvo naudojamas porinis Mano-Vitnio kriterijus. Šio kriterijaus rezultatai parodė tai, kad egzistuoja statistiškai reikšmingas skirtumas tarp kiekvienos iš porų, išskyrus *Lasso* ir *Ridge* tipus, kadangi tarp šių tipų statistiškai reikšmingas skirtumas nebuvo pastebėtas. Apibendrinant ELM modelius buvo pastebėta, kad didesnis paslėptųjų sluoksnių skaičius padidina modelio tikslumą (vertinant pagal MAPE metriką). Atsižvelgiant į skirtingus išvesties sluoksnio svorių nustatymo metodus rezultatai parodė, kad geriausi rezultatai yra gaunami panaudojant *Lasso* ir *Ridge* tipus, tačiau tarp šių tipų statistiškai reikšmingas skirtumas nebuvo pastebėtas.

3.6.4. Tiesioginių užsienio investicijų 2018 metais prognozavimas

Tiksliausiai TUI prognozuojantys dirbtinių neuroninių tinklų modeliai buvo panaudoti 2018 metų tiesioginėms užsienio investicijoms prognozuoti. Apibendrinti modelių rezultatai pateikiami 3.6 lentelėje. Tiesioginės užsienio investicijos 2000–2017 metais ir prognozuojamos TUI 2018 metais vizualiai pateikiamos 12 priede.

3.3 lentelė. Tiesioginės užsienio investicijos 2017 metais ir prognozuojamos geriausiai modeliais 2018 TUI


Šalis	TUI 2017 metais (mlrd.)	TUI 2018 metais (mlrd.)	Pokytis	Tendencija
AT	15.61	10.34	-51 %	TUI mažėja
BE	-39.48	-17.10	131 %	TUI didėja
BG	2.18	2.41	10 %	TUI didėja
CH	37.86	29.97	-26 %	TUI mažėja
CZ	9.21	3.88	-137 %	TUI mažėja
DE	77.98	51.86	-50 %	TUI mažėja
DK	2.36	1.20	-97 %	TUI mažėja
EE	1.56	1.47	-6 %	TUI mažėja
ES	6.2	27.79	78 %	TUI didėja
FI	14.2	13.70	-4 %	TUI mažėja
FR	47.34	43.39	-9 %	TUI mažėja
HR	2.04	0.97	-110 %	TUI mažėja
HU	-13.48	15.10	189 %	TUI didėja
IE	-3.44	-5.63	-39 %	TUI didėja
IS	-7.02	-1.84	282 %	TUI didėja
IT	9.24	15.03	39 %	TUI didėja
LT	1.19	1.25	5 %	TUI didėja
LU	6.62	21.98	70 %	TUI didėja
LV	1.14	0.86	-33 %	TUI mažėja

MT	3.46	3.54	2 %	TUI didėja
NL	316.54	317.11	0 %	TUI didėja
NO	1.64	2.15	24 %	TUI didėja
PL	10.67	12.17	12 %	TUI didėja
PT	10.02	12.71	21 %	TUI didėja
RO	5.95	7.15	17 %	TUI didėja
SE	31.53	12.16	-159 %	TUI mažėja
SI	1.08	1.15	6 %	TUI didėja
SK	5.92	3.40	-74 %	TUI mažėja
UK	64.69	31.86	-103 %	TUI mažėja

Iš šios lentelės galima pastebėti, kad 13-oje iš 29 tyrime naudotų šalių prognozuojamas tiesioginių užsienio investicijų mažėjimas, lyginant su 2017 metais. Likusiose 16-oje šalių, remiantis geriausiai prognozavimo modeliais, prognozuojamas TUI didėjimas, lyginant su 2017 metais. Tiesioginių užsienio investicijų didėjimo ar mažėjimo žemėlapis pateikiamas 13 priede. Didžiausias TUI didėjimas (įvertinant procentinį TUI pokytį) yra numatomas Islandijoje – 282 %. Nors toks TUI didėjimas atrodo ypač didelis, tačiau, remiantis TUI apžvalga, galima pastebėti tai, kad 2017 metais Islandijos TUI nukrito 323 %, lyginant su 2016 metais. Atsižvelgiant į tai, galima teigti, kad Islandijos TUI prognozuojamais (2018) metais beveik turėtų siekti 2016 metų TUI lygį. Tuo tarpu didžiausias TUI mažėjimas (įvertinant procentinį TUI pokytį) yra numatomas Suomijoje. Verta pastebėti ir tai, kad didžiausias TUI turinčioje šalyje – Nyderlanduose, TUI didėjimas sieks tik 0,18 %.

3.7. Tiesioginių užsienio investicijų klasifikavimo rezultatai


Tiesioginės užsienio investicijos gali būti prognozuojamas ne tik regresiniais neuroninių tinklų modeliais, kai prognozuojamas yra investicijų kiekis vėlesniame periode. Gali būti prognozuojama ir TUI tendencija (didėjimas ar mažėjimas). Šiuo atveju TUI prognozuoti yra panaudojami įvairūs klasifikavimo metodai, kurie leidžia prognozuoti TUI didėjimą arba mažėjimą. Siekiant įgyvendinti TUI duomenų klasifikavimą, turimos trumpos šalių laiko eilutės buvo sujungtos į vieną duomenų rinkinį, kuriame nebuvo atsižvelgiama į laiko kintamąjį. Klasifikavimo uždaviniui spręsti buvo pasirinkta *Python* programavimo kalba su *Keras* paketu. *Keras* paketo skaičiavimai buvo atliekami *TensorFlow* pakete. Šie paketai tyrime buvo pasirinkti dėl to, kad šiuo metu tai yra laikomi galingiausi mašininio mokymosi paketai. Žemiau pateiktame paveiksle (žr. 3.14 pav.) pateikiamas skirtingų mašininio mokymosi paketų palyginimas.



3.14 pav. Skirtingų giluminio mokymosi karkasų efektyvumo įvertinimas 2018 metais³

³ Šaltinis: <https://keras.io/why-use-keras/>

Duomenų klasifikavimo uždavinio sprendimo metu, skirtingai nei rekurentinių neuroninių tinklų atveju, galima išsiaiškinti, kuris rodiklis turi didžiausią reikšmę prognozavimo rezultatui. Pradinių duomenų klasifikavimas siekiant išsiaiškinti reikšmingiausius rodiklius buvo atliekamas panaudojant *sklearn.ensemble.ExtraTreesClassifier*. Naudojant šį metodą buvo naudojamas vienas tūkstantis sprendimų medžių. Atlikus duomenų klasifikavimą ir išskyrus didžiausią reikšmę turinčius rodiklius, buvo pastebėta, kad didžiausią reikšmę TUI didėjimui, įvertinant klasifikavimą, turi infliacijos lygis šalyje, eksporto didėjimo tempas, nuosavo kapitalo pelningumo rodiklis ir kt. Dvidešimt didžiausių reikšmę prognozavimo rezultatams turinčių rodiklių yra pateikiama toliau esančiame paveiksle (žr. 3.15 pav.). Rodiklių santrumpų paaiškinimas pateikiamas 1 priede. Po šio rodiklių išskyrimo buvo atliekamas ir paties klasifikavimo uždavinio sprendimas, klasifikuojant TUI tendenciją. Šiam tikslui, kaip buvo minėta anksčiau, buvo naudojami dirbtiniai neuroniniai tinklai iš *Keras* paketo. Sprendimų medžių klasifikavimo metodu išskirti rodikliai taip pat buvo panaudojami tolimesniame tyrime, tikrinant ar mažesnis skaičius rodiklių gali pateikti tokius pačius rezultatus, kaip ir panaudojant visus rodiklius. Klasifikavimo tyrimo rezultatai parodė (didžiausias tikslumas 83 proc.), kad tiksliausias klasifikavimas yra gaunamas panaudojant dviejų sluoksnių dirbtinį neuroninį tinklą su dviem šimtais neuronų kiekviename sluoksnyje, kuriame taip pat yra naudojami ir du „nubyrėjimo“ (angl. *dropout*) sluoksniai su 0.5 koeficientu. Šiame modelyje buvo naudojamos hiperbolinio tangento aktyvacijos funkcijos. Šiame dirbtinio neuroninio tinklo modelyje buvo panaudojama dvidešimt reikšmingiausių rodiklių, kuriuos išskyrė sprendimų medžiai. Šie rodikliai buvo normalizuojami atspariuoju (angl. *robust*) standartizavimo metodu. Siekiant įvertinti ar yra statistiškai reikšmingas skirtumas tarp skirtingų klasifikavimo modelio konfigūracijų buvo atliekamas neparametrinis vidurkių palyginimas. Atliekant šį vidurkių palyginimą buvo lyginami visi tyrimo metu gauti modeliai. Įvertinus vidurkių palyginimo rezultatus buvo pastebėta, kad statistiškai reikšmingas skirtumas vertinant visus sukurtus modelius nėra pastebimas, įvertinant visus keičiamus parametrus. Buvo pastebėta, kad nėra statistiškai reikšmingo skirtumo tarp standartinio ir atspariojo normalizavimo. Taip pat nebuvo pastebimas statistiškai reikšmingas skirtumas tarp skirtingų aktyvacijos funkcijų: sigmoidinės, hiperbolinio tangento ir sugludintos tiesinės. Vienintelis keičiamas parametras, parodęs statistiškai reikšmingą skirtumą – naudojamų rodiklių skaičius. Iš Mano-Vitnio kriterijaus buvo pastebėta, kad yra statistiškai reikšmingas skirtumas tarp skirtingų rodiklių skaičiaus, geriausius rezultatus įvertinant tik rodiklių skaičiaus keitimą, parodė visų rodiklių naudojimas.



3.15 pav. Reikšmingiausi šalių tiesioginių užsienio investicijų tendencijų klasifikavimo kintamieji (n = 20)

Išvados

1. Išanalizavus mokslinę literatūrą buvo pastebėta, kad investicinis patrauklumas ir tiesioginės užsienio investicijos yra stipriai susijusios. Šalies investicinis patrauklumas gali būti vertinamas, kaip aplinka lemianti tiesiogines užsienio investicijas. Tiesioginės užsienio investicijos tiesiogiai prisideda prie visos šalies ekonomikos plėtros, skatindamos žinių, technologijų ir inovacijų pritraukimą, infrastruktūros kūrimą. Teigiamas tiesioginių užsienio investicijų poveikis parodo tai, kad svarbu strateginiame šalies lygmenyje sumaniai formuoti šalies investicinį patrauklumą ir teisingai prognozuoti į šalį ateinančias tiesiogines užsienio investicijas.
2. Atlikta mokslinės literatūros analizė parodė, kad mokslininkai išskiria daug skirtingų tiesiogines užsienio investicijas šalyje lemiančių veiksnių. Po detalios mokslinės literatūros analizės, tiesiogines užsienio investicijas į šalį traukiantys veiksniai buvo suskirstyti į 5 patrauklumo sritis: ekonominis patrauklumas, politinis patrauklumas, technologinis patrauklumas, aplinkos patrauklumas, socialinis ir kultūrinis patrauklumas. Šias patrauklumo sritis sudarė 16 veiksnių grupių. Ekonominiam patrauklumui buvo priskiriamos ekonomikos atvirumo, socialinės atsakomybės ir išsivystymo lygio, ekonomikos pažangos, finansų rinkos išsivystymo, rinkos perkamosios galios, verslo ir mokestinės aplinkos veiksnių grupės. Politinis patrauklumas arba įvertinamas šalies politinio įvaizdžio ir šalies valdymo efektyvumo veiksnių grupėmis. Socialiniam ir kultūriniam patrauklumui priskiriama demografinė aplinka, švietimo ir mokymo sistemos kokybės, sveikatos apsaugos sistemos išsivystymo lygio ir darbo rinkos patrauklumo veiksnių grupės. Technologinis patrauklumas buvo vertinamas infrastruktūros išsivystymo lygiu ir inovacijų diegimo lygiu. Taip pat aplinkos patrauklumas yra apibūdinamas aplinkos užterštumo ir geografinės aplinkos veiksnių grupėmis. Atsižvelgiant į sudarytas veiksnių grupes, buvo surinktas tyrime naudojamas duomenų rinkinys, kuris yra sudarytas iš daugiau nei 170 rodiklių. Šio modelio naujumas, lyginant su kitais autorių darbais, yra tas, kad į modelį, kaip lygiavertis veiksnys, buvo įtrauktas socialinės atsakomybės išsivystymo lygio veiksnys, kuris pastaruoju metu formuoja ypatingą reikšmę investuotojams, renkantis šalis kaip investavimo objektą. Tyrimo metu sudarytas teorinis tiesiogines užsienio investicijas šalyje lemiančių veiksnių modelis yra tinkamas ir kitoms, ne tik Europos, šalims, todėl kuriamų modelių metodika gali būti pritaikoma daug plačiau.
3. Skirtingų dirbtinių neuroninių tinklų metodų analizė leido išskirti keturis galimus taikyti metodus investicinio patrauklumo prognozavime. Analizės metu buvo išskirti rekurentinių neuroninių tinklų, ilgalaikės-trumpalaikės atminties neuroninių tinklų, sulaikomojo sluoksnio neuroninių tinklų ir ekstremalaus mokymosi mašinų metodai. Analizės metu buvo patvirtinta, kad pateikti metodai yra tinkami tiesioginėms užsienio investicijoms prognozuoti, kadangi sugeba užfiksuoti praeities duomenis ir juos įtraukti į prognozavimą.
4. Atlikta šalių klasterinė ir saviorganizuojančių tinklų analizė parodė, kad šalių klasterizavimas, panaudojant visus tiesiogines investicijas į šalį lemiančius rodiklius, išskiria 6 pagrindinius klasterius. Tyrimo metu buvo pastebėta, kad šalys, turinčios panašiausius rodiklius, dažniausiai yra išskiriamos geografiniais regionais. Dažniausiai panašios geografiškai šalys turi panašius ir tiesiogines užsienio investicijas į šalį lemiančių veiksnių rodiklius. Pritaikyta pagrindinių komponentų analizė parodė, kad 14 pagrindinių komponentų pateikia tokius pačius rezultatus, kaip ir visų duomenų naudojimas, todėl ši analizė gali būti panaudojama šalių klasterizavimo uždaviniui spręsti.
5. Dirbtinių neuroninių tinklų modelių sudarymas parodė, kad geriausius rezultatus pateikė ELM metodas. Sukurtų modelių palyginimas su kitų mokslininkų naudojamais tiesinės regresijos

modeliais patvirtino, kad dirbtinių neuroninių tinklų modeliai yra tikslesnis, prognozuojant tiesiogines užsienio investicijas. Sukurtų modelių palyginimas su „Naive“ prognozavimo metodu patvirtino, kad sukurti metodai yra tikslesni ir už šį metodą. Vertinant kitus geriausius ne ELM metodus, buvo pastebėta, kad LSTM metodas nei vienai šaliai nepateikia tiksliausių prognozavimo rezultatų. Toks rezultatas galėjo būti gaunamas, kadangi tyrime yra naudojamos trumpos laiko eilutės ir nėra reikalinga tolima neuroninio tinklo atmintis. Pritaikyti geriausi dirbtinių neuroninių tinklų modeliai parodė, kad 13-oje iš 29 tyrime naudotų šalių prognozuojamas tiesioginių užsienio investicijų mažėjimas, lyginant su 2017 metais. Likusiose 16-oje šalių, remiantis geriausiai prognozavimo modeliais, prognozuojamas TUI didėjimas, lyginant su 2017 metais. Didžiausias TUI didėjimas (įvertinant procentinį TUI pokytį) yra numatomas Islandijoje – 282 %. Tuo tarpu didžiausias TUI mažėjimas (įvertinant procentinį TUI pokytį) yra numatomas Suomijoje. Verta pastebėti ir tai, kad didžiausias TUI turinčioje šalyje – Nyderlanduose, TUI didėjimas sieks tik 0,18 %.

6. Sudaryti dirbtinių neuroninių tinklų klasifikavimo modeliai patvirtino, kad didžiausią reikšmę teigiamoms TUI turi infliacijos lygis šalyje, eksporto didėjimo tempas, nuosavo kapitalo pelningumo rodiklis ir kt. Tyrimo metu buvo išskirti dvidešimt didžiausią reikšmę turintys rodikliai, kuriais remiantis galima sukurti naujus tiesiogines užsienio investicijas prognozuojančius modelius. Remiantis tokiais rezultatais galima pastebėti tai, kad efektyvus valstybės finansų valdymas ir infliacijos stabilizavimas gali turėti labai didelę įtaką tiesioginėms užsienio investicijoms. Taip pat iš šių rezultatų yra matoma ir tai, kad išlaidos darbuotojams (darbo užmokestis, papildomi mokesčiai) yra labai reikšmingi investuotojams.

Rekomendacijos

1. Tyrimo metu RNN, LSTM, GRU modeliuose naudojami tik 1 – 3 sluoksniai su 2 – 10 neuronais kiekviename sluoksnyje ir 3 skirtingos aktyvacijos funkcijos, todėl šių parametrų išplėtimas gali leisti rasti tikslesnius prognozavimo modelius. Poskyryje, kur aprašomos aktyvacijos funkcijos pateikiama daug skirtingų aktyvacijos funkcijų, todėl šių funkcijų pritaikymas leistų išplėsti tyrimą bei modelių palyginimą. ELM modeliuose taip pat gali būti pritaikomos skirtingos aktyvacijos funkcijos, tačiau šiuo atveju yra reikalingas papildomų paketų kūrimas.
2. Papildomų dirbtinių neuroninių tinklų modelio įgyvendinimas TUI prognozavime ESN (angl. *Echo state network*), LSM (angl. *Liquid state machine*) taip pat gali būti vertinamas, kaip papildoma tyrimo kryptis šioje temoje. Teigiama, kad ESN modeliai gerai prognozuoja įvairius nestabilius procesus, todėl jų panaudojimas tiesioginių užsienio investicijų prognozavime būtų naudingas.
3. Tyrimo metu buvo pastebėta, kad pagrindinių komponentų analizė ir nepriklausomų komponentų analizė leidžia išskirti pagrindinius rodiklius ir suteikia tokius pačius prognozavimo rezultatus. Dėl šios priežasties papildomų dimensijų mažinimo metodų panaudojimas, pavyzdžiui, ZCA (angl. *zero-phase component analysis*), SVD (angl. *singular-value decomposition*) gali padėti išbandyti daugiau skirtingų metodų ir palyginti skirtingus dimensijų mažinimo metodus.
4. Taikomoji duomenų modeliavimo programa nebuvo pagrindinis šio darbo tikslas, todėl tokios taikomosios programos plėtojimas gali būti nauja tyrimų sritis. Taikomosios duomenų modeliavimo programos tobulinimas įdiegiant Granger'io priežastingumo analizės, trūkstatų reikšmių užpildymo, prognozavimo, remiantis neuroninių tinklų modeliais ar kitais mašininio mokymosi modeliais, funkcijas. Tokios taikomosios programos plėtojimas leistų paprasčiau spręsti įvairius ekonominius uždavinius, atlikti greitą duomenų sisteminimą, jų analizę ir atlikti šiuos skaičiavimus realiu laiku. Taip pat papildoma sritis tyrimams yra papildomų *R* paketų kūrimas tenkinantis visus poreikius, kadangi šiuo metu duomenų surinkimui, modelių kūrimui, jų testavimui yra naudojami atskiri paketai. Paketų kūrimas leistų koncentruotai atlikti visus reikiamus žingsnius.
5. Sukurtas teorinis tiesiogines užsienio investicijas šalyje lemiančių veiksnių modelis yra tinkamas ne tik Europos šalims, o gali būti taikomas ir kitų šalių tiesioginėms užsienio investicijoms prognozuoti. Dėl šios priežasties, šalių imties išplėtimas, naudojant ne tik Europos šalis, tačiau ir kitų regionų šalis būtų naudinga papildoma tyrimų kryptis. Didesnė šalių imtis leistų įvertinti tiesioginių užsienio investicijų skirtumus ir tarp skirtingų regionų, kas tiriant tik Europos šalis nėra įmanoma.

Literatūros sąrašas

1. **DOROŻYŃSKI, TOMASZ ir KUNA-MARSZALEK, ANETTA.** Investment Attractiveness. The Case Of The Visegrad Group Countries. 2016 m., T. 19, 1.
2. **ZYKIENĖ, Ineta.** Evaluation of location's attractiveness for business growth in the context of smart development. *Daktaro disertacija*. Kaunas : Kauno technologijos universitetas, 2018 m.
3. **NOWICKI, Marcin, et al.** The Investment Attractiveness of the Regions and the Sub-regions of Poland. 2010 m., p. 15-19.
4. **ESTRIN, Saul ir UVALIC, Milica.** FDI into transition economies: are the Balkans different? 2014 m., p. 281-312.
5. **SUBASAT, Turan ir BELLOS, Sotirios.** Governance and foreign direct investment in Latin America: A panel gravity model approach. 2013 m., p. 107-131.
6. **XAYPANYA, Phonesavanh, RANGKAKULNUWAT, Poomthan ir PAWEENAWAT, Sasiwimon Warunsiri.** The determinants of foreign direct investment in ASEAN: The first differencing panel data analysis. 2015 m., T. 42, 3, p. 239-250.
7. **BRUNO, Luca Randolph ir CAMPOS, Nauro F.** Reexamining the conditional effect of foreign direct investment. 2013 m.
8. **KEMENY, Thomas.** Does foreign direct investment drive technological upgrading? 2010 m., p. 1543-1554.
9. **ROMAIN, Astrid ir DE LA POTTERIE, B. van Pottelsberghe.** The determinants of venture capital: A panel analysis of 16 OECD countries. 2004 m.
10. **JANTOŃ-DROZDOWSKA, Elżbieta ir MAJEWSKA, Maria.** Investment attractiveness of Central and Eastern European countries in the light of new locational advantages development. 2016 m., p. 97-119.
11. **CHOONG, Chee-Keong ir LAM, Siew-Yong.** The determinants of foreign direct investment in Malaysia: A revisit. *Global Economic Review*. 2010 m., p. 175-195.
12. **ANWAR, Sajid ir NGUYEN, Lan Phi.** Foreign direct investment and economic growth in Vietnam. *Asia Pacific business review*. 2010 m., p. 183-202.
13. **ISMAIL, Normaz Wana, SMITH, Peter ir KUGLER, Maurice.** The effect of ASEAN economic integration on foreign direct investment. *Journal of Economic Integration*. 2009 m., p. 385-407.
14. **BEVAN, Alan A. ir ESTRIN, Saul.** The determinants of foreign direct investment into European transition economies. *Journal of comparative economics*. 2004 m., p. 775-787.
15. **CORICELLI, Fabrizio ir IANCHOVICHINA, Elena.** Managing volatility in transition economies: the experience of the central and eastern European countries. 2004 m.
16. **CLAUSING, Kimberly A ir DOROBANTU, Cosmina L.** Re-entering Europe: Does European Union candidacy boost foreign direct investment? *Economics of transition*. 2005 m., p. 77-103.
17. **MERLEVEDE, Bruno ir SCHOORS, Koen.** Privatisation and foreign direct investment in 10 transition countries. *Post-communist economies*. 2009 m., p. 143-156.
18. **BÜTHE, Tim ir MILNER, Helen V.** The politics of foreign direct investment into developing countries: increasing FDI through international trade agreements? *American journal of political science*. 2008 m., p. 741-762.
19. **SAMIMI, Ahmad Jafari, SADEGHI, Somaye ir SADEGHI, Soraya.** The relationship between foreign direct investment and tourism development: evidence from developing countries. *Institutions and Economies*. 2017 m., p. 59-68.
20. **ALFARO, Laura, et al.** FDI and economic growth: the role of local financial markets. *Journal of international economics*. 2004 m., p. 89-112.
21. **PAPAIOANNOU, Elias.** What drives international financial flows? Politics, institutions and other determinants. *Journal of Development economics*. 2009 m., p. 269-281.
22. **KLEIN, Michael W, PEEK, Joe ir ROSENGREN, Eric S.** Troubled banks, impaired foreign direct investment: the role of relative access to credit. *American Economic Review*. 2002 m., p. 664-682.
23. **DI GIOVANNI, Julian.** What drives capital flows? The case of cross-border M&A activity and financial deepening. *Journal of international Economics*. 2005 m., p. 127-149.
24. **BAKER, Malcolm, FOLEY, C. Fritz ir WURGLER, Jeffrey.** Multinationals as arbitrageurs: The effect of stock market valuations on foreign direct investment. *The Review of Financial Studies*. 2008 m., p. 337-369.
25. **FORSSBÆCK, Jens ir OXELHEIM, Lars.** Corporate financial determinants of foreign direct investment. *The Quarterly Review of Economics and Finance*. 2011 m., p. 269-282.
26. **MIDOUN, Sissani ir ZAIRI, Belkacem.** Country Risk Components Effects On Algeria Attractiveness for foreign direct investment (1990-2012). 2015 m., p. 19-30.
27. **EREVELLES, M. Sunil, HORTON, Veronica ir MARINOVA, Ana.** The Triadic Model: a Comprehensive Framework for Managing Country Risk. *Marketing Management Journal*. 2005 m.

28. **ROTHAERMEL, Frank T, KOTHA, Suresh ir STEENSMA, H. Kevin.** International market entry by US internet firms: an empirical analysis of country risk, national culture, and market size. *Journal of Management*. 2006 m., p. 56-82.
29. **BOTRIĆ, Valerija ir ŠKUFLIĆ, Lorena.** Main determinants of foreign direct investment in the southeast European countries. *Transition Studies Review*. 2006 m., p. 359-377.
30. **RAMONA, Sarbu Maria.** The Impact of Foreign Direct Investment on Economic Growth: The Case of Romania. *Acta Universitatis Danubius*. 2015 m.
31. **SHARMA, Yogita.** Analysis of FDI in Insurance Sector in India. *International Journal of Research in Economics & Social Sciences*. 2013 m., p. 65-77.
32. **ALBU, Lucian Liviu.** Foreign Trade and FDI as Main Factors of Growth in the EU. *Journal for Economic Forecasting*. 2013 m., p. 7-17.
33. **FIDRMUC, Jan ir KOSTAGIANNI, Stefani.** Impact of IMF assistance on economic growth revisited. 2015 m.
34. **CICHY, Janusz ir GRADOŃ, Witold.** Innovative economy, and the activity of financial market institutions. Case of Poland. *Journal of International Studies*. 2016 m., p. 156-166.
35. **GEDIK, Melek Akdogan.** Determinants of foreign direct investment for OECD countries: Evidence from dynamic panel data analysis. *British Journal of Economics, Finance and Management Sciences*. 2013 m., p. 119-140.
36. **ARBATLI, Ms Elif.** *Economic policies and FDI inflows to emerging market economies*. s.l. : International Monetary Fund, 2011.
37. **RANJAN, Vinit ir AGRAWAL, Gaurav.** FDI inflow determinants in BRIC countries: A panel data analysis. *International Business Research*. 2011 m.
38. **DREHER, Axel, STURM, Jan-Egbert ir URSPRUNG, Heinrich W.** The impact of globalization on the composition of government expenditures: Evidence from panel data. *Public Choice*. 2008 m., p. 263-292.
39. **KOSTEVC, Črt, REDEK, Tjaša ir SUŠJAN, Andrej.** Foreign direct investment and institutional environment in transition economies. *Transition Studies Review*. 2007 m., p. 40-54.
40. **DU, Julan, LU, Yi ir TAO, Zhigang.** Economic institutions and FDI location choice: Evidence from US multinationals in China. *Journal of comparative Economics*. 2008 m., p. 412-429.
41. **ALI, Fathi A, FIESS, Norbert ir MACDONALD, Ronald.** Do institutions matter for foreign direct investment? *Open economies review*. 2010 m., p. 201-219.
42. **BARTELS, Frank L, NAPOLITANO, Francesco ir TISSI, Nicola E.** FDI in Sub-Saharan Africa: A longitudinal perspective on location-specific factors (2003–2010). *International Business Review*. 2014 m., p. 516-529.
43. **GLOBERMAN, Steven, SHAPIRO, Daniel ir TANG, Yao.** Foreign direct investment in emerging and transition European countries. *Emerging European financial markets: Independence and integration post-enlargement*. 2006 m., p. 431-459.
44. **KALOTAY, Kálmán.** FDI in Bulgaria and Romania in the wake of EU accession. *Journal of East-West Business*. 2008 m., p. 5-40.
45. **BUSSE, Matthias ir GROIZARD, José Luis.** *Foreign direct investment, regulations, and growth*. s.l. : The World Bank, 2006.
46. **DESAI, Mihir A ir DHARMAPALA, Dhammika.** Taxes, institutions and foreign diversification opportunities. *Journal of Public Economics*. 2009 m., p. 703-714.
47. **CORCORAN, Adrian ir GILLANDERS, Robert.** Foreign direct investment and the ease of doing business. *Review of World Economics*. 2015 m., p. 103-126.
48. **WANG, Miao ir SUNNY WONG, M. C.** What drives economic growth? The case of cross-border M&A and greenfield FDI activities. *Kyklos*. 2009 m., p. 316-330.
49. **CLAUSING, Kimberly A ir DOROBANTU, Cosmina L.** Re-entering Europe: Does European Union candidacy boost foreign direct investment? *Economics of transition*. 2005 m., p. 77-103.
50. **BELLAK, Christian ir LEIBRECHT, Markus.** Some further evidence on the role of effective corporate income taxes as determinants of foreign direct investment in Central and East European Countries. 2006 m.
51. —. Do low corporate income tax rates attract FDI?—Evidence from Central-and East European countries. *Applied Economics*. 2009 m., p. 2691-2703.
52. **GUAGLIANO, Claudia ir RIELA, Stefano.** o special economic areas matter in attracting FDI? Evidence from Poland, Hungary and Czech Republic. 2005 m.
53. **NENE, Mamica ir PASHOLLI, Alketa.** Financial Incentives and their Impact for Attracting FDI Survey with Foreign Investitures in Albania. *Journal of knowledge management, economics and information technology*. 2011 m.
54. **OWCZARCZUK, Magdalena.** Government Incentives and FDI inflow into R&D: The Case of Visegrad Countries. *Entrepreneurial Business and Economics Review*. 2013 m.
55. **CARSTENSEN, Kai ir TOUBAL, Farid.** Foreign direct investment in Central and Eastern European countries: a dynamic panel analysis. 2004 m., p. 3-22.

56. **JANICKI, Hubert P ir WUNNAVA, Phanindra V.** Determinants of foreign direct investment: empirical evidence from EU accession candidates. 2004 m., p. 505-509.
57. **KRUGELL, W.** The determinants of foreign direct investment in Africa. In: *Multinational Enterprises, Foreign Direct Investment and Growth in Africa*. 2005 m., p. 49-71.
58. **BELLAK, Christian, LEIBRECHT, Markus ir RIEDL, Aleksandra.** Labour costs and FDI flows into Central and Eastern European Countries: A survey of the literature and empirical evidence. *Structural Change and Economic Dynamics*. 2008 m., p. 17-37.
59. **BLONIGEN, Bruce A., et al.** FDI in space: Spatial autoregressive relationships in foreign direct investment. *European Economic Review*. 2007 m., p. 1303-1325.
60. **BALTAGI, Badi H, EGGER, Peter ir PFAFFERMAYER, Michael.** Estimating models of complex FDI: Are there third-country effects? *Journal of Econometrics*. 2007 m., p. 260-281.
61. **WOO, Jung-Yeop ir HEO, Uk.** Corruption and foreign direct investment attractiveness in Asia. 2009 m., p. 223-238.
62. **KYRKILIS, Dimitrios ir PANTELIDIS, Pantelis.** Macroeconomic determinants of outward foreign. T. 30, 7, p. 827-836.
63. **JUDE, Cristina ir LEVIEUGE, Gregory.** Growth effect of foreign direct investment in developing economies: The role of institutional quality. 2017 m., p. 715-742.
64. **HEAD, Keith ir MAYER, Thierry.** Market potential and the location of Japanese investment in the European Union. *Review of Economics and Statistics*. 2004 m., p. 959-972.
65. **GUPTA, Anil K ir GOVINDARAJAN, Vijay.** Managing global expansion: A conceptual framework. *Business Horizons*. 2000 m., p. 45-45.
66. **MITRA, Debanjan ir GOLDBERGER, Peter N.** Whose culture matters? Near-market knowledge and its impact on foreign market entry timing. *Journal of Marketing Research*. 2002 m., p. 350-365.
67. **VOGIATZOGLU, Klimis.** Vertical specialization and new determinants of FDI: evidence from South and East Asia. *Global economic review*. 2007 m., p. 245-266.
68. **BÉNASSY-QUÉRÉ, Agnès, COUPET, Maylis ir MAYER, Thierry.** Institutional determinants of foreign direct investment. *World economy*. 2007 m., p. 764-782.
69. **ARBATLI, Ms Elif.** Economic policies and FDI inflows to emerging market economies. *International Monetary Fund*. 2011 m.
70. **VARSAKELIS, Nikos C.** Education, political institutions and innovative activity: A cross-country empirical investigation. *Research Policy*. p. 1083-1090.
71. **HERCOG, Metka.** The role of the state in attracting highly-skilled migrants: The case of the Netherlands. *EIPAScope*. 2008 m., p. 1-6.
72. **SINGHANIA, Monica ir GUPTA, Akshay.** Determinants of foreign direct investment in India. *Journal of international trade law and policy*. 2011 m., p. 64-82.
73. **LUNDVALL, Bengt-Åke, et al.** National systems of production, innovation and competence building. *Research policy*. 2002 m., p. 213-231.
74. **HOLCOMB, Tim R, HOLMES Jr, R. Michael ir CONNELLY, Brian L.** Making the most of what you have: Managerial ability as a source of resource value creation. *Strategic Management Journal*. 2009 m., p. 457-485.
75. **LUND VINDING, Anker.** Absorptive capacity and innovative performance: A human capital approach. *Economics of innovation and New Technology*. 2006 m., p. 507-517.
76. **BLOOM, David E., CANNING, David ir JAMISON, Dean T.** Health, wealth, and welfare. *Finance and development*. p. 10-15.
77. **BLOOM, David E, CANNING, David ir SEVILLA, Jaypee.** The effect of health on economic growth: a production function approach. *World development*. 2004 m., p. 1-13.
78. **LYNN, David J.** The Tectonic Forces of Global Real Estate. *The Journal of Real Estate Portfolio Management*. 2007 m., p. 87-92.
79. **ERUMBAN, Abdul A ir DAS, Deb Kusum.** Information and communication technology and economic growth in India. *Telecommunications Policy*. 2016 m., p. 412-431.
80. **ISHIDA, Hazuki.** The effect of ICT development on economic growth and energy consumption in Japan. *Telematics and Informatics*. 2015 m., p. 79-88.
81. **PRADHAN, Rudra P. , et al.** Economic growth and the development of telecommunications infrastructure in the G-20 countries: A panel-VAR approach. *Telecommunications Policy*. 2014 m., p. 634-649.
82. **SHAHIDUZZAMAN, Md ir ALAM, Khorshed.** The long-run impact of Information and Communication Technology on economic output: The case of Australia. *Telecommunications Policy*. 2014 m., p. 623-633.
83. **MAQSOOD, Leena.** Use of mobile technology among rural women in Pakistan for agricultural extension information. *Telecommunication, Information Studies and Media*. 2015 m.

84. **MENGISTU, Berhanu ir ADAMS, Samuel.** Foreign direct investment, governance and economic development in developing countries. *Journal of social political and economic studies*. p. 223.
85. **LEDYAEVA, Svetlana.** Spatial econometric analysis of foreign direct investment determinants in Russian regions. *World Economy*. 2009 m., p. 643-666.
86. **BRUNECKIENĖ, Jurgita, ZYKIENĖ, Ineta ir STANKEVIČIUS, Česlovas Vytautas.** Critical analysis of city attractiveness factors in Lithuania–Poland cross-border regions: the viewpoints of businessmen and youth. *Journal of Geography, Politics and Society*. 2016 m.
87. **SNIEŠKA, Vytautas ir ZYKIENĖ, Ineta.** Viešojo infrastruktūra: poveikio regioninei plėtrai vertinimo ekonominiai aspektai. *Ekonomika ir vadyba*. 2010 m., p. 241-247.
88. **komisija, Europos.** [Tinkle] [Cituota: 2019 m. 04 13 d.] https://ec.europa.eu/growth/industry/innovation_en.
89. **CHAN, Luke M.W., et al.** Foreign direct investment and its determinants: A regional panel causality analysis. 2014 m., p. 579-589.
90. **LAU, Chi Keung Marco, et al.** Determinants of innovative activities: evidence from Europe and Central Asia region. 2015 m.
91. **RODRIGUEZ, Xose A ir PALLAS, Julio.** Determinants of foreign direct investment in Spain. *Applied Economics*. 2008 m., p. 2443-2450.
92. **KAUFMANN, Daniel, KRAAY, Aart ir MASTRUZZI, Massimo.** The worldwide governance indicators: methodology and analytical issues. *Hague Journal on the Rule of Law*. 2011 m.
93. **GLOBERMAN, Steven ir SHAPIRO, Daniel.** Global foreign direct investment flows: The role of governance infrastructure. *World development*. p. 1899-1919.
94. **TREVINO, Len J, THOMAS, Douglas E ir CULLEN, John.** The three pillars of institutional theory and FDI in Latin America: An institutionalization process. *International Business Review*. 2008 m.
95. **CUERVO-CAZURRA, Alvaro.** Who cares about corruption? *Journal of international business studies*. 2006 m., p. 807-822.
96. **ARGANDOÑA, Antonio.** Corruption and companies: The use of facilitating payments. *Journal of Business Ethics*. 2005 m., p. 251-264.
97. **KURTZMAN, Joel, YAGO, Glenn ir PHUMIWASANA, Triphon.** The global costs of opacity. *MIT Sloan Management Review*. 2004 m.
98. **LUCKE, Navina ir EICHLER, Stefan.** Foreign direct investment: the role of institutional and cultural determinants. *Applied Economics*. 2016 m., p. 935-956.
99. **EASTERLY, William ir LEVINE, Ross.** Tropics, germs, and crops: how endowments influence economic development. *Journal of monetary economics*. 2003 m., p. 3-39.
100. **ACEMOGLU, Daron, JOHNSON, Simon ir ROBINSON, James A.** Reversal of fortune: Geography and institutions in the making of the modern world income distribution. *The Quarterly journal of economics*. 2002 m., p. 1231-1294.
101. **SHEARMUR, Richard ir DOLOREUX, David.** Urban hierarchy or local buzz? High-order producer service and (or) knowledge-intensive business service location in Canada, 1991–2001. *The Professional Geographer*. 2008 m., p. 333-355.
102. **JACOBS, Wouter, KOSTER, Hans RA ir VAN OORT, Frank.** Co-agglomeration of knowledge-intensive business services and multinational enterprises. *Journal of Economic Geography*. 2013 m., p. 443-475.
103. **UPPENBERG, Kristian ir RIESS, Armin.** Determinants and growth effects of foreign direct investment. 2004 m., p. 52-84.
104. **ESKELAND, Gunnar S. ir HARRISON, Ann E.** Moving to greener pastures? Multinationals and the pollution haven hypothesis. *Journal of Development Economic*. 2003 m., T. 70, 1.
105. **JAVORCIK, Beata Smarzynska ir WEI, Shang-Jin.** Pollution havens and foreign direct investment: dirty secret or popular myth? *Contributions in Economic Analysis & Policy*. 2004 m.
106. **NASSANI, Abdelmohsen A., et al.** Moderating and mediating role of renewable energy consumption, FDI inflows, and economic growth on carbon dioxide emissions: evidence from robust least square estimator. *Environmental Science and Pollution Research*. 2019 m., p. 2806-2819.
107. **BRUNECKIENĖ, Jurgija, ZYKIENĖ, Ineta ir STANKEVIČIUS, Vytautas.** Critical analysis of city attractiveness factors in Lithuania–Poland cross-border regions: the viewpoints of businessmen and youth.
108. **NIKOLOVA, Liudmila ir PLOTNIKOVA, Ekaterina.** Regional investment attractiveness in an unstable and risky environment. 2013 m.
109. **CORCORAN, Adrian ir GILLANDERS, Robert.** Foreign direct investment and the ease of doing business. *Review of World Economics*. 2015 m., p. 103-126.
110. **TOSKOVIĆ, Jelena, et al.** Comparative analysis of the investment environment in the economies of the Western Balkans. *Regional and Business Studies*. 2016 m., p. 15-27.

111. **BELDERBOS, Rene, et al.** Where to locate innovative activities in global value chains: does co-location matter? *OECD Science, Technology and Industry Policy Papers* 30. 2016 m.
112. **ADAMS, Samuel.** Can foreign direct investment (FDI) help to promote growth in Africa? *African Journal of Business Management*. 2009 m., p. 178-183.
113. **STANKEVIČIENĖ, Jurgita ir LAKŠTUTIENĖ, Aušrinė.** Tiesioginių užsienio investicijų pritraukimą lemiančių veiksnių ir jų kitimo tendencijų tyrimas Baltijos šalyse. *Vadybos mokslas ir studijos-kaimo verslų ir jų infrastruktūros plėtrai*. 2012 m., p. 69-79.
114. **STRZELCZYK, Wojciech.** Investment attractiveness measurement of the regions versus general location of the enterprises. *Economic and Regional Studies*. 2014 m.
115. **LUCKE, Navina ir EICHLER, Stefan.** Foreign direct investment: the role of institutional and cultural determinants. *Applied Economics*. 2016 m., p. 935-956.
116. **LV, Ping ir SPIGARELLI, Francesca.** The integration of Chinese and European renewable energy markets: The role of Chinese foreign direct investments. *Energy Policy*. 2015 m., p. 14-26.
117. **ECONOMOU, Fotini, et al.** Foreign direct investment determinants in OECD and developing countries. *Review of Development Economics*. 2017 m., p. 527-542.
118. **GROH, ALEXANDER PETER ir WICH, Matthias.** composite measure to determine a host country's attractiveness for foreign direct investment. 2009 m.
119. **BLONIGEN, Bruce A ir PIGER, Jeremy.** Determinants of foreign direct investment. *Canadian Journal of Economics/Revue canadienne d'économique*. 2014 m., p. 775-812.
120. **MURAT, Marina ir PIROTTI, Tommaso.** The attractiveness of countries for FDI: a fuzzy approach. 2010 m.
121. **LIESER, Karsten ir GROH, Alexander Peter.** The determinants of international commercial real estate investment. *The Journal of Real Estate Finance and Economics*. 2014 m., p. 611-659.
122. **GROH, Alexander, et al.** The Venture Capital and Private Equity Country Attractiveness Index 2018. 2018 m.
123. **JAKUSONOKA, Ingrida ir ZARINA, Kristine.** ATTRACTIVENESS OF LATVIAN, LITHUANIAN AND ESTONIAN VENTURE CAPITAL MARKETS FOR INTERNATIONAL INVESTORS. *Science and Studies of Accounting and Finance: Problems and Perspectives*. 2018 m., p. 20-27.
124. **BIRNLEITNER, Helmut.** Attractiveness of countries for foreign direct investments from the macro-economic perspective. 2014 m.
125. **VILLAVERDE, José ir MAZA, Adolfo.** The determinants of inward foreign direct investment: Evidence from the European regions. *International Business Review*. 2015 m., p. 209-223.
126. **POELHEKKE, Steven.** Do global banks facilitate foreign direct investment? *European Economic Review*. 2015 m., p. 25-46.
127. **BOTRIĆ, Valerija ir ŠKUFLIĆ, Lorena.** Main determinants of foreign direct investment in the southeast European countries. *Transition Studies Review*. 2006 m., p. 359-377.
128. **KHARLAMOVA, Ganna.** Investment attractiveness of Ukrainian regions: rating assessment and marketing promotion. *Journal of International Studies*. 2014 m., p. 9-26.
129. **VERSHININA, Anna A., et al.** The formation of indicator framework for effective assessment of investment attractiveness of the region. *International Journal of Economics and Financial Issues*. 2015 m., p. 136-141.
130. **SABONIENĖ, Asta ir ZYKIENĖ, Ineta.** Verslo plėtros pasienio regionuose patrauklumo vertinimas infrastruktūros aspektu. *Economics and Management*. 2012 m., p. 1410-1416.
131. **LEE, Kwang-Hoon.** The conceptualization of country attractiveness: a review of research. *International Review of Administrative Sciences*. 2016 m., p. 807-826.
132. **O'MEARA, Graeme.** Examining the determinants of foreign direct investment. *Undergraduate Economic Review*. 2015 m.
133. **MOHAMMED, Mohssen, KHAN, Muhammad Badruddin ir BASHIER, Eihab Bashier Mohammed.** *Machine learning: algorithms and applications*. s.l. : Crc Press, 2016.
134. **DUDA, Richard O., HART, Peter E. ir STORK, David G.** Unsupervised learning and clustering. *Pattern Classification, 2nd Edition*. 2000.
135. **MACQUEEN, James, et al.** Some methods for classification and analysis of multivariate observations. 1967 m., p. 281-297.
136. **CHOLLET, François.** *Deep Learning with Python*. 2017. 9781617294433.
137. **MOHRI, Mehryar, ROSTAMIZADEH, Afshin ir TALWALKAR, Ameet.** Foundations of Machine Learning. 2012 m.
138. **CHICCO, Davide.** *Ten quick tips for machine learning in computational biology*. s.l. : BioData mining, 2017. p. 35. T. 10.1.
139. **THAGARD, Paul.** *Mind: Introduction to cognitive science*. s.l. : MIT press, 2005.

140. **GRAVES, Alex, MOHAMED, Abdel-rahman ir HINTON, Geoffrey.** Speech recognition with deep recurrent neural networks. *2013 IEEE international conference on acoustics, speech and signal processing.* 2013 m.
141. **HOCHREITER, Sepp ir SCHMIDHUBER, Jurgen.** Long short-term memory. *Neural computation.* 1997 m., p. 1735-1780.
142. **CHUNG, Junyoung, et al.** Empirical evaluation of gated recurrent neural networks on sequence modeling. 2014 m.
143. **KOHONEN, Teuvo.** Exploration of very large databases by self-organizing maps. *Proceedings of International Conference on Neural Networks (ICNN'97).* 1997 m.
144. **CAMBRIA, Erik, et al.** Extreme learning machines. *IEEE Intelligent Systems.* 2013 m., p. 30-59.
145. **HUANG, Guang-Bin ir CHEN, Lei.** Convex incremental extreme learning machine. *Neurocomputing.* 2017 m., p. 3056-3062.
146. **WITTEN, Ian H., et al.** Data Mining: Practical machine learning tools and techniques. 2016 m.
147. **ELSEN, M. B., et al.** Cluster analysis and display of genome-wide expression patterns. *Proceedings of the National Academy of Sciences.* 95(25), 1998 m., p. 14863-14868.
148. **JOLLIFFE, Ian T. ir CADIMA, Jorge.** Principal component analysis: a review and recent developments. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences.* 2016 m.
149. **BOUGHORBEL, Sabri, JARRAY, Fethi ir EL-ANBARI, Mohammed.** Optimal classifier for imbalanced data using Matthews Correlation Coefficient metric. 2017 m.
150. **CHAWLA, N.V.** *Data mining for imbalanced datasets: An overview.* New York, NY, USA : Springer, 2005.
151. **ŽODYNAS.LT.** [Tinkle] 2019 m. [Cituota: 2019 m. 04 02 d.] <https://www.zodynas.lt/>.

Priedai

Kai kurie priedai pateikiami tik kompaktiniame diske, pateiktame kartu su šiuo darbu, šių priedų pavadinime įvardijama tai, kad pateikiama tik diske.

1 priedas. Empiriniame tyrime naudoti duomenys. Duomenų failas pateikiamas kompaktiniame diske

Duomenų rinkinyje esančio rodiklio žymėjimas	Pavadinimas
FDI	Tiesioginės užsienio investicijos (TUI)
FDI_GDP	Tiesioginės užsienio investicijos tenkančios vienam gyventojui
GDP	Bendras vidaus produktas (\$)
GDP_PC	Bendras vidaus produktas tenkantis vienam gyventojui
GDP_PCG	Bendro vidaus produkto tenkančio vienam gyventojui augimo tempas (%)
Export_PC_GDP	Eksportas (% BVP)
EXP_USD	Eksportas (\$)
EXP_PC	Eksportas (\$ vienam gyventojui)
EXP_GR	Eksporto augimo tempas (%)
Import_PC_GDP	Importas (% BVP)
IMP_USD	Importas (\$)
IMP_PC	Importas (\$ vienam gyventojui)
POPULATION	Populiacija (žm.)
POP_GROWTH	Populiacijos augimo tempas (žm.)
Pop_growth_pc	Populiacijos augimo tempas (%)
Popg_U	Populiacijos augimo tempas mieste (%)
Popg_R	Populiacijos augimo tempas kaime (%)
LABOR_FORCE	Darbo jėga (žm.)
Unemp_Rate	Nedarbo lygis (%)
Urban_pop_perc	Populiacija mieste (% populiacija)
CP	Korupcijos suvokimo indeksas (angl. <i>corruption perceptions index</i>)
PS_AVT	Politinis stabilumas / smurto ir terorizmo nebuvimas (angl. <i>political stability / absence of violence / terrorism</i>)
IND_INT	Interneto vartotojai (1000 asmenų)
INF_CP	Infliacija (vartotojų kainų indeksas)
LIFE_EXP	Tikėtina gyvenimo trukmė (angl. <i>life expectancy</i>)
LF_INTEDU	Darbo jėga turinti vidurinį ar aukštesnį išsilavinimą (% visos darbo jėgos)
RND_PCGDP	Mokslinių tyrimų ir plėtros išlaidos (% BVP)
RND_PPL	Asmenys dirbantys mokslinių tyrimų ir plėtros srityje
RND_TOTAL_EUR	Mokslinių tyrimų ir plėtros išlaidos (Eur.)
RND_TOTAL_EUR_PC	Mokslinių tyrimų ir plėtros išlaidos (Eur / gyv.)
RND_BES_GDP	Verslo mokslinių tyrimų ir plėtros išlaidos (% BVP)
RND_BES_EUR	Verslo mokslinių tyrimų ir plėtros išlaidos (Eur.)
RND_BES_EUR_PC	Verslo mokslinių tyrimų ir plėtros išlaidos (Eur. / gyv.)
RND_GOV_GDP	Vyriausybės mokslinių tyrimų ir plėtros išlaidos (% BVP)
RND_GOV_EUR	Vyriausybės mokslinių tyrimų ir plėtros išlaidos (Eur.)
RND_GOV_EUR_PC	Vyriausybės mokslinių tyrimų ir plėtros išlaidos (Eur. / gyv.)
PATENTS	Patentų, kuriuos pateikė rezidentai, skaičius (vnt. / 1000000 gyv.)
NRES_GDP	Pajamos iš gamtos išteklių nuomos (% of GDP)
TR_EDU	Asmenys turintys aukštąjį išsilavinimą (5-8 lygiai) (% gyv.)
EDU_0_2	Asmenys turintys 0-2 lygio išsilavinimą (% gyv.)
EDU_3_8	Asmenys turintys 3-8 lygio išsilavinimą (% gyv.)
EDU_3_4	Asmenys turintys 3-4 lygio išsilavinimą (% gyv.)
RLPR_PER	Realus darbo našumo rodiklis tenkantis 1 asmeniui
RLPR_HW	Realus darbo našumo rodiklis tenkantis 1 darbo valandai
GH	Šiltnamio dujų emisija (tūkst. t.)
CO2	CO2 emisija (tūkst. t.)
VAT	Pajamos iš pridėtinės vertės mokesčio
EMP	Užimtumas (% gyv.)
MIG	Grynoji migracija (asm.)
RTT	Mažmeninės prekybos apyvartos indeksas (2010 metai = 100 %)
TRADE_OP	Prekybos atvirumas (\$)
TEL	Fiksuoto ryšio telefonų naudojimas (% gyv.)
MOBILE	IKT infrastruktūros mobiliųjų telefonų abonentai (% gyv.)

BROADBAND	Plačiajuosčio interneto abonentai (% gyv.)
KOFGI	Globalizacijos indeksas
KOFecGI	Ekonomikos globalizacijos indeksas
KOFTrGI	Prekybos globalizacijos indeksas
KOFFiGI	Finansinės globalizacijos indeksas
KOFSoGI	Socialinės globalizacijos indeksas
KOFIpGI	Tarpasmeninės globalizacijos indeksas
KOFInGI	Informacijos globalizacijos indeksas
KOFCuGI	Kultūrinės globalizacijos indeksas
KOFPoGI	Politinės globalizacijos indeksas
EC_FR	Ekonominės laisvės indeksas
PR	Nuosavybės teisės indeksas
GI	Vyriausybės vientisumo indeksas (angl. <i>government integrity</i>)
TB	Mokestinės naštos indeksas (angl. <i>tax burden</i>)
GS	Vyriausybės išlaidos (angl. <i>government spending</i>) (% BVP)
BF	Verslo laisvės indeksas (angl. <i>business freedom</i>)
MF	Pinigų laisvės indeksas (angl. <i>monetary freedom</i>)
TF	Prekybos laisvės indeksas (angl. <i>trade freedom</i>)
IF	Investicijų laisvės indeksas (angl. <i>investment freedom</i>)
FF	Finansinės laisvės indeksas (angl. <i>financial freedom</i>)
CPI	Vartotojų kainų indeksas (angl. <i>consumer price index</i>)
LC	Darbo sąnaudų indeksas (2012=100 %)
EXCH	Vietinės valiutos kursas lyginant su dolerio kursu
PPP	Pirkimo galios paritetetas (angl. <i>purchasing power parity</i>)
EURO_AREA	Narystė euro zonoje (1 – taip, 0 – ne)
EU_MEMB	Narystė Europos sąjungoje (1 – taip, 0 – ne)
SCH_AREA	Narystė Šengeno erdvėje (1 – taip, 0 – ne)
GOV_EXP_TOT_GDP	Bendros vyriausybės išlaidos (% BVP)
GOV_EXP_EP_GDP	Vyriausybės išlaidos skiriamos aplinkos apsaugai (% BVP)
GOV_EXP_HCA_GDP	Vyriausybės išlaidos skiriamos būsto ir bendruomenės patogumui (angl. <i>housing and community amenities</i>) (% BVP)
GOV_EXP_EA_GDP	Vyriausybės išlaidos skiriamos ekonomikos reikalams (angl. <i>economic affairs</i>) (% BVP)
GOV_EXP_H_GDP	Vyriausybės išlaidos skiriamos sveikatos apsaugai (% BVP)
GOV_EXP_RCR_GDP	Vyriausybės išlaidos skiriamos rekreacijai, kultūrai ir religijai (angl. <i>recreation, culture and religion</i>) (% BVP)
GOV_EXP_EDU_GDP	Vyriausybės išlaidos skiriamos švietimui (% BVP)
GOV_EXP_SP_GDP	Vyriausybės išlaidos skiriamos socialiniai apsaugai (% BVP)
SB	Verslo pradžios indeksas (angl. <i>starting business</i>)
SB_P	Procedūros norint pradėti verslą
SB_T	Laikas norint pradėti verslą
SB_C	Kaštai norint pradėti verslą
SB_min_C	Minimalus kapitalas pradėdant verslą
DCP	Darbo su statybos leidimais indeksas
DCP_P	Darbo su statybos leidimais procedūrų skaičius
DCP_T	Darbo su statybos leidimais laikas
DCP_C	Darbo su statybos leidimais kaštai
RP	Nuosavybės registravimo indeksas
RP_P	Nuosavybės registravimo procedūrų skaičius
RP_T	Nuosavybės registravimo laikas
RP_C	Nuosavybės registravimo kaštai
PT	Mokesčių mokėjimo indeksas (angl. <i>paying taxes</i>)
PT_P	Mokesčių mokėjimas (skaičius per metus)
PT_T	Mokėjimo mokesčiai (valandos per metus)
PT_TT	Mokesčių mokestis, bendras mokesčių tarifas (% pelno)
PT_PT	Mokesčių mokestis pelno mokestis (% pelno)
PT_LT	Mokesčių mokestis darbo mokestis ir įmokos (% pelno)
PT_OT	Mokesčių mokėjimas kiti mokesčiai (% pelno)
CB	Verslo uždarymo indeksas
CB_T	Verslo uždarymo laikas
CB_C	Uždarymo verslo kaina (% nuo turto)
CB_RR	Įmonės susigrąžinimo rodiklis (\$)
CTR	Įmonių mokesčio tarifas (angl. <i>corporate tax rate</i>)
SoI	Pramonės pridėtinė vertė (% visos pridėtinės vertės)
SoM	Gamybos pridėtinė vertė (% visos pridėtinės vertės)
SoS	Paslaugų pridėtinė vertė (% visos pridėtinės vertės)

CI_GDP	Kapitalo investicijos (% BVP)
HHC_GDP	Namų ūkių vartojimas (% BVP)
I_VA	Pramonės pridėtinė vertė
M_VA	Gamybos pridėtinė vertė
S_VA	Paslaugų pridėtinė vertė
HHC	Namų ūkių vartojimas (\$)
INF	Infliacija
Y_UNEMP	Jaunų asmenų nedarbo lygis (%)
EC_GR	Ekonomikos augimo tempas (%)
FR_AREA	Miško plotas (kv. km.)
N_IM	Grynoji palūkanų marža (%)
HDI	Žmogaus raidos indeksas (angl. <i>human development index</i>)
POP_65	65 metų ir vyresni gyventojai (% gyv.)
L_AREA	Žemės plotas (kv. km.)
INT_USERS	Interneto vartotojai (% gyv.)
INT_SUBS	Interneto abonentai (abonentai 100 gyv.)
RQ	Reguliavimo kokybės indeksas (angl. <i>regulatory quality</i>)
POL_RIGHTS	Politinės teisės indeksas (angl. <i>political rights</i>)
CIVIL_LIB	Pilietinės laisvės indeksas (angl. <i>civil liberties</i>)
VoC	Balsavimo ir atskaitomybės indeksas (angl. <i>voice and accountability</i>)
RoL	Išstatymų taisyklių indeksas (angl. <i>rule of law</i>)
GE	Valdžios efektyvumo indeksas (angl. <i>government effectiveness</i>)
CoC	Korupcijos kontrolės indeksas (angl. <i>control of corruption</i>)
PS	Bendras dalyvavimas pradiniam ugdyme (angl. <i>total enrollment in primary school</i>) (%)
GDP_pc_PPP	BVP tenkanti vienam gyventojui įvertinant PPP
CI	Kapitalo investicijos
SE	Šešėlinė ekonomika (angl. <i>shadow economy</i>) (%)
LF_P	Darbo jėgos dalyvavimas ekonominė veikloje (%)
AGE_DEP_RATIO	Priklausomi asmenys (vaikai ir pensininkai) (%)
TR_bal_GDP	Prekybos balansas (% BVP)
ToT	Sandorio sąlygos (angl. <i>terms of trade</i>)
BANK_CONC	Bankų koncentracija
BANK_Z_SCORE	Bankų Z-įvertinimas (angl. <i>bank Z-score</i>)
BANK_CRED_PRIV	Banko kreditas privačiam sektoriui
OH_COST	Pridėtinės darbo sąnaudos
RoA	Turto grąža
RoE	Nuosavybės grąža
BA_GDP	Banko turtas (% BVP)
LL_GDP	Likvidus turtas (% BVP)
DC_PRIV	Vidaus kreditas privačiam sektoriui
HT_EXP	Aukštųjų technologijų eksportas (\$)
HT_EXP_M	Aukštųjų technologijų eksportas (% nuo viso gamybos eksporto)
IT_EXP	Informacinių technologijų eksportas (% eksporto)
HS_pc	Sveikatos apsaugos išlaidos tenkančios vienam gyventojui
SS	Dalyvavimas viduriniame išsilavinime (angl. <i>secondary school enrollment</i>)
PrePS	Dalyvavimas prieš mokykliniame ugdyme (angl. <i>preprimary school enrollment</i>)
TAX_REV	Pajamos gaunamos iš surenkamų mokesčių
HEXP_GDP	Išlaidos sveikatos apsaugai (% BVP)

2 priedas. Rekurentinių neuroninių tinklų panaudojant visus kintamuosius geriausių modelių prognozavimo rezultatai

Šalis	Struktūra	Akt. funk	Lr	ME	RMSE	NRMSE	MAE	MPE	MAPE	MASE
AT	3	logistic	0.05	378.39	460.42	140.80	388.29	-13.52	141.62	0.68
BE	7;7;7	tanh	0.05	6274.95	6832.56	218.90	6274.95	96.47	96.47	2.89
BG	2;2;2	Gompertz	0.05	10.99	16.36	116.40	11.26	30.36	32.71	1.14
CH	8;8;8	tanh	0.1	1438.12	1601.37	196.90	1438.12	91.29	91.29	1.20
CZ	8;8;8	tanh	0.05	56.32	63.06	192.60	56.32	74.26	74.26	1.01
DE	10;10;10	tanh	0.05	4453.25	5945.63	127.40	5599.43	97.49	97.49	1.35
DK	6;6	tanh	0.1	30.70	177.85	77.80	147.34	73.78	73.78	0.82
EE	9	Gompertz	0.05	0.09	0.55	36.50	0.51	-8.30	24.38	0.37
ES	8;8;8	tanh	0.05	2204.83	2237.88	505.80	2204.83	96.43	96.43	3.64
FI	6;6	tanh	0.1	154.34	163.78	258.80	154.34	85.74	85.74	1.93
FR	6;6;6	tanh	0.05	3482.76	3519.71	599.20	3482.76	97.56	97.56	7.62
HR	5;5	logistic	0.1	1.47	2.30	111.80	1.47	17.39	17.44	0.61
HU	7	tanh	0.1	297.41	299.00	842.60	297.41	79.72	79.72	7.05
IE	10;10;10	tanh	0.01	2985.20	4678.69	106.90	4215.71	93.25	93.25	0.85
IT	9;9	tanh	0.1	1278.23	1287.76	713.30	1278.23	95.02	95.02	9.73
LT	7	logistic	0.01	0.15	0.28	49.10	0.20	13.63	16.85	0.21
LU	9;9;9	tanh	0.1	575.89	583.74	529.60	575.89	79.76	79.76	6.45
LV	3;3;3	tanh	0.05	-0.23	0.61	110.20	0.47	-15.72	52.63	1.17
NL	3;3;3	tanh	0.05	41690.33	53927.86	136.50	41690.33	97.06	97.06	1.16
NO	8;8;8	tanh	0.05	129.98	134.76	328.00	129.98	81.58	81.58	4.06
PL	10;10;10	tanh	0.05	151.50	178.13	164.60	151.50	82.58	82.58	1.65
PT	2;2	logistic	0.01	87.65	118.17	128.70	88.74	56.77	64.88	0.54
RO	10;10;10	tanh	0.1	20.61	34.51	108.00	20.61	37.74	37.74	0.93
SE	5;5	tanh	0.1	759.25	809.87	248.80	759.25	92.82	92.82	1.78
SI	7;7;7	Gompertz	0.05	0.61	1.36	96.20	0.75	9.28	26.97	0.35
SK	4	Gompertz	0.1	10.72	14.08	133.30	10.74	47.58	47.94	0.57
UK	3;3;3	tanh	0.1	16640.95	17563.63	270.80	16640.95	98.20	98.20	1.43
MT	9	tanh	0.01	58.76	117.21	89.20	66.93	-27.54	70.94	0.63
IS	3	Gompertz	0.01	0.08	0.99	23.80	0.87	11.13	19.61	0.25

3 priedas. Ilgalaikės-trumpalaikės atminties neuroninių tinklų panaudojant visus kintamuosius geriausių modelių prognozavimo rezultatai LSTM panaudojant visus kintamuosius

Šalis	Struktūra	Akt. funk	Lr	ME	RMSE	NRMSE	MAE	MPE	MAPE	MASE
AT	6;6	Gompertz	0.01	398.54	486.33	148.70	406.76	2.55	131.32	0.71
BE	5	logistic	0.1	6275.07	6832.70	218.90	6275.07	96.47	96.47	2.89
BG	10	logistic	0.05	10.46	15.82	112.60	11.03	28.01	32.84	1.12
CH	8	logistic	0.1	1438.26	1601.48	196.90	1438.26	91.30	91.30	1.20
CZ	10	tanh	0.1	56.40	63.13	192.80	56.40	74.41	74.41	1.02
DE	4	Gompertz	0.05	4409.29	5963.53	127.80	5643.81	99.31	99.31	1.36
DK	6	Gompertz	0.1	19.88	193.78	84.70	159.15	78.79	78.79	0.88
EE	7	Gompertz	0.05	1.02	1.34	89.20	1.03	29.75	31.10	0.74
ES	9;9	tanh	0.1	2204.91	2237.96	505.90	2204.91	96.43	96.43	3.64
FI	8	logistic	0.1	154.50	163.94	259.00	154.50	85.83	85.83	1.93
FR	10;10	tanh	0.1	3482.82	3519.77	599.20	3482.82	97.56	97.56	7.62
HR	7	Gompertz	0.1	1.77	2.41	117.40	1.77	22.92	22.92	0.73
HU	7	logistic	0.1	297.68	299.26	843.40	297.68	79.79	79.79	7.05
IE	8;8	Gompertz	0.1	2893.03	4730.83	108.10	4308.32	96.65	96.65	0.87
IT	9	Gompertz	0.1	1278.40	1287.92	713.40	1278.40	95.03	95.03	9.73
LT	6	Gompertz	0.01	0.06	0.30	51.20	0.28	-5.45	26.39	0.30
LU	10;10	tanh	0.1	576.11	583.97	529.80	576.11	79.79	79.79	6.46
LV	2	Gompertz	0.1	-0.30	0.54	97.60	0.50	-67.08	79.70	1.24
NL	10;10	Gompertz	0.1	41690.36	53927.88	136.50	41690.36	97.06	97.06	1.16
NO	7	tanh	0.1	130.23	135.00	328.60	130.23	81.74	81.74	4.06
PL	9	tanh	0.1	151.58	178.21	164.70	151.58	82.63	82.63	1.65
PT	5;5	logistic	0.1	88.47	118.01	128.50	88.47	61.62	61.62	0.54
RO	10	tanh	0.1	20.80	34.69	108.50	20.80	38.42	38.42	0.94
SE	9	logistic	0.1	759.37	809.99	248.90	759.37	92.83	92.83	1.78
SI	2	tanh	0.1	0.75	1.51	106.50	0.81	18.09	25.59	0.38
SK	10	tanh	0.1	10.86	14.21	134.50	10.86	48.50	48.52	0.58
UK	10;10	Gompertz	0.1	16641.00	17563.67	270.80	16641.00	98.20	98.20	1.43
MT	4	Gompertz	0.01	51.15	120.75	91.90	69.33	72.12	72.98	0.65
IS	5	tanh	0.05	-1.61	2.28	54.60	2.00	46.61	46.61	0.58

4 priedas. Sulaikomo pasikartojančio vieneto neuroninių tinklų, panaudojant visus kintamuosius, geriausių modelių prognozavimo rezultatai

Šalis	Struktūra	Akt. funk	Lr	ME	RMSE	NRMSE	MAE	MPE	MAPE	MASE
AT	3;3;3	tanh	0.01	387.61	469.08	143.40	397.35	-10.43	142.30	0.69
BE	10;10;10	logistic	0.1	6274.95	6832.57	218.90	6274.95	96.47	96.47	2.89
BG	10;10;10	tanh	0.01	11.08	16.08	114.40	11.08	32.17	32.17	1.13
CH	9	tanh	0.1	1438.14	1601.39	196.90	1438.14	91.29	91.29	1.20
CZ	8	Gompertz	0.1	56.31	63.05	192.60	56.31	74.25	74.25	1.01
DE	10	tanh	0.1	4423.77	5957.28	127.70	5628.92	98.70	98.70	1.36
DK	10	tanh	0.1	15.77	198.71	86.90	162.29	79.21	79.21	0.90
EE	3	tanh	0.05	0.38	0.64	43.00	0.58	14.24	26.00	0.42
ES	10;10;10	tanh	0.1	2204.84	2237.88	505.80	2204.84	96.43	96.43	3.64
FI	10;10	tanh	0.1	154.35	163.79	258.80	154.35	85.75	85.75	1.93
FR	10;10	logistic	0.1	3482.76	3519.71	599.20	3482.76	97.56	97.56	7.62
HR	10;10;10	tanh	0.1	1.44	2.29	111.30	1.48	16.79	17.59	0.61
HU	6	logistic	0.1	297.42	299.00	842.60	297.42	79.72	79.72	7.05
IE	10	logistic	0.1	2923.57	4712.53	107.70	4277.27	95.51	95.51	0.86
IT	10	logistic	0.1	1278.24	1287.77	713.30	1278.24	95.02	95.02	9.73
LT	8;8	Gompertz	0.01	0.04	0.19	33.60	0.19	0.66	17.34	0.20
LU	6	logistic	0.1	575.91	583.77	529.70	575.91	79.77	79.77	6.46
LV	10;10;10	logistic	0.01	-0.16	0.47	85.10	0.35	-54.71	67.84	0.87
NL	9;9;9	tanh	0.1	41690.33	53927.86	136.50	41690.33	97.06	97.06	1.16
NO	10	logistic	0.1	130.00	134.79	328.00	130.00	81.59	81.59	4.06
PL	10	Gompertz	0.1	151.50	178.14	164.70	151.50	82.58	82.58	1.65
PT	2;2;2	Gompertz	0.1	88.60	117.73	128.20	88.60	64.17	64.17	0.54
RO	9;9;9	logistic	0.1	20.63	34.53	108.00	20.63	37.83	37.83	0.93
SE	9;9	tanh	0.1	759.27	809.89	248.90	759.27	92.82	92.82	1.78
SI	3;3	Gompertz	0.01	0.78	1.51	106.70	0.79	21.61	23.07	0.37
SK	8	Gompertz	0.1	10.71	14.07	133.20	10.73	47.48	47.80	0.57
UK	8;8;8	Gompertz	0.1	16640.95	17563.63	270.80	16640.95	98.20	98.20	1.43
MT	2;2;2	Gompertz	0.01	51.41	125.82	95.80	75.17	85.80	92.20	0.70
IS	9	logistic	0.01	-1.60	1.78	42.60	1.60	17.65	41.11	0.47

5 priedas. Rekurentinių neuroninių tinklų, panaudojant pagrindinių komponenčių analizę (paaiškinama dispersija > 90 %), geriausių modelių prognozavimo rezultatai

Šalis	PK sk.	Struktūra	Akt. funk	Lr	ME	RMSE	NRMSE	MAE	MPE	MAPE	MASE
AT	6	6	logistic	0.05	382.03	460.03	140.70	384.10	47.75	80.25	0.67
BE	5	9;9;9	tanh	0.05	6274.95	6832.56	218.90	6274.95	96.47	96.47	2.89
BG	6	9;9;9	logistic	0.01	10.68	16.00	113.90	11.02	29.23	32.16	1.12
CH	6	10;10;10	tanh	0.1	1438.12	1601.37	196.90	1438.12	91.29	91.29	1.20
CZ	5	10;10	tanh	0.1	56.30	63.04	192.50	56.30	74.23	74.23	1.01
DE	6	5;5	tanh	0.1	4453.25	5945.63	127.40	5599.43	97.49	97.49	1.35
DK	5	3;3	tanh	0.1	30.96	177.91	77.80	147.61	74.62	74.62	0.82
EE	6	5;5;5	logistic	0.01	0.49	1.29	86.10	1.09	3.53	39.04	0.79
ES	5	4;4	tanh	0.05	2204.83	2237.88	505.80	2204.83	96.43	96.43	3.64
FI	6	8;8;8	tanh	0.05	154.33	163.77	258.80	154.33	85.74	85.74	1.93
FR	6	4;4;4	tanh	0.1	3482.76	3519.71	599.20	3482.76	97.56	97.56	7.62
HR	7	7	logistic	0.1	1.48	2.31	112.40	1.49	17.50	17.66	0.61
HU	6	10;10	tanh	0.05	297.41	299.00	842.60	297.41	79.72	79.72	7.05
IE	5	6;6	tanh	0.01	3108.32	4866.06	111.20	4338.84	94.95	94.95	0.88
IT	6	10;10;10	tanh	0.1	1278.23	1287.76	713.30	1278.23	95.02	95.02	9.73
LT	5	7;7;7	Gompertz	0.01	-0.12	0.16	28.40	0.16	-13.94	16.22	0.17
LU	7	10;10	tanh	0.01	575.89	583.74	529.60	575.89	79.76	79.76	6.45
LV	6	2;2;2	tanh	0.05	0.31	0.50	90.10	0.36	42.34	53.94	0.90
NL	6	7;7;7	tanh	0.1	41690.33	53927.86	136.50	41690.33	97.06	97.06	1.16
NO	6	10;10	tanh	0.05	129.98	134.76	328.00	129.98	81.58	81.58	4.06
PL	5	10;10	tanh	0.1	151.50	178.13	164.60	151.50	82.58	82.58	1.65
PT	5	5	Gompertz	0.01	84.62	115.12	125.40	86.20	52.38	64.16	0.52
RO	6	8;8;8	tanh	0.1	20.62	34.51	108.00	20.62	37.76	37.76	0.93
SE	7	10;10;10	tanh	0.05	759.25	809.87	248.80	759.25	92.82	92.82	1.78
SI	6	4;4	Gompertz	0.05	0.68	1.35	95.20	0.68	18.32	18.32	0.32
SK	6	10;10;10	tanh	0.05	10.70	14.06	133.10	10.70	47.55	47.55	0.57
UK	6	4;4;4	tanh	0.05	16640.95	17563.63	270.80	16640.95	98.20	98.20	1.43
MT	7	3;3;3	tanh	0.01	60.80	118.91	90.50	62.69	36.40	36.40	0.59
IS	7	8;8;8	Gompertz	0.01	-0.71	1.69	40.50	1.31	-3.54	32.88	0.38

6 priedas. Ilgalaikės-trumpalaikės atminties neuroninių tinklų, panaudojant pagrindinių komponentių analizę (paaiškinama dispersija > 90 %), geriausių modelių prognozavimo rezultatai

Šalis	PK sk.	Struktūra	Akt. funk	Lr	ME	RMSE	NRMSE	MAE	MPE	MAPE	MASE
AT	6	8	tanh	0.05	382.77	460.37	140.80	383.86	55.49	72.58	0.67
BE	5	9	Gompertz	0.01	6275.16	6832.80	218.90	6275.16	96.47	96.47	2.89
BG	6	6	Gompertz	0.01	10.59	15.67	111.50	10.60	29.89	29.94	1.08
CH	6	9	tanh	0.1	1438.33	1601.57	196.90	1438.33	91.30	91.30	1.20
CZ	5	9	logistic	0.1	56.40	63.14	192.90	56.40	74.38	74.38	1.02
DE	6	5	tanh	0.01	4417.06	5960.15	127.80	5635.81	98.98	98.98	1.36
DK	5	10	logistic	0.01	23.03	188.93	82.60	155.74	77.85	77.85	0.86
EE	6	4	logistic	0.05	1.08	1.46	97.20	1.08	31.99	31.99	0.78
ES	5	9	Gompertz	0.1	2204.95	2237.99	505.90	2204.95	96.43	96.43	3.64
FI	6	7	Gompertz	0.05	154.50	163.93	259.00	154.50	85.84	85.84	1.93
FR	6	7	Gompertz	0.05	3482.83	3519.78	599.20	3482.83	97.56	97.56	7.62
HR	7	9	Gompertz	0.1	2.00	2.65	129.20	2.00	26.14	26.14	0.82
HU	6	8	logistic	0.01	297.65	299.23	843.30	297.65	79.78	79.78	7.05
IE	5	6	logistic	0.05	2915.22	4718.02	107.80	4286.46	95.85	95.85	0.86
IT	6	9	tanh	0.01	1278.37	1287.90	713.40	1278.37	95.03	95.03	9.73
LT	5	9	logistic	0.1	-0.14	0.33	57.70	0.29	-28.63	37.11	0.31
LU	7	10	tanh	0.1	576.23	584.09	530.00	576.23	79.81	79.81	6.46
LV	6	5	logistic	0.05	-0.58	0.62	112.00	0.58	-109.50	109.50	1.44
NL	6	10;10	Gompertz	0.1	41690.34	53927.87	136.50	41690.34	97.06	97.06	1.16
NO	6	10	logistic	0.1	130.20	134.98	328.50	130.20	81.72	81.72	4.06
PL	5	9	Gompertz	0.05	151.61	178.26	164.80	151.61	82.64	82.64	1.65
PT	5	4	Gompertz	0.05	85.61	115.24	125.50	85.61	58.91	58.91	0.52
RO	6	9	Gompertz	0.1	20.87	34.62	108.30	20.87	39.06	39.06	0.94
SE	7	9	logistic	0.05	759.39	810.01	248.90	759.39	92.84	92.84	1.78
SI	6	5	Gompertz	0.1	0.76	1.34	94.90	0.76	24.65	24.65	0.35
SK	6	6	Gompertz	0.01	10.95	14.28	135.10	10.95	49.45	49.45	0.58
UK	6	10;10	tanh	0.1	16641.00	17563.67	270.80	16641.00	98.20	98.20	1.43
MT	7	5	Gompertz	0.05	51.36	117.94	89.80	66.74	66.54	66.98	0.62
IS	7	9	logistic	0.1	-1.99	2.94	70.30	2.36	49.86	49.86	0.69

7 priedas. Sulaikomo pasikartojančio vieneto neuroninių tinklų, panaudojant pagrindinių komponentių analizę (paaiškinama dispersija > 90 %), geriausių modelių prognozavimo rezultatai

Šalis	PK sk.	Struktūra	Akt. funk	Lr	ME	RMSE	NRMSE	MAE	MPE	MAPE	MASE
AT	6	10	tanh	0.01	382.63	459.77	140.60	383.04	60.75	67.16	0.67
BE	5	10	tanh	0.01	6274.95	6832.56	218.90	6274.95	96.47	96.47	2.89
BG	6	4	Gompertz	0.01	10.12	15.40	109.60	10.70	26.89	31.94	1.09
CH	6	9	Gompertz	0.01	1438.13	1601.39	196.90	1438.13	91.29	91.29	1.20
CZ	5	10	logistic	0.1	56.31	63.04	192.60	56.31	74.25	74.25	1.01
DE	6	10	Gompertz	0.1	4409.03	5963.31	127.80	5643.65	99.31	99.31	1.36
DK	5	9	logistic	0.01	19.49	193.30	84.50	158.57	77.87	77.87	0.88
EE	6	4	logistic	0.1	0.14	0.48	32.30	0.45	-6.13	21.98	0.33
ES	5	9	logistic	0.1	2204.83	2237.88	505.80	2204.83	96.43	96.43	3.64
FI	6	10	logistic	0.1	154.35	163.79	258.80	154.35	85.75	85.75	1.93
FR	6	10;10	tanh	0.05	3482.76	3519.71	599.20	3482.76	97.56	97.56	7.62
HR	7	7;7;7	logistic	0.1	1.46	2.26	109.90	1.46	17.35	17.35	0.60
HU	6	9	tanh	0.1	297.43	299.01	842.60	297.43	79.72	79.72	7.05
IE	5	10	logistic	0.05	2892.76	4730.57	108.10	4308.05	96.64	96.64	0.87
IT	6	10	logistic	0.01	1278.25	1287.77	713.30	1278.25	95.02	95.02	9.73
LT	5	9;9;9	logistic	0.01	0.02	0.37	63.30	0.30	2.53	21.01	0.32
LU	7	10	tanh	0.01	575.90	583.76	529.70	575.90	79.76	79.76	6.45
LV	6	7	Gompertz	0.1	-0.23	0.41	75.50	0.41	-61.11	72.18	1.01
NL	6	10	logistic	0.01	41690.33	53927.86	136.50	41690.33	97.06	97.06	1.16
NO	6	8	tanh	0.05	130.01	134.79	328.10	130.01	81.60	81.60	4.06
PL	5	10	logistic	0.01	151.51	178.14	164.70	151.51	82.58	82.58	1.65
PT	5	9;9;9	tanh	0.01	85.78	115.77	126.10	86.17	57.29	60.21	0.52
RO	6	10;10	logistic	0.1	20.63	34.53	108.00	20.63	37.82	37.82	0.93
SE	7	9	tanh	0.01	759.26	809.89	248.90	759.26	92.82	92.82	1.78
SI	6	8;8;8	Gompertz	0.05	0.56	1.19	83.70	0.66	11.43	22.70	0.31
SK	6	7	Gompertz	0.01	10.70	14.05	133.00	10.70	47.61	47.61	0.57
UK	6	10	Gompertz	0.1	16640.95	17563.63	270.80	16640.95	98.20	98.20	1.43
MT	7	3	logistic	0.1	47.55	118.07	89.90	69.10	61.40	79.31	0.65
IS	7	9;9;9	tanh	0.01	-1.13	1.74	41.60	1.36	27.95	27.95	0.40

8 priedas. Rekurentinių neuroninių tinklų, panaudojant nepriklausomų komponentių analizę, geriausių modelių prognozavimo rezultatai

Šalis	NK sk.	Struktūra	Akt. funk	Lr	ME	RMSE	NRMSE	MAE	MPE	MAPE	MASE
AT	10	2	logistic	0.01	397.37	476.81	145.80	397.37	73.43	73.43	0.69
BE	2	10;10;10	tanh	0.1	6274.95	6832.56	218.90	6274.95	96.47	96.47	2.89
BG	3	10	Gompertz	0.05	10.28	15.42	109.70	10.59	28.20	30.77	1.08
CH	3	10;10	tanh	0.1	1438.12	1601.37	196.90	1438.12	91.29	91.29	1.20
CZ	5	9;9	tanh	0.1	56.30	63.03	192.50	56.30	74.23	74.23	1.01
DE	10	9;9;9	tanh	0.1	4453.25	5945.63	127.40	5599.43	97.49	97.49	1.35
DK	3	10;10	tanh	0.1	30.67	177.81	77.70	147.32	73.80	73.80	0.82
EE	5	4;4;4	tanh	0.1	0.30	0.46	30.80	0.39	19.90	25.18	0.28
ES	2	5;5;5	tanh	0.1	2204.83	2237.88	505.80	2204.83	96.43	96.43	3.64
FI	5	5;5;5	tanh	0.1	154.33	163.77	258.80	154.33	85.74	85.74	1.93
FR	2	6;6;6	tanh	0.1	3482.76	3519.71	599.20	3482.76	97.56	97.56	7.62
HR	5	6;6;6	tanh	0.1	1.38	2.21	107.70	1.44	16.10	17.26	0.59
HU	3	9;9	tanh	0.01	297.41	299.00	842.60	297.41	79.72	79.72	7.05
IE	2	10;10	tanh	0.1	2985.15	4678.61	106.90	4215.66	93.25	93.25	0.85
IT	2	3;3;3	tanh	0.05	1278.23	1287.76	713.30	1278.23	95.02	95.02	9.73
LT	10	4;4;4	logistic	0.01	0.30	0.38	66.50	0.31	18.39	21.42	0.33
LU	3	9;9	tanh	0.05	575.89	583.74	529.60	575.89	79.76	79.76	6.45
LV	10	3;3;3	Gompertz	0.05	-0.10	0.40	72.60	0.37	-37.37	54.37	0.92
NL	2	7;7;7	tanh	0.1	41690.33	53927.86	136.50	41690.33	97.06	97.06	1.16
NO	3	7;7;7	tanh	0.1	129.98	134.76	328.00	129.98	81.58	81.58	4.06
PL	2	10;10;10	tanh	0.1	151.50	178.13	164.60	151.50	82.58	82.58	1.65
PT	3	2	Gompertz	0.05	85.79	115.08	125.30	85.79	60.79	60.79	0.52
RO	2	9;9;9	tanh	0.1	20.61	34.51	108.00	20.61	37.74	37.74	0.93
SE	3	7;7;7	tanh	0.05	759.25	809.87	248.80	759.25	92.82	92.82	1.78
SI	3	2;2	Gompertz	0.01	0.83	1.51	106.30	0.83	26.21	26.21	0.39
SK	2	6	tanh	0.1	10.69	14.03	132.80	10.69	47.57	47.57	0.57
UK	2	8;8;8	tanh	0.1	16640.95	17563.63	270.80	16640.95	98.20	98.20	1.43
MT	10	7;7;7	tanh	0.01	53.16	117.54	89.50	64.14	28.52	51.48	0.60
IS	10	4	Gompertz	0.05	-1.23	2.39	57.30	2.03	28.68	45.76	0.59

9 priedas. Ilgalaikės-trumpalaikės atminties neuroninių tinklų, panaudojant nepriklausomų komponentių analizę, geriausių modelių prognozavimo rezultatai

Šalis	NK sk.	Struktūra	Akt. funk	Lr	ME	RMSE	NRMSE	MAE	MPE	MAPE	MASE
AT	10	7	tanh	0.1	383.66	460.38	140.80	383.66	68.09	68.09	0.67
BE	10	9;9	tanh	0.05	6275.08	6832.69	218.90	6275.08	96.47	96.47	2.89
BG	3	8	Gompertz	0.1	10.72	15.74	112.00	10.72	30.54	30.54	1.09
CH	10	10	tanh	0.05	1438.25	1601.48	196.90	1438.25	91.30	91.30	1.20
CZ	5	10	Gompertz	0.1	56.38	63.10	192.70	56.38	74.42	74.42	1.02
DE	5	9	logistic	0.05	4419.60	5959.06	127.70	5633.20	98.88	98.88	1.36
DK	10	9	logistic	0.1	23.53	188.39	82.40	155.32	77.07	77.07	0.86
EE	10	8	tanh	0.01	0.81	1.20	80.40	0.89	18.85	27.21	0.64
ES	2	10;10	Gompertz	0.01	2204.88	2237.92	505.80	2204.88	96.43	96.43	3.64
FI	3	10	logistic	0.05	154.46	163.90	259.00	154.46	85.82	85.82	1.93
FR	3	10;10	logistic	0.05	3482.81	3519.77	599.20	3482.81	97.56	97.56	7.62
HR	10	10	Gompertz	0.01	1.89	2.59	126.20	1.89	24.11	24.11	0.78
HU	3	8	logistic	0.05	297.60	299.18	843.10	297.60	79.77	79.77	7.05
IE	10	10	Gompertz	0.01	2920.24	4714.77	107.70	4281.12	95.65	95.65	0.86
IT	5	10	Gompertz	0.01	1278.36	1287.89	713.40	1278.36	95.03	95.03	9.73
LT	10	10	tanh	0.05	0.00	0.28	48.20	0.28	-12.10	28.82	0.30
LU	10	9	tanh	0.1	576.10	583.95	529.80	576.10	79.79	79.79	6.46
LV	2	10	tanh	0.01	-0.44	0.59	106.60	0.51	-97.50	101.79	1.27
NL	10	10;10	tanh	0.01	41690.37	53927.91	136.50	41690.37	97.06	97.06	1.16
NO	3	10	logistic	0.05	130.24	135.05	328.70	130.24	81.73	81.73	4.06
PL	3	9	tanh	0.01	151.58	178.20	164.70	151.58	82.63	82.63	1.65
PT	3	9	logistic	0.05	85.49	115.13	125.40	85.55	58.26	58.68	0.52
RO	3	9	logistic	0.1	20.88	34.59	108.20	20.88	39.18	39.18	0.94
SE	2	10	Gompertz	0.05	759.36	809.97	248.90	759.36	92.84	92.84	1.78
SI	2	4	tanh	0.05	0.72	1.36	95.70	0.73	20.99	22.31	0.34
SK	10	10	Gompertz	0.1	10.86	14.13	133.70	10.86	49.41	49.41	0.58
UK	3	10;10	logistic	0.01	16640.95	17563.63	270.80	16640.95	98.20	98.20	1.43
MT	5	7	tanh	0.05	51.11	117.80	89.70	66.80	67.03	67.65	0.63
IS	10	8	tanh	0.01	-1.47	1.95	46.60	1.54	33.92	33.92	0.45

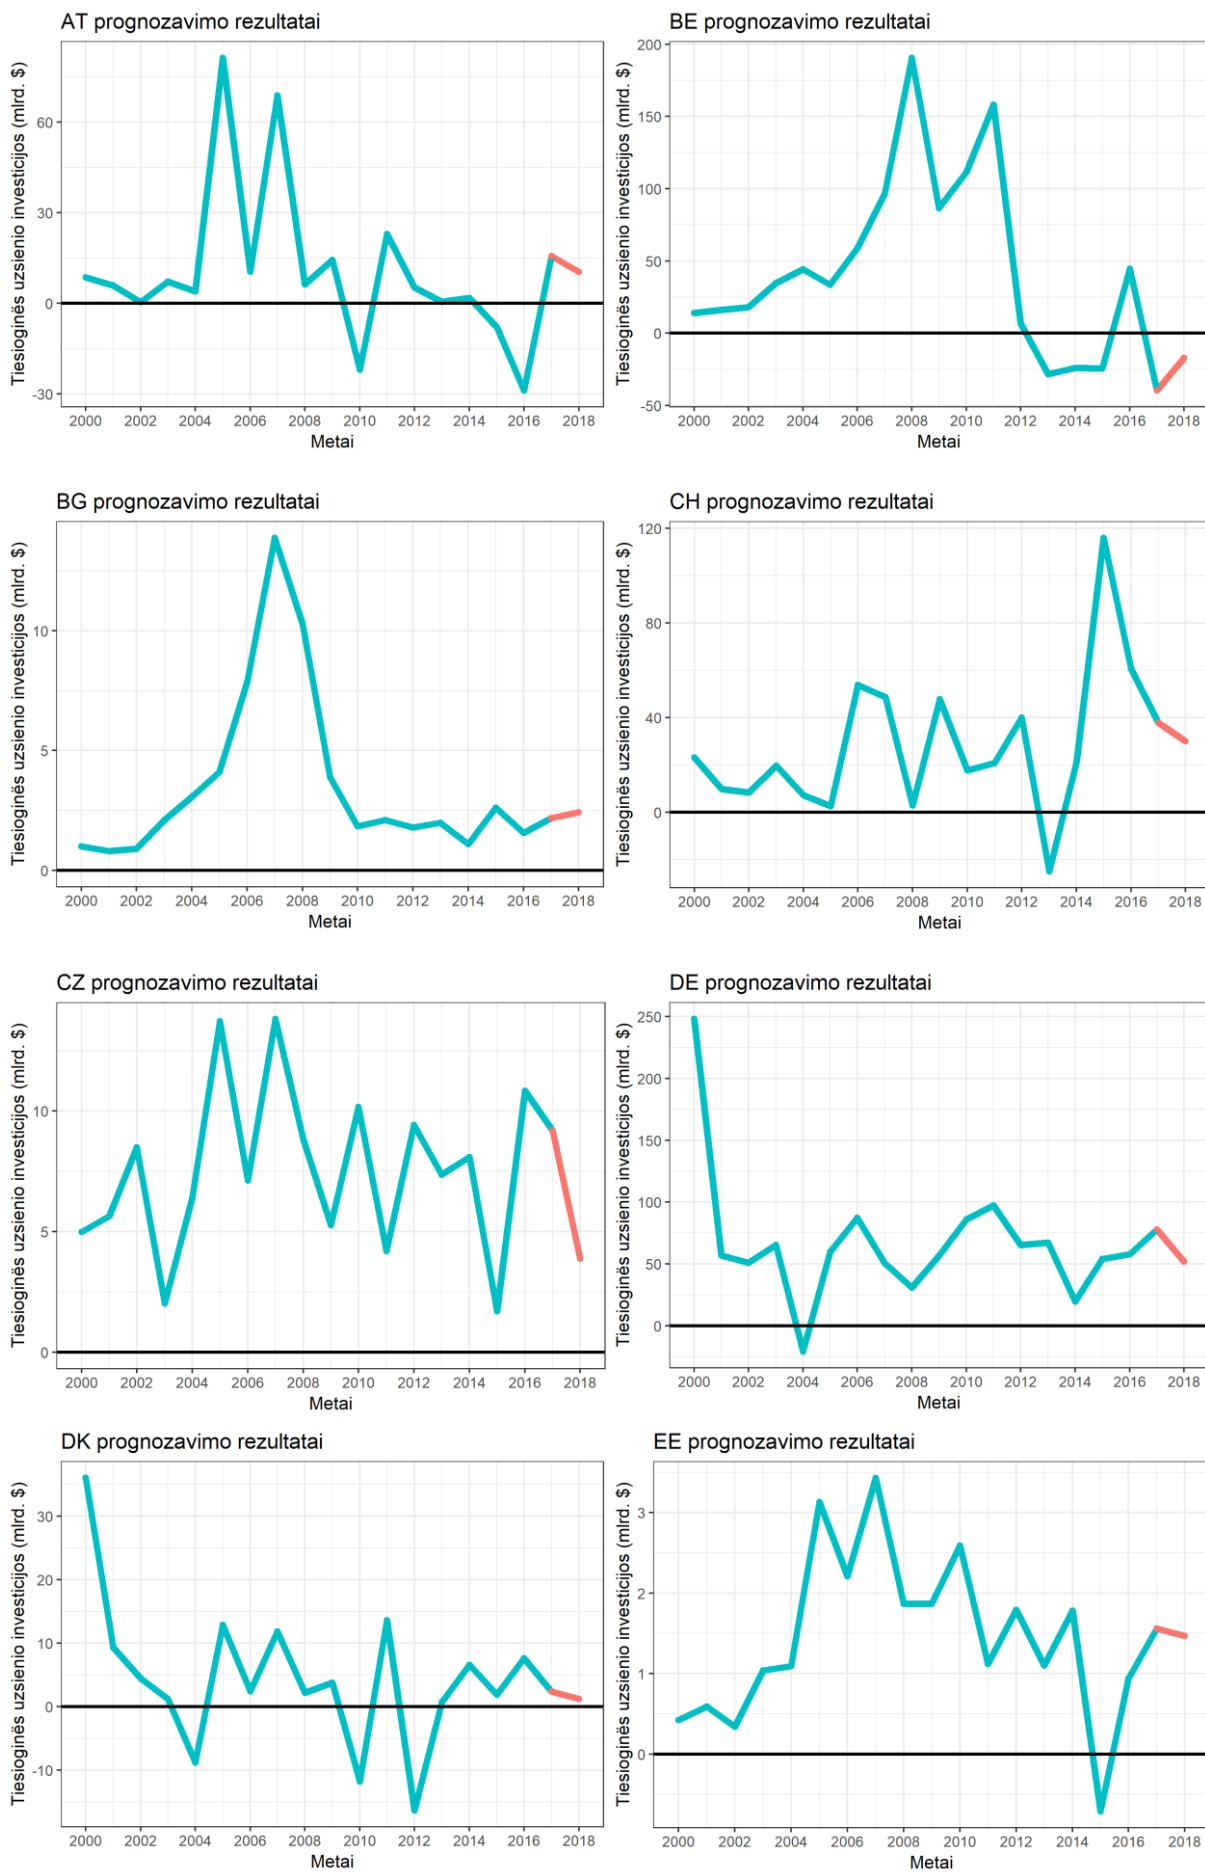
10 priedas. Sulaikomo pasikartojančio vieneto neuroninių tinklų, panaudojant nepriklausomų komponentių analizę, geriausių modelių prognozavimo rezultatai








Šalis	NK sk.	Struktūra	Akt. funk	Lr	ME	RMSE	NRMSE	MAE	MPE	MAPE	MASE
AT	3	3	Gompertz	0.05	382.68	459.86	140.60	383.15	60.26	67.68	0.67
BE	10	8	tanh	0.1	6274.95	6832.56	218.90	6274.95	96.47	96.47	2.89
BG	3	7	logistic	0.01	10.48	15.36	109.30	10.48	30.08	30.08	1.06
CH	10	8	Gompertz	0.05	1438.12	1601.37	196.90	1438.12	91.29	91.29	1.20
CZ	3	8;8	Gompertz	0.1	56.30	63.04	192.50	56.30	74.24	74.24	1.01
DE	10	10;10	Gompertz	0.01	4423.78	5957.28	127.70	5628.92	98.70	98.70	1.36
DK	10	7	logistic	0.1	19.48	193.30	84.50	158.57	77.82	77.82	0.88
EE	2	4	Gompertz	0.01	0.47	0.71	47.60	0.52	10.11	17.04	0.38
ES	5	10	Gompertz	0.01	2204.84	2237.88	505.80	2204.84	96.43	96.43	3.64
FI	2	10	logistic	0.05	154.35	163.79	258.80	154.35	85.75	85.75	1.93
FR	5	10	Gompertz	0.01	3482.76	3519.71	599.20	3482.76	97.56	97.56	7.62
HR	2	9	Gompertz	0.01	1.44	2.26	109.90	1.45	17.09	17.23	0.60
HU	10	10	Gompertz	0.01	297.41	299.00	842.60	297.41	79.72	79.72	7.05
IE	10	9;9	Gompertz	0.05	2923.56	4712.51	107.70	4277.25	95.51	95.51	0.86
IT	2	10;10	tanh	0.01	1278.24	1287.76	713.30	1278.24	95.02	95.02	9.73
LT	2	8;8;8	Gompertz	0.01	-0.05	0.09	15.70	0.08	-7.95	9.98	0.08
LU	2	9	logistic	0.01	575.90	583.76	529.70	575.90	79.76	79.76	6.46
LV	2	4	tanh	0.05	-0.31	0.35	64.40	0.31	-52.84	52.84	0.77
NL	5	9	Gompertz	0.1	41690.33	53927.86	136.50	41690.33	97.06	97.06	1.16
NO	3	10	tanh	0.1	130.00	134.78	328.00	130.00	81.59	81.59	4.06
PL	3	10	logistic	0.01	151.50	178.14	164.70	151.50	82.58	82.58	1.65
PT	10	2	tanh	0.01	85.35	115.05	125.30	85.41	58.02	58.47	0.52
RO	2	10;10	tanh	0.01	20.62	34.52	108.00	20.62	37.80	37.80	0.93
SE	10	10	logistic	0.01	759.26	809.89	248.90	759.26	92.82	92.82	1.78
SI	10	4	logistic	0.01	0.55	1.15	81.00	0.60	12.46	17.97	0.28
SK	5	10	tanh	0.1	10.69	14.04	132.90	10.70	47.44	47.66	0.57
UK	5	7	Gompertz	0.1	16640.95	17563.63	270.80	16640.95	98.20	98.20	1.43
MT	10	7	logistic	0.01	49.16	118.02	89.80	67.78	68.86	72.81	0.63
IS	2	10	tanh	0.05	-0.79	1.01	24.10	0.87	11.29	23.53	0.25





11 priedas. Ekstremalaus mokymosi mašinų geriausių modelių prognozavimo rezultatai

Šalis	Struktūra	tipas	Regressors	ME	RMSE	NRMSE	MAE	MPE	MAPE	MASE
AT	7:7	lm	Yes	0.19	28.28	206.00	22.48	-926.90	926.90	2.46
BE	9:2:9	lm	Yes	-11.11	15.57	50.10	11.64	26.15	40.07	0.43
BG	8:3:8	step	No	-0.18	0.37	65.40	0.31	-8.80	18.22	0.34
CH	4:7:4	lasso	No	10.39	44.04	85.00	30.47	59.78	63.63	0.47
CZ	9:8:9	step	Yes	0.83	2.12	60.70	1.39	5.98	15.10	0.30
DE	6:4:6	lm	Yes	-3.42	10.06	52.10	6.79	-6.61	12.39	0.31
DK	7:2:7	lm	Yes	-0.79	6.73	69.70	4.72	64.05	64.05	0.56
EE	3:3:3	lm	Yes	-0.42	0.48	47.00	0.42	-32.58	32.91	0.30
ES	3:5:3	lm	Yes	-3.98	5.57	49.10	4.68	-13.67	15.42	0.27
FI	2:2:2	lasso	Yes	0.51	8.06	85.90	7.16	44.64	91.03	0.64
FR	7:3:7	lm	Yes	-4.91	6.23	39.80	4.91	-21.64	21.64	0.29
HR	4:8:4	lm	Yes	-0.12	0.36	25.30	0.24	-22.62	26.01	0.11
HU	5:2:5	step	No	-13.94	20.28	66.60	13.94	-40.97	66.35	0.45
IE	9:7:9	lasso	No	-11.63	37.69	47.80	22.60	3.65	19.39	0.26
IT	8:6:8	lm	Yes	-1.69	5.22	63.90	4.14	-46.98	59.47	0.52
LT	6:5:6	lm	Yes	-0.03	0.10	48.30	0.09	-4.12	11.94	0.44
LU	2:9:2	step	No	2.09	10.94	20.10	7.15	-10.09	30.78	0.17
LV	10:10:10	step	Yes	-0.07	0.11	33.80	0.09	-7.56	10.09	0.41
NL	4:4	step	Yes	-52.40	74.02	90.80	59.15	-27.53	30.35	0.62
NO	6:2:6	step	Yes	6.70	13.26	80.10	9.71	-38.33	68.98	0.63
PL	2:5:2	lm	Yes	0.63	2.51	31.40	2.01	-2.47	16.55	0.24
PT	10:10:10	step	No	3.08	6.73	95.60	4.24	1.27	37.06	0.54
RO	4:2:4	step	Yes	-0.43	0.82	68.10	0.49	-7.90	9.32	0.61
SE	4:4	step	Yes	-2.72	4.52	64.60	3.22	-0.74	49.50	0.42
SI	7:7:7	lm	No	0.57	0.78	100.50	0.63	11.68	80.47	1.28
SK	8:9:8	lm	Yes	-0.66	1.18	63.00	1.04	-115.93	115.93	0.57
UK	9:9:9	lm	Yes	14.75	32.12	33.40	16.45	6.05	9.80	0.27
MT	8:7:8	lm	Yes	0.71	1.05	72.60	0.84	53.14	119.75	0.52
IS	6:9:6	lm	Yes	-0.05	0.43	48.30	0.29	24.31	27.45	0.34


12 priedas. Geriausių modelių prognozavimo rezultatai kiekvienai tyrime nagrinėjamai šaliai








RO prognozavimo rezultatai




SE prognozavimo rezultatai




SI prognozavimo rezultatai



SK prognozavimo rezultatai



UK prognozavimo rezultatai



13 priedas. Tiesioginių užsienio investicijų 2018 metais didėjimo / mažėjimo žemėlapis

- 2018 metais TUI mažėja
- 2018 metais TUI didėja



14 priedas. Python programos kodas šalių investicijų klasifikavimo uždaviniui spręsti

```
from sklearn.ensemble import ExtraTreesClassifier
Class_data = pd.read_csv('Klasifikavimo duomenys.csv')
Y = Class_data['FDI'].values
Class_data.drop(['geo', 'time', 'FDI', "FDI_GDP", "Unemp_Rate", "INF", "EC_GR"], axis=1, inplace=True)
X = Class_data
model = ExtraTreesClassifier(n_estimators=1000)
model.fit(X_train, Y_train)
print(model.feature_importances_) #use inbuilt class feature_importances of tree based classifiers
#plot graph of feature importances for better visualization
feat_importances = pd.Series(model.feature_importances_, index=X_train.columns)
feat_importances.nlargest(20).plot(kind='barh')
plt.show()

max_feat = feat_importances.nlargest(5)
varsn = pd.DataFrame({'Var':max_feat.index, 'Importance':max_feat.values})
features5 = varsn["Var"]
max_feat = feat_importances.nlargest(10)
varsn = pd.DataFrame({'Var':max_feat.index, 'Importance':max_feat.values})
features10 = varsn["Var"]
max_feat = feat_importances.nlargest(20)
varsn = pd.DataFrame({'Var':max_feat.index, 'Importance':max_feat.values})
features20 = varsn["Var"]

X.loc[:, X.columns.isin(features20)]

Class_data = pd.read_csv('Klasifikavimo duomenys.csv')
Y = Class_data['FDI'].values
Class_data.drop(['geo', 'time', 'FDI', "FDI_GDP", "Unemp_Rate", "INF", "EC_GR"], axis=1, inplace=True)
X = Class_data

from sklearn.model_selection import StratifiedShuffleSplit

sss = StratifiedShuffleSplit(n_splits=1, test_size=0.2, random_state=0)
sss.get_n_splits(X, Y)
for train_index, test_index in sss.split(X, Y):
    print("TRAIN:", train_index, "TEST:", test_index)

msk = np.random.rand(len(Class_data)) < 0.8
X_train = X.loc[train_index,]
X_test = X.loc[test_index,]
Y_train = Y[train_index]
Y_test = Y[test_index]

import timeit
from sklearn.model_selection import train_test_split
from keras import Sequential
from keras.layers import Dense
from keras.layers import Dropout
from sklearn.model_selection import StratifiedKFold
import numpy as np
import pandas as pd

# METRICS
from sklearn.metrics import accuracy_score
from sklearn.metrics import auc
from sklearn.metrics import roc_curve
from sklearn.metrics import confusion_matrix
from sklearn.metrics import classification_report
from sklearn.metrics import average_precision_score
from sklearn.metrics import balanced_accuracy_score
from sklearn.metrics import f1_score
from sklearn.metrics import fbeta_score
from sklearn.metrics import hamming_loss
from sklearn.metrics import hinge_loss
from sklearn.metrics import log_loss
from sklearn.metrics import matthews_corrcoef
from sklearn.metrics import precision_score
from sklearn.metrics import recall_score
from sklearn.metrics import roc_auc_score
from sklearn.metrics import zero_one_loss
# SCALLERS
from sklearn.preprocessing import StandardScaler
from sklearn.preprocessing import RobustScaler
from sklearn.preprocessing import MinMaxScaler
from time import gmtime, strftime
from keras.callbacks import ModelCheckpoint
```

```

Results = pd.DataFrame(columns=['Act func','Initializer','Nodes number',
                              "Scaler","Layers","Features","Dropout Layers",
                              "Dropout Rate","Batch size",
                              'Validation Accuracy',
                              "Validation Accuracy Std dev","Test Accuracy",
                              "Test AUC","Balanced accuracy","F1 score",
                              "F-Beta score","Hamming loss","Hinge Loss",
                              "Log loss","Matthews Corr","Precision",
                              "Recall","Roc Auc score","Zero One Loss",
                              "Time"
])
features_no = ["All","20","10","5"]
drops_perc = [0.1,0.2,0.5]
drops = ["None","One","Two","Three"]
layers = ["None","One","Two","Three"]
scalers = ["Standard","Robust","MinMax"]
act_func = ["relu", "sigmoid", "tanh"]
initializer = ["random_normal"] #Insert random uniform initializer for other initialization
nodes_n = [100,200,500] #Insert 50 for lower node number
batches = [32] #Insert 1 for stochastic gradient descent and len(X_train) for all data in same time
epochs = 100
k_folds = 5
Model_no = 1
seed = 7
Total_models =
len(features_no)*len(drops_perc)*len(drops)*len(layers)*len(scalers)*len(act_func)*len(initializer)*
len(nodes_n)*len(batches)

for features in features_no:
    if (features=="All"):
        X = X_train
        Y = Y_train

    if (features=="20"):
        X = X_train.loc[:, X.columns.isin(features20)]
        X_test = X_test.loc[:, X.columns.isin(features20)]
        Y = Y_train

    if (features=="10"):
        X = X_train.loc[:, X.columns.isin(features10)]
        X_test = X_test.loc[:, X.columns.isin(features10)]
        Y = Y_train

    if (features=="5"):
        X = X_train.loc[:, X.columns.isin(features5)]
        X_test = X_test.loc[:, X.columns.isin(features5)]
        Y = Y_train

    for scaler in scalers:

        if (scaler=="Standard"):
            sc = StandardScaler()
            X = sc.fit_transform(X)
            X_test = sc.transform(X_test)

        if (scaler=="Robust"):
            sc = RobustScaler()
            X = sc.fit_transform(X)
            X_test = sc.transform(X_test)

        if (scaler=="MinMax"):
            sc = MinMaxScaler(feature_range=(0, 1))
            X = sc.fit_transform(X)
            X_test = sc.transform(X_test)

        for layer in layers:
            for drop in drops:
                for drop_perc in drops_perc:
                    if (drop == "None") and ((drop_perc == "0.2") or (drop_perc == "0.5")) :
                        Model_no = Model_no +
len(features_no)*len(layers)*len(scalers)*len(act_func)*len(initializer)*len(nodes_n)*len(batches)
                        continue
                    for init in initializer:
                        for i in act_func:
                            Results.to_csv("Results/{}.csv".format(strftime("%Y_%m_%d_%H_%M_%S",
gmtime()))))

                            for batch in batches:
                                for node in nodes_n:

print("=====")

```



```

print("Model {} of {}".format(Model_no, Total_models))
print("=====")
print("Activation function used: {}".format(i))
print("Nodes used: {}".format(node))
print("Batch size used: {}".format(batch))
print("Initializer used: {}".format(init))
print("Dropout layers used: {}".format(drop))
print("Dropout percentage used: {}".format(drop_perc))
print("Layer used: {}".format(layer))
print("Scaler used: {}".format(scaler))
print("Features used: {}".format(features))
print("=====")

kfold = StratifiedKFold(n_splits=k_folds, shuffle=True, random_state=seed)
                        cvscores = []
                        fold = 1

classifier = Sequential()
#First Hidden Layer
classifier.add(Dense(node, activation=i, kernel_initializer=init, input_dim=X.shape[1]))
#Second Hidden Layer
if (layer=="One") or (layer=="Two") or (layer=="Three"):
classifier.add(Dense(node, activation=i, kernel_initializer=init))
if (drops=="One") or (drops=="Two") or (drops=="Three"):
classifier.add(Dropout(drop_perc))
#Second Hidden Layer
if (layer=="Two") or (layer=="Three"):
classifier.add(Dense(node, activation=i, kernel_initializer=init))
if (drops=="Two") or (drops=="Three"):
classifier.add(Dropout(drop_perc))
#Output Layer
if (layer=="Three"):
classifier.add(Dense(node, activation=i, kernel_initializer=init))
if (drops=="Three"):
classifier.add(Dropout(drop_perc))
classifier.add(Dense(1, activation='sigmoid', kernel_initializer=init))
#Compiling the neural network
classifier.compile(optimizer='adam', loss='binary_crossentropy', metrics=['accuracy'])

checkpointer = ModelCheckpoint(filepath="weight.hdf5", verbose=0, save_best_only=True,
monitor='val_acc', mode='max')

start = timeit.default_timer()
for train, valid in kfold.split(X, Y):
#Fitting the data to the training dataset
#classifier.fit(X[train], Y[train], batch_size=10, epochs=epochs, validation_split=0.2,
callbacks=[checkpointer])
classifier.fit(X[train], Y[train], batch_size=batch, validation_data=(X[valid], Y[valid]),
epochs=epochs, callbacks=[checkpointer])

# evaluate the model
scores = classifier.evaluate(X[valid], Y[valid], verbose=0)

print("%s: %.2f%%" % (classifier.metrics_names[1], scores[1]*100))
cvscores.append(scores[1] * 100)

print("=====")
print("KFold fold {} finished".format(fold))
print("=====")
fold = fold + 1
print("%.2f%% (+/- %.2f%%)" % (np.mean(cvscores), np.std(cvscores)))
classifier.load_weights('weight.hdf5')
y_pred=classifier.predict(X_test)
y_pred = (y_pred>0.5)
cm = confusion_matrix(Y_test, y_pred)
print(cm)
accuracy_score(Y_test, y_pred)
fpr, tpr, thresholds = roc_curve(Y_test, y_pred, pos_label=2)
Results = Results.append({'Act func': i, "Initializer":init, "Nodes number": node, "Scaler":scaler,
"Layers":layer, "Features":features, "Dropout Layers":drop, "Dropout Rate":drop_perc, "Batch
size":batch, 'Validation Accuracy': np.mean(cvscores), "Validation Accuracy Std
dev":np.std(cvscores), "Test Accuracy":accuracy_score(Y_test, y_pred)*100, "Test AUC": auc(fpr,
tpr),
"Balanced accuracy":balanced_accuracy_score(Y_test, y_pred), "F1 score" : f1_score (Y_test, y_pred),
"F-Beta score":fbeta_score(Y_test, y_pred,2), "Hamming loss":hamming_loss(Y_test, y_pred), "Hinge
Loss":hinge_loss(Y_test, y_pred), "Log loss":log_loss(Y_test, y_pred), "Matthews Corr":
matthews_corrcoef(Y_test, y_pred), "Precision":precision_score(Y_test, y_pred),
Recall":recall_score(Y_test, y_pred), "Roc Auc score":roc_auc_score(Y_test, y_pred), "Zero One
Loss":zero_one_loss(Y_test, y_pred), "Time": timeit.default_timer() - start}, ignore_index=True)

Model_no = Model_no + 1

```

14 priedas. Pagrindinis R programos kodas šalių TUI prognozuoti

```
library(forecast)
library(eurostat)
library(neuralnet)
library(hydroGOF)
library(xts)
library(nnfor)
library(rnn)
source("min-max norm.R")
source("CalcMASE.R")
library(ica)
Full_dataset <- read.csv("Full.csv")
colnames(Full_dataset)[1] <-"geo"
# -----
# Pradiniai nustatymai
# -----
# Training percentage
train_perc = 0.7
# Nustatomos visos šalys esančios duomenų rinkinyje
countries <- as.character(unique(Full_dataset$geo))
countries <- c("LT")
# Nustatomas neuronų skaičius kiekviename sluoksnyje (min-max reikšmė)
i_min = 2
i_max = 10
# Sukuriamos naujos matricos á kurias bus árašomi tarpiniai ir galutiniai rezultatai
acc_mean = NULL
Accuracy <- NULL
es_accuracy <- NULL
myResults=NULL
err = NULL
aggResults <- NULL
# Nustatomi papildomi kintantys rodikliai
ex_regressors <- c("Use X regressors","Do not use X regressors")
Data_reduct <- c("PCA","No","ICA")
tries = 1
layers = c("1","2","3")
# RNN, LSTM, GRU analizė
train_start = floor(nrow(duom)*train_perc)
start = min(duom$time)
end = max(duom$time)
n = end-(start+train_start)
duom$Life_exp <- as.numeric(as.character(duom$Life_exp))
model_no = 1
country_no = 1
countries_tot = length(countries)
start_time = Sys.time()
All_X_results <- NULL
for (p in seq(1, (length(countries)),1)) {
  CountryResults <- NULL
  duom <- Full_dataset[Full_dataset$geo==countries[p],]
  duom$Life_exp <- as.numeric(as.character(duom$Life_exp))
  train_start = floor(nrow(duom)*train_perc)
  start = min(duom$time)
  end = max(duom$time)
  n = end-(start+train_start)
  # Normlizavimo perdarymas pagal train ir test duomenis
  what <- duom[1:train_start,]
  # PABAIGA
  datanorm <- as.data.frame(lapply(duom[, -c(1,2, which(colnames(duom)=="FDI"))], normalize))
  datanorm <- datanorm[colSums(!is.na(datanorm)) > 0]
  Y <- as.data.frame(duom$FDI)
  colnames(Y) <- "FDI"
  datanorm <- cbind(Y, datanorm)
  if ("3" %in% layers){
    for (i in seq(i_min, i_max, 1)){
      for (tipas in c("lstm", "gru", "rnn")){
        for (act in c("tanh", "logistic", "Gompertz")){
          for (lr in c(0.1, 0.05, 0.01)){
            hidden = c(i, i, i)
            sluoksniai = length(hidden)
            if (length(hidden)==3){
              strukt = paste(as.character(hidden)[1],
                            as.character(hidden)[2],
                            as.character(hidden)[3],
                            sep=";")
            }
          }
          err = NULL
          for (m in seq(1, (n-1), 1)){
```

```

Y <- data.matrix(datanorm[, which( colnames(datanorm)=="FDI")])
X <- data.matrix(datanorm[,-which( colnames(datanorm)=="FDI")])
# Train and test data sets
Y_train <- data.matrix(Y[c(-m),])
X_train <- data.matrix(X[c(-m),])
Y_test <- data.matrix(Y[m,])
X_test <- t(data.matrix(X[m,]))
# Matrix formatting as [samples, timesteps, features]
XT <- array(c(X),dim=c(NROW(X),1,NCOL(X)))
YT <- array(c(Y),dim=c(NROW(X),1,NCOL(Y)))
XT_train <- array(c(X_train),dim=c(NROW(X_train),1,NCOL(X_train)))
YT_train <- array(c(Y_train),dim=c(NROW(X_train),1,NCOL(Y_train)))
XT_test <- array(c(X_test),dim=c(NROW(X_test),1,NCOL(X_test)))
YT_test <- array(c(Y_test),dim=c(NROW(X_test),1,NCOL(Y_test)))
# Training
model <- trainr(X=XT_train,Y=YT_train,network_type =
tipas,learningrate=lr,hidden_dim=hidden,numepochs=10,sigmoid = act)
# Predicting test set
Yp <- predictr(model,XT_test)
prediction <- Yp*(max(duom$FDI)-min(duom$FDI))+min(duom$FDI)
actual <- Y_test*(max(duom$FDI)-min(duom$FDI))+min(duom$FDI)
df <-data.frame(countries[p],m,prediction,actual)
myResults <-rbind(myResults,df)
err <-rbind(err,data.frame(prediction,actual))
acc <- accuracy(err$prediction,err$actual)
NRMSE <- nrmse(err$prediction,err$actual)
MASE <- calculateMASE(err$prediction,err$actual)
df <-data.frame(countries[p],Data_reduct[2],"-",sluoksniai,struk,
tipas,act,lr,acc[1],acc[2],NRMSE,acc[3],acc[4],acc[5],MASE)
colnames(df) <-c("Country","Data reduction","DR no","Sluoksnio
sk.,"Struktura","tipas","Act func","Lr","ME","RMSE","NRMSE","MAE","MPE","MAPE","MASE")
aggResults <-rbind(aggResults,df)
CountryResults <- rbind(CountryResults,df)
All_X_results <- rbind(All_X_results,df)
print(paste0(country_no," of ",countries_tot," country.,"Model ended: ",model_no, "
of 729"))
    model_no = model_no + 1
  }
}
}
}
if ("2" %in% layers){
  for (i in seq(i_min,i_max,1)){
    for (tipas in c("lstm","gru","rnn")){
      for (act in c("tanh","logistic","Gompertz")){
        for(lr in c(0.1,0.05,0.01)){
          hidden = c(i,i)
          sluoksniai = length(hidden)
          if (length(hidden)==2){
            strukt = paste(as.character(hidden)[1],
                          as.character(hidden)[2],
                          sep=";")
          }
          err = NULL
          for (m in seq(1,(n-1),1)){
            #TODO: Implement RNN, LTSM and GRU methods into this cycle
            Y <- data.matrix(datanorm[, 1])
            X <- data.matrix(datanorm[,c(-1)])
            # Train and test data sets
            Y_train <- data.matrix(Y[c(-m),])
            X_train <- data.matrix(X[c(-m),])
            Y_test <- data.matrix(Y[m,])
            X_test <- t(data.matrix(X[m,]))
            # Matrix formatting as [samples, timesteps, features]
            XT <- array(c(X),dim=c(NROW(X),1,NCOL(X)))
            YT <- array(c(Y),dim=c(NROW(X),1,NCOL(Y)))
            XT_train <- array(c(X_train),dim=c(NROW(X_train),1,NCOL(X_train)))
            YT_train <- array(c(Y_train),dim=c(NROW(X_train),1,NCOL(Y_train)))
            XT_test <- array(c(X_test),dim=c(NROW(X_test),1,NCOL(X_test)))
            YT_test <- array(c(Y_test),dim=c(NROW(X_test),1,NCOL(Y_test)))
            # Training
            model <- trainr(X=XT_train,Y=YT_train,network_type =
tipas,learningrate=lr,hidden_dim=hidden,numepochs=10,sigmoid = act)
            # Predicting test set
            Yp <- predictr(model,XT_test)
            prediction <- Yp*(max(duom$FDI)-min(duom$FDI))+min(duom$FDI)
            actual <- Y_test*(max(duom$FDI)-min(duom$FDI))+min(duom$FDI)
            df <-data.frame(countries[p],m,prediction,actual)
            myResults <-rbind(myResults,df)

```

```

        err <-rbind(err,data.frame(prediction,actual))}
    acc <- accuracy(err$prediction,err$actual)
    NRMSE <- nrmse(err$prediction,err$actual)
    MASE <- calculateMASE(err$prediction,err$actual)
    df <-data.frame(countries[p],Data_reduct[2],"-",sluoksniai,strukt,
tipas,act,lr,acc[1],acc[2],NRMSE,acc[3],acc[4],acc[5],MASE)
    colnames(df) <-c("Country","Data reduction","DR no","Sluoksnio
sk.,"Struktûra","tipas","Act func","Lr","ME","RMSE","NRMSE","MAE","MPE","MAPE","MASE")
    aggResults <-rbind(aggResults,df)
    CountryResults <- rbind(CountryResults,df)
    All_X_results <- rbind(All_X_results,df)
    print(paste0(country_no," of ",countries_tot," country.,"Model ended: ",model_no, " of
729"))
    model_no = model_no + 1
    }
    }
    }
    }
}
if ("1" %in% layers){
  for (i in seq(i_min,i_max,1)){
    for (tipas in c("lstm","gru","rnn")){
      for (act in c("tanh","logistic","Gompertz")){
        for (lr in c(0.1,0.05,0.01)){
          hidden = c(i)
          sluoksniai = length(hidden)
          if (length(hidden)==1){
            strukt = paste(as.character(hidden)[1],
                          sep=";")
          }
          err = NULL
          for (m in seq(1,(n-1),1)){
            #TODO: Implement RNN, LTSM and GRU methods into this cycle
            Y <- data.matrix(datanorm[, 1])
            X <- data.matrix(datanorm[,c(-1)])
            # Train and test data sets
            Y_train <- data.matrix(Y[c(-m),])
            X_train <- data.matrix(X[c(-m),])
            Y_test <- data.matrix(Y[m,])
            X_test <- t(data.matrix(X[m,]))
            # Matrix formatting as [samples, timesteps, features]
            XT <- array(c(X),dim=c(NROW(X),1,NCOL(X)))
            YT <- array(c(Y),dim=c(NROW(X),1,NCOL(Y)))
            XT_train <- array(c(X_train),dim=c(NROW(X_train),1,NCOL(X_train)))
            YT_train <- array(c(Y_train),dim=c(NROW(X_train),1,NCOL(Y_train)))
            XT_test <- array(c(X_test),dim=c(NROW(X_test),1,NCOL(X_test)))
            YT_test <- array(c(Y_test),dim=c(NROW(X_test),1,NCOL(Y_test)))
            # Training
            model <- trainr(X=XT_train,Y=YT_train,network_type =
tipas,learningrate=lr,hidden_dim=hidden,numepochs=10,sigmoid = act)
            # Predicting test set
            Yp <- predictr(model,XT_test)
            prediction <- Yp*(max(duom$FDI)-min(duom$FDI))+min(duom$FDI)
            actual <-Y_test*(max(duom$FDI)-min(duom$FDI))+min(duom$FDI)
            df <-data.frame(countries[p],m,prediction,actual)
            myResults <-rbind(myResults,df)
            err <-rbind(err,data.frame(prediction,actual))}
          acc <- accuracy(err$prediction,err$actual)
          NRMSE <- nrmse(err$prediction,err$actual)
          MASE <- calculateMASE(err$prediction,err$actual)
          df <-data.frame(countries[p],Data_reduct[2],"-",sluoksniai,strukt,
tipas,act,lr,acc[1],acc[2],NRMSE,acc[3],acc[4],acc[5],MASE)
          colnames(df) <-c("Country","Data reduction","DR no","Sluoksnio
sk.,"Struktûra","tipas","Act func","Lr","ME","RMSE","NRMSE","MAE","MPE","MAPE","MASE")
          aggResults <-rbind(aggResults,df)
          CountryResults <- rbind(CountryResults,df)
          All_X_results <- rbind(All_X_results,df)
          print(paste0(country_no," of ",countries_tot," country.,"Model ended: ",model_no, " of
729"))
          model_no = model_no + 1
        }
      }
    }
  }
}
write.csv(CountryResults, paste("NN/",countries[p],"_NN_ALL_X_results",".csv", sep=""))
country_no = country_no + 1
}
write.csv(All_X_results,"All_X_results.csv")
Sys.time() - start_time

```

```

# RNN, LSTM, GRU analizė panaudojant PCA (pagrindines komponentes)
duom <- Full_dataset
duom$Life_exp <- as.numeric(as.character(duom$Life_exp))
train_start = floor(nrow(duom)*train_perc)
start = min(duom$time)
end = max(duom$time)
n = end-(start+train_start)
acc_mean = NULL
Accuracy <- NULL
es_accuracy <- NULL
myResults=NULL
err = NULL
ex_regressors <- c("Use X regressors","Do not use X regressors")
duom$Life_exp <- as.numeric(as.character(duom$Life_exp))
total_models = length(countries)*length(layers)*(i_max-i_min)*3*3*4
model_no = 1
country_no = 1
start_time = Sys.time()
PCA_results <- NULL
for (p in seq(1,(length(countries)),1)) {
  CountryResults <- NULL
  duom <- Full_dataset[Full_dataset$geo==countries[p],]
  duom$Life_exp <- as.numeric(as.character(duom$Life_exp))
  train_perc = 0.7
  train_start = floor(nrow(duom)*train_perc)
  start = min(duom$time)
  end = max(duom$time)
  n = end-(start+train_start)
  datanorm <- as.data.frame(lapply(duom[,c(-1,-2)], normalize))
  datanorm <- datanorm[colsSums(!is.na(datanorm)) > 0]
  Y <- as.data.frame(duom$FDI)
  colnames(Y)<-"FDI"
  # PCA implementation into analysis
  pca_info = 0.9
  datanorm <- subset(datanorm, select=-c(FDI))
  principal <- prcomp(datanorm, scale. = TRUE)
  pca_no = 0
  sum = 0
  total = sum(principal$sdev^2)
  for (pca_no in seq(1,dim(principal$x)[2],1)){
    sum = sum + principal$sdev[pca_no]^2
    if (sum/total > pca_info) {
      break
    }
    pca_no = pca_no +1
  }
  PCA_number = as.character(pca_no)
  PCA_number
  X <- principal$x[,1:pca_no]
  datanorm <- as.data.frame(lapply(as.data.frame(X), normalize))
  datanorm <- cbind(Y, datanorm)
  if ("3" %in% layers){
    for (i in seq(i_min,i_max,1)){
      for (tipas in c("lstm","gru","rnn")){
        for (act in c("tanh","logistic","Gompertz")){
          for(lr in c(0.1,0.05,0.01)){
            hidden = c(i,i,i)
            sluoksniai = length(hidden)
            if (length(hidden)==3){
              strukt = paste(as.character(hidden)[1],
                             as.character(hidden)[2],
                             as.character(hidden)[3],
                             sep=";")
            }
          }
        }
      }
      err = NULL
      for (m in seq(1,(n-1),1)){
        #TODO: Implement RNN, LTSM and GRU methods into this cycle
        Y <- data.matrix(datanorm[, 1])
        X <- data.matrix(datanorm[, -1])
        # Train and test data sets
        Y_train <- data.matrix(Y[c(-m),])
        X_train <- data.matrix(X[c(-m),])
        Y_test <- data.matrix(Y[m,])
        X_test <- t(data.matrix(X[m,]))
        # Matrix formatting as [samples, timesteps, features]
        XT <- array(c(X),dim=c(NROW(X),1,NCOL(X)))
        YT <- array(c(Y),dim=c(NROW(X),1,NCOL(Y)))
        XT_train <- array(c(X_train),dim=c(NROW(X_train),1,NCOL(X_train)))
        YT_train <- array(c(Y_train),dim=c(NROW(X_train),1,NCOL(Y_train)))
        XT_test <- array(c(X_test),dim=c(NROW(X_test),1,NCOL(X_test)))
      }
    }
  }
}

```

```

        YT_test <- array(c(Y_test),dim=c(NROW(X_test),1,NCOL(Y_test)))
        # Training
        model <- trainr(X=XT_train,Y=YT_train,network_type =
tipas,learningrate=lr,hidden_dim=hidden,numepochs=10,sigmoid = act)
        # Predicting test set
        Yp <- predictr(model,XT_test)
        prediction <- Yp*(max(duom$FDI)-min(duom$FDI))+min(duom$FDI)
        actual <- Y_test*(max(duom$FDI)-min(duom$FDI))+min(duom$FDI)
        df <-data.frame(countries[p],m,prediction,actual)
        myResults <-rbind(myResults,df)
        err <-rbind(err,data.frame(prediction,actual))}
        acc <- accuracy(err$prediction,err$actual)
        NRMSE <- nrmse(err$prediction,err$actual)
        MASE <- calculateMASE(err$prediction,err$actual)
        df <-data.frame(countries[p],Data_reduct[1],PCA_number,sluoksniai,strukt,
tipas,act,lr,acc[1],acc[2],NRMSE,acc[3],acc[4],acc[5],MASE)
        colnames(df) <-c("Country","Data reduction","DR no","Sluoksnio
sk.,"Struktūra","tipas","Act func","Lr","ME","RMSE","NRMSE","MAE","MPE","MAPE","MASE")
        aggResults <-rbind(aggResults,df)
        CountryResults <- rbind(CountryResults,df)
        PCA_results <- rbind(PCA_results,df)
        print(paste0(country_no," of ",countries_tot," country.,"Model ended: ",model_no, "
of 729"))
        model_no = model_no + 1
    }
}
}
}
}
if ("2" %in% layers){
for (i in seq(i_min,i_max,1)){
for (tipas in c("lstm","gru","rnn")){
for (act in c("tanh","logistic","Gompertz")){
for(lr in c(0.1,0.05,0.01)){

        hidden = c(i,i)
        sluoksniai = length(hidden)
        if (length(hidden)==2){
            strukt = paste(as.character(hidden)[1],
                as.character(hidden)[2],
                sep=";")
        }
        err = NULL
        for (m in seq(1,(n-1),1)){
            #TODO: Implement RNN, LTSM and GRU methods into this cycle
            Y <- data.matrix(datanorm[, 1])
            X <- data.matrix(datanorm[,-1])
            # Train and test data sets
            Y_train <- data.matrix(Y[c(-m),])
            X_train <- data.matrix(X[c(-m),])
            Y_test <- data.matrix(Y[m,])
            X_test <- t(data.matrix(X[m,]))

            # Matrix formatting as [samples, timesteps, features]
            XT <- array(c(X),dim=c(NROW(X),1,NCOL(X)))
            YT <- array(c(Y),dim=c(NROW(X),1,NCOL(Y)))
            XT_train <- array(c(X_train),dim=c(NROW(X_train),1,NCOL(X_train)))
            YT_train <- array(c(Y_train),dim=c(NROW(X_train),1,NCOL(Y_train)))
            XT_test <- array(c(X_test),dim=c(NROW(X_test),1,NCOL(X_test)))
            YT_test <- array(c(Y_test),dim=c(NROW(X_test),1,NCOL(Y_test)))
            # Training
            model <- trainr(X=XT_train,Y=YT_train,network_type =
tipas,learningrate=0.1,hidden_dim=hidden,numepochs=10,sigmoid = act)
            # Predicting test set
            Yp <- predictr(model,XT_test)
            prediction <- Yp*(max(duom$FDI)-min(duom$FDI))+min(duom$FDI)
            actual <- Y_test*(max(duom$FDI)-min(duom$FDI))+min(duom$FDI)
            df <-data.frame(countries[p],m,prediction,actual)
            myResults <-rbind(myResults,df)
            err <-rbind(err,data.frame(prediction,actual))}
            acc <- accuracy(err$prediction,err$actual)
            NRMSE <- nrmse(err$prediction,err$actual)
            MASE <- calculateMASE(err$prediction,err$actual)
            df <-data.frame(countries[p],Data_reduct[1],pca_no,sluoksniai,strukt,
tipas,act,lr,acc[1],acc[2],NRMSE,acc[3],acc[4],acc[5],MASE)
            colnames(df) <-c("Country","Data reduction","DR no","Sluoksnio
sk.,"Struktūra","tipas","Act func","Lr","ME","RMSE","NRMSE","MAE","MPE","MAPE","MASE")
            aggResults <-rbind(aggResults,df)
            CountryResults <- rbind(CountryResults,df)

```

```

PCA_results <- rbind(PCA_results,df)
print(paste0(country_no," of ",countries_tot," country.,"Model ended: ",model_no, " of
729"))
    model_no = model_no + 1
  }
}
}
}
}
if ("1" %in% layers){
  for (i in seq(i_min,i_max,1)){
    for (tipas in c("lstm","gru","rnn")){
      for (act in c("tanh","logistic","Gompertz")){
        for(lr in c(0.1,0.05,0.01)){
          hidden = c(i)
          sluoksniai = length(hidden)
          if (length(hidden)==1){
            strukt = paste(as.character(hidden)[1],
                          sep=";")
          }
          err = NULL
          for (m in seq(1,(n-1),1)){
            #TODO: Implement RNN, LTSM and GRU methods into this cycle
            Y <- data.matrix(datanorm[, 1])
            X <- data.matrix(datanorm[,])
            # Train and test data sets
            Y_train <- data.matrix(Y[c(-m),])
            X_train <- data.matrix(X[c(-m),])
            Y_test <- data.matrix(Y[m,])
            X_test <- t(data.matrix(X[m,]))
            # Matrix formatting as [samples, timesteps, features]
            XT <- array(c(X),dim=c(NROW(X),1,NCOL(X)))
            YT <- array(c(Y),dim=c(NROW(X),1,NCOL(Y)))
            XT_train <- array(c(X_train),dim=c(NROW(X_train),1,NCOL(X_train)))
            YT_train <- array(c(Y_train),dim=c(NROW(X_train),1,NCOL(Y_train)))
            XT_test <- array(c(X_test),dim=c(NROW(X_test),1,NCOL(X_test)))
            YT_test <- array(c(Y_test),dim=c(NROW(X_test),1,NCOL(Y_test)))
            # Training
            model <- trainr(X=XT_train,Y=YT_train,network_type =
tipas,learningrate=0.1,hidden_dim=hidden,numepochs=10,sigmoid = act)
            # Predicting test set
            Yp <- predictr(model,XT_test)
            prediction <- Yp*(max(duom$FDI)-min(duom$FDI))+min(duom$FDI)
            actual <- Y_test*(max(duom$FDI)-min(duom$FDI))+min(duom$FDI)
            df <-data.frame(countries[p],m,prediction,actual)
            myResults <-rbind(myResults,df)
            err <-rbind(err,data.frame(prediction,actual)) }
          acc <- accuracy(err$prediction,err$actual)
          NRMSE <- nrmse(err$prediction,err$actual)
          MASE <- calculateMASE(err$prediction,err$actual)
          df <-data.frame(countries[p],Data_reduct[1],pca_no,sluoksniai,strukt,
tipas,act,lr,acc[1],acc[2],NRMSE,acc[3],acc[4],acc[5],MASE)
          colnames(df) <-c("Country","Data reduction","DR no","Sluoksnio
sk.,"Struktūra","tipas","Act func","Lr","ME","RMSE","NRMSE","MAE","MPE","MAPE","MASE")
          aggResults <-rbind(aggResults,df)
          CountryResults <- rbind(CountryResults,df)
          PCA_results <- rbind(PCA_results,df)
          print(paste0(country_no," of ",countries_tot," country.,"Model ended: ",model_no, " of
729"))
            model_no = model_no + 1
          }
        }
      }
    }
  }
}
write.csv(CountryResults, paste("NN/",countries[p],"_NN_PCA_results",".csv", sep=""))
country_no = country_no + 1
}
write.csv(PCA_results,"PCA_results.csv")
Sys.time() - start_time
# RNN, LSTM, GRU analizė panaudojant ICA (nepriklausomos komponentes)
duom <- Full_dataset
duom$Life_exp <- as.numeric(as.character(duom$Life_exp))
train_start = floor(nrow(duom)*train_perc)
start = min(duom$time)
end = max(duom$time)
n = end-(start+train_start)
acc_mean = NULL
Accuracy <- NULL
es_accuracy <- NULL

```

```

myResults=NULL
err = NULL
ex_regressors <- c("Use X regressors","Do not use X regressors")
duom$Life_exp <- as.numeric(as.character(duom$Life_exp))
model_no = 1
country_no = 1
start_time = Sys.time()
ICA_results <- NULL
for (p in seq(1,(length(countries)),1)) {
  CountryResults <- NULL
  duom <- Full_dataset[Full_dataset$geo==countries[p],]
  duom$Life_exp <- as.numeric(as.character(duom$Life_exp))
  train_perc = 0.7
  train_start = floor(nrow(duom)*train_perc)
  start = min(duom$time)
  end = max(duom$time)
  n = end-(start+train_start)
  for (ica_no in c(2,3,5,10)){
    datanorm <- as.data.frame(lapply(duom[,c(-1,-2)], normalize))
    datanorm <- datanorm[colSums(!is.na(datanorm)) > 0]
    Y <- as.data.frame(duom$FDI)
    colnames(Y) <- "FDI"
    # ICA implementation into analysis
    ica <- icafast(datanorm, nc=ica_no)
    datanorm <- subset(datanorm, select=-c(FDI))
    datanorm <- as.data.frame(lapply(as.data.frame(ica$S), normalize))
    datanorm <- cbind(Y, datanorm)
    if ("3" %in% layers){
      for (i in seq(i_min,i_max,1)){
        for (tipas in c("lstm","gru","rnn")){
          for (act in c("tanh","logistic","Gompertz")){
            for(lr in c(0.1,0.05,0.01)){
              hidden = c(i,i,i)
              sluoksniai = length(hidden)
              if (length(hidden)==3){
                strukt = paste(as.character(hidden)[1],
                              as.character(hidden)[2],
                              as.character(hidden)[3],
                              sep=";")
              }
            }
          }
        }
      }
    }
    err = NULL
    for (m in seq(1,(n-1),1)){
      #TODO: Implement RNN, LTSM and GRU methods into this cycle
      Y <- data.matrix(datanorm[, 1])
      X <- data.matrix(datanorm[, -1])
      # Train and test data sets
      Y_train <- data.matrix(Y[c(-m),])
      X_train <- data.matrix(X[c(-m),])
      Y_test <- data.matrix(Y[m,])
      X_test <- t(data.matrix(X[m,]))
      # Matrix formatting as [samples, timesteps, features]
      XT <- array(c(X),dim=c(NROW(X),1,NCOL(X)))
      YT <- array(c(Y),dim=c(NROW(X),1,NCOL(Y)))
      XT_train <- array(c(X_train),dim=c(NROW(X_train),1,NCOL(X_train)))
      YT_train <- array(c(Y_train),dim=c(NROW(X_train),1,NCOL(Y_train)))
      XT_test <- array(c(X_test),dim=c(NROW(X_test),1,NCOL(X_test)))
      YT_test <- array(c(Y_test),dim=c(NROW(X_test),1,NCOL(Y_test)))
      # Training
      model <- trainr(X=XT_train,Y=YT_train,network_type =
tipas,learningrate=lr,hidden_dim=hidden,numepochs=10,sigmoid = act)
      # Predicting test set
      Yp <- predictr(model,X_test)
      prediction <- Yp*(max(duom$FDI)-min(duom$FDI))+min(duom$FDI)
      actual <- Y_test*(max(duom$FDI)-min(duom$FDI))+min(duom$FDI)
      df <-data.frame(countries[p],m,prediction,actual)
      myResults <-rbind(myResults,df)
      err <-rbind(err,data.frame(prediction,actual))
    }
    acc <- accuracy(err$prediction,err$actual)
    NRMSE <- nrmse(err$prediction,err$actual)
    MASE <- calculateMASE(err$prediction,err$actual)
    df <-data.frame(countries[p],Data_reduct[3],as.character(ica_no),sluoksniai,strukt,
tipas,act,lr,acc[1],acc[2],NRMSE,acc[3],acc[4],acc[5],MASE)
    colnames(df) <-c("Country","Data reduction","DR no","Sluoksniai
sk.," "Struktūra","tipas","Act func","Lr","ME","RMSE","NRMSE","MAE","MPE","MAPE","MASE")
    aggResults <-rbind(aggResults,df)
    CountryResults <- rbind(CountryResults,df)
    ICA_results <- rbind(ICA_results,df)
    print(paste0(country_no," of ",countries_tot," country.," "Model ended: ",model_no, "
of 2916"))
  }
}

```



```

        model_no = model_no + 1
    }
}
}
}
}
if ("2" %in% layers){
  for (i in seq(i_min,i_max,1)){
    for (tipas in c("lstm","gru","rnn")){
      for (act in c("tanh","logistic","Gompertz")){
        for(lr in c(0.1,0.05,0.01)){
          hidden = c(i,i)
          sluoksniai = length(hidden)
          if (length(hidden)==2){
            strukt = paste(as.character(hidden)[1],
                          as.character(hidden)[2],
                          sep=";")
          }
          err = NULL
          for (m in seq(1,(n-1),1)){
            #TODO: Implement RNN, LTSM and GRU methods into this cycle
            Y <- data.matrix(datanorm[, 1])
            X <- data.matrix(datanorm[,-1])
            # Train and test data sets
            Y_train <- data.matrix(Y[c(-m),])
            X_train <- data.matrix(X[c(-m),])
            Y_test <- data.matrix(Y[m,])
            X_test <- t(data.matrix(X[m,]))
            # Matrix formatting as [samples, timesteps, features]
            XT <- array(c(X),dim=c(NROW(X),1,NCOL(X)))
            YT <- array(c(Y),dim=c(NROW(X),1,NCOL(Y)))
            XT_train <- array(c(X_train),dim=c(NROW(X_train),1,NCOL(X_train)))
            YT_train <- array(c(Y_train),dim=c(NROW(X_train),1,NCOL(Y_train)))
            XT_test <- array(c(X_test),dim=c(NROW(X_test),1,NCOL(X_test)))
            YT_test <- array(c(Y_test),dim=c(NROW(X_test),1,NCOL(Y_test)))
            # Training
            model <- trainr(X=XT_train,Y=YT_train,network_type =
            tipas,learningrate=0.1,hidden_dim=hidden,numepochs=10,sigmoid = act)
            # Predicting test set
            Yp <- predictr(model,XT_test)
            prediction <- Yp*(max(duom$FDI)-min(duom$FDI))+min(duom$FDI)
            actual <- Y_test*(max(duom$FDI)-min(duom$FDI))+min(duom$FDI)
            df <-data.frame(countries[p],m,prediction,actual)
            myResults <-rbind(myResults,df)
            err <-rbind(err,data.frame(prediction,actual))
          }
          acc <- accuracy(err$prediction,err$actual)
          NRMSE <- nrmse(err$prediction,err$actual)
          MASE <- calculateMASE(err$prediction,err$actual)
          df <-data.frame(countries[p],Data_reduct[3],as.character(ica_no),sluoksniai,strukt,
            tipas,act,lr,acc[1],acc[2],NRMSE,acc[3],acc[4],acc[5],MASE)
          colnames(df) <-c("Country","Data reduction","DR no","Sluoksnio
            sk.,"Struktūra","tipas","Act func","Lr","ME","RMSE","NRMSE","MAE","MPE","MAPE","MASE")
          aggResults <-rbind(aggResults,df)
          CountryResults <- rbind(CountryResults,df)
          ICA_results <- rbind(ICA_results,df)

          print(paste0(country_no," of ",countries_tot," country.,"Model ended: ",model_no, "
            of 2916"))
          model_no = model_no + 1
        }
      }
    }
  }
}
}
}
if ("1" %in% layers){
  for (i in seq(i_min,i_max,1)){
    for (tipas in c("lstm","gru","rnn")){
      for (act in c("tanh","logistic","Gompertz")){
        for(lr in c(0.1,0.05,0.01)){
          hidden = c(i)
          sluoksniai = length(hidden)
          if (length(hidden)==1){
            strukt = paste(as.character(hidden)[1],
                          sep=";")
          }
          err = NULL
          for (m in seq(1,(n-1),1)){
            #TODO: Implement RNN, LTSM and GRU methods into this cycle
            Y <- data.matrix(datanorm[, 1])
            X <- data.matrix(datanorm[,])

```

```

# Train and test data sets
Y_train <- data.matrix(Y[c(-m),])
X_train <- data.matrix(X[c(-m),])
Y_test <- data.matrix(Y[m,])
X_test <- t(data.matrix(X[m,]))
# Matrix formatting as [samples, timesteps, features]
XT <- array(c(X), dim=c(NROW(X), 1, NCOL(X)))
YT <- array(c(Y), dim=c(NROW(X), 1, NCOL(Y)))
XT_train <- array(c(X_train), dim=c(NROW(X_train), 1, NCOL(X_train)))
YT_train <- array(c(Y_train), dim=c(NROW(X_train), 1, NCOL(Y_train)))
XT_test <- array(c(X_test), dim=c(NROW(X_test), 1, NCOL(X_test)))
YT_test <- array(c(Y_test), dim=c(NROW(X_test), 1, NCOL(Y_test)))
# Training
model <- trainr(X=XT_train, Y=YT_train, network_type =
tipas, learningrate=0.1, hidden_dim=hidden, numepochs=10, sigmoid = act)
# Predicting test set
Yp <- predictr(model, XT_test)
prediction <- Yp*(max(duom$FDI) - min(duom$FDI)) + min(duom$FDI)
actual <- Y_test*(max(duom$FDI) - min(duom$FDI)) + min(duom$FDI)
df <- data.frame(countries[p], m, prediction, actual)
myResults <- rbind(myResults, df)
err <- rbind(err, data.frame(prediction, actual))
acc <- accuracy(err$prediction, err$actual)
NRMSE <- nrmse(err$prediction, err$actual)
MASE <- calculateMASE(err$prediction, err$actual)
df <- data.frame(countries[p], Data_reduct[3], as.character(ica_no), sluoksniai, strukt,
tipas, act, lr, acc[1], acc[2], NRMSE, acc[3], acc[4], acc[5], MASE)
colnames(df) <- c("Country", "Data reduction", "DR no", "Sluoksniø
sk.", "Struktūra", "tipas", "Act func", "Lr", "ME", "RMSE", "NRMSE", "MAE", "MPE", "MAPE", "MASE")
aggResults <- rbind(aggResults, df)
CountryResults <- rbind(CountryResults, df)
ICA_results <- rbind(ICA_results, df)
print(paste0(country_no, " of ", countries_tot, " country.", "Model ended: ", model_no, "
of 2916"))
model_no = model_no + 1
}
}
}
}
}
write.csv(CountryResults, paste("NN/", countries[p], "_NN_ICA_results", ".csv", sep=""))
country_no = country_no + 1
}
Sys.time() - start_time
write.csv(ICA_results, "ICA_results.csv")
# Iðvedami galutiniai rezultatai á failà
write.csv(aggResults, "Results.csv")
# ELM MODELLING
duom <- Full_dataset
train_perc = 0.7
train_start = floor(nrow(duom)*train_perc)
start = min(duom$time)
end = max(duom$time)
start+train_start
n = end-(start+train_start)
countries <- as.character(unique(Full_dataset$geo))
countries <- countries[11:length(countries)]
# Setting parameters
i_min = 2
i_max = 10
j_min = 2
j_max = 10
acc_mean = NULL
Accuracy <- NULL
es_accuracy <- NULL
myResults=NULL
err = NULL
aggResults <- NULL
ex_regressors <- c("Use X regressors", "Do not use X regressors")
tries = 10
layers = c("1", "2", "3")
for (p in seq(1, (length(countries)), 1)) {
CountryResults <- NULL
duom <- Full_dataset[Full_dataset$geo==countries[p],]
train_perc = 0.7
train_start = floor(nrow(duom)*train_perc)
start = min(duom$time)
end = max(duom$time)
n = end-(start+train_start)

```

```

datanorm <- as.data.frame(lapply(duom[,-c(1,2,which(colnames(duom)=="FDI"))], normalize))
datanorm <- datanorm[colSums(!is.na(datanorm)) > 0]
Y <- as.data.frame(duom$FDI)
colnames(Y) <- "FDI"
what <- cbind(Y, datanorm)
if ("3" %in% layers){
  for (i in seq(i_min, i_max, 1)){
    for (j in seq(j_min, j_max, 1)){
      for (tipas in c("lasso", "ridge", "step", "lm")){
        hidden = c(i, j, i)
        sluoksniai = length(hidden)
        if (length(hidden)==3){
          strukt = paste(as.character(hidden)[1],
                        as.character(hidden)[2],
                        as.character(hidden)[3],
                        sep=";")
        }

        err = NULL
        for (m in seq(0, (n-1), 1)){
          train <- ts(what[1:(start+m)], start=start, end=(start+train_start+m))
          test <- ts(what[train_start+m+1,], start=(start+train_start+1+m),
end=(start+train_start+1+m))
          laiko_reg <- ts(what, start=start, end=end)
          try(fit <- elm(train[,1], xreg=laiko_reg[, -1], type=tipas, reps=tries, hd=hidden))
          print(fit)
          try(frc <- forecast(fit, h=1, xreg=laiko_reg[, -1]))
          # plot(frc)
          prediction <- frc$mean
          actual <- test[,1]
          #df <-data.frame(countries[1], i, j, k, m, frc$mean, test[,2])
          #myResults <-rbind(myResults, df)
          err <-rbind(err, data.frame(prediction = as.numeric(prediction), actual =
as.numeric(actual)))
        }
        ex_regs = "Yes"
        acc <- accuracy(err$prediction, err$actual)
        NRMSE <- nrmse(err$prediction, err$actual)
        MASE <- calculateMASE(err$prediction, err$actual)
        df <-data.frame(countries[p], sluoksniai, strukt, tipas, ex_regs,
acc[1], acc[2], NRMSE, acc[3], acc[4], acc[5], MASE)
        colnames(df) <-c("Country", "Sluoksniai", "Struktūra", "tipas", "Regressors", "ME", "RMSE", "NRMSE", "MAE", "MPE", "MAPE", "MASE")
        sk.", "Struktūra", "tipas", "Regressors", "ME", "RMSE", "NRMSE", "MAE", "MPE", "MAPE", "MASE")
        aggResults <-rbind(aggResults, df)
        CountryResults <- rbind(CountryResults, df)
        err = NULL
        for (l in seq(0, (n-1), 1)){
          train <- ts(what[1:(start+l)], start=start, end=(start+train_start+l))
          test <- ts(what[train_start+l+1,], start=(start+train_start+1+l),
end=(start+train_start+1+l))
          laiko_reg <- ts(what, start=start, end=end)
          try(fit <- elm(train[,1], type=tipas, reps=tries, hd=hidden))
          print(fit)
          try(frc <- forecast(fit, h=1))
          # plot(frc)
          prediction <- frc$mean
          actual <- test[,1]
          #df <-data.frame(countries[1], i, j, k, m, frc$mean, test[,2])
          #myResults <-rbind(myResults, df)
          err <-rbind(err, data.frame(prediction = as.numeric(prediction), actual =
as.numeric(actual)))
        }
        ex_regs = "No"
        acc <- accuracy(err$prediction, err$actual)
        NRMSE <- nrmse(err$prediction, err$actual)
        MASE <- calculateMASE(err$prediction, err$actual)
        df <-
data.frame(countries[p], sluoksniai, strukt, tipas, ex_regs, acc[1], acc[2], NRMSE, acc[3], acc[4], acc[5], MAS
E)
        colnames(df) <-c("Country", "Sluoksniai", "Struktūra", "tipas", "Regressors", "ME", "RMSE", "NRMSE", "MAE", "MPE", "MAPE", "MASE")
        sk.", "Struktūra", "tipas", "Regressors", "ME", "RMSE", "NRMSE", "MAE", "MPE", "MAPE", "MASE")
        aggResults <-rbind(aggResults, df)
        CountryResults <- rbind(CountryResults, df)
      }
    }
  }
}

# 2 LAYERS EXTREME LEARNING MACHINE
if ("2" %in% layers){

```

```

for (i in seq(i_min,i_max,1)){
  for (tipas in c("lasso","ridge","step","lm")){
    hidden = c(i,i)
    sluoksniai = length(hidden)
    if (length(hidden)==2){
      strukt = paste(as.character(hidden)[1],
                    as.character(hidden)[2],
                    sep=";")
    }
    err = NULL
    for (m in seq(0,(n-1),1)){
      train <- ts(what[1:(start+m)],, start=start, end=(start+train_start+m))
      test <- ts(what[train_start+m+1,], start=(start+train_start+1+m),
end=(start+train_start+1+m))
      laiko_reg <- ts(what, start=start, end=end)
      try(fit <- elm(train[,1], xreg=laiko_reg[,-1], type=tipas, reps=tries, hd=hidden))
      print(fit)
      try(frc <- forecast(fit, h=1, xreg=laiko_reg[,-1]))
      # plot(frc)
      prediction <- frc$mean
      actual <- test[,1]
      #df <-data.frame(countries[1],i,j,k,m,frc$mean,test[,2])
      #myResults <-rbind(myResults,df)
      err <-rbind(err,data.frame(prediction = as.numeric(prediction),actual =
as.numeric(actual)))
    }
    ex_regs = "Yes"
    acc <- accuracy(err$prediction,err$actual)
    NRMSE <- nrmse(err$prediction,err$actual)
    MASE <- calculateMASE(err$prediction,err$actual)
    df <-data.frame(countries[p],sluoksniai,strukt,tipas,ex_regs,
acc[1],acc[2],NRMSE,acc[3],acc[4],acc[5],MASE)
    colnames(df) <-c("Country","Sluoksnio
sk.,""Struktūra","tipas","Regressors","ME","RMSE","NRMSE","MAE","MPE","MAPE","MASE")
    aggResults <-rbind(aggResults,df)
    CountryResults <- rbind(CountryResults, df)
    err = NULL
    for (l in seq(0,(n-1),1)){
      train <- ts(what[1:(start+l)],, start=start, end=(start+train_start+l))
      test <- ts(what[train_start+l+1,], start=(start+train_start+l+1),
end=(start+train_start+l+1))
      laiko_reg <- ts(what, start=start, end=end)
      try(fit <- elm(train[,1], type=tipas, reps=tries, hd=hidden))
      print(fit)
      try(frc <- forecast(fit, h=1))
      # plot(frc)
      prediction <- frc$mean
      actual <- test[,1]
      #df <-data.frame(countries[1],i,j,k,m,frc$mean,test[,2])
      #myResults <-rbind(myResults,df)
      err <-rbind(err,data.frame(prediction = as.numeric(prediction),actual =
as.numeric(actual)))
    }
    ex_regs = "No"
    acc <- accuracy(err$prediction,err$actual)
    NRMSE <- nrmse(err$prediction,err$actual)
    MASE <- calculateMASE(err$prediction,err$actual)
    df <-
data.frame(countries[p],sluoksniai,strukt,tipas,ex_regs,acc[1],acc[2],NRMSE,acc[3],acc[4],acc[5],MAS
E)
    colnames(df) <-c("Country","Sluoksnio
sk.,""Struktūra","tipas","Regressors","ME","RMSE","NRMSE","MAE","MPE","MAPE","MASE")
    aggResults <-rbind(aggResults,df)
    CountryResults <- rbind(CountryResults, df)
  }
}
}
# 1 LAYER EXTREME LEARNING MACHINE
if ("1" %in% layers){
  for (i in seq(i_min,i_max,1)){
    for (tipas in c("lasso","ridge","step","lm")){
      hidden = c(i)
      sluoksniai = length(hidden)
      if (length(hidden)==1){
        strukt = as.character(hidden[1])
      }
      err = NULL
      for (m in seq(0,(n-1),1)){
        train <- ts(what[1:(start+m)],, start=start, end=(start+train_start+m))

```

```

        test <- ts(what[train_start+m+1,], start=(start+train_start+1+m),
end=(start+train_start+1+m))
        laiko_reg <- ts(what, start=start, end=end)
        try(fit <- elm(train[,1], xreg=laiko_reg[,-1], type=tipas, reps=tries, hd=hidden))
        print(fit)
        try(frc <- forecast(fit, h=1, xreg=laiko_reg[,-Y_no]))
        # plot(frc)
        prediction <- frc$mean
        actual <- test[,1]
        #df <-data.frame(countries[1],i,j,k,m,frc$mean,test[,2])
        #myResults <-rbind(myResults,df)
        err <-rbind(err,data.frame(prediction = as.numeric(prediction),actual =
as.numeric(actual)))
    }
    ex_regs = "Yes"
    acc <- accuracy(err$prediction,err$actual)
    NRMSE <- nrmse(err$prediction,err$actual)
    MASE <- calculateMASE(err$prediction,err$actual)
    df <-data.frame(countries[p],sluoksniai,strukt,tipas,ex_regs,
acc[1],acc[2],NRMSE,acc[3],acc[4],acc[5],MASE)
    colnames(df) <-c("Country","Sluoksnio
sk.,"Struktūra","tipas","Regressors","ME","RMSE","NRMSE","MAE","MPE","MAPE","MASE")
    aggResults <-rbind(aggResults,df)
    CountryResults <- rbind(CountryResults, df)
    err = NULL
    for (l in seq(0, (n-1),1)){
        train <- ts(what[1:(start+1),], start=start, end=(start+train_start+1))
        test <- ts(what[train_start+1+l,], start=(start+train_start+1+l),
end=(start+train_start+1+l))
        laiko_reg <- ts(what, start=start, end=end)
        try(fit <- elm(train[,1], type=tipas, reps=tries, hd=hidden))
        print(fit)
        try(frc <- forecast(fit, h=1))
        # plot(frc)
        prediction <- frc$mean
        actual <- test[,1]
        #df <-data.frame(countries[1],i,j,k,m,frc$mean,test[,2])
        #myResults <-rbind(myResults,df)
        err <-rbind(err,data.frame(prediction = as.numeric(prediction),actual =
as.numeric(actual)))
    }
    ex_regs = "No"
    acc <- accuracy(err$prediction,err$actual)
    NRMSE <- nrmse(err$prediction,err$actual)
    MASE <- calculateMASE(err$prediction,err$actual)
    df <-
data.frame(countries[p],sluoksniai,strukt,tipas,ex_regs,acc[1],acc[2],NRMSE,acc[3],acc[4],acc[5],MAS
E)
    colnames(df) <-c("Country","Sluoksnio
sk.,"Struktūra","tipas","Regressors","ME","RMSE","NRMSE","MAE","MPE","MAPE","MASE")
    aggResults <-rbind(aggResults,df)
    CountryResults <- rbind(CountryResults, df)
}
}
}
write.csv(CountryResults, paste("ELM/",countries[p],"_ELM_results",".csv", sep=""))
}
write.csv(aggResults, "ELM/ELM_results.csv")

```

15 priedas. Tiesiogines užsienio investicijas į šalį lemiančios veiksnių grupės, veiksniai ir rodikliai

-	Veiksnių grupė	Veiksniai	Rodikliai
Ekonominis patrauklumas	Ekonomikos pažanga	Ekonomikos gyvybingumas	Ekonomikos augimo tempas (%) Bendras vidaus produktas (\$) Bendras vidaus produktas tenkantis vienam gyventojui Bendro vidaus produkto tenkančio vienam gyventojui augimo tempas (%) Prekybos atvirumas (\$) BVP tenkanti vienam gyventojui įvertinant PPP Infliacija (vartotojų kainų indeksas) Infliacija Pirkimo galios paritetas (angl. <i>purchasing power parity</i>) Mažmeninės prekybos apyvartos indeksas (2010 metai = 100 %) Pramonės pridėtinė vertė (% visos pridėtinės vertės) Gamybos pridėtinė vertė (% visos pridėtinės vertės) Paslaugų pridėtinė vertė (% visos pridėtinės vertės) Grynoji palūkanų marža (%) Vartotojų kainų indeksas (angl. <i>consumer price index</i>)
		Esamas investavimo lygis	Tiesioginės užsienio investicijos Tiesioginės užsienio investicijos vienam gyventojui Kapitalo investicijos Kapitalo investicijos (% BVP) Turto grąža Nuosavybės grąža Investicijų laisvės indeksas (angl. <i>investment freedom</i>)
	Verslo ir mokesstinė aplinka	Verslo laisvė	Verslo laisvės indeksas (angl. <i>business freedom</i>)
		Verslo pradžios sudėtingumas	Verslo pradžios indeksas (angl. <i>starting business</i>) Procedūros norint pradėti verslą Laikas norint pradėti verslą Kaštai norint pradėti verslą Minimalus kapitalas pradedant verslą
		Verslo statybos sudėtingumas	Darbo su statybos leidimais indeksas Darbo su statybos leidimais procedūrų skaičius Darbo su statybos leidimais laikas Darbo su statybos leidimais kaštai
		Turto registravimo sudėtingumas	Nuosavybės registravimo indeksas Nuosavybės registravimo procedūrų skaičius Nuosavybės registravimo laikas Nuosavybės registravimo kaštai Nuosavybės teisės indeksas
		Verslo mokesčių našta	Mokesčių mokėjimo indeksas (angl. <i>paying taxes</i>) Mokesčių mokėjimas (skaičius per metus) Mokėjimo mokesčiai (valandos per metus) Mokesčių mokestis, bendras mokesčių tarifas (% pelno) Mokesčių mokestis pelno mokestis (% pelno) Mokesčių mokestis darbo mokestis ir įmokos (% pelno) Mokesčių mokėjimas kiti mokesčiai (% pelno) Įmonių mokesčio tarifas (angl. <i>corporate tax rate</i>) Mokestinės naštos indeksas (angl. <i>tax burden</i>)
		Verslo uždarymo sudėtingumas	Verslo uždarymo indeksas Verslo uždarymo laikas Uždarymo verslo kaina (% nuo turto) Įmonės susigrąžinimo rodiklis (\$)
		Rinkos perkamoji galia	Namų ūkio pajamos
	Namų ūkio išlaidos		Namų ūkių vartojimas (% BVP) Namų ūkių vartojimas (\$)
	Socialinės atsakomybės išsivystymo lygis	Nusikalstamumo lygis	Žmogžudystės 100 000 žmonių Apiplėšimai 100 000 žmonių Kalinių skaičius 100 000 žmonių
		Pajamų nelygė	Vyriausybės išlaidos skiriamos socialiniai apsaugai (% BVP)
		Nelaimingi atsitikimai darbe	Nelaimingi atsitikimai darbe 100000 žmonių

	Ekonomikos atvirumas	Ekonomikos integralumas su užsienio rinkomis	Narystė euro zonoje (1 – taip, 0 – ne) Narystė Europos sąjungoje (1 – taip, 0 – ne) Narystė Šengeno erdvėje (1 – taip, 0 – ne) Ekonominės laisvės indeksas Eksportas (% BVP) Eksportas (\$) Eksportas (\$ vienam gyventojui) Eksporto augimo tempas (%) Prekybos balansas (% BVP) Importas (% BVP) Importas (\$) Ekonomikos globalizacijos indeksas Prekybos globalizacijos indeksas Importas (\$ vienam gyventojui) Prekybos laisvės indeksas (angl. <i>trade freedom</i>) Globalizacijos indeksas Sandorio sąlygos (angl. <i>terms of trade</i>)
		Turistinis patrauklumas	Turistų skaičius šalyje
		Socialinė globalizacija	Socialinės globalizacijos indeksas Tarpasmeninės globalizacijos indeksas
	Finansų rinkos išvystymas	Finansų sistemos išsivystymo lygis	Finansinės globalizacijos indeksas
		Bankų sistemos stabilumas	Bankų koncentracija Bankų Z-įvertinimas (angl. <i>bank Z-score</i>) Banko kreditas privačiam sektoriui Banko turtas (% BVP) Vidaus kreditas privačiam sektoriui Likvidus turtas (% BVP)
		Finansinė laisvė	Finansinės laisvės indeksas (angl. <i>financial freedom</i>) Vietinės valiutos kursas lyginant su dolerio kursu Pinigų laisvės indeksas (angl. <i>monetary freedom</i>)
Politinis patrauklumas	Šalies politinis įvaizdis	Politinis stabilumas	Politinis stabilumas / smurto ir terorizmo nebuvimas (angl. <i>political stability / absence of violence / terrorism</i>)
		Korupcijos lygis	Korupcijos kontrolės indeksas (angl. <i>control of corruption</i>) Korupcijos suvokimo indeksas (angl. <i>corruption perceptions index</i>)
	Šalies valdymo efektyvumas	Vyriausybės išlaidos	Vyriausybės išlaidos (angl. <i>government spending</i>) (% BVP) Vyriausybės išlaidos skiriamos būsto ir bendruomenės patogumui (angl. <i>housing and community amenities</i>) (% BVP) Vyriausybės išlaidos skiriamos ekonomikos reikalams (angl. <i>economic affairs</i>) (% BVP) Vyriausybės išlaidos skiriamos rekreacijai, kultūrai ir religijai (angl. <i>recreation, culture and religion</i>) (% BVP)
		Vyriausybės vientisumas	Vyriausybės vientisumo indeksas (angl. <i>government integrity</i>)
		Valdžios efektyvumas	Valdžios efektyvumo indeksas (angl. <i>government effectiveness</i>) Balsavimo ir atskaitomybės indeksas (angl. <i>voice and accountability</i>) Įstatymų taisyklių indeksas (angl. <i>rule of law</i>) Politinės globalizacijos indeksas Reguliavimo kokybės indeksas (angl. <i>regulatory quality</i>) Politinės teisės indeksas (angl. <i>political rights</i>) Pilietinės laisvės indeksas (angl. <i>civil liberties</i>) Pajamos iš pridėtinės vertės mokesčio Šešėlinė ekonomika (angl. <i>shadow economy</i>) (%) Pajamos gaunamos iš surenkamųjų mokesčių
Technologinis patrauklumas	Inovacijų diegimo lygis	Inovacijų sistemos funkcionalumas	Inovatyvumo indeksas Informacijos globalizacijos indeksas Aukštųjų technologijų eksportas (\$) Aukštųjų technologijų eksportas (% nuo viso gamybos eksporto) Informacinių technologijų eksportas (% eksporto)
		Verslo produktyvumo lygis	Realus darbo našumo rodiklis tenkantis 1 asmeniui Realus darbo našumo rodiklis tenkantis 1 darbo valandai
	Infrastruktūros išsivystymo lygis	IKT išsivystymas	Interneto vartotojai (% gyv.) Interneto abonentai (abonentai 100 gyv.) Fiksuoto ryšio telefonų naudojimas (% gyv.) IKT infrastruktūros mobiliųjų telefonų abonentai (% gyv.) Plačiajuosčio interneto abonentai (% gyv.)

		Šalies pasiekiamumas (oru, sausuma ir vandeniui)	Kelių transporto kokybė Oro transporto kokybė Vandens transporto kokybė
Aplinkos patrauklumas	Geografinė aplinka	Geografinė padėtis	Žemės plotas (kv. km.)
		Gamtos išteklių potencialas	Miško plotas (kv. km.) Pajamos iš gamtos išteklių nuomos (% of GDP)
	Ekologinė aplinka	Atsinaujinančioji energetika	Atsinaujinančios energijos suvartojimas (% viso suvartojimo) Atsinaujinančios energijos gamyba
		Aplinkos užterštumas	Šiltnamio dujų emisija (tūkst. t.) CO2 emisija (tūkst. t.) Vyriausybės išlaidos skiriamos aplinkos apsaugai (% BVP)
Socialinis ir kultūrinis patrauklumas	Darbo rinkos patrauklumas	Darbo vietos kaina	Pridėtinės darbo sąnaudos Darbo sąnaudų indeksas (2012=100 %)
		Darbo jėgos kvalifikacija	Darbo jėga turinti vidurinį ar aukštesnį išsilavinimą (% visos darbo jėgos)
		Darbo jėgos pasiekiamumas	Darbo jėgos dalyvavimas ekonominė veikloje (%) Darbo jėga (žm.) Nedarbo lygis (%) Užimtumas (% gyv.) Jaunų asmenų nedarbo lygis (%) Kultūrinės globalizacijos indeksas
	Demografinė aplinka	Rinkos dydis	Populiacija (žm.) Populiacijos augimo tempas (žm.) Populiacijos augimo tempas (%) Populiacijos augimo tempas mieste (%) Populiacijos augimo tempas kaime (%) Populiacija mieste (% populiacija)
		Gyventojų demografinė sudėtis	65 metų ir vyresni gyventojai (% gyv.) Priklausomi asmenys (vaikai ir pensininkai) (%) Grynoji migracija (asm.)
	Švietimo ir mokymo sistemos kokybė	Švietimo ir mokslo sistemos išvystymo lygis	Asmenys turintys aukštąjį išsilavinimą (5-8 lygiai) (% gyv.) Asmenys turintys 0-2 lygio išsilavinimą (% gyv.) Asmenys turintys 3-8 lygio išsilavinimą (% gyv.) Asmenys turintys 3-4 lygio išsilavinimą (% gyv.) Asmenys dirbantys mokslinių tyrimų ir plėtros srityje Mokslinių tyrimų ir plėtros išlaidos (% BVP)
		Mokslo, verslo ir valdžios bendradarbiavimas	Vyriausybės išlaidos skiriamos švietimui (% BVP) Patentų, kuriuos pateikė rezidentai, skaičius (vnt. / 1000000 gyv.) Vyriausybės mokslinių tyrimų ir plėtros išlaidos (Eur. / gyv., Eur, % BVP) Verslo mokslinių tyrimų ir plėtros išlaidos (Eur. / gyv., Eur, % BVP) Verslo mokslinių tyrimų ir plėtros išlaidos (% BVP) Mokslinių tyrimų ir plėtros išlaidos (Eur / gyv.) Mokslinių tyrimų ir plėtros išlaidos (Eur.)
	Sveikatos apsaugos sistemos išvystymo lygis	Išlaidos sveikatos apsaugai	Vyriausybės išlaidos skiriamos sveikatos apsaugai (% BVP) Sveikatos apsaugos išlaidos tenkančios vienam gyventojui Išlaidos sveikatos apsaugai (% BVP)
		Gyventojų sveikatos lygis	Žmogaus raidos indeksas (angl. <i>human development index</i>) Tikėtina gyvenimo trukmė (angl. <i>life expectancy</i>)

16 priedas. Duomenų vizualizavimo programinis kodas (pateikiamas kompaktiniame diske)

17 priedas. Klasterinės analizės programinis kodas (pateikiamas kompaktiniame diske)

18 priedas. Saviorganizuojančių dirbtinių neuroninių tinklų programinis kodas (pateikiamas kompaktiniame diske)

19 priedas. Prognozavimo remiantis geriausiais modeliais programinis kodas (pateikiamas kompaktiniame diske)

20 priedas. Geriausių prognozavimo modelių sujungimo ir vizualizavimo programinis kodas (pateikiamas kompaktiniame diske)

21 priedas. Tiesinės regresijos modelių kūrimo programinis kodas (pateikiamas kompaktiniame diske)

22 priedas. Naive prognozavimo modelių kūrimo programinis kodas (pateikiamas kompaktiniame diske)

23 priedas. Hipotezių tikrinimas programinis kodas (pateikiamas kompaktiniame diske)

24 priedas. Klasifikavimo duomenys (pateikiamas kompaktiniame diske)

25 priedas. ManLukModelling taikomoji modeliavimo programa (pateikiamas kompaktiniame diske)