



**KAUNO TECHNOLOGIJOS UNIVERSITETAS
MATEMATIKO IR GAMTOS MOKSLŲ FAKULTETAS**

Laura Barkauskaitė

**ŠIAURĖS EUROPOS ŠALIŲ INVESTICINIO PATRAUKLUMO
MODELIAVIMAS NEURONINIAIS TINKLAIS**

Baigiamasis magistro projektas

Vadovai:

Doc. dr. Tomas Ruzgas

Doc. Jurgita Bruneckienė

KAUNAS, 2018

**KAUNO TECHNOLOGIJOS UNIVERSITETAS
MATEMATIKO IR GAMTOS MOKSLŲ FAKULTETAS**

**ŠIAURĖS EUROPOS ŠALIŲ INVESTICINIO PATRAUKLUMO
MODELIAVIMAS NEURONINIAIS TINKLAIS**

Baigiamasis magistro projektas

Didžiųjų verslo duomenų analitika (621G12002)

Vadovai

Dr. Tomas Ruzgas

Doc. Jurgita Bruneckienė

Recenzantai

Dr. Mindaugas Kavaliauskas

Doc. dr. Alina Stundžienė

Projektą atliko

Laura Barkauskaitė

KAUNAS, 2018



KAUNO TECHNOLOGIJOS UNIVERSITETAS
Matematikos ir gamtos mokslų fakultetas

(Fakultetas)

Laura Barkauskaitė

(Studento vardas, pavardė)

Didžiųjų verslo duomenų analitika, 621G12002

(Studijų programos pavadinimas, kodas)

Baigiamojo projekto „Pavadinimas“
AKADEMINIO SAŽININGUMO DEKLARACIJA

20 18 m. Birželio 1 d.
Kaunas

Patvirtinu, kad mano, **Lauros Barkauskaitės**, baigiamasis projektas tema „Šiaurės Europos šalių investicinio patrauklumo modeliavimas 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)

TURINYS

SANTRAUKA	5
LENTELIŲ SĄRAŠAS.....	7
PAVEIKSLĖLIŲ SĄRAŠAS.....	8
TERMINŲ IR SANTRUPŲ ŽODYNAS.....	9
IŠVADAS	10
1. LITERATŪROS APŽVALGA	11
1.1. INVESTICINIO PATRAUKLUMO SAMPRATA.....	11
1.2. INVESTICINIO PATRAUKLUMO VERTINIMO METODŲ APŽVALGA	11
1.2.1. TIESIOGINIŲ UŽSIENIO INVESTICIJŲ IR INVESTICINIO PATRAUKLUMO RYŠYS.....	12
1.2.1.1. TIESIOGINIŲ UŽSIENIO INVESTICIJŲ SAMPRATA IR SVARBA EKONOMIKAI.....	12
1.2.1.2. TIESIOGINIŲ UŽSIENIO INVESTICIJŲ PASISKIRSTYMO TENDENCIJOS	13
1.2.2. INVESTICINIO PATRAUKLUMO INDEKSAI.....	19
1.3. INVESTICINIO PATRAUKLUMO VEIKSNIAI IR JŲ GRUPĖS	22
2. METODŲ ANALIZĖ	24
2.1. KLAŠTERINĖ ANALIZĖ	24
2.2. PAGRINDINIŲ KOMPONENČIŲ ANALIZĖ	27
2.3. NEURONINIAI TINKLAI.....	29
2.4. REKURENTINIAI NEURONINIAI TINKLAI.....	32
2.5. ILGALAIKĖS – TRUMPALAIKĖS ATMINTIES NEURONINIAI TINKLAI	34
2.6. METODŲ VERTINIMAS	36
3. EMPIRINIS TYRIMAS	37
3.1. DUOMENYS	37
3.2. TIESIOGINIŲ UŽSIENIO INVESTICIJŲ KINTAMOJO APŽVALGA	38
3.3. IŠORINIŲ KINTAMŲJŲ PAIEŠKA.....	39
3.4. IŠORINIŲ KINTAMŲJŲ APŽVALGA	40
3.5. VALSTYBIŲ KLAŠTERIZAVIMAS	42
3.6. IŠORINIŲ KINTAMŲJŲ DIMENSIJOS MAŽINIMAS.....	45
3.7. TIESIOGINIŲ UŽSIENIO INVESTICIJŲ PROGNOZAVIMAS NEURONINIAIS TINKLAIS.....	46
3.7.1. TINKAMIAUSIO MOEDLIO PAIEŠKA IR PARAMETRŲ DERINIMAS	46
3.7.2. TIKLIAUSIAI TIESIOGINES UŽSIENIO INVESTICIJAS PROGNOZUOJANTYS MODELIAI.....	49
3.7.3. TIESIOGINIŲ UŽSIENIO INVESTICIJŲ 2017 METAIS PROGNOZAVIMAS.....	50
3.7.4. PROGNOZUOJAMAS PATRAUKLUMO INDEKSAS IR INVESTICINIO PATRAUKLUMO ŽEMĖLAPIS.....	53
IŠVADOS	56
LITERATŪROS SĄRAŠAS	58
PRIEDAI.....	61

Barkauskaitė, Laura. ŠIAURĖS EUROPOS ŠALIŲ INVESTICINIO PATRAUKLUMO MODELIAVIMAS NEURONINIAIS TINKLAIS. *Magistrantūros* baigiamasis projektas / vadovai doc. dr. Tomas Ruzgas ir doc. Jurgita Bruneckienė; Kauno technologijos universitetas, Matematikos ir gamtos mokslų fakultetas.

Studijų kryptis ir sritis (studijų krypčių grupė): Taikomoji matematika (A02), Matematikos mokslai (A)

Reikšminiai žodžiai: *neuroniniai tinklai, regionų investicinio patrauklumo modeliavimas.*

Kaunas, 2018. 57 p.

SANTRAUKA

Valstybės investicinis patrauklumas glaudžiai siejamas su ekonomine ir socialine jos gerove, tad jo modeliavimas – aktualus uždavinys, kuris šiame darbe pradedamas nuo investicinį patrauklumą lemiančių veiksnių išskyrimo. Atlikus literatūros analizę, sudarytas teorinis investicinio patrauklumo modelis iš 13 veiksnių grupių (32 veiksnių). Granger priežastingumo analizės pagalba rastas 61 tiesiogines Šiaurės Europos valstybių pritraukiamas užsienio investicijas veikiantis kiekybinis rodiklis, valstybės sugrupuotos naudojant klasterinę analizę, išorinių kintamųjų skaičius sumažintas pasitelkiant pagrindinių komponentių analizę. Darbe apjungti du dažniausiai naudojami investicinio patrauklumo nustatymo metodai – valstybės pritraukiamų tiesioginių užsienio investicijų lyginimas bei investicinio patrauklumo indekso skaičiavimas. Tiesioginių užsienio investicijų prognozavimui bei investicinio patrauklumo indekso skaičiavimui pasitelkti teoriniame modelyje išskirti kiekybiniai rodikliai. Prognozuojant tiesiogine užsienio investicijas, išmėginti įvairios struktūros bei dydžio neuroniniai tinklai, jų aktyvacijos funkcijos. Geriausio modelio ieškota valstybėms ir išskirtoms jų grupėms atskirai, naudojant tiek visus išorinius kintamuosius, tiek pagrindines komponentes. Remiantis tiksliausiu modeliu (iš tirtų) sudarytos Šiaurės Europos valstybių pritraukiamų tiesioginių užsienio investicijų bei investicinio patrauklumo indekso 2017 metų prognozės, bei remiantis jomis, suformuotas investicinio patrauklumo žemėlapis.

Barkauskaitė, Laura, MODELING OF NORD EUROPE COUNTRIES INVESTMENT ATTRACTIVENESS BY NEURAL NETWORKS: *Master's thesis in applied mathematics / supervisor assoc. prof. Tomas Ruzgas and assoc. Jurgita Bruneckienė. The Faculty of Applied Mathematics and Natural Sciences.*

Study field and area (study field group): Applied Mathematics (A02), Mathematical Sciences (A)

Key words: neural networks, evaluation of location's attractiveness.

Kaunas, 2018. 57 p.

SUMMARY

Investment attractiveness of a country is closely linked to its economic and social well-being, therefore its modeling is an important task, which in this work begins by determining the factors of investment attractiveness. After analyzing the literature, the theoretical model of investment attractiveness has been introduced, containing 13 groups of factors (32 factors). Granger causation analysis have been applied and 61 quantitative indicators that can be linked to the foreign direct investment to Northern Europe countries have been found, also these countries have been grouped using cluster analysis and the number of external variables have been reduced by analysis of key components. In the work, two of the most commonly used methods of investment attractiveness have been used together: the comparison of foreign direct investment and the calculation of the investment attractiveness index. In order to quantify the foreign direct investment and calculate the investment attractiveness index, quantitative indicators in the theoretical model have been used. To forecast foreign direct investment, various neural networks of different structures, sizes, and activation functions have been tested. Models have been constructed for both countries and their groups individually, using all external variables and only core components in order to compare. Using the most precise models (from the ones that have been analyzed), the forecasts of 2017 have been made for foreign direct investment attracted by the Northern Europe countries separately and their investment attractiveness index and based on both forecasts investment attractiveness map of countries have been made.

LENTELIŲ SĄRAŠAS

1.3.1 lentelė. Investicinio patrauklumo veiksniai.....	22
2.1.1 lentelė. Metriniai atstumo matai.....	24
2.1.2 lentelė. Klasterių atstumo matai.....	25
2.3.1 lentelė. Aktyvacijos funkcijos.....	30
2.6.1 lentelė. Paklaidos funkcijos.....	36
3.5.1 lentelė. Klasterių skaičiaus pagal TUI ir BVP parinkimas.....	42
3.5.2 lentelė. Klasterizavimo pagal visus išorinius kintamuosius rezultatai	43
3.5.3 lentelė. Investicinio patrauklumo indeksas regionams	44
3.6.1 lentelė. Pagrindinių komponentių analizės rezultatai – valstybės	45
3.6.2 lentelė. Pagrindinių komponentių analizės rezultatai – regionai.....	45
3.7.1.1 lentelė. FNN valstybėms/regionams – visi išoriniai kintamieji.....	46
3.7.1.2 lentelė. FNN valstybėms/regionams – pagrindinės komponentės.....	47
3.7.1.3 lentelė. RNN valstybėms/regionams – visi išoriniai kintamieji.....	47
3.7.1.4 lentelė. RNN valstybėms/regionams – pagrindinės komponentės.....	48
3.7.1.5 lentelė. LSTM valstybėms/regionams – visi išoriniai kintamieji.....	48
3.7.1.6 lentelė. LSTM valstybėms/regionams – pagrindinės komponentės.....	48
3.7.2.1 lentelė. Tiksliausiai TUI prognozuojantys modeliai ir jų parametrai.....	49
3.7.3.1 lentelė. TUI prognozė 2017 metams.....	52
3.7.4.1 lentelė. Investicinio patrauklumo indeksas – 2017 metų prognozė.....	53

PAVEIKSLĖLIŲ SĄRAŠAS

1.2.1.2.1 pav. TUI kitimas pasaulyje 2006–2016 metais.....	13
1.2.1.2.2 pav. TUI pasiskirstymas pasaulyje 2016 metais.....	14
1.2.1.2.3 pav. TUI kitimas Didžiojoje Britanijoje 2006–2016 metais.....	14
1.2.1.2.4 pav. TUI kitimas Airijoje 2006–2016 metais.....	15
1.2.1.2.5 pav. TUI kitimas Skandinavijos valstybėse 2006–2016 metais.....	15
1.2.1.2.6 pav. TUI kitimas Baltijos valstybėse 2006–2016 metais.....	15
1.2.1.2.7 pav. Vidutiniškai pritraukiamų TUI pasiskirstymas Šiaurės Europos valstybėse.....	16
1.2.2.1 pav. 2017 metų GFICA rezultatai – Šiaurės Europos valstybės.....	20
1.2.2.2 pav. 2017 metų VCPE rezultatai – Šiaurės Europos valstybės.....	20
1.2.2.3 pav. VPV modelis.....	21
1.3.1 pav. Valstybės investicinio patrauklumo modelis – veiksmų grupės.....	23
2.1.1 pav. Klasterizavimo metodų tipai	25
2.1.2 pav. Klasterių artumo matai – artimiausias kaimynas.....	25
2.1.3 pav. Klasterių artumo matai – tolimiausias kaimynas.....	25
2.1.4 pav. Klasterių artumo matai – vidutinė jungtis.....	25
2.1.5 pav. Klasterių artumo matai – centroidas.....	26
2.1.6 pav. k– vidurkių metodo schema.....	26
2.2.1 pav. Pirmoji ir antroji pagrindinės komponentės.....	27
2.3.1 pav. Perceptrono modelis.....	29
2.3.2 pav. Aktyvacijos funkcija – tapatumo.....	30
2.3.3 pav. Aktyvacijos funkcija – dvinarė.....	30
2.3.4 pav. Aktyvacijos funkcija – logistinė.....	30
2.3.5 pav. Aktyvacijos funkcija – hip. tangentas.....	30
2.3.6 pav. Daugiasluoksni neuroninio tinklo sluoksniai.....	31
2.3.7 pav. Signalų kryptis daugiasluoksniame neuroniniame tinkle.....	31
2.4.1 pav. Ciklai rekurentiniuose neuroniniuose tinkluose.....	32
2.4.2 pav. RNN interpretacija.....	33
2.4.3 pav. RNN – nedidelis atotrūkis tarp svarbios informacijos ir jos panaudojimo.....	33
2.4.4 pav. RNN – didelis atotrūkis tarp svarbios informacijos ir jos panaudojimo.....	33
2.5.1 pav. LSTM schema.....	34
2.5.2 pav. LSTM schema – užmiršimo vartų sluoksnis.....	34
2.5.3 pav. LSTM schema – įvesties vartų sluoksnis.....	35
2.5.4 pav. LSTM schema – sukauptų būsenų atnaujinimas.....	35
2.5.5 pav. LSTM schema – išvesties signalas.....	35
3.2.1 pav. TUI statistinė apžvalga.....	38
3.2.2 pav. TUI kitimas 2006–2016 metais	38
3.2.3 pav. TUI stačiakampė diagrama.....	38
3.3.1 pav. Fiksuotų reikšmingų priežastingumų tarp TUI ir išorinių kintamųjų pasiskirstymas.....	39
3.3.2 pav. Fiksuotų vidutinių ir stiprių koreliacijų tarp TUI ir išorinių kintamųjų pasiskirstymas.....	39
3.4.1 pav. BVP pasiskirstymas.....	40
3.4.2 pav. Nedarbo lygis 2006–2016 metais.....	40
3.4.3 pav. Ekonomikos globalizacijos indekso stačiakampė diagrama.....	41
3.4.4 pav. Modernių technologijų eksporto pasiskirstymas.....	41
3.5.1 pav. Klasterizavimas pagal BVP ir TUI.....	42
3.5.2 pav. Klasterių pokyčiai.....	43
3.5.3 pav. Išskirtų valstybių grupių palyginimas.....	44
3.6.1 pav. Pagrindinių komponentių paaiškinama skaida – Danija	45
3.7.2.1 pav. TUI prognozavimo modelis – Švedija	49
3.7.3.1 pav. TUI prognozė 2017 metams – Danija.....	50
3.7.3.2 pav. TUI prognozė 2017 metams – Estija	50
3.7.3.3 pav. TUI prognozė 2017 metams – Suomija	50
3.7.3.4 pav. TUI prognozė 2017 metams – Airija	50
3.7.3.5 pav. TUI prognozė 2017 metams – Islandija	50
3.7.3.6 pav. TUI prognozė 2017 metams – Didžioji Britanija	50
3.7.3.7 pav. TUI prognozė 2017 metams – Lietuva	51
3.7.3.8 pav. TUI prognozė 2017 metams – Latvija	51
3.7.3.9 pav. TUI prognozė 2017 metams – Norvegija	51
3.7.3.10 pav. TUI prognozė 2017 metams – Švedija	51
3.7.3.11 pav. TUI prognozė 2017 metams – Skandinavijos regionas	51
3.7.3.12 pav. TUI prognozė 2017 metams – Baltijos regionas	51
3.7.3.13 pav. TUI pasiskirstymas 2016 ir 2017 metais	52
3.7.4.1 pav. Prognozuojamas investicinio patrauklumo žemėlapis 2017 metais.....	54
3.7.4.2 pav. Prognozuojamų investicinių patrauklumą lemiančių veiksmų valstybėse palyginimas.....	54

TERMINŲ IR SANTRUPŲ ŽODYNAS

TUI	– tiesiogines užsienio investicijas (angl. <i>Foreign Direct Investment</i>)
OECD	– Ekonominio bendradarbiavimo ir plėtros organizacija (angl. <i>Organisation for Economic Co-operation and Development</i>)
IMF	– Tarptautinis valiutos fondas (angl. <i>International Monetary Fund</i>),
IDA	– Tarptautinė plėtros asociacija (angl. <i>International Development Association</i>)
GFICA	– Pasaulinis patrauklumo tiesioginėms užsienio investicijoms indeksas (angl. <i>A Global Foreign Direct Investment Country Attractiveness Index</i>),
VCPE	– Rizikos ir privataus kapitalo šalių patrauklumo indeksas (angl. <i>The Venture Capital & Private Equity Country Attractiveness Index</i>)
VPV	– vietovės patrauklumo verslo plėtrai sumanaus vystymosi kontekste veiksniai
ML	– mašininis mokymasis (angl. <i>machine learning</i>)
ANN	– dirbtiniai neuroniniai tinklai (angl. <i>artificial neural networks</i>)
FNN	– tiesioginio ryšio neuroniniai tinklai (angl. <i>feedforward neural networks</i>)
RNN	– rekurentiniai neuroniniai tinklai (angl. <i>recurrent neural networks</i>)
BP	– klaidos skleidimas atgal (angl. <i>backpropagation</i>)
LSTM	– ilgalaikės – trumpalaikės atminties tinklai (angl. <i>Long Short Term Memory networks</i>)
MSE	– vidutinė kvadratinė paklaida (angl. <i>mean square error</i>)
RMSE	– šaknis iš vidutinės kvadratinės paklaidos (angl. <i>root mean square error</i>)
MPE	– vidutinė procentinė paklaida (angl. <i>mean percentage error</i>)
MAPE	– vidutinė absoliutinė procentinė paklaida (angl. <i>mean absolute percentage error</i>)
MASE	– vidutinė absoliutinė normuota paklaida (angl. <i>mean absolute scaled error</i>)
BVP	– bendras vidaus produktas (angl. <i>Gross Domestic Product</i>)

ĮVADAS

Darbo problematika ir aktualumas. Dinamiška ir konkurencinga verslo aplinka, kintantys vartotojų poreikiai, globalizacija, technologinė pažanga – tai tik keletas faktorių, skatinančių verslininkus ieškoti naujų investavimo galimybių užsienio valstybėse. Valstybių pritraukiamas užsienio kapitalas glaudžiai siejamas su ekonomine bei socialine valstybės gerove – jis sąlygoja ūkio konkurencingumo augimą, greitesnį modernių technologijų įsisavinimą, finansinį stabilumą, tarpvalstybinių ryšių tvirtumą. Dėl šių priežasčių svarbu nustatyti, kas lemia valstybės patrauklumą investuotojams. Investicinis patrauklumas suprantamas kaip tam tikrų veiksmų rinkinys, suteikiantis didesnę konkurencinę pranašumą verslo plėtrai. Nors pritraukiamas užsienio investicijas nusakančius kiekybinius rodiklius palyginti nesunku, tačiau veiksmų, sąlygojančių juos ir investicinį patrauklumą, išskyrimas tampa gana sudėtingu uždaviniu, kuris būtinas norint prognozuoti investicinį patrauklumą bei jį atspindinčius kiekybinius rodiklius.

Darbo tikslas ir uždaviniai. Darbo tikslas yra, sudarius teorinį investicinio patrauklumo veiksmų modelį bei remiantis neuroninių tinklų prognozavimo modeliais, sudaryti Šiaurės Europos valstybių pritraukiamas tiesiogines užsienio investicijas prognozuojančius modelius. Darbo tikslui pasiekti buvo iškelti tokie uždaviniai:

1. Atlikus investicinio patrauklumo sampratos ir jį lemiančių veiksmų bei vertinimo metodų analizę, sudaryti investicinį patrauklumą atspindinčių veiksmų teorinį modelį bei, suradus investicinio patrauklumo veiksmus atspindinčius kiekybinius rodiklius, suformuoti duomenų matricą.
2. Tiriamoje Šiaurės Europos regiono valstybių aibėje išskirti panašų investicinį patrauklumą turinčių valstybių grupes.
3. Sumažinti investicinį patrauklumą atspindinčių kiekybinių rodiklių aibę juos apjungiant.
4. Sudaryti investicinį patrauklumą atspindinčių tiesioginių užsienio investicijų prognozavimo modelį kiekvienai valstybei bei valstybių grupei naudojantis neuroniniais tinklais.
5. Palyginti Šiaurės Europos valstybių prognozuojamą investicinį patrauklumą bei tiesiogines užsienio investicijas ir išskirti bendras investicinio patrauklumo bei investavimo tendencijas, svarbias priimant strateginius siūlymus.

Darbo struktūra. Darbą sudaro trys dalys. Literatūros analizėje (1 skyrelis) trumpai aptariama investicinio patrauklumo samprata, vertinimo metodikos bei sudaromas teorinis investicinio patrauklumo veiksmų modelis. Metodų apžvalgoje (2 skyrelis) pristatomi darbe taikyti metodai: klasterinė ir pagrindinių komponentų analizė, neuroniniai tinklai. Tyrimo rezultatus (3 skyrelis) sudaro septynios dalys. Čia aptariami tyrime naudoti duomenų šaltiniai, kintamųjų paieška bei apžvalga, regionų išskyrimas, išorinių kintamųjų dimensijos mažinimas, geriausio prognozavimo modelio paieška bei investicinio patrauklumo modeliavimas.

1. LITERATŪROS APŽVALGA

1.1. INVESTICINIO PATRAUKLUMO SAMPRATA

Kintanti verslo aplinka lemia didėjantį verslininkų bei investuotojų poreikį analizuoti bei vertinti vietovių, kuriose vykdoma ar galima verslo plėtra, patrauklumą [1]. Vietovės pasirinkimą lemia įvairūs aspektai: rinkų, reikalingų išteklių, informacijos, technologijų prieinamumas, vyraujanti konkurencinė aplinka, darbo jėgos kaina, politinis stabilumas ir daug kitų. Šie aspektai kinta priklausomai nuo tikslinės grupės – verslininkų, investuotojų poreikių ir lūkesčių – tačiau apibendrintai vietovės patrauklumas verslo ir investicinių įplaukų pritraukimo kontekste gali būti suprantamas kaip ekonominių, socialinių, teisinių, politinių, technologinių, geografinių, infrastruktūrinių, teritorinių veiksnių rinkinys, suteikiantis didesnę konkurencinę pranašumą konkrečiau verslo plėtrai toje vietovėje lyginant ją su kitomis [1]. Kai kurie tyrėjai taip pat pabrėžia, jog investicinis patrauklumas nėra tik šių veiksnių rinkinys – tai vietovės sugebėjimas pritraukti investicijas bei verslą, pasinaudojant tam tikromis veiksnių kombinacijomis [2].

Svarbu paminėti, jog patrauklumas nėra statinė koncepcija. Tai procesas [1]. Analizuojant ir vertinant vietovės patrauklumą verslo plėtrai, suvokiamas šios charakteristikos kitimas laike. Tam tikroms tikslinėms grupėms – verslininkams, investuotojams, įmonėms – vietovė gali atrodyti tinkama verslo plėtojimui esamuoju laiku, tačiau ateityje pasirodyti nebepatraukli. Tai numačiusios ir įvertinusios tikslinės grupės išsikels kitur arba vietovės nepasirinks – vietovė galimai neteks investicijų, žmogiškojo ar technologinio kapitalo. Kadangi investicijų bei verslo plėtros pritraukimas yra viena iš būtinų sąlygų, reikalingų norint užtikrinti ekonominę bei socialinę vietovės gerovę ir verslo konkurencingumą, tinkamas ir pakartotinis vietovės investicinio patrauklumo vertinimas tampa būtinas, norint strategiškai bei tikslingai planuoti vietovės investicinio patrauklumo išlaikymą bei didinimą.

1.2. INVESTICINIO PATRAUKLUMO VERTINIMO METODŲ APŽVALGA

Investicinio vietovės patrauklumo įvertinimas yra svarbus žingsnis, norint analizuoti, prognozuoti ir kontroliuoti investicinius srautus. Tik žinant esamojo laiko ir ateityje prognozuojamą regiono investicinį patrauklumą, galima formuoti jo investicinio patrauklumo išlaikymo ir didinimo strategiją. Nagrinėjant literatūrą, pastebėtos šios autorių taikomos investicinio patrauklumo vertinimo metodikos:

- regionų pritraukiamų tiesioginių užsienio investicijų lyginimas;
- regionų investicinio patrauklumo indekso sudarymas ir lyginimas.

1.2.1. TIESIOGINIŲ UŽSIENIO INVESTICIJŲ IR INVESTICINIO PATRAUKLUMO RYŠYS

Vienas iš žinomų ir dažnai naudojamų būdų, leidžiančių įvertinti regiono investicinį patrauklumą, yra stebėti ir lyginti kiekybinius rodiklius, tokius kaip tiesioginės užsienio investicijos, tiesioginių investuotojų skaičius ar investavimo įmonių skaičius. Investicinis patrauklumas suvokiamas, kaip tam tikrų veiksnių rinkinys, veikiantis šiuos rodiklius. Rodikliai tampa savotišku tiesiogiai nuo investicinio patrauklumo priklausančiu ir jį iš dalies atspindinčiu indikatoriumi. Dėl šios priežasties investicinio patrauklumo kontekste investicijų samprata tampa labai svarbi.

1.2.1.1. TIESIOGINIŲ UŽSIENIO INVESTICIJŲ SAMPRATA IR SVARBA EKONOMIKAI

Lietuvos Respublikos investicijų įstatyme pagal investuotojo įtaką ūkio subjektui išskiriamos dvi investicijų rūšys:

- tiesioginės investicijos – investuojant įgyta kapitalo dalis leidžia tiesioginiam investuotojui daryti lemiamą įtaką investicijas priimančiam ūkio subjektui;
- netiesioginės (portfelinės) investicijos – investuojant įgyta kapitalo dalis nėra pakankama, jog leistų investuotojui daryti lemiamą įtaką investicijas priimančiam ūkio subjektui [3].

Taip pat išskiriamos vidaus bei užsienio investicijos:

- vidaus investicijos – tiriamos valstybė fizinių, juridinių asmenų ir įmonių investicijos toje valstybėje;
- užsienio investicijos – užsienio valstybių, fizinių, juridinių asmenų ar tarptautinių organizacijų investicijos tiriamoje valstybėje [3].

Darbe bus kalbama apie išorines tiesiogines užsienio investicijas (angl. *Foreign Direct Investment*), toliau TUI. Remiantis Ekonominio bendradarbiavimo ir plėtros organizacija (angl. *Organisation for Economic Co-operation and Development*), toliau OECD, TUI gali būti apibrėžiamos kaip finansiniai srautai, parodantys per tam tikrą laikotarpį (dažniausiai metus ar ketvirčius) įvykusių tarpvalstybinių investicinių sandorių vertę [4]. Išskiriamas išorinis ir vidinis tiesioginių užsienio investicijų srautas. Išorinis TUI srautas apima nagrinėjamos valstybės investicijas užsienio valstybėse, o vidinis – į nagrinėjamą valstybę pritraukiamas užsienio valstybių investicijas. Remiantis Tarptautiniu valiutos fondu (angl. *International Monetary Fund*), toliau IMF, tiesioginės užsienio investicijos suvokiamos kaip tarptautinių investicijų kategorija, kuri atspindi vienos valstybės ar ekonomikos dalyvio (tiesioginio investuotojo) ilgalaikį susidomėjimą kitos valstybės ar ekonomikos dalyviu (investicijas priimančia įmone) [5]. Ilgalaikis susidomėjimas šiame apibrėžime suprantamas kaip ilgalaikių santykių palaikymas bei didelė tiesioginio investuotojo įtaka investicijas priimančios įmonės valdyme. Abiejuose apibrėžimuose


minimi finansiniai investiciniai srautai apima reinvesticijas, ilgalaikes ir trumpalaikes paskolas bei kitą įmonės kapitalą (prekybos skolas, neišmokėtus dividendus, palūkanas už paskolas ir kt.).

Tiesioginės užsienio investicijos laikomos vienu pagrindinių veiksnių, lemiančių ekonomikos augimą bei ūkio plėtrą. Mokslininkas Mpango, apžvelgdamas literatūrą, teigia, jog didelės ir mažos investicijos ar jų nebuvimas gali atitinkamai slopinti ar skatinti ekonomikos augimą [6]. Ruplienė savo darbe teigia, jog TUI yra vienas svarbiausių šalies makroekonominių rodiklių. Pasak jos, iš užsienio pritrauktas kapitalas leidžia lengviau įdiegti naujausias technologijas, taip didina produktyvumą bei vidaus produkto apimtį [7]. Tai, jog TUI prisideda prie ūkio produktyvumo skatinimo, akcentuoja ir Čegyte. Ji teigia, jog TUI prisideda prie greitesnio pažangių technologijų, darbo organizavimo bei valdymo metodų plėtojimo, įgalina parengti ir įgyvendinti sudėtingus projektus, surasti naujų rinkos nišų savo produkcijai [8].


1.2.1.2. TIESIOGINIŲ UŽSIENIO INVESTICIJŲ PASISKIRSTYMO TENDENCIJOS

Oficialiai pateikiami tik 2016 metų TUI duomenys, todėl 2017 ir 2018 metai į tolimesnę apžvalgą bei tyrimą neįtraukti.

Remiantis Pasaulio investicijų ataskaita, nepaisant pastebimo augimo 2015 metais, išorinės TUI pasaulyje 2016 metais sumažėjo 2 % (1,75 trilijonais dolerių) (žiūrėti 1.2.1.2.1 pav.) [9]. Ypač skaudų smūgį patyrė besivystančios šalys – Azijos, Afrikos, Lotynų Amerikos ir Karibų regionų valstybės. TUI šiuose regionuose smuko net 14 % (646 bilijonais dolerių). Priešingai – TUI srautai pereinamojo laikotarpio šalyse padvigubėjo. Tai puikiai atspindi įvykusius privatizavimo sandorius bei augančias investicijas gamtinių išteklių paieškai. TUI srautai išsivysčiusios ekonomikos valstybėse 2016 metais taip pat augo bei siekė 5 % (1 trilijoną dolerių). TUI čia sudarė net 59 % visų pritrauktų investicijų pasaulyje (žiūrėti 1.2.1.2.2 pav.) Verta pastebėti, jog pritraukiamų investicinių srautų mažėjimą Europoje kompensavo kuklus augimas Šiaurės Amerikoje bei pastebimas augimas kitose išsivysčiusios ekonomikos valstybėse.




1.2.1.2.1 pav. TUI kitimas pasaulyje 2006 – 2016 metais



1.2.1.2.2 pav. TUI pasiskirstymas pasaulyje 2016 metais


Kadangi Lietuva nuo 2016 metų priskiriama Šiaurės Europos valstybėms, toliau plačiau apžvigsime ir analizuosime būtent šį regioną.

Nepaisant sėkmingai pasibaigusių tarpvalstybinių sandorių Didžiojoje Britanijoje, TUI srautas 19 – oje Europos valstybių iš 32 – jų sumažėjo 6 % (533 bilijonu dolerių). Tokią situaciją lėmė dvi priešingą poveikį turėjusios tendencijos: užbaigti tarpvalstybiniai susijungimo ir įsigijimo sandoriai bei kompanijų paskolos. Užbaigtų tarpvalstybinių susijungimo ir įsigijimo sandorių vertė Europoje 2016 metais siekė 377 bilijonus dolerių – tai didžiausia vertė po 2007 metų (žiūrėti 1.2.1.2.3 pav.). Didžioji dalis šių sandorių vyko Didžiojoje Britanijoje. Čia TUI išaugo nuo 33 bilijonų dolerių 2015 metais iki 365 bilijonų dolerių 2016 metais. Trys iš keturių didžiausių susijungimo ir įsigijimo sandorių pasaulyje 2016 metais vyko būtent Didžiojoje Britanijoje: „Anheuser-Busch“ (Belgija) įsigijo gėrimų bendrovę „SABMiller“, „Shell“ (Olandija) įsigijo naftos ir dujų kompaniją „BG Group“ bei „SoftBank“ (Japonija) įsigijo puslaidininkų technologijų kompaniją „ARM“.




1.2.1.2.3 pav. TUI kitimas Didžiojoje Britanijoje 2006 – 2016 metais

Pritraukiamų TUI mažėjimą kitose Europos valstybėse 2016 metais gana stipriai lėmė kompanijų paskolos. Daugiausiai TUI (188 bilijonus dolerių) 2015 metais pritraukusi Airija, 2016 metais pritraukė vos 22 bilijonus dolerių (žiūrėti 1.2.1.2.4 pav.). Didžiąją dalį nuosmukio (124 bilijonus dolerių) sudarė būtent bendrovių paskolos. Remiantis Pasaulio investicijų ataskaita, didžioji dalis paskolų buvo skirta tarptautinių įmonių grupei (angl. *Multinational Enterprise Groups*) priklausančių kompanijų struktūros pertvarkymui, todėl ateityje šis skaičius turėtų mažėti [9].




1.2.1.2.4 pav. TUI kitimas Airijoje 2006 – 2016 metais

Padidėjęs reinvestavimas bei tai, jog „Mylan“ (Jungtinės Amerikos Valstijos) įsigijo farmacinę bendrovę „Meda“, lėmė, jog 2016 metais TUI Švedijoje išaugo 20 bilijonų dolerių. Priešingai – Norvegijoje 2016 metais stebėtas investicijų atsitraukimas: bendra investicinių transakcijų suma buvo neigiama ir lygi 5,5 bilijonams dolerių. Kitose Skandinavijos valstybėse (Danijoje, Suomijoje, Islandijoje) pritraukiamos investicijos 2016 metais mažėjo ir išliko žemos (žiūrėti 1.2.1.2.5 pav.).




1.2.1.2.5 pav. TUI kitimas Skandinavijos valstybėse 2006 – 2016 metais

Baltijos regiono valstybėse stebėtos dvi skirtingos tendencijos. Lietuvoje ir Latvijoje 2016 metais užfiksuotas investicijų atsitraukimas – bendrai TUI sumažėjo 208 milijonais dolerių. Nors tarpvalstybinių susijungimo ir įsigijimo sandorių vertė Estijoje taip pat buvo neigiama, tačiau bendra investicinių transakcijų suma 2016 metais čia siekė 870 milijonu dolerių (žiūrėti 1.2.1.2.6 pav.).



1.2.1.2.6 pav. TUI kitimas Baltijos valstybėse 2006 – 2016 metais



1.2.1.2.7 pav. Vidutiniškai pritraukiamų TUI pasiskirstymas Šiaurės Europos valstybėse

Iš grafiko (1.2.1.2.7 pav.) matyti, jog vidutiniškai daugiausiai užsienio investicijų 2006 – 2016 metų laikotarpyje pritraukė Didžioji Britanija. Vienu pagrindinių Didžiosios Britanijos pranašumų yra laikomas biurokratinių procesų greitis: naujos kompanijos registracijos procesas čia užtrunka vos 13 dienų (Europos vidurkis – 32 dienos). Pagal šį rodiklį Didžioji Britanija pirmauja Europoje, o pasaulyje yra šešta. Prie palankaus investicinio klimato prisideda ir sąlyginai nedideli mokesčiai bei Londono, kuris laikomas viena iš pirmaujančių pasaulio finansinių sostinių, patrauklumas [10]. Didžiosios Britanijos silpnybėmis laikomos labai didelė finansų sektoriaus įtaka BVP, gana prasta infrastruktūra bei didelė užsienio investuotojų konkurencija. Didžiausias TUI augimas Didžiojoje Britanijoje pastebimas 2016 metais. Jis siejamas su jau minėtais sėkmingais susijungimo ir įsigijimo sandoriais, įvykusiais nepaisant Britanijos apsisprendimo palikti Europos Sąjungą. Remiantis Pasaulio investicijų ataskaita, didžioji Didžiosios Britanijos pritraukiamų TUI dalis atkeliauja iš Europos Sąjungos valstybių, tad išstojimas iš Europos Sąjungos galimai paveiks šiuos srautus. Tiesa, tai turėtų būti pastebima tik praėjus keliems metams ir išaiškėjus visiems išstojimo iš Europos Sąjungos niuansams [9].

2015 metais į priekį išsiveržė Airija. Ji laikoma patrauklia užsienio investuotojams, tačiau TUI srautai čia nėra pastovūs – juos lemia didelių šalyje įsikūrusių tarptautinių kompanijų veikla. Geras to pavyzdys yra 2015 ir 2016 metai. Nors 2015 metais Airija pritraukė net 188 milijonus dolerių ir tapo pirmaujanti Europoje, 2016 šis skaičius sumažėjo net 88 % (nukrito iki 22 milijonų dolerių). 2015 metų šuolis labiau siejamas su finansinėmis permainomis bei įmonių restruktūrizacija, o ne su naujų investuotojų pritraukimu. Tais metais įvyko nemažai tarptautinių įmonių susijungimo sandorių, po kurių kompanijos sugebėjo sumažinti savo pelno apmokestinimą. 2015 metais Investicijų skatinimo agentūra (angl. *the Investment Promotion Agency*) paskelbė 5 metų strategiją, kurios tikslas – pasinaudojant TUI, sukurti 80000 darbo vietų. Nors oficiali statistika rodo didelį pritraukiamų TUI sumažėjimą, remiantis Airijos Tarptautinės plėtros asociacijos (angl. *International Development Association*), toliau IDA, duomenimis, 2016 Airija

pasiekė rekordinį darbuotojų, dirbančių užsienio kapitalo kompanijose, skaičių (199877 darbuotojai) [11]. Airija gali pasigirti investuotojams patrauklia mokesčių bei teisine sistema. Pelno mokestis čia lygus 12,5 % ir stipriai atsilieka nuo Europos vidurkio (beveik 19 %). Airijoje taip pat nestinga jaunos ir kvalifikuotos darbo jėgos. Pusę populiacijos sudaro žmonės iki 35 metų [12]. Užsienio investuotojų susidomėjimą Airija lemia ir tai, jog ji yra Angliškai kalbanti bei Euro Zonai priklausanti valstybė. Airijos trūkumais, pritraukiant užsienio investuotojus, laikomi ribota vidaus rinka bei auganti darbo jėgos kaina.

Skandinavijos valstybės pritraukiamomis TUI vidutiniškai atsilieka tiek nuo Didžiosios Britanijos, tiek nuo Airijos (žiūrėti 1.2.1.2.7 pav.). Vidutiniškai mažiausiai TUI, lyginant su kitomis Skandinavijos valstybėmis, pritraukia Islandija. Islandijos geoterminė bei vėjo energija, naudojama elektros gamybai, didžiąja dalimi yra šių investicijų priežastis. Ši energija taip pat skatina pigios ir alternatyvios energijos šaltinių ieškančių įmonių susidomėjimą. Nepaisant gana jaunos ir kvalifikuotos darbo jėgos, lanksčios darbo rinkos bei modernios infrastruktūros, investuotojus Islandijoje gąsdina ribota vidaus rinka, gana didelė gamybos kaina, ekonomikos neatsparumas finansinėms krizėms bei valstybės geografinė padėtis – Islandijos valstybė yra saloje, nutolusioje nuo Europos regiono.

Norvegija 2016 metais patyrė skaudų investuotojų atsitraukimą ir pasiekė bene didžiausią neigimą TUI vertę (5,3 bilijonus dolerių). Didžiąją dalį užsienio investicijų Norvegijoje pritraukia naftos, dujų, gamybos, mažmeninės ir didmeninės prekybos bei bankininkystės sektoriai. Nors Norvegija gali pasigirti stabilia politine ir verslo aplinka, gana didele gyventojų perkamąja galia bei kvalifikuota darbo jėga, tačiau užsienio investuotojus dažnai gąsdina tai, jog Norvegijos ekonomika stipriai priklauso nuo naftos kainos. Geografiškai izoliuotos ir sunkiai pasiekiamos, kai kurios Norvegijos teritorijos investuotojams asocijuojasi su didelėmis transporto, komunikacijos ir logistikos išlaidomis. Giežtai reguliuojama darbo rinka bei didelė darbo jėgos kaina taip pat laikomos vienomis iš priežasčių, dėl kurių Norvegija negali pasigirti didelėmis užsienio investicijomis.

Įvykus finansinei krizei, Danija patyrė skaudų investuotojų atsitraukimą. 2010 metais fiksuotas neigiamas 9,16 bilijonų dolerių TUI srautas. Nors 2011 metais TUI siekė net 11,44 bilijonus dolerių, Danijai vis dar nepavyko susigražinti ilgalaikio investuotojų pasitikėjimo. 2016 metais TUI čia nesiekė 1 bilijono dolerių. Nepaisant to, jog Danija gali pasigirti kvalifikuota darbo jėga, lanksčia darbo rinka, modernia infrastruktūra bei puikiai išplėtotą telekomunikacijos sistema, užsienio investuotojus gąsdina tai, jog Danijos ekonomika stipriai priklauso nuo bendros ekonominės situacijos Europoje. Investuotojus galimai atstumia ir gana ribota vidaus rinka bei pelno mokestis, kuris čia viršija Europos vidurkį ir siekia 22 %

Finansinės krizės padarinių neišvengė ir Suomija. 2008 metais fiksuotas investuotojų atsitraukimas lygus 1,14 bilijonui dolerių. Tiesa, jau 2014 metais Suomija pritraukiamomis užsienio investicijomis aplenkė kitas Skandinavijos valstybes – TUI 2014 metais siekė net 18,3 bilijonus dolerių. Didžioji dalis pritrauktų investicijų tai metais siejamos su vidiniais finansiniais tarptautinių kompanijų sandoriais bei įmonių įsigijimu. Kaip ir kitos Skandinavijos valstybės, Suomija gali pasigirti stabilia politine situacija bei vienu žemiausiu pasaulyje korupcijos lygiu. Priešingai nei izoliuota Islandija, Suomija geografiškai yra strategiškai svarbioje vietoje tarp Skandinavijos, Rusijos bei augančio Baltijos regiono. Ji taip pat gali pasigirti viena konkurencingiausių ekonomikų [13], išvystytais aplinką tausojančių technologijų, gamybos, sveikatos bei informacinių ir ryšių technologijų, toliau IRT, sektoriais. Dėl šių priežasčių Suomijos potencialas pritraukti užsienio investicijas yra gana didelis.

Iki finansinės krizės stipriai pirmavusi, Švedija 2008 – 2010 metais patyrė skaudų investuotojų atsitraukimą. TUI nuo 36,95 bilijonų dolerių 2008 metais sumažėjo iki 0,1 bilijono dolerių 2010 metais. Nepaisant to, verslui palanki aplinka ir konkurencinga Švedijos ekonomika lėmė spartų investuotojų sugrįžimą. 2016 metais Švedija vėl išsiveržė į priekį užsienio investicijomis, kurių vertė siekė 19,58 bilijonus dolerių. Užsienio investuotojus Švedija vilioja stabilia politine situacija, konkurencinga ekonomika, palankia verslui aplinka bei nesudėtingomis biurokratinėmis procedūromis. Švedijos trūkumais, pritraukiant užsienio investicijas, laikomi didelė darbo jėgos kaina, griežti darbo teisės aktai bei brangus pragyvenimo lygis.

Lyginant Baltijos regiono valstybes 2006 – 2016 metų laikotarpiu, vidutiniškai daugiausiai TUI pritraukė Estija. Užsienio investuotojų lėšos Estijai, taip pat ir kitoms Baltijos regiono valstybėms, yra būtinos norint užtikrinti ekonomikos plėtrą ir stabilumą. Estijai stengiantis integruotis į Šiaurės Europos valstybių rinką, vis daugiau įmonių tampa Skandinavijos kompanijų padaliniais. Didžioji dalis investuotojų dėmesio Estijoje atitenka informacinių technologijų, biotechnologijų bei aplinką tausojančių technologijų sektoriams. Nors investuotojus vilioja liberali Estijos ekonomika, strategiškai svarbi geografinė padėtis (valstybė ribojasi su Europos Sąjungos valstybėmis bei Rusija), narystė Europos Sąjungoje, tačiau Suomijos ir Švedijos produktų dominavimas, maža vidinė rinka bei perkamoji galia lemia tai, jog Estija negali pasigirti tokiais didelėmis užsienio investicijomis kaip Didžiąja Britanija, Airija ar Skandinavijos valstybės.

Antroje vietoje, lyginat Baltijos regiono valstybes pagal jų pritraukiamas investicijas, yra Latvija. Didžiąją TUI dalį Latvijoje sudaro pakartotinis investavimas bei sėkmingi tarptautinių įmonių įsigijimo ir susijungimo su vietinėmis įmonėmis sandoriai telekomunikacijų, naftos vamzdynų, nekilnojamojo turto, mažmeninės prekybos bei bankininkystės sektoriuose. Latvijai įstojus į Europos Sąjungą, TUI išaugo ir 2007 metais siekė 2,37 bilijonus dolerių. Tačiau finansinė

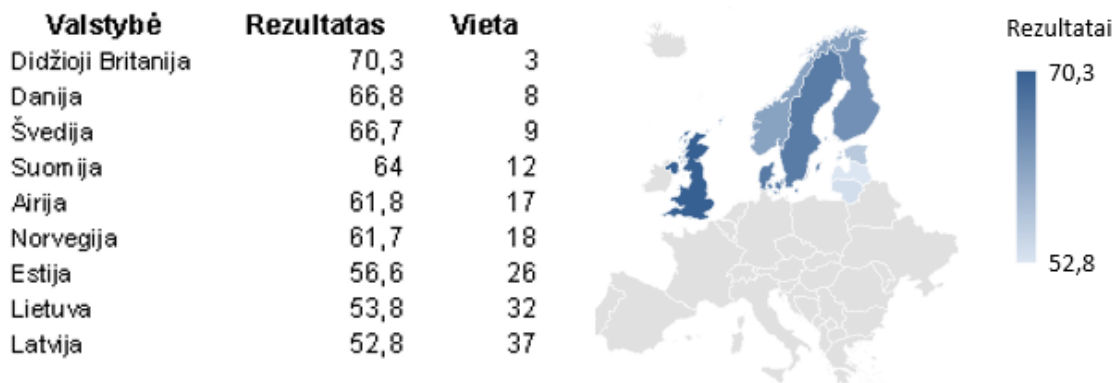
krizė lėmė tai, jog TUI pastaraisiais metais tendencingai mažėjo ir 2016 metais siekė vos 130 milijonų dolerių. Nors Latvija gali pasigirti kvalifikuota ir pigia darbo jėga, aukštu produktyvumo lygiu, strategiškai svarbia geografine padėtimi (valstybė ribojasi su Europos Sąjungos valstybėmis bei Rusija), naryste Europos Sąjungoje, tačiau investuotojus gąsdina ribotas vidinės rinkos dydis, mažas užsienio kapitalo įmonių skaičius valstybėje, ekonomikos ir rinkos nestabilumas.

Vidutiniškai mažiausiai TUI, lyginant su kitomis Baltijos regiono valstybėmis 2006 – 2016 metų laikotarpiu, pritraukė Lietuva. Pritraukiamų TUI srautų svyravimą per pastaruosius dešimt metų ne tik Lietuvoje, bet ir kitose Baltijos regiono valstybėse, stipriai lėmė pasaulinė ekonominė krizė bei regiono finansinė krizė, sėjama su Rusija bei Ukraina. Nors 2015 metais TUI išaugo iki 870 milijonų dolerių ir Lietuva pagal pritraukiamas investicijas pirmavo Baltijos regione, 2016 metais stebėtas neigiamas TUI srautas (210 milijonas dolerių) rodo, jog ilgalaikio investuotojų pasitikėjimo dar teks palaukti. Didžiausiais investuotojais Lietuvoje laikoma Švedija, Olandija bei Vokietija. Investuotojus Lietuvoje, kaip ir Latvijoje, vilioja kvalifikuota ir pigi darbo jėga, strategiškai svarbi geografinė padėtis, narystė Europos Sąjungoje. Tai, jog Lietuva pritraukia mažiausiai TUI regione, siejama su žemu pajamų lygiu, emigracija, sudėtingais biurokratiniais procesais ir aukštu korupcijos lygiu.

1.2.2. INVESTICINIO PATRAUKLUMO INDEKSAI

Tiesiogines užsienio investicijas nusakančių kiekybinių rodiklių lyginimo procesas gana primityvus ir ne visuomet atskleidžia pilną regiono investicinio patrauklumo potencialą. Dėl šios priežasties, kai kurie autoriai yra linkę grupuoti investicinį patrauklumą lemiančius veiksnius bei skaičiuoti investicinio patrauklumo indeksą.

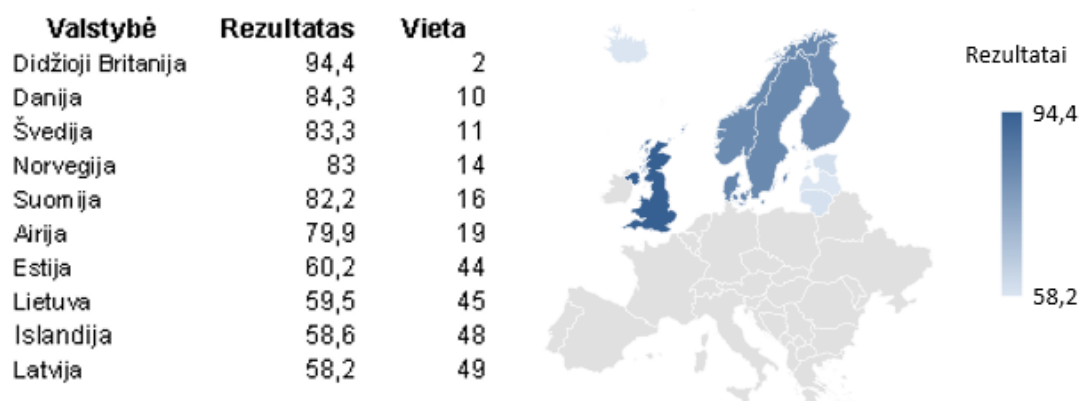
Pasaulinis patrauklumo tiesioginėms užsienio investicijoms indeksas (angl. *A Global Foreign Direct Investment Country Attractiveness Index*), toliau GFICA – vienas iš investicinį patrauklumą vertinančių indeksų [14]. Šis indeksas įvertina ir lygina 109 valstybių galimybes pritraukti tiesiogines užsienio investicijas ir yra sudarytas iš 60 investicinį patrauklumą lemiančių veiksnių, sujungtų į 11 grupių, kurios sudaro 3 pagrindinius klasterius – prielaidas, pagrindinius veiksnius bei papildomus veiksnius. Prielaidomis laikomi investuotojų susidomėjimui atsirasti būtini veiksniai. Tai makroekonominis stabilumas, finansinė struktūra ir plėtra, viešasis valdymas bei verslo aplinka. Pagrindiniai veiksniai lemia galutinį investuotojų pasirinkimą. Tai rinkos pasiekiamumas, dydis ir potencialas, žmogiškieji ir gamtos ištekliai, kaštai, logistikos plėtra bei telekomunikacijos ir IKT. Papildomi veiksniai parodo, jog investuotojams svarbus ir aglomeracijos efektas bei inovacijos. Skaičiuojant GFICA indeksą didžiausias svoris suteikiamas pagrindinių veiksnių grupei. Verta paminėti, jog svariai grupių viduje esantiems indikatoriams paliekami vienodi.



1.2.2.1 pav. 2017 metų GFICA rezultatai – Šiaurės Europos valstybės

Šiaurės Europos valstybių investicinio patrauklumo vertinimas pateikiamas 1.2.2.1 pav.. Remiantis GFICA, investuotojams patraukliausia yra Didžioji Britanija. Ji bendrame 109 valstybių sąraše atsiduria trečioje vietoje ir yra lenkiama tik Jungtinių Amerikos Valstijų ir Honkongo. Vidutiniškai daug TUI pritraukianti Airija GFICA 2017 metais klasifikacijoje užima tik 17 vietą ir yra lenkiama visų Skandinavijos valstybių, išskyrus Norvegijos, kuri užima 18 vietą. Pabrėžtina, jog Islandijos valstybės GFICA vertinamų šalių sąraše nėra. Baltijos valstybės – Estija, Lietuva ir Latvija – kaip ir lyginant TUI, laikomos investuotojams mažiausiai patraukliomis ir atitinkamai užima 26, 32 ir 37 vietas.

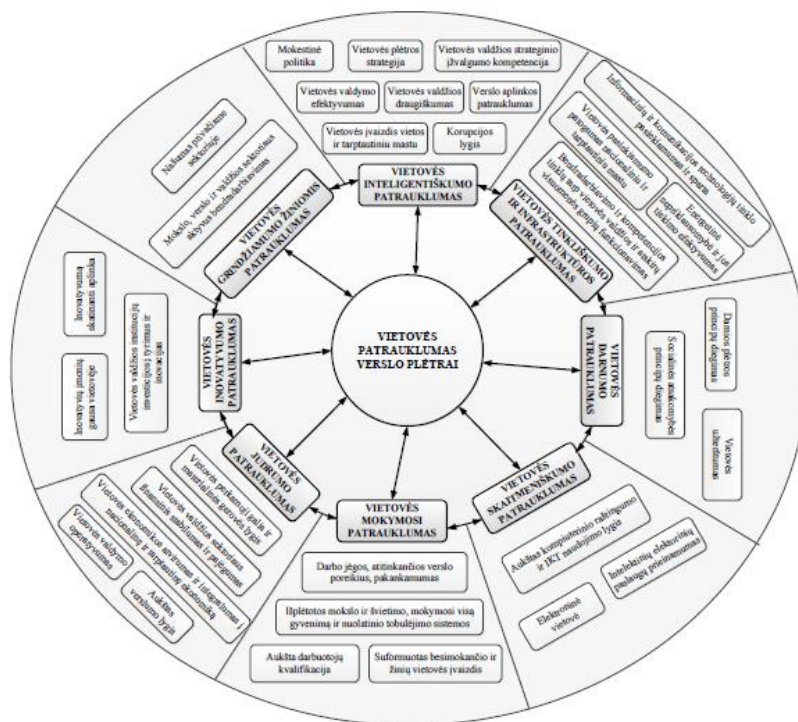
Kitas valstybės patrauklumą investicijoms nusakantis indeksas – rizikos ir privataus kapitalo šalių patrauklumo indeksas (angl. *The Venture Capital & Private Equity Country Attractiveness Index*), toliau VCPE [15]. Šis indeksas įvertina ir lygina 80-ies valstybių iš viso pasaulio galimybes pritraukti tiesiogines užsienio investicijas. Indeksą sudaro 6 pagrindinės veiksnių grupės: ekonominis gyvybingumas, kapitalo rinkos gylis, mokesstinė politika, investuotojų apsauga ir įmonių valdymas, žmogiškasis kapitalas ir socialinė aplinka, verslumo kultūra ir galimybės. Didžiausias svoris, skaičiuojant VCPE indeksą, suteikiamas kapitalo rinkos gylį atspindinčių veiksnių grupei. Kaip ir skaičiuojant GFICA indeksą, svariai grupių viduje esantiems indikatoriams paliekami vienodi.



1.2.2.2 pav. 2017 metų VCPE rezultatai – Šiaurės Europos valstybės

Remiantis VCPE, investuotojams taip pat patraukliausia yra Didžioji Britanija (žiūrėti 1.2.2.2 pav.), užimanti antrąją vietą pasaulyje. Airija atsilieka nuo Skandinavijos valstybių, išskyrus Islandiją, kuri, kaip ir Baltijos regiono valstybės, atsiduria sąrašo apačioje.

Indeksus, skirtus investiciniam patrauklumui vertinti, valstybės regionų kontekste sudarinėjo ir Lietuvos mokslininkai. Zykienė savo disertacijoje sudarė investicinio patrauklumo regionuose indeksą – vietovės patrauklumo verslo plėtrai sumanaus vystymosi kontekste veiksmų (VPV) modelį (1.2.2.3 pav.) [1]. Šis indeksas taikomas Lietuvos regionų investicinio patrauklumo vertinimui ir yra sudarytas iš 8 pagrindinių veiksmų grupių – tai vietovės inteligentiškumas, vietovės tinkliškumo ir infrastruktūros patrauklumas, darnumas, skaitmeniškumas, vietovės mokymuisi patrauklumas, vietovės judrumo patrauklumas, inovatyvumas, vietovės grindžiamumo žiniomis patrauklumas. Visos grupės bei jas sudarantys indikatoriai formuojant vietovės patrauklumo verslo plėtrai indeksą yra laikomi vienodai svarbiais.



1.2.2.3 pav. VPV modelis [1]

Regiono investicinį patrauklumo indeksą savo darbe pateikė ir Nikolova bei Plotnikova [16]. Šis indeksas sudarytas iš 8 investicinio patrauklumo veiksmų grupių. Tai gamtinių išteklių, darbo jėgos, ekonominis potencialas, ekonominio išsivystymo lygis, ekonominės veiklos mastas, perkamoji galia, finansinė būklė bei ekonominių reformų progresas. Čia taip pat kalbama apie veiksmų grupių bei jas sudarančių indikatorių svorių vienodumą.

Apibendrinant nagrinėtus autorius ir jų sudarytus valstybės ar jos regiono patrauklumo indeksus, pastebėta, jog, skaičiuojant indeksą, investicinio patrauklumo veiksniai yra grupuojami, dažniausiai remiamasi vienodų svorių priskyrimo metodika, taip nesuteikiant galimai atsitiktinio pranašumo vienai iš veiksmų grupių.

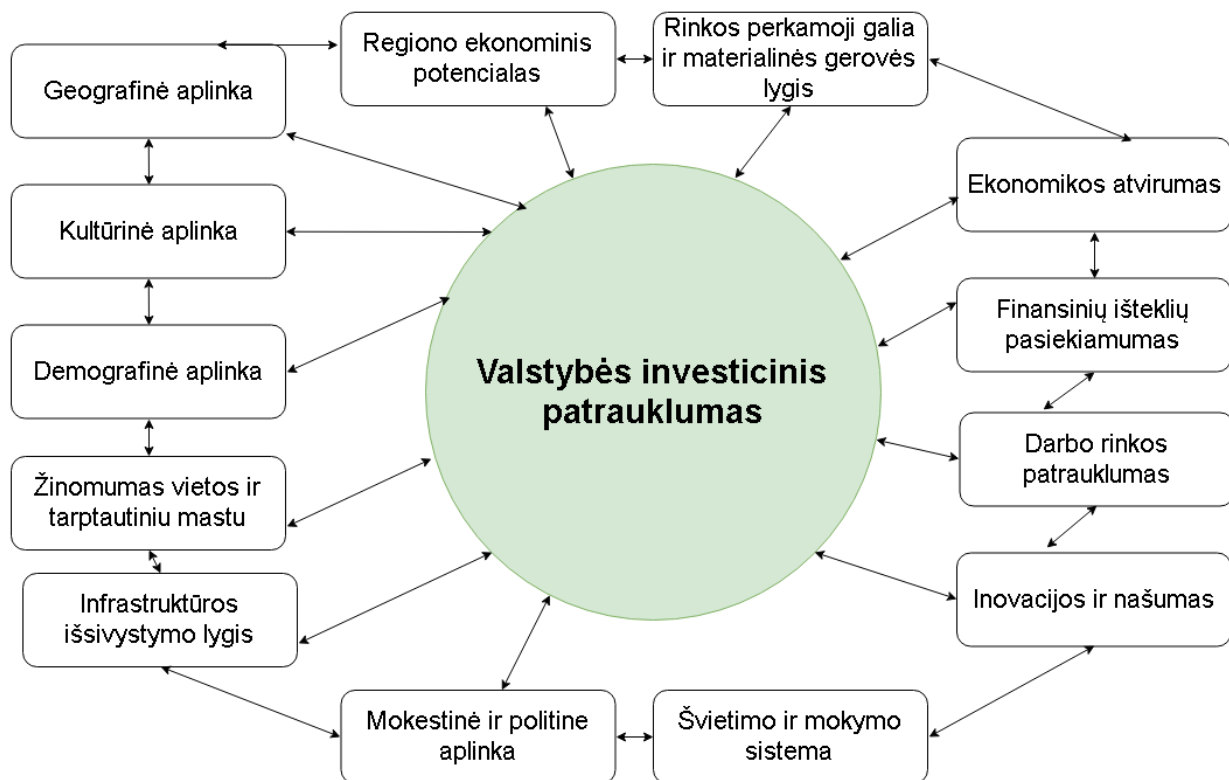
1.3. INVESTICINIO PATRAUKLUMO VEIKSNIAI IR JŲ GRUPĖS

Nors investicinius srautus nusakančių kiekybinių rodiklių vertinimo bei lyginimo procesas gana intuityvus, tačiau pačio investicinio patrauklumo išskaidymas į jį lemiančius veiksnius tampa gana sudėtingu, daug žingsnių apimančiu bei laiko reikalaujančiu procesu. Analizuojant literatūrą pastebėta, jog minimi skirtingi vietovės patrauklumo investicijoms ir verslo plėtrai veiksniai.

Siekiant apjungti skirtingų autorių minimus investicinio patrauklumo veiksnius ir sudaryti apibendrinantį investicinio patrauklumo veiksnų modelį, atlikta mokslinės literatūros analizė be išskirti pagrindiniai investicinį patrauklumą lemiantys veiksniai ir jų grupės (1.3.1 lentelė). Toliau, modeliuojant investicinį patrauklumą ir TUI srautus, ši veiksnų aibė bus laikoma atspirties tašku.

1.3.1 lentelė. Investicinio patrauklumo veiksniai

Veiksnų grupė	Veiksny	Autoriai
Regiono ekonominis potencialas	Ekonomikos gyvybingumas	Bruneckienė ir kiti (2016) [17],
	Esamo investavimo lygis	L. Nikolova ir E. Plotnikova (2013) [16],
	Valdžios sektoriaus išlaidos	I. Zykiene ir V. Snieška (2011) [1].
Darbo rinkos patrauklumas	Darbo vietos kaina	Belderbos ir kiti (2016) [18],
	Darbo jėgos pasiekiamumas	L. Nikolova ir E. Plotnikova (2013) [16], I. Zykiene ir V. Snieška (2011) [1].
Rinkos perkamoji galia ir materialinės gerovės lygis	Namų ūkio pajamos ir išlaidos	J. Stankevičienė ir A. Lakštutienė (2012) [19],
	Pakankamas materialinės gerovės lygis, užtikrinantis vartojimą	S. Adams (2009) [20], D. Ruplienė ir kt. (2008) [7].
Ekonomikos atvirumas	Tarptautinės prekybos intensyvumas	S. Adams (2009) [20],
	Tarptautinės prekybos intensyvumas	K. W. Jun ir H. Singh (1995) [21].
Demografinė aplinka	Infliacijos lygis	
	Rinkos dydis	Belderbos ir kiti (2016) [18],
	Viešasis saugumas	Glebova ir kiti (2015) [22], L. Nikolova ir E. Plotnikova (2013) [16].
Infrastruktūros išsivystymo lygis	IKT išsivystymas	
	Automobizacijos lygis	Belderbos ir kiti (2016) [18],
	Pasiekiamumo ir mobilumo lygis	Bonasso ir kiti (2014) [23], Cohen (2006) [24].
Žinomumas vietos ir tarptautiniu mastu	Nekilnojamo turto kaina	
	Aglomeracija	
	Globalizacijos lygis	Giner ir kiti (2017) [25], Bonasso ir kiti (2014) [23], Strzelczyk (2014) [26].
Mokestinė ir politinė aplinka	Įvaizdis	
	Mokestinė našta	Bruneckienė ir kiti (2016) [17],
	Politinis stabilumas	Belderbos ir kiti (2016) [18], I. Zykiene ir V. Snieška (2011) [1].
Švietimo ir mokymo sistema	Korupcijos lygis	
	Švietimo sistema	Belderbos ir kiti (2016) [18], Bonasso ir kiti (2014) [23],
	Mokslo, verslo ir valdžios	J. Stankevičienė ir A. Lakštutienė (2012) [19].
Inovacijos ir našumas	Inovacijoms palanki aplinka	
	Našumo lygis	Bruneckienė ir kiti (2016) [17], I. Zykiene ir V. Snieška (2011) [1].
Finansinių išteklių pasiekiamumas	Finansų sistemos išsivystymo lygis	L. Nikolova ir E. Plotnikova (2013) [16],
	Bankų sistemos stabilumas	M. Ballota (2004) [27].
Geografinė aplinka	Geografinė padėtis	Bruneckienė ir kiti (2016) [17],
	Gamtinių išteklių potencialas	Bonasso ir kiti (2014) [23], J. Stankevičienė ir A. Lakštutienė (2012) [19].
Kultūrinė aplinka	Kultūrinės veiklos sąlygos	S. K. Kahai (2011) [28],
	Kalba	J. Stankevičienė, A. Lakštutienė (2012) [19], A. Benassy ir kt. (2007) [29].



1.3.1 pav. Valstybės investicinio patrauklumo modelis – veiksmų grupės

Išskirtos veiksmų grupės bei jas sudarantys veiksniai sąveikauja tarpusavyje bei veikia ir yra veikiami valstybės investicinio patrauklumo (žiūrėti 1.3.1 pav.).

Lyginant šį modelį su 1.2.2.3 pav. vaizduojamu VPV modelius, akivaizdu, jog kalbant apie valstybės investicinį patrauklumą, didesnis dėmesys tenka jos ekonominei situacijai, mokesčiai ir politinei aplinkai bei finansiniams ištekliams, kurie tos pačios valstybės regionų investicinio patrauklumo kontekste nėra taip akcentuojami. Investicinį patrauklumą tiek valstybėje, tiek regione lemia inovacijos, švietimo ir mokymosi sistema, žinomumas, infrastruktūros lygis.

2. METODŲ ANALIZĖ

Tiriant valstybių investicinį patrauklumą, naudoti įvairūs statistikos bei mašininio mokymosi metodai. Grupuoiant valstybės naudota klasterinė analizė, mažinant dimensijų skaičių – pagrindinių komponentų analizė, o modeliuojant TUI – dirbtiniai neuroniniai tinklai.

2.1. KLAŠTERINĖ ANALIZĖ

Klasterinės analizės tikslas – homogeninių grupių, dar vadinamų klasteriais, sudarymas. Klasteriai formuojami iš objektų aibės, kurioje kiekvienas elementas apibūdinamas požymių vektoriumi. Grupės formuojamos siekiant užtikrinti, jog elementai priklausantys tam pačiam klasteriui būtų „panašūs“. Dažniausiai naudojami šie objektų **panašumo matai** [30]:

- metriniai atstumo matai;
- koreliacijos koeficientai;
- asociatyvumo koeficientai.

Metriniai atstumo matai dar vadinami skirtingumo matais. Jie parodo, kaip stipriai objektai skiriasi vienas nuo kito. Dažniausiai naudojami Euklido, Minkovskio, Čebyšovo atstumų kvadratų matai pateikiami 2.1.1 lentelėje.

2.1.1 lentelė. Metriniai atstumo matai

Pavadinimas	Formulė
Euklido atstumo kvadratas	$d(X, Y) = \ X - Y\ ^2 = \sum_{i=1}^n (x_i - y_i)^2$ (2.1.1)
Manheteno atstumo kvadratas	$d(X, Y) = \sum_{i=1}^n x_i - y_i $ (2.1.2)
Čebyšovo atstumo kvadratas	$d(X, Y) = \min_i x_i - y_i $ (2.1.3)

Čia X ir Y – lyginami objektai, n – objektų požymių (koordinatų) skaičius, o x_i ir y_i – objektų koordinatės.

Objektų panašumą parodo ir koreliacijos koeficientai. Esant kiekybiniam duomenim, vienas iš dažniausiai taikomų būdų objektų panašumui įvertinti yra teisinės koreliacijos koeficientas:

$$r_{XY} = \frac{COV(X, Y)}{\sigma_X \sigma_Y}, \quad (2.1.4)$$

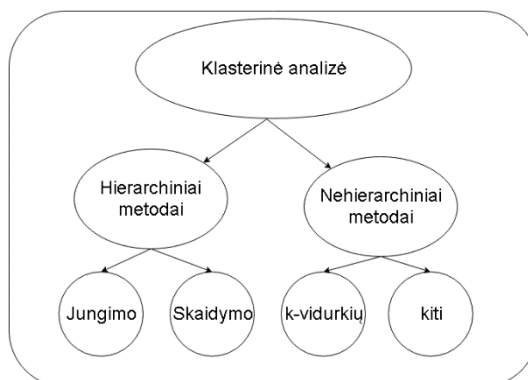
kur σ_X, σ_Y – atitinkamai X ir Y standartinis nuokrypis, o $cov(X, Y)$ – kovariacija.

Esant kokybiniam duomenim, naudojami asociatyvumo koeficientai, kurie atspindi lyginamų objektų nesutampančių požymių (koordinatų) skaičių:

$$d(X, Y) = \frac{\#(x_i \neq y_i)}{n}, \quad (2.1.5)$$

kur $\#(x_i \neq y_i)$ yra nesutampančių koordinatų reikšmių skaičius.

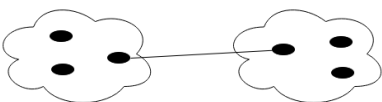
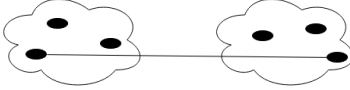
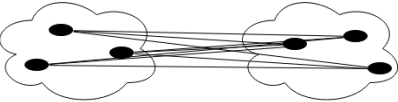
Apjungiant objektus į grupes naudojamos ne tik skirtingais panašumo matais. Skirtingo pobūdžio uždaviniams spręsti pasitelkiamos ir skirtingos skirstymo į klasterius strategijos. Išskiriami hierarchiniai ir nehierarchiniai klasterizavimo metodai bei skirtingi atstumų tarp klasterių nustatymo kriterijai: hierarchiniai jungimo ir skaidymo metodai, nehierarchinis k-vidurkių metodas ir kiti. (žiūrėti 2.1.1 pav.).

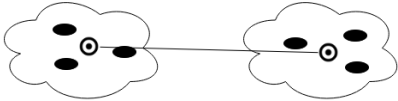


2.1.1 pav. Klasterizavimo metodų tipai

Atliekant hierarchinį klasterizavimą, nustatoma klasterių tarpusavio priklausomybių struktūra. Taikant skaidymo metodą, priminis klasteris, kurį sudaro visi objektai, skaidomas tol, kol kiekvienas objektas tampa atskiru klasteriu. Taikant jungimo metodą, procesas vykdomas atvirkščiai – pradedama nuo atskirų objektų, kurie jungiami į klasterius tol, kol gaunama viena homogeninė grupė. Taikant hierarchinius metodus svarbu apsibrėžti, kuris klasterių artumo matas yra taikomas. Dažniausiai naudojami artimiausio, tolimiausio kaimyno, vidutinės jungties ir centroidų klasterių artumo matai (2.1.2 lentelė).


2.1.2 lentelė. Klasterių artumo matai

Pavadinimas	Paaiškinimas	Grafinė interpretacija
Artimiausias kaimynas	Lyginami skirtinguose klasteriuose esantys panašiausi (artimiausi) objektai.	 2.1.2 pav. Klasterių artumo matai – artimiausias kaimynas
Tolimiausias kaimynas	Lyginami skirtinguose klasteriuose esantys skirtingiausi (tolimiausi) objektai.	 2.1.3 pav. Klasterių artumo matai – tolimiausias kaimynas
Vidutinė jungtis	Klasterių panašumas nustatomas lyginant atstumo tarp visų objektų iš skirtingų klasterių vidurkių.	 2.1.4 pav. Klasterių artumo matai – vidutinė jungtis

Centroidas	Klasterių panašumas nustatomas lyginant atstumą tarp skirtingų klasterių centrų.	 <p>2.1.5 pav. Klasterių artumo matai – centroidas</p>
------------	----------------------------------------------------------------------------------	------------------------------------------------------------------------------------------------------------------------------------------

Hierarchiniai metodai taikomi tik esant nedideliems duomenų rinkiniams (iki 250 stebėjimų). Norint klasterizuoti dideles objektų aibes, naudojami nehierarchiniai metodai. Vienu iš populiariausių nehierarchinio klasterizavimo metodų laikomas k-vidurkių metodas. Jis paremtas išankstiniu klasterių skaičiaus nurodymu, tačiau, iš anksto nežinant duomenų struktūros, visuomet galimas tyrimo kartojimas keičiant šią pirminę parinktį ir ieškant priimtinausio rezultato. Išskiriami šie k-vidurkių metodo žingsniai (2.1.6 pav.):

1. objektai atsitiktinai suskirstomi į k pradinių klasterių;
2. apskaičiuojami klasterių centrai;
3. apskaičiuojamas kiekvieno objekto atstumas (Euklido, Euklido kvadrato ar kt.) iki klasterių centų;
4. objektas priskiriamas tam klasteriui, kurio centui yra artimiausias;
5. 2 – 4 žingsniai kartojami tok, kol persiskirstymo tarp klasterių nebelieka.



2.1.6 pav. k-vidurkių metodo schema

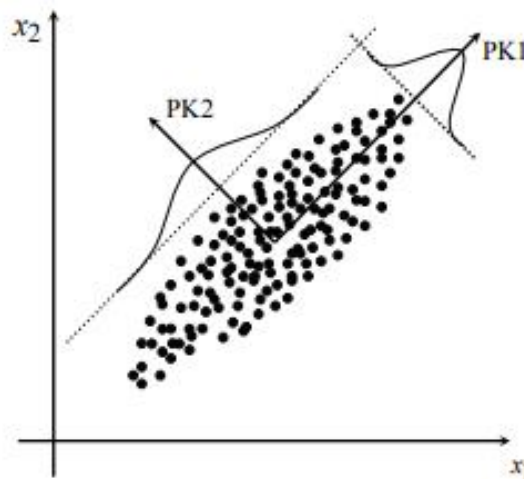
K-vidurkių metodas pasižymi tiesiniu greičiu, lengvu pritaikymu ir efektyvumu dideliems duomenų rinkiniams. Didžiausiu šio metodo trūkumu laikoma tai, jog iš anksto tenka nustatyti klasterių skaičių. Tai patvirtinantys argumentai:

- populiacijos klasterių skaičius gali nesutapti su tiriamos imties klasterių skaičiumi;
- atskirus klasterius gali sudaryti išskirtys.

2.2. PAGRINDINIŲ KOMPONENČIŲ ANALIZĖ

Pagrindinių komponentių analizės (angl. *principal component analysis*), toliau PKA, pagrindinis uždavinys yra maksimizuoti kintamųjų tiesinių kombinacijų dispersiją. Tai duomenų transformacija, kuri plačiai naudojama mažinant dimensijų kiekį duomenyse. PKA idėja yra sumažinti duomenų dimensijų skaičių atsisakant komponentių (gautų po transformacijos), kurių dispersijos yra mažiausios.

Atliekant PKA, pirmiausia randama kryptis, kuria duomenų dispersija yra didžiausia – ši kryptis vadinama pagrindine komponente, toliau PK1 (žiūrėti 2.2.1 pav.). PK1 eina per duomenų centrinį tašką, kurio koordinatės yra duomenų aibės taškų atskirų koordinatžių vidurkiai. Vidutinis atstumas tarp PK1 ir duomenų aibės taškų yra minimalus. Antroji pagrindinė komponentė, toliau PK2, taip pat kerta centrinį tašką bei yra statmena PK1 [31].



2.2.1 pav. Pirmoji ir antroji pagrindinės komponentės [31]

Toliau suformuluosime formalų pagrindinių komponentių apibrėžimą. Tegul $X = (X_1, X_2, \dots, X_d)^T$ yra d -matis atsitiktinis dydis. Pirmąją pagrindine komponente vadinama tiesinė kombinacija $a_1^T X$, jei a_1 vektorius yra toks, jog šios pagrindinės komponentės dispersija yra maksimali pagal visus $\|a_1\| = 1$ vektorius.

Antrąją komponente vadinsime tiesinę kombinaciją $a_2^T X$, jei a_2 vektorius yra toks, jog šios pagrindinės komponentės dispersija yra maksimali pagal visus $\|a_2\| = 1$ vektorius, kurie ortogonalūs a_1 .

d -tąją pagrindine komponente vadinsime tiesinę kombinaciją $a_d^T X$, jei d vektorius yra toks, jog šios pagrindinės komponentės dispersija yra maksimali pagal visus $\|a_d\| = 1$ vektorius, kurie ortogonalūs a_1, a_2, \dots, a_{d-1} [32].

Vektoriai a_1, a_2, \dots, a_d vadinami pagrindinių komponentių kryptimis ir gali būti apibrėžiami šiomis lygtimis:

$$a_1 = \arg \max_{\|a\|=1} Da^T X, \quad (2.2.1)$$

$$a_2 = \arg \max_{\|a\|=1, a \perp a_1} Da^T X, \dots, \quad (2.2.2)$$

$$a_d = \arg \max_{\|a\|=1, a \perp a_1, \dots, a \perp a_{d-1}} Da^T X, \quad (2.2.3)$$

čia D žymi dispersiją.

Tegul R yra atsitiktinio vektoriaus X kovariacinė matrica, kurios skleidinys tikrinėmis reikšmėmis gali būti užrašytas taip:

$$R = QDQ^T, \quad (2.2.4)$$

čia D yra diagonalinė matrica, kuri sudaryta iš matricos R tikrinių reikšmių λ_i , išdėstytų nedidėjimo tvarka $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_d$, o Q yra matrica, kurios stulpeliai yra atitinkamai R tikrines reikšmes λ_i atitinkantys ortonormuoti tikriniai vektoriai q_i .

Tokiu atveju pagrindinių komponentių kryptys sutampa su ortonormuotais tikriniais vektoriais, išdėstytais apibrėžta tvarka:

$$a_i = q_i. \quad (2.2.5)$$

Be to, pagrindinių komponentių dispersijos yra lygios tikrinėms reikšmėms:

$$Da_i^T X = \lambda_i. \quad (2.2.6)$$

Sprendžiant statistikos uždavinius ir turint atsitiktinę imtį, vietoje stebėto vektoriaus X kovariacinės matricos dažniausiai naudojama empirinė kovariacija. Pirmosios p pagrindinių komponentių turi:

$$\frac{\lambda_1 + \lambda_2 + \dots + \lambda_p}{\lambda_1 + \lambda_2 + \dots + \lambda_d} \quad (2.2.7)$$

pradinių duomenų dispersijos, tad pasirinkę konkrečią reikiamą išlaikyti dispersijos dalį, galime nustatyti reikiamą pagrindinių komponentių kiekį [32].

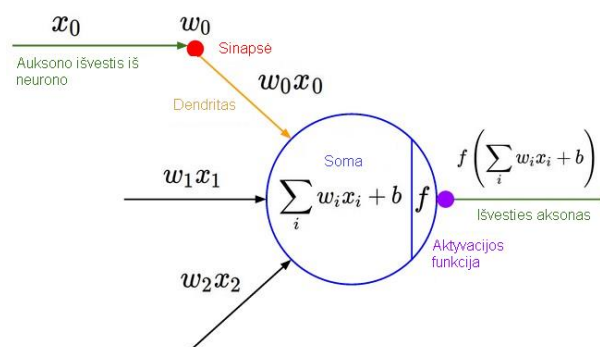
2.3. NEURONINIAI TINKLAI

Mašininis mokymasis (angl. *machine learning* arba ML) – adaptyvių kompiuterinių programų, kurios geba prisitaikyti prie duomenų ir taip pagerinti savo veiklą, kūrimas. Ši kompiuterių mokslo (angl. *computer science*) sritis glaudžiai siejasi su optimizavimu, nes mokymosi uždavinys dažnai tapatinamas su paklaidos funkcijos minimizavimu [33]. Išskiriamos trys pagrindinės ML kategorijos:

- **prižiūrimasis mokymasis** (angl. *supervised learning*) – žinomi pradiniai duomenys ir rezultatai, programa siekia sukurti duomenis į rezultatus atvaizduojančią funkciją;
- **neprižiūrimasis mokymasis** (angl. *unsupervised learning*) – žinomi tik pradiniai duomenys, programa siekia atrasti panašumus ir duomenis apjungti į grupes;
- **skatinamasis mokymasis** (angl. *reinforcement learning*) – netiesiogiai sąveikaujant su aplinka renkami tiek pradiniai, tiek anksčiau atlikto veiksmo rezultatų duomenys, kuriuos programa pasitelkia tolesniam apsimokymo etape [34].

Vienas iš dažnai naudojamų prižiūrimo mašininio mokymosi metodų – **dirbtiniai neuroniniai tinklai** (angl. *artificial neural networks* arba ANNs). Savo architektūra bei savybėmis dirbtiniai neuroniniai tinklai primena žmogaus smegenis. Šia informacijos apdorojimo sistema bandoma atkartoti smegenyse sluoksniais išsidėsčiusių ir tarpusavyje susijungusių neuronų gebėjimą mokytis iš patirties.

Dirbtinis neuroninis tinklas, sudarytas iš vieno dirbtinio neurono, vadinamas **perceptronu**. Tai pats paprasčiausias modelis, kuris padeda suprasti, kaip imituojamos biologinio neurono funkcijos. Perceptrono modelis ir sąsaja su biologiniu neuronu pateikiama 2.3.1 paveikslėlyje.



2.3.1 pav. Perceptrono modelis [35]

Iš 2.3.1 pav. matyti, jog perceptronui pateikiami priminiai duomenys – jis gauna $k = 2$ įvesties signalus x_1, \dots, x_k . Sakoma, jog šie įvesties signalai priklauso įėjimo sluoksniui. x_1, \dots, x_k dažniausiai yra realieji skaičiai ir kiekvienas jų turi tam tikrą svorį w_1, \dots, w_k . Šie svoriai parodo signalų svarbą modelyje ir galėtų būti lyginami su biologinio neurono sinapsių efektyvumu [35]. Perdavimo funkcijos rezultatas gaunamas susumavus įvesčių ir svorių sandaugas:

$$\sum_i w_i x_i + b \quad (2.3.1)$$

čia b – slenkstinė reikšmė.

Jis perduodamas **aktyvacijos funkcijai** $f(\sum_i w_i x_i + b)$, kurios rezultatas tampa tinklo toliau perduodamu signalu arba galutiniu rezultatu. Aktyvacijos funkcijas galima skirstyti į dvi pagrindines grupes:

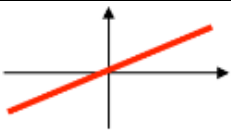
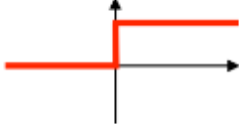

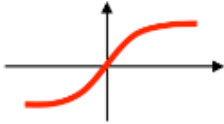
- tiesinės aktyvacijos funkcijos;
- netiesinės aktyvacijos funkcijos [36].

Tiesinės aktyvacijos funkcijos retai naudojamos, kadangi nesugeba susidoroti su sudėtingesnėmis užduotomis ir įvesčių gausa. Dažniau naudojamos netiesinės aktyvacijos funkcijos, kurias galime skaidyti į dvi pagrindines grupes:

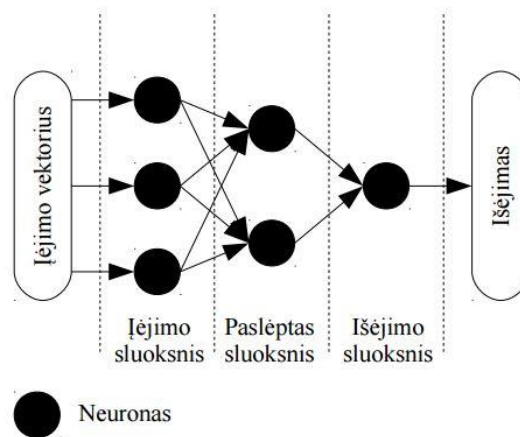
- logistinės funkcijos;
- tangento aktyvacijos funkcijos.

Sigmoidė (viena iš logistinių funkcijų) įgyja reikšmes (0,1) intervale. Ši funkcija diferencijuojama, monotonišė. Ji ypač puikiai tinka modeliuose, kurių išvestis yra prognozuojama tikimybė. Hiperbolinis tangentas įgyja reikšmes (-1,1) intervale. Ši funkcija diferencijuojama, monotonišė. Funkcijos pranašumu laikoma tai, jog esant neigiamoms x reikšmėms hiperbolinis tangentas bus stipriai neigiamas. Dažnai ši funkcija naudojama esant dviejų klasių atskyrimo uždaviniui. Aktyvacijos funkcijų aprašymas pateikiamas 2.3.1 lentelėje.

2.3.1 lentelė. Aktyvacijos funkcijos

Pavadinimas	Grafinė interpretacija	Funkcija	Išvestinė
Tapatumo funkcija	 2.3.2 pav. Aktyvacijos funkcija – tapatumo [36]	$f(x) = x$ (2.3.2)	$f'(x) = 1$ (2.3.3)
Dvinarė funkcija	 2.3.3 pav. Aktyvacijos funkcija – dvinarė [36]	$f(x) = \begin{cases} 0, & x < 0 \\ 1, & x \geq 0 \end{cases}$ (2.3.4)	$f'(x) = \begin{cases} 0, & x \neq 0 \\ ?, & x = 0 \end{cases}$ (2.3.5)
Logistinė funkcija	 2.3.4 pav. Aktyvacijos funkcija – logistinė [36]	$f(x) = \frac{1}{1+e^{-x}}$ (2.3.6)	$f'(x) = f(x)(1-f(x))$ (2.3.7)
Hiperbolinis tangentas	 2.3.5 pav. Aktyvacijos funkcija – hip. tangentas [36]	$f(x) = \frac{2}{1+e^{-2x}} - 1$ (2.3.8)	$f'(x) = 1 - f(x)^2$ (2.3.9)

Vienasluksniai neuroniniai tinklai, kurie yra sudaryti iš vieno įėjimo ir vieno išėjimo sluoksnio, nėra tinkami sudėtingų uždavinių sprendimui. Tai lemia jų skiriamųjų paviršių paprastumas. Sudėtingiems uždaviniams naudojami **daugiasluksniai neuroniniai tinklai**, kurie gali turėti vieną ir daugiau paslėptųjų sluoksnių. Paslėptuosius sluoksnius sudaro neuronai, kurie priima informaciją iš įvesties sluoksnio arba kitų paslėptojo sluoksnio neuronų. Apdorota informacija toliau perduodama išvesties sluoksnio neuronams arba kitiems paslėpto sluoksnio neuronams (2.3.6 pav.).

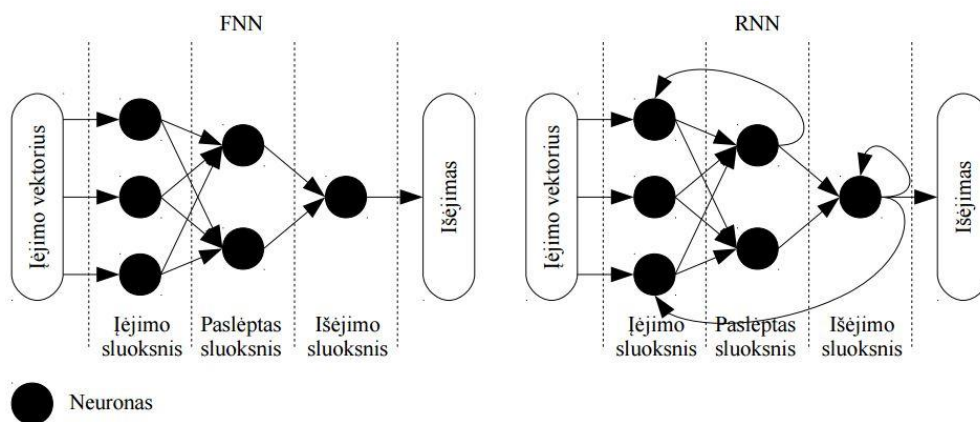


2.3.6 pav. Daugiasluksnio neuroninio tinklo sluoksniai [37]

Pagal siunčiamų signalų neuroniniame tinke kryptį išskiriami:

- tiesioginio ryšio neuroniniai tinklai (angl. *feedforward neural networks* arba FNN);
- rekurentiniai neuroniniai tinklai (angl. *recurrent neural networks* arba RNN) [37].

Tam tikrame FNN sluoksnyje esantys išvesties signalai gali sietis tik su tolimesnio sluoksnio įvestimis. RNN tinkle šio apribojimo nebelieka, t.y. šiems tinklams būdingas tam tikras vėlavimas (2.3.7 pav.).



2.3.7 pav. Signalų kryptis daugiasluksniame neuroniniame tinkle [37]

Dažniausiai taikomas ir paprasčiausias ANN **apmokymo algoritmas** – klaidos skleidimo atgal (angl. *error backpropagation* arba BP). Juo siekiama neurono tinklo svorių atžvilgiu minimizuoti paklaidos funkciją [38]. Metodo procesas interatyvus. Turint apmokymui skirtą duomenų aibę, tinklą sudarančių jungčių svoriai pasirenkami atsitiktinai. Tinklo išvesties rezultatas palyginamas su rezultatais, kurių tikėtasi, bei apskaičiuojama E_{total} paklaidos funkcija. BP algoritmo tikslas yra šią funkciją minimizuoti – dėl šios priežasties skaičiuojamos dalinės išvestinės kiekvienam jungties svoriui ir šis svoris atitinkamai keičiamas:

$$w_i = w_i - \alpha \frac{\partial E_{total}}{\partial w_i}, \quad (2.3.10)$$

kur α yra žingsnio ilgis.


Tuomet procesas su pakeistais svoriais kartojamas tol, kol gaunama norima paklaidos reikšmė. Deja, toks algoritmas remiasi tik lokaliais nuolydžiais, todėl neretai jis gali įstrigti.

Nors neuroniniai tinklai puikiai susidoroja įvairiomis užduotimis, jiems būdingi ir tam tikri trūkumai:

- taikant ANN didelė apmokymo duomenų imtis lemia ilgą apmokymo laiką;
- ANN laikomi „juoda dėžė“, todėl parametrų interpretacija negalima;
- ANN sukurti modeliai nėra tikimybiniai: nežinomas gauto modelio pasikliautinumas.


2.4. REKURENTINIAI NEURONINIAI TINKLAI

Kaip jau minėta ankstesniame skyrelyje, neuroniniai tinklai bando mėgdžioti žmogaus smegenų ląstelių veiklą. Svarbu pabrėžti, jog žmogaus mintys yra tęstinės. Jos priklauso ir remiasi ankstinėmis žiniomis – būsenomis. Tai vienas iš dalykų, kurio negalima atkartoti tiesioginio sklidimo neuroniniais tinklais [39]. Rekurentiniai neuroniniai tinklai su šia užduotimi susidoroja. RNN tinkluose esantys ciklai lemia tam tikrus vėlavimus, kurie leidžia kaupti ankstesnes būsenas – informaciją. 2.4.1 paveikslėlyje matyti supaprastinta RNN tinklo schema. A žymi neuroninio tinklo dalį, x_t – įvestį laiko momentu t , h_t – išvesties signalą laiko momentu t .




2.4.1 pav. Ciklai rekurentiniuose neuroniniuose tinkluose [39]

RRN gali būti interpretuojami ir kaip kelios sujungtos to paties tinklo kopijos, kurios ne tik pateikia išvesties signalą, bet ir perduoda ją tolimesniam tinklui (žiūrėti 2.4.2 pav.).




2.4.2 pav. RNN interpretacija [39]

Sprendžiant skirtingus uždavinius, praeities būsenų, kurios yra svarbios galutiniam rezultatui, skaičius yra skirtingas. Puikus pavyzdys galėtų būti žodžius generuojantis RNN modelis. Tarkime, jog RNN tikslas yra prognozuoti paskutinį sakinio žodį. Tinklui pateikus įvestį „Daug debesų yra“, prieš tai buvęs sakiny s nėra labai svarbus tiksliai prognozei – žodžiui „danguje“. Kai atotrūkis tarp svarbios informacijos ir vietos, kurioje ji reikalinga, nedidelis, RNN tinklai susidoroja gana neblogai (žiūrėti 2.4.3 pav.).



2.4.3 pav. RNN – nedidelis atotrūkis tarp svarbios informacijos ir jos panaudojimo [39]


Tačiau kai kuriais atvejais reikalingas platesnis kontekstas. Tinklui pateikus įvestį „Aš užaugau Lietuvoje. Aš kalbu“, paskutinė įvestis – žodis „kalbu“ – sufleruoja, jog žodis sakinio pabaigoje turėtų būti kalbos pavadinimas, tačiau nežinoma kokios. Šioje situacijoje prieš tai buvęs sakiny tampa labai svarbus tiksliai prognozei – žodžiui „lietuviškai“. Kai atotrūkis tarp svarbios informacijos ir vietos, kurioje ji reikalinga, didelis, RNN tinklai susiduria su tam tikromis problemomis ir jų prognozės tampa ne visai tikslios [40].



2.4.4 pav. RNN – didelis atotrūkis tarp svarbios informacijos ir jos panaudojimo [39]

2.5. ILGALAIKĖS – TRUMPALAIKĖS ATMINTIES NERONINIAI TINKLAI

Uždaviniams, kuriuose atotrūkis tarp svarbios informacijos ir jos panaudojimo yra sąlyginai didelis, spęsti dažnai naudojami ilgalaikės – trumpalaikės atminties dirbtiniai neuroniniai tinklai (angl. *Long Short Term Memory networks* arba LSTM). LSTM laikomi tam tikra RNN tinklų atmaina, kuri geba prisiminti didelį kiekį informacijos.




2.5.1 pav. LSTM schema [39]

LSTM tinklas schematiškai pavaizduotas 2.5.1 paveikslėlyje. Linijos žymi siunčiamą signalą – vektorių, 4 geltoni stačiakampiai žymi atskirus tinklo sluoksnius, raudoni apskritimai žymi operacijas, atliekamas tarp susikertančių vektorių. Pirmajame žingsnyje LSTM turi nuspręsti, kurios būsenos bus pašalintos iš jau sukauptų. Šį sprendimą priima sluoksnis, turintis sigmoidės aktyvacijos funkciją, dar vadinamas užmiršimo vartų sluoksniu (angl. *forget gate layer*) (žiūrėti 2.5.2 pav.). Šio sluoksnio įvestys yra būsenos $t - 1$ išvesties signalas h_{t-1} ir t būsenos įvestis x_t :

$$f_t = \sigma(W_f * [h_{t-1}, x_t] + b_f) \quad (2.5.1)$$

Sigmoidės funkcijos rezultatas – skaičius tarp 0 ir 1, atitinkantis kiekvieną C_{t-1} sukauptą būseną. 1 reiškia šią būseną išsaugoti, 0 – pamiršti.




2.5.2 pav. LSTM schema – užmiršimo vartų sluoksnis [39]

Antrajame žingsnyje LSTM turi nuspręsti, kuri nauja informacija bus išsaugoma kaupiamose būsenose. Šį sprendimą priima du sluoksniai: antrasis sluoksnis, kuris taip pat turi sigmoidės aktyvacijos funkciją ir yra vadinamas įvesties vartų sluoksniu (angl. *input gate layer*), bei trečiasis sluoksnis, turintis hiperbolinio tangento aktyvacijos funkciją (žiūrėti 2.5.3 pav.). Įvesties vartų sluoksnis analogiškas užmiršimo vartų sluoksniui:

$$i_t = \sigma(W_i * [h_{t-1}, x_t] + b_i) \quad (2.5.2)$$

Hiperbolinio tangento sluoksnis sukuria kandidatuojančių į išsaugomas būsenas reikšmių vektorių \tilde{C}_t :


$$\tilde{C}_t = \tanh(W_C * [h_{t-1}, x_t] + b_C) \quad (2.5.3)$$



2.5.3 pav. LSTM schema – įvesties vartų sluoksnis [39]

Kitame žinginyje senos C_{t-1} būsenos atnaujinamos į C_t (žiūrėti 2.5.4 pav.). Pirmiausiai C_{t-1} būsenos padauginamos iš f_t , visiškai arba sąlyginai pamirštant kai kurias būsenas. Paskui prie būsenų pridama įvesties vartų bei kandidatuojančių naujų būsenų sandauga:

$$C_t = f_t C_{t-1} + i_t \tilde{C}_t \quad (2.5.4)$$




2.5.4 pav. LSTM schema – sukauptų būsenų atnaujinimas [39]

Iteracijos pabaigoje tinklas apskaičiuoja išvesties signalą. Pirmiausiai būsenos $t - 1$ išvesties signalas h_{t-1} ir t būsenos įvestis x_t yra paveikiamas sigmoidės aktyvacijos funkcija, taip nusprendžiant, kurios būsenos bus svarbios formuojant išvesties signalą:

$$o_t = \sigma(W_o * [h_{t-1}, x_t] + b_o) \quad (2.5.5)$$

C_t būsenos tuomet yra paveikiamos hiperbolinio tangento funkcija bei padauginamos iš sigmoidės funkcijos išvesties, taip išaugant tik sigmoidės funkcijos parinktas būsenas:

$$h_t = o_t * \tanh(C_t) \quad (2.5.6)$$



2.5.5 pav. LSTM schema – išvesties signalas [33]

2.6. METODŲ VERTINIMAS

Paklaidos funkcija padeda įvertinti modelio daromą klaidą lyginant modelio prognozuojamas bei tikrąsias reikšmes. Dažniausiai naudojamos paklaidos funkcijos pateikiamos 2.6.1 lentelėje [41].

2.6.1 lentelė. Paklaidos funkcijos

Pavadinimas	Formulė
<i>MSE</i> – vidutinė kvadratinė paklaida (angl. <i>mean square error</i>)	$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (2.6.1)$
<i>RMSE</i> – kvadratinė šaknis iš vidutinės kvadratinės paklaidos (angl. <i>root mean square error</i>)	$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (2.6.2)$
<i>MPE</i> – vidutinė procentinė paklaida (angl. <i>mean percentage error</i>)	$MPE = \frac{100}{n} \sum_{i=1}^n \frac{\hat{y}_i - y_i}{y_i} \quad (2.6.3)$
<i>MAPE</i> – vidutinė absoliutinė procentinė paklaida (angl. <i>mean absolute percentage error</i>)	$MAPE = \frac{100}{n} \sum_{i=1}^n \left \frac{\hat{y}_i - y_i}{y_i} \right \quad (2.6.4)$
<i>MASE</i> – vidutinė absoliutinė normuota paklaida (angl. <i>mean absolute scaled error</i>)	$MASE = \frac{1}{n} \sum_{i=1}^n \frac{ \hat{y}_i - y_i }{\frac{1}{n-1} \sum_{i=2}^n y_{i-1} - y_i } \quad (2.6.5)$

Čia n – įvesčių skaičius; y_i yra i -tąją įvestį atitinkanti reikšmė; \hat{y}_i – prie i -osios įvesties prognozuojamas rezultatas.

3. EMPIRINIS TYRIMAS

3.1. DUOMENYS

Bandant surasti investicinį patrauklumą lemiančių veiksnių kiekybinius rodiklius, naudotasi trimis duomenų šaltiniais.

1. **Eurostat** – Europos Bendrijų statistikos tarnyba, skelbianti oficialius statistinius rodiklius, kurie apskaičiuojami pasitelkiant nacionalinių statistikos institucijų duomenis. Duomenys internetinėje svetainėje pateikiami apibendrintose ataskaitose, lentelėse bei vaizduojami grafiškai. Duomenys laisvai prieinami.
2. **WorldBank** – Pasaulio banko statistikos tarnyba, glaudžiai bendradarbiaujanti su Jungtinėmis Tautomis, Tarptautine ekonominio bendradarbiavimo ir plėtros organizacija, Tarptautiniu valiutos fondu, vykdanči duomenų mainus bei duomenų kokybės užtikrinimą bei kaupianti duomenis teminėse duomenų bazėse. Duomenys renkami pasitelkiant bendradarbiaujančių valstybių nacionalinių statistikos institucijų duomenis. Duomenys internetinėje svetainėje pateikiami lentelėse bei vaizduojami grafiškai. Duomenys laisvai prieinami.
3. **TheGlobaEconomy** – Amerikos ekonomikos asociacijos rekomenduojama virtuali duomenų bazė, kurioje pateikiami įvairūs ekonominiai, verslo aplinkos rodikliai daugiau nei 200 valstybių. Duomenys renkami ir atnaujinami pasitelkiant WorldBank, Tarptautinio valiutos fondo, Pasaulio ekonomikos forumo bei kitų šaltinių duomenis. Duomenys internetinėje svetainėje pateikiami lentelėse bei vaizduojami grafiškai. Duomenys laisvai prieinami.

Tiriant Šiaurės Europos valstybes, dėl statistinių duomenų trūkumo kitoms valstybėms, apsiribota Danijos, Estijos, Didžiosios Britanijos, Suomijos, Airijos, Islandijos, Lietuvos, Latvijos, Norvegijos bei Švedijos valstybėmis. Norint užtikrinti, jog duomenys būtų be trūkstamų reikšmių, pasirinktas 2006 – 2016 metų tyrimo laikotarpis. Surinkti duomenys – kiekybiniai. Kintamųjų lietuviški ir angliški pavadinimai bei veiksniai ir veiksnių grupės, kurioms jie priklauso, pateikiami prieduose „Duomenų matrica“.


3.2. TIESIOGINIŲ UŽSIENIO INVESTICIJŲ KINTAMOJO APŽVALGA

Vienas iš būdų nustatyti valstybės investicinį patrauklumą yra palyginti jos pritraukiamas tiesiogines užsienio investicijas su kitų valstybių TUI tam tikru laiko intervalu, todėl tyrimas pradėtas apžvelgiant bendras TUI kitimo tendencijas. Programinis kodas ir visi rezultatai pateikiami prieduose „TUI apžvalga“. Lyginant vidutines TUI reikšmes 2006–2016 metų laikotarpiu (3.2.1 pav.), matyti, jog iš nagrinėtų valstybių vidutiniškai daugiausiai, net 95,02 milijonus dolerių, TUI pritraukia Didžioji Britanija. Antroje vietoje atsiduria Airija su beveik 39,67 milijonais dolerių. Skandinavijos regiono valstybės gerokai atsilieka nuo pirmaujančios Didžiosios Britanijos bei Airijos. Jų pritraukiamos TUI svyruoja nuo 15 milijonų (Švedija) iki 1,37 bilijono dolerių (Islandija). Islandija pritraukiamomis TUI artimesnė atsiliekančiam Baltijos regionui. Čia vidutiniškai pritraukiamų investicijų vertė šiek tiek didesnė nei 1 bilijonas dolerių.

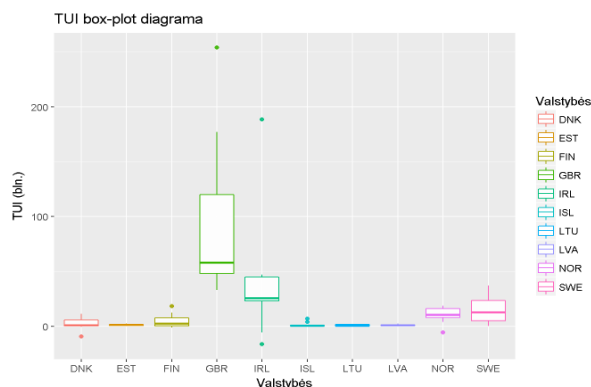
Valstybė	Vidurkis	Standartinis nuokrypis	Mediana
GBR	95.0228088074618	69.747542720964	58.2002815295305
IRL	39.6699817281622	53.281329193215	25.7153295927029
SWE	15.1234521878575	11.8729727987211	12.9294652839591
NOR	10.4119470183741	6.96757860766581	10.5260449719568
FIN	4.86218652958369	6.08910392500861	2.54985090810518
DNK	2.58392595370905	5.57264992068466	1.05051181291631
ISL	1.37383011220185	2.11823283259926	0.708540847034923
EST	1.24970028120373	0.641074370701132	1.33441009808804
LVA	0.978798061381722	0.679095193644656	0.903116075091714
LTU	0.894555530084717	0.816484337011557	0.799396062486342

3.2.1 pav. TUI statistinė apžvalga

Iš TUI kitimą 2006–2016 metais atspindinčio grafiko (3.2.2 pav.) matyti, kad nors 2015 metais Airija pritraukė rekordinį kiekį užsienio investicijų (188 milijonus dolerių), 2016 metais šis dydis sumažėjo net 88 %. Gana ryški išskirtis matoma ir Didžiosios Britanijos TUI stačiakampėje diagramoje (3.2.3 pav.). Stebėto laikotarpio pabaigoje (2016 m.) Didžiosios Britanijos TUI pasiekė net 253,83 milijonus dolerių, nors iki tol, po 2007 metų finansinės krizės, TUI tendencingai mažėjo. Investicijų mažėjimas, nors ir ne toks ryškus, krizės laikotarpiu matomas ir kitose valstybėse. Pastebėtų tendencijų priežastys plačiau aptariamos 1.2.1.2 skyrelyje.




3.2.2 pav. TUI kitimas 2006–2016 metais



3.2.3 pav. TUI stačiakampė diagrama


3.3. IŠORINIŲ KINTAMŲJŲ PAIEŠKA

Kaip minėta 1.3 skyrelyje, tiesioginės užsienio investicijos priklauso nuo įvairių išorinių veiksnių, nusakomų skirtingais kiekybiniais rodikliais. Sprendžiant didelio dimensijų kiekio problemą ir siekiant išsiaiškinti, kurie rodikliai priežastingai veikia TUI, pirmiausiai buvo atlikta Grangerio priežastingumo analizė. Šios analizės metu iš plačios aibės rodiklių atrinkti tie, kurie priežastingai veikia bent vienos iš dešimties nagrinėtų valstybių TUI (programinis kodas ir visi rezultatai pateikiami prieduose „Priežastingumo analizė“). Apibendrinant analizės rezultatus ir apžvelgiant fiksuotų priežastingumų nagrinėtoje valstybių aibėje pasiskirstymą (3.3.1 pav.), pastebėta, jog 22 rodikliai (iš 61 reikšmingo) priežastingai veikia tik vienos iš dešimties nagrinėtų valstybių TUI. Neaptiktas toks rodiklis, kuris priežastingai veiktų visų valstybių TUI. Taip pat pastebėta aiški mažėjimo tendencija – atvejų, kuriuose priežastingumas užfiksuotas tam tikrame valstybių skaičiuje, skaičius, augant valstybių skaičiui, mažėja.



3.3.1 pav. Fiksuotų reikšmingų priežastingumų tarp TUI ir išorinių kintamųjų pasiskirstymas

Taip pat bandyta įvertinti, ar panašūs rezultatai gaunami taikant koreliacinę analizę (programinis kodas ir pilni rezultatai pateikiami prieduose „Koreliacinė analizė“). Apibendrinant analizės rezultatus ir apžvelgiant fiksuotų vidutinių ir stipresnių (absoliutinė koreliacijos koeficiento reikšmė didesnė arba lygi 0,3) koreliacijos atvejų nagrinėtoje valstybių aibėje pasiskirstymą (3.3.2 pav.), taip pat pastebėta, jog bendro išorinio kintamojo, kuris vidutiniškai ar stipriai koreliuotų su visų valstybių TUI, nėra.




3.3.2 pav. Fiksuotų vidutinių ir stiprių koreliacijų tarp TUI ir išorinių kintamųjų pasiskirstymas

Remiantis šiais rezultatais nuspręsta, jog TUI geriausiai būtų modeliuoti kiekvienai valstybei atskirai arba ieškoti klasterių, į kuriuos būtų galima apjunti nagrinėjamas valstybes (plačiau apie tai 3.5 skyrelyje).

3.4. IŠORINIŲ KINTAMŲJŲ APŽVALGA

Remiantis teoriniu modeliu (1.3 skyrelis) bei atliekant priežastingai TUI veikiančių kintamųjų paiešką (3.3 skyrelis), rastas 61 TUI galimai veikiantis kiekybinis kintamasis. Visi išoriniai kintamieji pateikiami prieduose „Duomenų matrica“. Toliau paaiškinamos kai kurios savybės, aptiktos atliekant šių kintamųjų statistinę apžvalgą.


1. Lyginant valstybių bendrojo vidaus produkto (toliau BVP), tenkančio vienam gyventojui, pasiskirstymą 2006–2016 metų laikotarpiu (3.4.1 pav.), galime išskirti tris valstybių grupes:



3.4.1 pav. BVP pasiskirstymas

- Lietuvos, Latvijos ir Estijos pasiskirstymai gana simetriški, smailiomis viršūnėmis bei pasislinkę į kairę pusę – vidutinis BVP, tenkantis vienam gyventojui, 2006–2016 laikotarpiu šiose valstybėse buvo mažesnis lyginant su kitomis;
- Didžiosios Britanijos, Suomijos, Danijos, Švedijos, Airijos, Islandijos BVP pasiskirstymų viršūnės (2006–2016 laikotarpiu dažniausiai stebėtos reikšmės) išsidėstę ties 50000 dolerių BVP atžyma;
- Norvegijos BVP pasiskirstymas neturi išreikštos viršūnės bei yra pasislinkęs į dešinę pusę – vidutinis BVP, tenkantis vienam gyventojui, 2006–2016 laikotarpiu šioje valstybėse buvo didesnis, lyginant su kitomis.

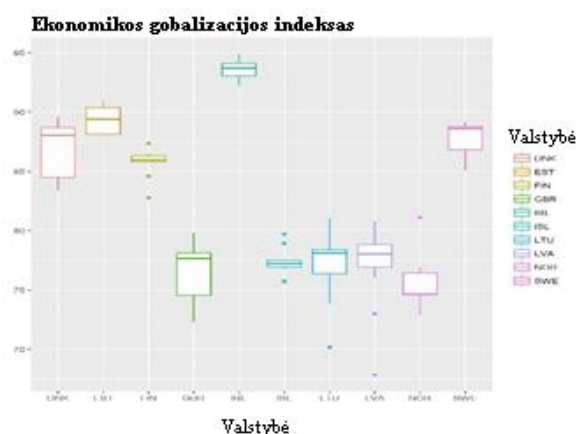
2. Lyginant nedarbo lygio tendencijas 2006–2016 metų laikotarpiu (3.4.2 pav.), taip pat išskirtos trys valstybių grupės:



3.4.2 pav. Nedarbo lygis 2006–2016 metais


- Lietuvos, Latvijos, Estijos bei Airijos nedarbo lygis stebėtu laikotarpiu didžiausias – vidutiniškai siekiantis beveik 13,5 %, o ryškus jo šuolis matomas 2008 metais prasidėjus finansinei krizei;
- Didžiosios Britanijos, Suomijos, Danijos, Švedijos, Islandijos nedarbo lygis gana panašus ir vidutiniškai siekiantis 6,5 %;
- Norvegijos nedarbo lygis iš stebėtų valstybių stabiliausias bei žemiausias – vidutiniškai siekiantis 3,4 %.

3. Liginant ekonomikos globalizacijos indekso pasiskirstymą 2006–2016 metų laikotarpiu (3.4.3 pav.), taip pat išskirtos trys valstybių grupės:



3.4.3 pav. Ekonomikos globalizacijos indekso stačiakampė diagrama

- Didžiosios Britanijos, Islandijos, Lietuvos, Latvijos bei Norvegijos ekonomikos globalizacijos indeksas vidutiniškai lygus 76,6;
 - Suomijos, Danijos, Švedijos, Estijos ekonomikos globalizacijos indeksas vidutiniškai lygus 86,7;
 - Airijos ekonomikos globalizacijos indeksas aukščiausias ir vidutiniškai siekia 93,6.
4. Liginant moderniujų technologijų eksporto, tenkančio vienam gyventojui, vertę 2006–2016 metų laikotarpiu (3.4.4pav.), išskirtos 2 valstybių grupės:



3.4.4 pav. Moderniųjų technologijų eksporto pasiskirstymas

- Suomijos, Danijos, Švedijos, Estijos, Didžiosios Britanijos, Islandijos, Lietuvos, Latvijos bei Norvegijos moderniujų technologijų eksporto, tenkančio vienam gyventojui, vertė vidutiniškai lygi 1000 dolerių;
- Airijos moderniujų technologijų eksporto, tenkančio vienam gyventojui, vertė aukščiausia ir vidutiniškai siekia 5711 dolerių.

Šiame skyrelyje aptartos tik kai kurių išorinių kintamųjų savybės. Visi apžvalgos rezultatai bei programinis kodas pateikiami prieduose „Išorinių kintamųjų statistinė apžvalga“. Apibendrinant rezultatus, pastebėta, jog ryškėja valstybių, kurioms būdinga panaši ekonominė, verslo aplinka bei aplinkos kitimo tendencijos, grupės. Valstybių grupavimas aptariamas 3.5 skyrelyje.

3.5. VALSTYBIŲ KLASTERIZAVIMAS

Atliekant TUI kintamojo bei išorinių kintamųjų statistinę analizę, pastebėta, jog valstybės gali būti grupuojamos. Valstybių grupavimui taikytas k–vidurkių klasterizavimo metodas. Kintamųjų reikšmės agreguotos skaičiuojant vidurkius. Visi klasterizavimo rezultatai bei programinis kodas pateikiami prieduose „Klasterizavimas“.


Pirminės grupės sudarytos remiantis valstybių gebėjimu pritraukti užsienio investicijas be valstybių BVP vienam gyventojui. Imant 2006–2016 metų laikotarpiu stebėtų reikšmių vidurkius, rastos 5 valstybių grupės (3.5.1 lentelė), kurios paaiškina 98,6 % duomenų sklaidos (3.5.1 pav.). Kontūrinės linijos diagramoje atskiria mažas–vidutines–dideles TUI bei žemą–vidutinę–aukštą ekonominę galią (nagrinėjamų valstybių BVP kontekste).

3.5.1 lentelė. Klasterių skaičiaus pagal TUI ir BVP parinkimas

Klasterių skaičius	Paiškinama sklaida
2	43,9 %
3	82,6 %
4	92,8 %
5	98,6 %


Išskirtos 5 valstybių grupės:

- Lietuvos, Latvijos, Estijos valstybėms būdingas žemas ekonominis lygis ir mažos TUI;
- Islandijos, Suomijos, Danijos, Švedijos valstybėms būdingas vidutinis ekonominis lygis bei mažos TUI;
- Norvegijos valstybei būdingas aukštas ekonomikos lygis ir mažos TUI;
- Airijos valstybei būdingas vidutinis ekonomikos lygis ir vidutinės TUI;
- Didžiosios Britanijos valstybei būdingas vidutinis ekonominis lygis bei didelės TUI.



3.5.1 pav. Klasterizavimas pagal BVP ir TUI

Bandant nustatyti, kaip šios grupės keitėsi 2006–2016 metų laikotarpiu, pastebėtos 3.2 skyrelyje minėtos ir 1.2.1.2 skyrelyje plačiau aptartos tendencijos: rekordinės Airijos TUI 2015 metais bei Didžiosios Britanijos išsiveržimas 2016 metais (3.5.2 pav.).



3.5.2 pav. Klasterių pokyčiai

Nors valstybių grupavimas lyginant kiekybinius TUI ir BVP rodiklius yra gana intuityvus, tačiau pats investicinis patrauklumas turėtų būti suprantamas kaip jį lemiančių veiksnių visuma. Dėl šios priežasties k-vidurkių klasterizavimo metodas dar kartą pritaikytas įtraukiant visus TUI lemiančius išorinius veiksnius.

3.5.2 lentelė. Klasterizavimo pagal visus išorinius kintamuosius rezultatai

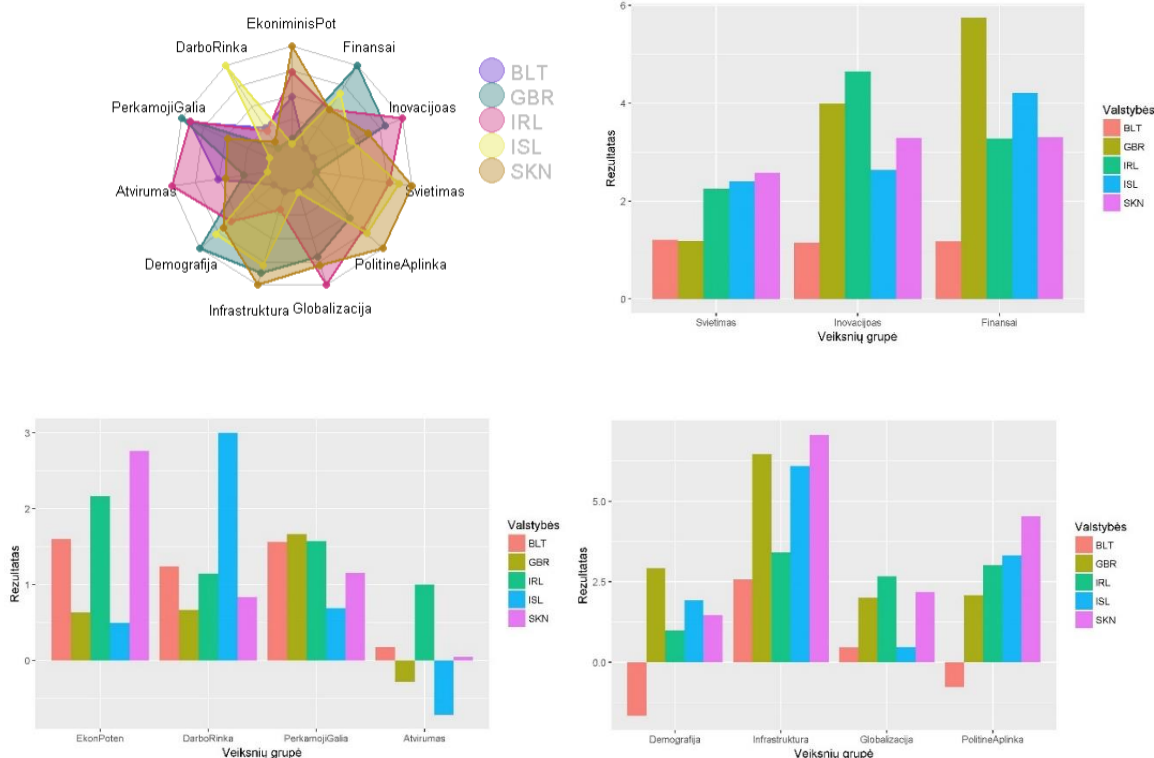
Klasterių skaičius	Paaškinama sklaida
2	38,3 %
3	52,3 %
4	65,9 %
5	75,7 %

Iš rezultatų matome, jog, įtraukiant visus išorinius kintamuosius, taip pat išskirtos 5, nors kiek kitokios, valstybių grupės (3.5.2 lentelė), kurios paaškina 75,7 % duomenų sklaidos.

Išskirtos šios valstybių grupės:

- Danijos, Suomijos, Norvegijos ir Švedijos valstybės (Skandinavijos regionas);
- Islandija;
- Didžioji Britanija;
- Lietuvos, Latvijos ir Estijos valstybės (Baltijos regionas);
- Airija.

Norint palyginti šias išskirtas grupes, sudaryta voratinklinė diagrama. Išoriniai kintamieji agreguoti skaičiuojant vidurkius. Standartizuotos jų reikšmės apjungtos sumuojant – suformuoti išskirtas veiksnių grupes (1.3 skyrelis) atspindintys indeksai, kurie ir vaizduojami voratinklinėje bei stulpelinėje diagramose (3.5.3 pav.). Visi rezultatai bei programinis kodas pateikiami prieduose pavadinimu „Voratinklinė diagrama“.



3.5.3 pav. Išskirtų valstybių grupių palyginimas

Pastebėta, jog regionai pasižymi skirtingomis savybėmis:

- Skandinavijos regiono valstybės gali pasigirti didžiausiu ekonominiu potencialu, puikia infrastruktūra, švietimo sistema bei stabilia politine aplinka
- Islandija gali pasigirti puikiomis darbo rinkos sąlygomis, tačiau ekonominis atvirumas čia vertinamas prasčiausiai
- Didžiosios Britanijos perkamoji galia bei finansinė situacija geriausia
- Airija gali pasigirti savo inovatyvumu bei ekonominiu atvirumu
- Nors ir gana neblogą ekonominį potencialą bei perkamąją galią turinčios Baltijos regiono valstybės negali pasigirti stabilia politine aplinka bei verslui palankia demografinė padėtimi


Norint įvertinti sudarytų valstybių grupių/regionų investicinį patrauklumą, remiantis veiksmų grupėmis (1.3 skyrelis) sudarytas investicinį patrauklumą 2016 metais atspindintis indeksas. Rezultatai pateikiami 3.5.3 lentelėje. Iš jos matyti, jog Didžioji Britanija buvo patraukliausia investuotojams, tuo tarpu Baltijos regionas atsiduria sąrašo apačioje. Šie rezultatai neprieštarauja 1.2.2 skyrelyje aptartų GFICA ir VCPE patrauklumo indeksų rezultatams.

3.5.3 lentelė. Investicinio patrauklumo indeksas regionams

Valstybė/regionas	Indekso rezultatas	Vieta
Skandinavijos regionas	26,79	2
Baltijos regionas	8,26	6
Didžioji Britanija	27,13	1
Airija	25,37	4
Islandija	25,23	5

3.6. IŠORINIŲ KINTAMŲJŲ DIMENSIJOS MAŽINIMAS

Norint sumažinti dimensijų skaičių, taikyta pagrindinių komponentių analizė. Visi klasterizavimo rezultatai bei programinis kodas pateikiami prieduose „Pagrindinių komponentių analizė“. Pagrindinių komponentių ieškota tiek kiekvienai valstybei, tiek 3.5 skyrelyje išskirtoms valstybių grupėms atskirai. 3.6.1 paveikslėlyje pateikiamas Danijos pagrindinių komponentių paaiškinamos sklaidos grafikas.



3.6.1 pav. Pagrindinių komponentių paaiškinama sklaida – Danija

Iš grafiko matome, jog pirmoji pagrindinė komponentė paaiškina net 50 % sklaidos. Panašūs rezultatai gauti ir kitoms valstybėms bei regionams. Nustatyta, jog užtenka 4 – 5 pagrindinių komponentių, norint peržengti 90 % visų komponentių suminės sklaidos ribą valstybėms (3.6.1 lentelė) bei regionams (3.6.2 lentelė).

3.6.1 lentelė. Pagrindinių komponentių analizės rezultatai – valstybės

Valstybė	Pagrindinių komponentių skaičius	Paaiškinama suminė sklaida	Bartleto kriterijus
Danija	5	0,90930	$p < 2,2e-16$
Estija	5	0,93116	$p < 2,2e-16$
Suomija	5	0,93480	$p < 2,2e-16$
Didžioji Britanija	5	0,90676	$p < 2,2e-16$
Airija	4	0,91050	$p < 2,2e-16$
Islandija	4	0,90811	$p < 2,2e-16$
Lietuva	4	0,91037	$p < 2,2e-16$
Latvija	5	0,93399	$p < 2,2e-16$
Norvegija	5	0,91635	$p < 2,2e-16$
Švedija	5	0,93097	$p < 2,2e-16$

3.6.2 lentelė. Pagrindinių komponentių analizės rezultatai – regionai

Regionas	Pagrindinių komponentių skaičius	Paaiškinama suminė sklaida	Bartleto kriterijus
Baltijos regionas	4	0,91862	$p < 2,2e-16$
Skandinavijos regionas	5	0,93494	$p < 2,2e-16$

3.7. TIESIONGINIŲ UŽSIENIO INVESTICIJŲ PROGNOZAVIMAS NEURONINIAIS TINKLAIS

Modeliuojant TUI pasitelkti skirtingos struktūros neuroniniai tinklai – FNN ir RNN. Taip pat išmėginti LSTM tinklai. Tyrimas pradėtas nuo tinklų parametrų derinimo (3.7.1 skyrelis). Kiekvienai valstybei bei valstybių grupei sudarytas tiksliausiai TUI reikšmes prognozuojantis modelis (3.7.2 skyrelis). Šis modelis pritaikytas prognozuojant 2017 metų TUI (3.7.3 skyrelis). Remiantis teorinių modelių sudarytas prognozuojamas 2017 investicinio patrauklumo indeksas bei investicinio patrauklumo žemėlapis (3.7.4 skyrelis).

3.7.1. TINKAMIAUSIO MOEDLIO PAIEŠKA IR PARAMETRŲ DERINIMAS

FNN modeliai sudaryti esant skirtingiems neuronų skaičiams trijose paslėptuose sluoksniuose. Neuronų skaičius sluoksnyje keistas intervale [1; 10]. Taip pat keista aktyvacijos funkcija – naudotos logistinė ir hiperbolinio tangento funkcijos. Parametrai derinti keliems skirtingiems atvejams:

1. kiekvienai valstybei atskirai su visais išoriniais kintamaisiais;
2. kiekvienam regionui atskirai su visais išoriniais kintamaisiais;
3. kiekvienai valstybei atskirai su pagrindinėmis komponentėmis;
4. kiekvienam regionui atskirai su pagrindinėmis komponentėmis.

Paklaidos skaičiuotos naudojant kryžminės validacijos metodą – pašalinant iš imties kiekvieną stebėjimą ir jį prognozuojant. Geriausi rezultatai pateikiami 3.7.1.1 ir 3.7.1.2 lentelėse. Visi rezultatai bei programinis kodas pateikiami prieduose pavadinimu „Prognozavimas FNN“.

3.7.1.1 lentelė. FNN valstybėms/regionams – visi išoriniai kintamieji

Valstybė/regionas	i	j	k	Aktyvacijos f.	RMSE	MPE	MAPE	MASE
DNK	10	8	1	tanh	5555799078,71	87,72	163,86	0,66
EST	2	7	6	logistic	375649627,41	-36,34	59,45	0,56
FIN	3	2	8	tanh	4891187797,38	-149,81	443,57	0,47
GBR	8	5	6	tanh	38388111945,11	-0,09	26,35	0,66
IRL	10	10	4	tanh	37253315687,17	41,18	70,61	0,47
ISL	3	1	3	tanh	894556713,23	-17,12	103,46	0,48
LTU	2	7	10	logistic	383100533,68	147,82	154,93	0,36
LVA	3	5	9	logistic	375587777,14	-44,14	75,20	0,53
NOR	3	2	1	tanh	5364305129,23	-21,37	49,82	0,76
SWE	10	10	3	logistic	5740174595,62	-220,51	256,89	0,43
SKN	6	4	8	logistic	2101952646,27	-23,27	35,20	0,44
BLT	9	8	10	logistic	214913201,68	-8,93	26,05	0,44

3.7.1.2 lentelė. FNN valstybėms/regionams – pagrindinės komponentės

Valstybė/regionas	i	j	k	Aktyvacijos f.	RMSE	MPE	MAPE	MASE
DNK	1	5	7	logistic	5390332006,41	-47,55	206,79	0,69
EST	10	1	3	logistic	575854444,18	-83,59	104,87	0,77
FIN	9	6	5	logistic	5851568851,61	-1225,11	1289,22	0,58
GBR	4	8	3	logistic	63962196735,69	-5,84	40,79	0,99
IRL	8	1	7	logistic	49687378541,42	83,30	136,85	0,59
ISL	10	5	5	logistic	2195440833,29	-90,74	174,04	0,93
LTU	1	1	5	logistic	760109334,41	844,75	871,40	0,89
LVA	1	2	6	logistic	602750876,57	-40,09	74,32	0,81
NOR	5	5	1	logistic	6774568500,95	21,58	63,39	0,85
SWE	1	3	7	logistic	11837187044,47	-2043,24	2079,47	0,96
SKN	1	3	3	logistic	4161990559,32	-44,87	65,10	0,90
BLT	1	9	5	logistic	617078963,95	-4,65	38,81	1,07

RNN modeliai sudaryti esant skirtingiems neuronų skaičiams trijose paslėptuose sluoksniuose. Neuronų skaičius sluoksnyje keistas intervale [1; 10] žingsniu 5. Taip pat keista aktyvacijos funkcija – naudotos logistinė, hiperbolinio tangento bei Gompertzo funkcijos. Parametrai derinti keliems skirtingiems atvejams:

1. kiekvienai valstybei atskirai su visais išoriniais kintamaisiais;
2. kiekvienam regionui atskirai su visais išoriniais kintamaisiais;
3. kiekvienai valstybei atskirai su latentiniais kintamaisiais;
4. kiekvienam regionui atskirai su latentiniais kintamaisiais.

Paklaidos skaičiuotos naudojant kryžminės validacijos metodą, pašalinant iš imties kiekvieną stebėjamą ir jį prognozuojant. Geriausi rezultatai pateikiami 3.7.1.3 ir 3.7.1.4 lentelėse. Visi rezultatai bei programinis kodas pateikiami prieduose pavadinimu „Prognozavimas RNN“.

3.7.1.3 lentelė. RNN valstybėms/regionams – visi išoriniai kintamieji

Valstybė/regionas	i	j	k	Aktyvacijos f.	RMSE	MPE	MAPE	MASE
DNK	10	5	1	Gompertz	5814635810,39	43,68	100,86	0,70
EST	10	10	10	Gompertz	581272642,82	-75,70	103,34	1,01
FIN	10	10	1	Gompertz	6276213078,31	-700,79	1326,96	0,64
GBR	10	10	10	Gompertz	68903775104,79	-48,54	71,81	1,22
IRL	10	10	1	Gompertz	52320118517,74	95,55	145,57	0,61
ISL	5	1	10	Gompertz	1813144418,37	-216,90	296,53	0,97
LTU	10	10	10	Gompertz	682891754,63	978,55	991,00	0,82
LVA	10	10	1	Gompertz	680541749,37	-109,37	151,25	0,96
NOR	10	10	10	Gompertz	6377153127,29	19,04	61,53	0,85
SWE	10	1	1	tanh	10345533715,73	-576,19	627,93	0,83
SKN	10	10	10	Gompertz	437656209	-35,042	55,65	0,92
BLT	10	10	10	Gompertz	3313382164	-31,6076	57,83	0,81

3.7.1.4 lentelē. RNN valstybēms/regionams – pagrindinēs komponentēs

Valstybē/regionas	i	j	k	Aktyvacijas f.	RMSE	MPE	MAPE	MASE
DNK	10	10	1	logistic	7555108599,52	107,29	115,83	3,24
EST	10	10	1	logistic	798604061,36	-119,94	155,88	3,26
FIN	1	5	1	logistic	7155111161,82	341,90	421,42	3,11
GBR	10	10	1	Gompertz	76764782813,03	-9,22	52,18	2,73
IRL	1	5	1	logistic	76781737087,18	-399,21	695,51	3,35
ISL	5	1	10	tanh	2846206269,05	555,88	577,12	3,22
LTU	5	1	5	tanh	832354905,94	2156,06	4020,17	2,98
LVA	5	5	10	tanh	722374864,50	-158,83	190,68	2,78
NOR	10	10	1	logistic	8434366443,64	50,87	151,78	3,05
SWE	10	10	1	Gompertz	13571756357,54	-1256,48	1306,23	2,68
SKN	10	10	1	Gompertz	76764782813,03	-9,22	52,18	2,73
BLT	1	5	1	logistic	76781737087,18	-399,21	695,51	3,35

LSTM modeļi sudaryti esant vienodam neuronu skaičiui trijose paslēptuose sluksniuose. Neuronu skaičius sluksnyje keistas intervale [2; 10] žingsniu 2. Taip pat taikyta kryžminė validacija. Geriausi rezultatai pateikiami 3.7.1.5 ir 3.7.1.6 lentelėse. Visi rezultatai bei programinis kodas pateikiami prieduose pavadinimu „Prognozavimas LSTM“.

3.7.1.5 lentelē. LSTM valstybēms/regionams – visi išoriniai kintamieji

Valstybē/regionas	i	j	k	Aktyvacijos f.	RMSE	MPE	MAPE	MASE
DNK	6	6	6	logistic	5449685316,88	54,77	88,99	0,67
EST	4	4	4	logistic	607091548,84	-83,33	112,11	1,04
FIN	8	8	8	logistic	6799241324,79	-1589,26	2652,99	0,81
GBR	6	6	6	logistic	80335956558,70	-117,25	128,68	1,73
IRL	8	8	8	logistic	64372643109,68	77,68	316,75	1,20
ISL	8	8	8	logistic	2613243898,59	-576,49	722,04	1,93
LTU	6	6	6	logistic	778978129,45	989,45	1012,43	0,93
LVA	8	8	8	logistic	661996213,31	-200,66	219,14	0,96
NOR	10	10	10	logistic	7493490408,90	44,66	60,94	1,09
SWE	6	6	6	logistic	11668206270,47	-1743,02	1765,55	1,13
SKN	8	8	8	logistic	585161984,41	-64,02	83,78	1,26
BLT	6	6	6	logistic	3837996142,96	-33,96	62,75	0,92

3.7.1.6 lentelē. LSTM valstybēms/regionams – pagrindinēs komponentēs

Valstybē/regionas	i	j	k	Aktyvacijos f.	RMSE	MPE	MAPE	MASE
DNK	8	8	8	logistic	7430862659,00	108,94	125,50	3,21
EST	8	8	8	logistic	785560905,81	-124,98	157,80	3,19
FIN	4	4	4	logistic	6949052531,28	314,43	384,62	3,06
GBR	10	10	10	logistic	70187278825,96	-34,40	64,65	2,73
IRL	2	2	2	logistic	75469581748,81	-348,17	624,79	3,30
ISL	8	8	8	logistic	3120668185,39	375,47	382,25	4,03
LTU	4	4	4	logistic	807809512,80	1701,45	3335,29	3,24
LVA	8	8	8	logistic	806095451,10	-184,94	214,77	3,29
NOR	4	4	4	logistic	8315870507,52	47,28	156,45	3,03
SWE	4	4	4	logistic	12607607844,13	-1755,47	1789,46	2,79
SKN	10	10	10	logistic	70187278825,96	-34,40	64,65	2,73
BLT	2	2	2	logistic	75469581748,81	-348,17	624,79	3,30


3.7.2. TIKLIAUSIAI TIESIOGINES UŽSIENIO INVESTICIJAS PROGNOZUOJANTYS MODELIAI

Apibendrinant FNN, RNN ir LSTM rezultatus, nustatyti geriausi valstybių/regionų TUI prognozavimo modeliai, kurie pateikiami 3.7.2.1 lentelėje.

3.7.2.1 lentelė. Tiksliausiai TUI prognozuojantys modeliai ir jų parametrai

Valstybė/regionas	Metodas	Pagrindinės komponentės	Parametrai	MASE
DNK	FNN	ne	10,8,1 tanh	0,66
EST	FNN	ne	2,7,6 logistic	0,56
FIN	FNN	ne	3,2,8 tanh	0,47
GBR	FNN	ne	8,5,6 tanh	0,66
IRL	FNN	ne	10,10,4 tanh	0,47
ISL	FNN	ne	3,1,3 tanh	0,48
LTU	FNN	ne	2,7,10 logistic	0,36
LVA	FNN	ne	3,5,9 logistic	0,53
NOR	FNN	ne	3,2,1 tanh	0,76
SWE	FNN	ne	10,10,3 logistic	0,43
SKN	FNN	ne	6,4,8 logistic	0,44
BLT	FNN	ne	9,8,10 logistic	0,44

Kaip pavyzdys pateikiamas Švedijai sudarytas prognozavimo modelis (žiūrėti 3.7.2.1 pav.). Visi rezultatai bei programinis kodas pateikiami prieduose „Prognozavimas – geriausias modelis“.




3.7.2.1 pav. TUI prognozavimo modelis – Švedija


Įdomu tai, jog paprastos struktūros FNN neuroniniai tinklai savo tikslumu aplenkė sudėtingesnės struktūros RNN ir LSTM tinklus. RNN ir LSTM tinklai naudojami ir turėtų būti tikslesni tais atvejais, kai sprendžiamo uždavinio rezultatai priklauso nuo kontekstinės informacijos – praeities situacijos ir artimų (RNN) ar tolimesnių (LSTM) būsenų. Didesnis FNN modelių tikslumas rodo, jog prognozuojant TUI, artimoje ar tolimoje praeityje valstybėje vyravusi investicinio patrauklumo veiksnių lemiamą investicinę aplinką nėra svarbi prognozuojant tolimesnius TUI srautus.

3.7.3. TIESIOGINIŲ UŽSIENIO INVESTICIJŲ 2017 METAIS PROGNOZAVIMAS


Naudojant tiksliausiai TUI prognozuojančius neuroninių tinklų metodus, sudaryta 2017 metų prognozė. Išorinių kintamųjų reikšmės, neturėjusios oficialių statistinių 2017 metų duomenų, taip pat buvo prognozuojamos. Išorinių kintamųjų prognozavimui taikyti paprasti vienmatės laiko eilutės prognozavimo metodai. Visi rezultatai bei programinis kodas pateikiami prieduose pavadinimu „Išorinių kintamųjų prognozavimas“. 3.7.3.1 – 3.7.3.12 grafikai vaizduoja sudaryto modelio prognozes valstybėms bei regionams.




3.7.3.1 pav. TUI prognozė 2017 metams – Danija




3.7.3.2 pav. TUI prognozė 2017 metams – Estija




3.7.3.3 pav. TUI prognozė 2017 metams – Suomija




3.7.3.4 pav. TUI prognozė 2017 metams – Airija




3.7.3.5 pav. TUI prognozė 2017 metams – Islandija




3.7.3.6 pav. TUI prognozė 2017 metams – Britanija




3.7.3.7 pav. TUI prognozė 2017 metams – Lietuva




3.7.3.8 pav. TUI prognozė 2017 metams – Latvija




3.7.3.9 pav. TUI prognozė 2017 metams – Norvegija



3.7.3.10 pav. TUI prognozė 2017 metams – Švedija



3.7.3.11 pav. TUI prognozė 2017 metams – Skandinavija




3.7.3.12 pav. TUI prognozė 2017 metams – Baltija

Apibendrinti TUI prognozavimo rezultatai pateikiami 3.7.3.1 lentelėje. Iš jos matyti, jog didžiausias TUI investicijų augimas prognozuojamas Islandijoje (net 193 %) bei Lietuvoje (184 %). TUI augimas taip pat numatomas ir Danijoje, Latvijoje bei Airijoje. Gana ryškus TUI mažėjimas prognozuojamas Norvegijoje – 201%. TUI mažėjimas, nors ir ne toks ryškus, prognozuojamas ir Estijoje, Suomijoje, Didžiojoje Britanijoje bei Švedijoje. Baltijos regione prognozuojamas TUI augimas (52 %), o Skandinavijos regione – mažėjimas (6 %).

3.7.3.1 lentelė. TUI prognozė 2017 metams

Valstybė/regionas	TUI 2016 metais (bln.)	Prognozuojamos TUI 2017 metais (bln.)	Prognozuojama tendencija
Danija	0,95	1,29	36%
Estija	0,87	0,62	-29%
Suomija	0,04	0,02	-52%
Didžioji Britanija	253,83	163,13	-36%
Airija	22,30	46,30	108%
Islandija	-0,48	0,45	193%
Lietuva	-0,21	0,17	184%
Latvija	0,13	0,28	121%
Norvegija	-5,53	-16,66	-201%
Švedija	19,58	18,00	-8%
Skandinavijos regionas	3,76	3,55	-6%
Baltijos regionas	0,26	0,40	52%

Prognozuojama, jog visas tiriamų Šiaurės Europos valstybių regionas pritrauks šiek tiek daugiau nei 213 milijonų dolerių, o tai yra 27 % mažiau nei 2016 metais. Prognozuojama, jog didžiąją dalį investicijų (66 %) sudarys Didžiosios Britanijos pritraukiamas užsienio kapitalas (3.7.3.13 pav.).



3.7.3.13 pav. TUI pasiskirstymas 2016 ir 2017 metais

3.7.4. PROGNOZUOJAMAS PATRAUKLUMO INDEKSAS IR INVESTICINIO PATRAUKLUMO ŽEMĖLAPIS

Naudojant teoriniame investicinio patrauklumo modelyje apibrėžtus veiksmus ir veiksmų grupes (1.3 skyrelis) bei išorinių kintamųjų prognozes, sudarytas investicinio patrauklumo indeksas valstybėms bei regionams 2017 metams. Visi rezultatai bei programinis kodas pateikiami prieduose „Indekso skaičiavimas“. Apibendrinti rezultatai pateikiami 3.7.4.1 lentelėje.


3.7.4.1 lentelė. Investicinio patrauklumo indeksas – 2017 metų prognozė

Valstybė/regionas	Indekso rezultatas 2017 metais	Vieta
Danija	26,60	2
Estija	14,67	8
Suomija	22,23	7
Didžioji Britanija	25,49	3
Airija	24,27	6
Islandija	24,93	5
Lietuva	9,07	10
Latvija	10,73	9
Norvegija	24,94	4
Švedija	26,81	1
Skandinavijos regionas	26,03	Na
Baltijos regionas	8,29	Na

Iš lentelės matyti, jog nepaisant to, jog Didžioji Britanija pritraukia daugiausiai tiesioginių užsienio investicijų, reitingo lentelėje ji užima tik 3 vietą. Ją aplenkia Švedija ir Danija, kurios pagal prognozuojamas TUI 2017 metais užima atitinkamai 3 ir 4 vietas. Tai rodo didelį šių Skandinavijos valstybių potencialą pritraukiant užsienio investicijas. Antrąją vietą pagal prognozuojamas TUI užimanti Airija reitingo lentelėje tere 6 vietoje. Tai rodo, jog nors Airija ir toliau galimai pritrauks užsienio kapitalą (susijungimo – įsigijimo sandoriais), investicinė aplinka verslui čia neturi tokio didelio potencialo, kaip kad Didžiojoje Britanijos ir kai kurios Skandinavijos regiono valstybės. Priešinga situacija matoma Norvegijoje. Šios valstybės prognozuojamos TUI toliau bus neigiamos, tačiau investicinio patrauklumo reitinge ji nedaug nusileidžia Didžiajai Britanijai ir užima 4 vietą. Tai rodo, jog nepaisant kai kurių investuotojų atsitraukimo, Norvegijos stabili ekonomika bei politika ir toliau turėtų vilioti investuotojus. Skandinavijos regione išsiskiria ir Suomija. Ji pritraukia mažiau TUI nei Lietuva, kuri gali „pasigirti“ mažiausiu užsienio kapitalu tarp visų Baltijos regiono valstybių. Nepaisant to, Suomijos investicinis potencialas didesnis nei Baltijos regiono valstybių ir reitingo lentelėje ji užima 7 vietą.

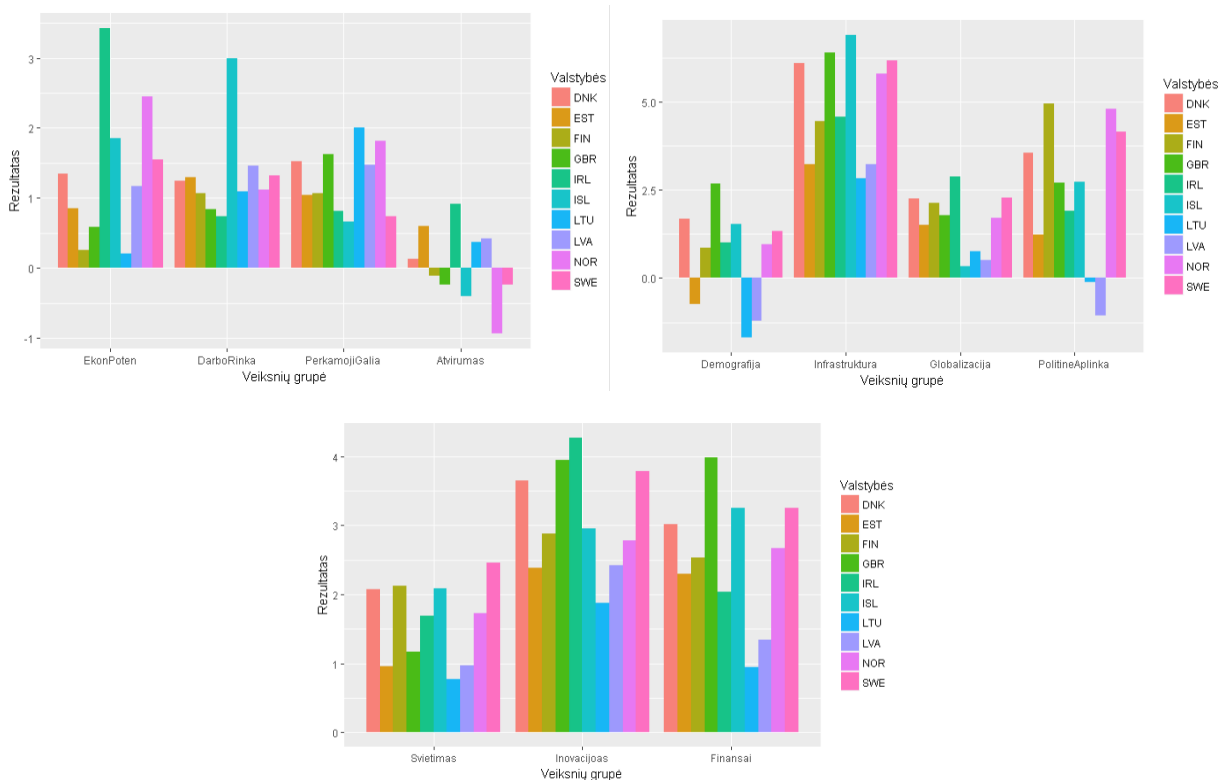
Norint apibendrinti prognozuojamų TUI ir indekso rezultatus, nuspręsta sudaryti investicinio patrauklumo žemėlapi, kuriame vaizduojamas 2017 metais prognozuojamas investicinio

patraukumo potencialas bei jo realizacija (atitinkamai standartizuotos prognozuojamo indekso bei TUI reikšmės) (3.7.4.1 pav.)



3.7.4.1 pav. Prognozuojamas investicinio patraukumo žemėlapis 2017 metais

Iš žemėlapiu matyti, jog tiek dideliu investiciniu potencialu tiek jo realizacija 2017 metais numanoma išsiskirs Didžioji Britanija. Tai lems didelę Didžiosios Britanijos palanki demografinė padėtis bei finansinė situacija (3.7.4.2 pav.). Vienintelis neapibrėžtumas – Didžiosios Britanijos išstojimas iš Europos Sąjungos, tad tikriausiai pagrindinis valstybės strategų uždavinys – išlaikyti patrauklią investuotojams aplinką.



3.7.4.2 pav. Prognozuojamų investicinių patraukumą lemiančių veiksnių valstybėse palyginimas

Airija bei Skandinavijos valstybės ir toliau išliks potencialiai patrauklios investuotojoms. Airija galės pasigirti sąlyginai dideliu ekonominiu potencialu bei atvirumu, augančia globalizacija ir inovatyvumu, Norvegija bei Danija – stabilia politine aplinka bei išplėta infrastruktūra, Švedija – puikia švietimo sistema, Suomija – stabiliausia politine aplinka, Islandija – geriausiai išplėta infrastruktūra bei palankiai vertinama darbo rinka (3.7.4.2 pav.). Nors šios valstybės užims aukštas vietas investicinio indekso sąrašė, prognozuojama, jog daug TUI 2017 metais, lyginant su Didžiąja Britanija, jos nepritrauks ir savo potencialo neišnaudos. Tai gana rimtas signalas šių valstybių strategams. Norint išnaudoti minėtas šių valstybių stipriąsias savybes reikia skatinti naujų užsienio parterių paiešką ir bendradarbiavimą akcentuojant būtent jas.

Baltijos regionas investicinio patrauklumo kontekste – silpniausias. Nors šio regiono valstybės ir toliau galės pasigirti gana didele perkamąja galia, nestabili politinė situacija, nepalanki demografinė padėtis lems tai, jog investuotojai ir toliau išliks atsargūs (3.7.4.2 pav.). Neturėdamos investicinio potencialo, valstybės ir jų strategai turėtų didesnę dėmesį sutelkti jau minėtų silpnybių stiprinimui, siekiant sukurti užsienio investuotojams nors kiek palankesnes sąlygas.

Šis žemėlapis taip pat aiškiai parodo šalių artimiausius konkurentus – kitas panašų investicinį patrauklumą turinčias šalis ir išsiskiriančių grupių lyderius. Pavyzdžiui Lietuvai ir Latvijai derėtų lygiuotis į Estiją, Skandinavijos regiono valstybėms – į Airiją, o pastarajai – į Didžiąją Britaniją.

IŠVADOS

1. Norint apjunti du dažniausiai naudojamus investicinio patrauklumo metodus – investicinio patrauklumo indeksą bei valstybės pritraukiamų tiesioginių užsienio investicijų lyginimą – atlikta literatūros analizė ir sudarytas skirtingų autorių minimus investicinio patrauklumo veiksnius apibendrinantis teorinis valstybės investicinio patrauklumo modelis, kurį sudaro 13 investicinį patrauklumą lemiančių veiksnių grupių bei 32 veiksniai. Atlikus koreliacinę bei priežastingumo analizę, atrastas 61 šiuos veiksnius atitinkantis kiekybinis rodiklis bei suformuota duomenų matrica.

2. Lyginant valstybes pagal jų investicinį patrauklumą nusakančius veiksnius bei taikant k – vidurkių metodą, nustatyta, jog atskiromis valstybių grupėmis – regionais – galime laikyti Lietuvos, Latvijos, Estijos (Baltijos regionas) bei Norvegijos, Švedijos, Suomijos, Danijos (Skandinavijos regionas) valstybes. Didžioji Britanija, Airija bei Islandija nesudaro jokios valstybių grupės todėl tyrime nagrinėjamos atskirai. Toks klasterizavimo modelis paaiškina 75,7 % sklaidos.

3. Siekiant sumažinti dimensijų skaičių ir pritaikius pagrindinių komponentių analizę, nustatyta, jog norint paaiškinti daugiau nei 90 % kintamųjų sklaidos, Danijos, Estijos, Suomijos, Didžiosios Britanijos, Latvijos, Norvegijos ir Švedijos valstybių atveju užtenka 5 pirmųjų pagrindinių komponentių, o Airijos, Islandijos ir Lietuvos – 4. Išskirto Baltijos bei Skandinavijos regiono valstybių atveju taip pat užtenka atitinkamai 4 ir 5 pagrindinių komponentių.

4. Išbandžius FNN, RNN ir LSTM struktūros neuroninius tinklus ir taikant kryžminę patikrą, nustatyta, jog tiek visoms valstybėms, tiek išskirtiems regionams atskirai, tiksliausias ir stabiliausias tiesioginių investicijų prognozavimo modelis gaunamas pasitelkus paprastesnės struktūros FNN tinklus bei naudojant visus išorinius kintamuosius, o ne pagrindines komponentes. RNN ir LSTM tinklai naudojami ir turėtų būti tikslesni tais atvejais, kai sprendžiamo uždavinio rezultatai priklauso nuo kontekstinės informacijos – praeities būsenų. Didesnis FNN modelių tikslumas rodo, jog praeityje valstybėje vyravusi investicinė aplinka nėra tokia svarbi prognozuojant tolimesnius TUI srautus. Sudarytas Danijos TUI prognozavimo modelis su paklaida $MASE = 0,66$, Estijos TUI prognozavimo modelis su paklaida $MASE = 0,56$, Suomijos – $MASE = 0,47$, Didžiosios Britanijos – $MASE = 0,66$, Airijos – $MASE = 0,47$, Islandijos – $MASE = 0,48$, Lietuvos – $MASE = 0,36$, Latvijos – $MASE = 0,53$, Norvegijos – $MASE = 0,76$, Švedijos – $MASE = 0,43$.

5. Pritaikius mažiausią paklaidą turėjusius FNN modelius su atitinkamais parametrais, sudarytos kiekvienos valstybės bei išskirto regiono tiesioginių investicijų prognozės 2017 metams. 2017 metų prognozę lyginant su 2016 metais, TUI augimas numatomas Danijoje (36 %), Airijoje (108 %), Islandijoje (193 %), Lietuvoje (184 %), Latvijoje (121 %) ir bendrai Baltijos regiono

valstybėse (52 %). TUI mažėjimas numatomas Estijos (29 %), Suomijos (52 %), Didžiosios Britanijos (36 %), Norvegijos (201 %), Švedijos (8 %) valstybėse ir bendrai Skandinavijos regione (6 %). Remiantis teoriniu investicinio patrauklumo modeliu ir sudarius valstybių investicinio patrauklumo indekso prognozę 2017 metams, nustatyta, jog lyginant visas Šiaurės Europos valstybes, investuotojams palankiausia aplinką turės Švedija, o mažiausiai palankią – Lietuva.

6. Darbe apjungus dvi investicinio patrauklumo vertinimo metodikas – TUI bei indeksą – sudarytas valstybių investicinio patrauklumo žemėlapis, rodantis, jog Didžioji Britanija ir toliau išliks patraukliausia investuotojams. Skandinavijos regiono valstybės bei Airija nors ir bus potencialiai patrauklios investuotojams, savo potencialo neišnaudos ir daug TUI nepritrauks. Norint išnaudoti darbe aptartas šių valstybių stipriąsias savybes – Airijos ekonominę potencialą bei atvirumą, stabilią politinę situaciją Norvegijoje, Danijoje bei Suomijoje, palankiai vertinamą darbo rinką Islandijoje, puikią švietimo sistemą Švedijoje – šių valstybių strategams reikėtų skatinti naujų užsienio partnerių paiešką ir bendradarbiavimą akcentuojant būtent jas. Baltijos regionas investicinio patrauklumo kontekste 2017 metais bus silpniausias. Šioms valstybėms išliks svarbiausia mažinti savo silpnybes – gerinti demografinę padėtį bei užtikrinti politinį stabilumą.

LITERATŪROS SĄRAŠAS

1. **Ineta Zykienė**. Evaluation of location's attractiveness for business growth in the context of smart development. Kauno technologijos universiteto Ekonomikos ir verslo fakultetas, kataro disertacija. 2018 m., p. 5- 90.
2. **Marcin Nowicki, PrzemSusmarski, Maciej Tarkowski, Marcin Wandalowski, Wojciech Wozniak**. The Investment Attractiveness of the Regions and the Sub-regions of Poland .The Gdansk Institute for Market Economics. 2010 m., p. 15-19.
3. **Seimas, Lietuvos Respublikos**. Lietuvos Respublikos investicijų įstatymas. 1999 m..
4. **Ekonominio bendradarbiavimo ir plėtros organizacija**. FDI flows. [žiūrėta 2018-05-19]. Prieiga per internetą: <https://data.oecd.org/fdi/fdi-flows.htm>.
5. **Tarptautinis valiutos fondas** . Foreign Direct Investment Trends and Statistics. [žiūrėta 2018-05-19]. Prieiga per internetą: [žiūrėta 2018-05-19]. Prieiga per internetą: <https://www.imf.org/external/np/sta/fdi/eng/2003/102803.htm>.
6. **Philip Mpanggo**. The role of investment in economic development and growth strategy of Tanzania: the case of the lake Tanganyika zone. The lake tanganyika investment forum. 2015 m., p. 3-11.
7. **Dovilė Ruplienė, Kristina Montvilaitė**. Tiesiogines užsienio investicijas lemiantys veiksniai. Ekonomika ir vadyba: aktualijos ir perspektyvos. 2008 m., p. 271-280.
8. **Orinta Čegyūtė, Algita Miečinskienė**. Tiesioginių užsienio investicijų poveikio tyrimas. Mokslas - Lietuvos ateitis. 2009m., p. 9-12.
9. **United nations conference on trade and development**. World investment report 2017: investment and the digital economy. [žiūrėta 2018-05-19]. Prieiga per internetą: http://unctad.org/en/PublicationsLibrary/wir2017_en.pdf
10. **Trade Portal**. Foreign investment. [žiūrėta 2018-05-19]. Prieiga per internetą: <https://en.portal.santandertrade.com/establish-overseas/united-kingdom/foreign-investment>
11. **IDA Ireland**. Investing. [žiūrėta 2018-05-19]. Prieiga per internetą: <https://www.idaireland.com>
12. **Ireland demographics profile 2018**. Age structure.[žiūrėta 2018-05-19]. Prieiga per internetą: https://www.indexmundi.com/ireland/demographics_profile.html
13. **Klaus Schwab**. WEF Global Competitiveness Report 2015-2016. World Economic forum. [žiūrėta 2018-05-19]. Prieiga per internetą: http://www3.weforum.org/docs/gcr/2015-2016/Global_Competitiveness_Report_2015-2016.pdf
14. **Riadh Ben Jelili**. A Global Foreign Direct Investment Country Attractiveness Index. [žiūrėta 2018-05-19]. Prieiga per internetą: <http://www.fdiattractiveness.com>

15. **Alexander Groh, Heinrich Liechtenstein, Karsten Lieser, Markus Biesinger.** The Venture Capital & Private Equity Country Attractiveness Index. [žiūrėta 2018-05-19]. Prieiga per internetą: <https://blog.iese.edu/vcpeindex/>
16. **Nikolova Liudmila, Ekaterina Plotnikova.** Regional investment attractiveness in an unstable and risky environment. In Scientific Reports of 11th Global Conference on Sustainable Manufacturing Innovative Solutions, Germany . 2013 m., p. 159-164.
17. **Bruneckienė ir kiti.** Critical analysis of city attractiveness factors in Lithuania – Poland cross-border. Journal of geography, politics and society, Gdańsk. 2016 m., p. 45-48.
18. **Belderbos ir kiti.** Where to Locate Innovative Activities in Global Value Chains. 2016 m..
19. **Jurgita Stankevičienė, Aušrinė Lakštutienė .** Tiesioginių užsienio investicijų pritraukimą lemiančių veiksnių ir jų kitimo tendencijų tyrimas Baltijos šalyse . 2012 m., p. 69-79.
20. **Samuel Adams.** Can foreign direct investment (FDI) help to promote growth in Africa? African journal of Business Management. 2009 m., p. 178-183.
21. **Harinder Singh, Kwang Jun.** Some new evidence on determinants of foreign direct investment in developing countries. World Bank Policy Research Working Paper. 1995 m., p. 356-360.
22. **Glebova ir kiti.** Correlation of balanced socio-economic development of the city and its attractiveness (in the case of Russian cities with population over a million citizens). Mediterranean Journal of Social Sciences. 2015 m., p. 284-288.
23. **Bonasso ir kiti.** Factors affecting location decisions. 2014 m.. [žiūrėta 2018-05-19]. Prieiga per internetą: <https://prezi.com/du81kiu2kgok/factors-affecting-location-decisions/>
24. **Natalie Cohen .** Business location decision-making and the cities: bringing companies back. Washington, DC: Brookings Institution Center on Urban and Metropolitan. 2000 m..
25. **Giner ir kiti.** High-growth firms: does location matter? International Entrepreneurship and Management Journal. 2017 m., p. 75–96.
26. **Wojciech Strzelczyk.** Investment attractiveness measurement of the regions and versus general location of the enterprises. Economic and Regional Studies. 2014 m., p. 5-25.
27. **Massimiliano Ballotta.** Factors, Actions and Policies to Determine the Investment Attractiveness of a Territorial System. World bank BI/PSD Investment Climate Seminar Series. 2004 m..

28. **Simran Kahai**. Traditional and Non-Traditional Determinants of Foreign direct investment In Developing countries . Journal of Applied Business Research. 2011 m., p. 43
29. **Benassy Quere**. Institutional determinants of foreign Direct investment. The World Econom. 2007 m., p.29.
30. **Lijana Stabingienė**. Ekonometriniai modeliai. Klaipėdos Universitetas, 2014 m.. [žiūrėta 2018-05-19]. Prieiga per internetą: http://www.ilab.lt/stabingiene/sk2_1.html
31. **Gintautas Dzemyda, Olga Kurasova, Julius Žilinskas**. Daugiamatčių duomenų vizualizavimo metodai. Matematikos ir informatikos institutas, 2008 m.. [žiūrėta 2018-05-19]. Prieiga per internetą: <http://web.vu.lt/mii/j.zilinskas/DzemydaKurasovaZilinskasDDVM.pdf>
32. **Mindaugas Kavaliauskas**. Daugiamate statistine analizė. Pagrindinių komponentų analizė, faktorinė analizė. Paskaitų konspektas. 2017 m., p.4.
33. **Suvrit Sra, Sebastian Nowozin, Stephen J. Wright**. Optimization for Machine Learning. The MIT Press, Cambridge, Massachusetts, London, Englan. 2012. p. 404.
34. **Stuart J. Russell, Peter Norvig**. Artificial Intelligence: A modern Approach. Prentice Hall, Englewood Cliffs, New Jersey, 2003. p.528.
35. **Md Nasir Uddin Laskar**. Perceptrono modelis. [žiūrėta 2018-05-19]. Prieiga per internetą: <https://nasirml.wordpress.com/2017/11/19/single-layer-perceptron-in-tensorflow/>
36. **Haykin, Simon S**. Neural Networks: A Comprehensive Foundation. Prentice Hall. 1999.
37. **Rūta Makūnaitė**. Neuroniniai tinklai. [žiūrėta 2018-05-19]. Prieiga per internetą: <http://www.elektronika.lt/teorija/kompiuterija/4342/neuroniniai-tinklai/>
38. **Robert Hecht Nielsen**. Theory of the Backpropagation Neural Network. University of California, San Diego. 1992.
39. **Christopher Olah**. Understanding LSTM Networks. [žiūrėta 2018-05-19]. Prieiga per internetą: <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>
40. **Sepp Hochreiter, Yoshua Bengio, Paolo Frasconi, Juergen Schmidhuber**. Gradient flow in recurrent nets: the difficulty of learning long-term dependencies. In S. C. Kremer and J. F. Kolen, eds., A Field Guide to Dynamical Recurrent Neural Networks. 2001 m., p. 1-15
41. **Eduardo F. Camacho, Manuel Berenguel, Fancisco R. Rubio, Diego Martinez**. Control of Solar Energy Systems. Springer – Verlag, London, 2012. p.42.

PRIEDAI

Kai kurių priedų programinis kodas pateikiamas tik elektroniniu variantu (kompaktiniame diske)

1 priedas. Duomenų matrica. Duomenus – kompaktiniame diske.

Sutrumpintas angliškas rodiklio pavadinimas	Rodiklio pavadinimas lietuvių kalba
Country	Valstybė
Date	Metai
FDI	Tiesioginės užsienio investicijos
GDPPerCapita	BVP vienam gyventojui (US doleriais)
CapitalInvestment	Kapitalo investicijos (BVP procentinė dalis)
Savings	Suntaupos (BVP procentinė dalis)
Net_investment_nonfinancial_assets	Grynosios investicijos į nefinansinį turtą (BVP procentinė dalis)
GovernmentSpending	Vyriausybės išlaidos (BVP procentinė dalis)
AvgWage	Vidutinis atlyginimas (US doleriais)
LaborForce	Darbo jėga (milijonai žmonių)
LaborParticipationRate	Darbo jėgos dalyvavimo lygis
UnemploymentRate	Nedarbo lygis
Income	Namų ūkių realios koreguotosios disponuojamos pajamos - vienam gyventojui, PGS (indeksas = 2008 m.)
HouseholdConsumption	Namų ūkio vartojimas (BVP procentinė dalis)
DependentPeople	Priklausomi žmonės kaip darbingo amžiaus gyventojų procentas
SocialExpenditure	Išlaidos socialinei apsaugai eurai vienam gyventojui
Exports	Prekių ir paslaugų eksportas (BVP procentinė dalis)
Imports	Prekių ir paslaugų importas (BVP procentinė dalis)
Inflation	Infliacija: vartotojų kainų indekso pokytis procentais
Population	Populiacija (milijonais)
PopulationGrowth	Metinis populiacijos augimas
PopulationDensity	Populiacijos tankumas
UrbanPopulation	Miestuose gyvenančių žmonių procentinė dalis
Prisoners	Nusikaltėlių skaičius 100000 žmonių
Homicides	Savižudybių skaičius 100000 žmonių
FixedBroadbandInternetSubscribers	Interneto naudotojų skaičius 100 žmonių
MobilePhoneSubscribers	Mobiliųjų telefonų vartotojų skaičius 100 žmonių
NewCommercialVehicleSales	Naujų komercinių automobilių pardavimų skaičius
NewPassengerCarSales	Naujų keleivinių automobilių pardavimų skaičius
QualityAirTransportInfrastructure	Oro transporto kokybė
QualityRoads	Kelių kokybė
QualityPortInfrastructure	Uostų kokybė
HPI	Namų kainų indeksas
HPI_growth	Namų kainų indekso pokytis
EconomicGlobalizationIndex	Ekonominės globalizacijos indeksas
SocialGlobalizationIndex	Socialinės globalizacijos indeksas
PoliticalGlobalizationIndex	Politinės globalizacijos indeksas
TaxRevenue	Mokesčių pajamos (BVP procentinė dalis)
TaxRate	Mokesčių tarifas (komercinio pelno procentinė dalis)

GainTaxes	Pajamų, pelno ir kapitalo prieaugio mokesčiai (pajamų procentinė dalis)
PoliticalStabilityIndex	Politinio stabilumo indeksas
RegulatoryQualityIndex	Biurokratinių procesų kokybės indeksas
VoiceAccountabilityIndex	Atskaitomybės indeksas
RuleOfLawIndex	Teisinės sistemos indeksas
GovernmentEffectivenessIndex	Vyriausybės efektyvumo indeksas
ControlOfCorruption	Korupcijos kontrolės indeksas
FreedomFromCorruptionIndex	Nepriklausomumo nuo korupcijos indeksas
CorruptionPerceptionsIndex	Požiūrio į korupciją indeksas
SecondarySchoolEnrollment	Besimokančiųjų vidurinėse mokyklose dalis
PrimarySchoolEnrollment	Besimokančiųjų pradinėje mokykloje dalis
TertiarySchoolEnrollment	Besimokančiųjų aukštesniosiose mokymo įstaigose
PublicSpendingEducationPercent	Išlaidos skiriamos edukaciniai sistemai
HighTechnologyExports	Moderniųjų technologijų eksportas
HTExportsPercent	Moderniųjų technologijų eksportas (gamybos eksporto dalis)
PatentApplicationsByResidents	Užregistruotų patentų skaičius
Itexports	Informacinių technologijų eksportas
HRST	Žmogiškųjų išteklių mokslo ir technologijų srityje dalis
ValueAddedIndustry	Pramonės sektoriaus pridėtinė vertė (BVP procentinė dalis)
ValueAddedManufacturing	Gamybos sektoriaus pridėtinė vertė (BVP procentinė dalis)
ValueAddedServices	Paslaugų sektoriaus pridėtinė vertė (BVP procentinė dalis)
BankAssets	Banko turtas (BVP procentinė dalis)
LiquidLiabilities	Likvidūs įsipareigojimai (BVP procentinė dalis)
DomesticCreditPrivateSector	Vidaus kreditas privačiam sektoriui (BVP procentinė dalis)
ATMMachines	Bankomatų skaičius 100000 suaugusiųjų
CapitalToRisk	Bankų sistemos reguliavimo kapitalas pagal riziką įvertintą turtą
BankLiquidAssetsDeposits	Banko likvidus turtas į indėlius ir trumpalaikį finansavimą
BankingSystemZscores	Bankų sistemos z balai

2 priedas. TUI apžvalga. Programinis kodas – kompaktiniame diske.

4 priedas. Koreliacinė analizė. Programinis kodas – kompaktiniame diske.

5 priedas. Išorinių kintamųjų statistinė apžvalga. Programinis kodas – kompaktiniame diske.

6 priedas. Klasterizavimas. Programinis kodas – kompaktiniame diske.

7 priedas. Voratinklinė diagrama. Programinis kodas – kompaktiniame diske.

8 priedas. Pagrindinių komponentų analizė. Programinis kodas – kompaktiniame diske.

10 priedas. Prognozavimas RNN. Programinis kodas – kompaktiniame diske.

11 priedas. Prognozavimas LSTM. Programinis kodas – kompaktiniame diske.

12 priedas. Prognozavimas – geriausias modelis. Programinis kodas – kompaktiniame diske.

13 priedas. Išorinių kintamųjų prognozavimas. Programinis kodas – kompaktiniame diske.

14 priedas. TUI prognozavimas. Programinis kodas – kompaktiniame diske.

15 priedas. Indekso skaičiavimas. Programinis kodas – kompaktiniame diske.

3 priedas. Priežastingumo analizė. Programinis kodas – kompaktiniame diske.

Rodiklis (sutrumpintas angl. pav.)	D N K	E S T	F I N	G B R	I R L	I S L	L T U	L V A	N O R	S W E	Priežastingumų skaičius
GDPPerCapita						✓		✓			2
CapitalInvestment				✓							1
Savings	✓			✓	✓			✓			4
Net_investment_nonfinancial_assets				✓	✓					✓	3
GovernmentSpending				✓				✓			2
AvgWage		✓	✓	✓				✓			4
LaborForce		✓		✓					✓		3
LaborParticipationRate					✓				✓		2
UnemploymentRate				✓							1
Income			✓	✓	✓	✓					4
HouseholdConsumption	✓					✓		✓		✓	4
DependentPeople			✓	✓					✓		3
SocialExpenditure				✓		✓		✓	✓	✓	5
Exports						✓					1
Imports				✓							1
Inflation							✓	✓			2
Population			✓							✓	2
PopoulationGrowth	✓	✓				✓				✓	4
PopulationDensity	✓	✓									2
UrbanPopulation		✓		✓					✓		3
Prisoners				✓					✓		2
Homicides							✓		✓		2
FixedBroadbandInternetSubscribers	✓		✓	✓	✓					✓	5
MobilePhoneSubscribers	✓		✓								2
NewCommercialVehicleSales				✓							1
NewPassengerCarSales				✓		✓		✓			3
QualityAirTransportInfrastructure				✓		✓		✓			3
QualityRoads					✓		✓	✓			3
QualityPortInfrastructure				✓		✓	✓			✓	4
HPI	✓			✓	✓			✓		✓	5
HPI_growth	✓					✓	✓	✓		✓	5
EconomicGlobalizationIndex										✓	1
SocialGlobalizationIndex							✓		✓	✓	3
PoliticalGlobalizationIndex	✓			✓					✓	✓	4
TaxRevenue	✓					✓			✓	✓	4
TaxRate	✓			✓					✓	✓	4
GainTaxes								✓	✓	✓	3
PoliticalStabilityIndex		✓			✓			✓			3
RegulatoryQualityIndex				✓	✓				✓	✓	4
VoiceAccountabilityIndex		✓					✓				2
RuleOfLawIndex	✓						✓			✓	3
GovernmentEffectivenessIndex		✓					✓			✓	3

ControlOfCorruption				✓		✓	✓			✓	4
FreedomFromCorruptionIndex						✓					1
CorruptionPerceptionsIndex				✓		✓		✓			3
SecondarySchoolEnrollment			✓								1
PrimarySchoolEnrollment				✓							1
TertiarySchoolEnrollment		✓									1
PublicSpendingEducationPercent	✓										1
HighTechnologyExports									✓		1
HTExportsPercent								✓			1
PatentApplicationsByResidents				✓							1
Itexports							✓	✓			2
HRST					✓	✓					2
ValueAddedIndustry			✓								1
ValueAddedManufacturing			✓		✓						2
ValueAddedServices			✓								1
BankAssets				✓			✓			✓	3
LiquidLiabilities				✓		✓				✓	3
DomesticCreditPrivateSector			✓	✓				✓	✓	✓	5
ATMMachines					✓				✓		2
CapitalToRisk	✓					✓				✓	3
BankLiquidAssetsDeposits		✓			✓	✓	✓	✓		✓	6
BankingSystemZscores			✓	✓		✓		✓			4

9 priedas. Prognozavimas FNN

```

```{r, message=FALSE, warning=FALSE, results='hide'}
library(data.table)
library(readxl)
library(DT)
library(knitr)
library(stringr)
library(reshape2)
library(ggplot2)
library(gridExtra)
library(plyr)
library(corrplot)
library(RColorBrewer)
library(psych)
library(ggpubr)
library(ggrepel)
library(dendextend)
library(fmsb)
library(textir)
library(neuralnet)
library(fpp)
library(hydroGOF)
```

### Duomenys {.tabset .tabset-fade}
```{r, message=FALSE, warning=FALSE}
myData <- read_excel("D:\\Mano duomenys\\Desktop\\ManoDuomenys.xlsx", sheet
="Duomenys")
regmyData <- myData
regmyData[(regmyData$Country=="DNK" | regmyData$Country=="FIN" | regmyData$Country
=="NOR" | regmyData$Country=="SWE"),1] <- "SKN"

```



```

regmyData[(regmyData$Country=="EST"|regmyData$Country=="LVA"|regmyData$Country=="LTU"),1] <-"BLT"
regmyData <- aggregate(regmyData, by=list(regmyData$Country,regmyData$Date),
FUN=mean, na.rm=TRUE)
regmyData <- regmyData[,c(-3,-4)]
colnames(regmyData)[1]<-"Country"
colnames(regmyData)[2]<-"Date"
colnames(regmyData)[3]<-"FDI"
Year <-
c("2006","2007","2008","2009","2010","2011","2012","2013","2014","2015","2016")
DNKLAT <- read.csv(file="D:\\Mano
duomenys\\Desktop\\06_Rezultatai_PKA\\DNK.txt", header=TRUE, sep="\t")
ESTLAT <- read.csv(file="D:\\Mano
duomenys\\Desktop\\06_Rezultatai_PKA\\EST.txt", header=TRUE, sep="\t")
FINLAT <- read.csv(file="D:\\Mano
duomenys\\Desktop\\06_Rezultatai_PKA\\FIN.txt", header=TRUE, sep="\t")
GBRLAT <- read.csv(file="D:\\Mano
duomenys\\Desktop\\06_Rezultatai_PKA\\GBR.txt", header=TRUE, sep="\t")
IRLLAT <- read.csv(file="D:\\Mano
duomenys\\Desktop\\06_Rezultatai_PKA\\IRL.txt", header=TRUE, sep="\t")
ISLLAT <- read.csv(file="D:\\Mano
duomenys\\Desktop\\06_Rezultatai_PKA\\ISL.txt", header=TRUE, sep="\t")
LTULAT <- read.csv(file="D:\\Mano
duomenys\\Desktop\\06_Rezultatai_PKA\\LTU.txt", header=TRUE, sep="\t")
LVALAT <- read.csv(file="D:\\Mano
duomenys\\Desktop\\06_Rezultatai_PKA\\LVA.txt", header=TRUE, sep="\t")
NORLAT <- read.csv(file="D:\\Mano
duomenys\\Desktop\\06_Rezultatai_PKA\\NOR.txt", header=TRUE, sep="\t")
SWELAT <- read.csv(file="D:\\Mano
duomenys\\Desktop\\06_Rezultatai_PKA\\SWE.txt", header=TRUE, sep="\t")
SKNLAT <- read.csv(file="D:\\Mano
duomenys\\Desktop\\06_Rezultatai_PKA\\SKN.txt", header=TRUE, sep="\t")
BLTLAT <- read.csv(file="D:\\Mano
duomenys\\Desktop\\06_Rezultatai_PKA\\BLT.txt", header=TRUE, sep="\t")
DNKLAT <- cbind(Country =
rep("DNK",11),Year, DNKLAT,myData[myData$Country=="DNK",3])
ESTLAT <- cbind(Country =
rep("EST",11),Year, ESTLAT,myData[myData$Country=="EST",3])
FINLAT <- cbind(Country =
rep("FIN",11),Year, FINLAT,myData[myData$Country=="FIN",3])
GBRLAT <- cbind(Country =
rep("GBR",11),Year, GBRLAT,myData[myData$Country=="GBR",3])
IRLLAT <- cbind(Country =
rep("IRL",11),Year, IRLLAT,myData[myData$Country=="IRL",3])
ISLLAT <- cbind(Country =
rep("ISL",11),Year, ISLLAT,myData[myData$Country=="ISL",3])
LTULAT <- cbind(Country =
rep("LTU",11),Year, LTULAT,myData[myData$Country=="LTU",3])
LVALAT <- cbind(Country =
rep("LVA",11),Year, LVALAT,myData[myData$Country=="LVA",3])
NORLAT <- cbind(Country =
rep("NOR",11),Year, NORLAT,myData[myData$Country=="NOR",3])
SWELAT <- cbind(Country =
rep("SWE",11),Year, SWELAT,myData[myData$Country=="SWE",3])
SKNLAT <- cbind(Country =
rep("SKN",11),Year, SKNLAT, FDI=regmyData[regmyData$Country=="SKN",3])
BLTLAT <- cbind(Country =
rep("BLT",11),Year, BLTLAT, FDI=regmyData[regmyData$Country=="BLT",3])
latdata <-
list(DNKLAT,ESTLAT,FINLAT,GBRLAT,IRLLAT,ISLLAT,LTULAT,LVALAT,NORLAT,SWELAT)
reglatdata <- list(GBRLAT,IRLLAT,ISLLAT,SKNLAT,BLTLAT)
calculateMASE <- function(f,y) { # f = vector with forecasts, y = vector with
actuals

```

```

 if(length(f)!=length(y)){ stop("Vector length is not equal") }
 n <- length(f)
 return(mean(abs((y - f) / ((1/(n-1)) * sum(abs(y[2:n]-y[1:n-1]))))))
 }
normalize <- function(x) {return ((x - min(x)) / (max(x) - min(x)))}
...
Valstybems visi X FFN
```{r, message=FALSE, warning=FALSE}
myData <- myData
countries <- c("DNK","EST","FIN","GBR","IRL","ISL","LTU","LVA","NOR","SWE")
colY <- colnames(myData)[c(3)]
variables <- colnames(myData)[c(-1,-2,-3)]
formula <- as.formula(paste(paste(colY,"~",sep=""),paste(variables,collapse=" + ")))
m <- 11
myResults <- NULL
aggResults <- NULL
df <- NULL
MSE <- NULL
NRMSE <- NULL
for (p in 1:(length(countries)))
{
    data <-myData[myData$Country==countries[p],c(-1,-2)]
    datanorm <- as.data.frame(lapply(data, normalize))
    for(i in seq(1,10,1))
    {
        for(j in seq(1,10,1))
        {
            for(k in seq(1,10,1))
            {
                for(sig in c("logistic","tanh"))
                {
                    err <- NULL
                    hiddenLayer <- c(i,j,k)
                    for(m in 1:m)
                    {
                        train.cv <- datanorm[c(-m),]
                        test.cv <- datanorm[m,]
                        set.seed(1)
                        nn <-
neuralnet(formula,data=train.cv,hidden=hiddenLayer,linear.output=TRUE,act.fct
= sig)
                        prediction <- compute(nn,test.cv[,c(-1)])
                        prediction <- prediction$net.result*(max(data$FDI) -
min(data$FDI))+min(data$FDI)
                        actual <- (test.cv$FDI) * (max(data$FDI) -
min(data$FDI))+min(data$FDI)
                        df <-data.frame(countries[p],i,j,k,m,prediction,actual)
                        myResults <-rbind(myResults,df)
                        err <-rbind(err,data.frame(prediction,actual))
                    }
                    acc <- accuracy(err$prediction,err$actual)
                    NRMSE <- nrmse(err$prediction,err$actual)
                    MASE <- calculateMASE(err$prediction,err$actual)
                    df <-
data.frame(countries[p],i,j,k,sig,acc[1],acc[2],NRMSE,acc[3],acc[4],acc[5],MA
SE)
                    colnames(df) <-
c("Country","i","j","k","sigmoid","ME","RMSE","NRMSE","MAE","MPE","MAPE","MAS
E")
                    aggResults <-rbind(aggResults,df)
                    write.table(aggResults, file="D:\\Mano
duomenys\\Desktop\\07_Rezultatai_Prognozavimas\\Vlastybems_VisiX_FFN.txt",
row.names=FALSE, col.names=TRUE)

```

```

    }
  }
}
write.table(aggResults, file="D:\\Mano
duomenys\\Desktop\\07_Rezultatai_Prognozavimas\\Vlastybems_VisiX_FFN.txt",
row.names=FALSE, col.names=TRUE)
```
Regionai visi X FFN
```{r, message=FALSE, warning=FALSE}
myData <- regmyData
countries <- c("SKN", "BLT", "GBR", "IRL", "ISL")
colY <- colnames(myData)[c(3)]
variables <- colnames(myData)[c(-1, -2, -3)]
formula <- as.formula(paste(paste(colY, "~", sep=""), paste(variables, collapse=" + ")))
normalize <- function(x) {return ((x - min(x)) / (max(x) - min(x)))}
m <- 11
myResults <- NULL
aggResults <- NULL
df <- NULL
MSE <- NULL
NRMSE <- NULL
for (p in 1:(length(countries)))
{
  data <- myData[myData$Country==countries[p], c(-1, -2)]
  datanorm <- as.data.frame(lapply(data, normalize))
  for(i in seq(1,10,1))
  {
    for(j in seq(1,10,1))
    {
      for(k in seq(1,10,1))
      {
        for(sig in c("logistic", "tanh"))
        {
          err <- NULL
          hiddenLayer <- c(i, j, k)
          for(m in 1:m)
          {
            train.cv <- datanorm[c(-m), ]
            test.cv <- datanorm[m, ]
            set.seed(1)
            nn <-
neuralnet(formula, data=train.cv, hidden=hiddenLayer, linear.output=TRUE)
            prediction <- compute(nn, test.cv[, c(-1)])
            prediction <- prediction$net.result * (max(data$FDI) -
min(data$FDI)) + min(data$FDI)
            actual <- (test.cv$FDI) * (max(data$FDI) -
min(data$FDI)) + min(data$FDI)
            df <- data.frame(countries[p], i, j, k, m, prediction, actual)
            myResults <- rbind(myResults, df)
            err <- rbind(err, data.frame(prediction, actual))
          }
          acc <- accuracy(err$prediction, err$actual)
          NRMSE <- nrmse(err$prediction, err$actual)
          MASE <- calculateMASE(err$prediction, err$actual)
          df <-
data.frame(countries[p], i, j, k, sig, acc[1], acc[2], NRMSE, acc[3], acc[4], acc[5], MA
SE)
          colnames(df) <-
c("Country", "i", "j", "k", "sigmoid", "ME", "RMSE", "NRMSE", "MAE", "MPE", "MAPE", "MAS
E")
          aggResults <- rbind(aggResults, df)

```

```

    }
  }
}
write.table(aggResults, file="D:\\Mano
duomenys\\Desktop\\07_Rezultatai_Prognozavimas\\Regionams_VisiX_FNN.txt",
row.names=FALSE, col.names=TRUE)
```
Valstybems latentiniai X FNN
```{r, message=FALSE, warning=FALSE}

myData <- latdata
countries <- c("DNK", "EST", "FIN", "GBR", "IRL", "ISL", "LTU", "LVA", "NOR", "SWE")
normalize <- function(x) {return ((x - min(x)) / (max(x) - min(x)))}
m <- 11
myResults <- NULL
aggResults <- NULL
df <- NULL
MSE <- NULL
NRMSE <- NULL
for (p in 1:(length(countries)))
{
  data <- as.data.frame(myData[p])
  data <- data[, c(-1, -2)]
  datanorm <- as.data.frame(lapply(data, normalize))
  colY <- "FDI"
  variables <- colnames(data)
  variables <- variables[- which(variables %in% "FDI")]
  formula <- as.formula(paste(paste(colY, "~", sep=""), paste(variables, collapse=" + ")))

  for(i in seq(1,10,1))
  {
    for(j in seq(1,10,1))
    {
      for(k in seq(1,10,1))
      {
        for(sig in c("logistic", "tanh"))
        {
          err <- NULL
          hiddenLayer <- c(i, j, k)
          for(m in 1:m)
          {
            train.cv <- datanorm[c(-m), ]
            test.cv <- datanorm[m, ]
            set.seed(1)
            nn <-
neuralnet(formula, data=train.cv, hidden=hiddenLayer, linear.output=TRUE)
            prediction <- compute(nn, test.cv[, c(-1)])
            prediction <- prediction$net.result * (max(data$FDI) -
min(data$FDI)) + min(data$FDI)
            actual <- (test.cv$FDI) * (max(data$FDI) -
min(data$FDI)) + min(data$FDI)
            df <- data.frame(countries[p], i, j, k, m, prediction, actual)
            myResults <- rbind(myResults, df)
            err <- rbind(err, data.frame(prediction, actual))
          }
          acc <- accuracy(err$prediction, err$actual)
          MASE <- calculateMASE(err$prediction, err$actual)
          NRMSE <- nrmse(err$prediction, err$actual)
          df <-
data.frame(countries[p], i, j, k, sig, acc[1], acc[2], NRMSE, acc[3], acc[4], acc[5], MA
SE)

```

```

        colnames(df) <-
c("Country","i","j","k","sigmoid","ME","RMSE","NRMSE","MAE","MPE","MAPE","MAS
E")
        aggResults <-rbind(aggResults,df)
        write.table(aggResults, file="D:\\Mano
duomenys\\Desktop\\07_Rezultatai_Prognozavimas\\Vlastybems_LatentiniaiX_FFN.t
xt", row.names=FALSE, col.names=TRUE)
    }
}
}
}
write.table(aggResults, file="D:\\Mano
duomenys\\Desktop\\07_Rezultatai_Prognozavimas\\Vlastybems_LatentiniaiX_FFN.t
xt", row.names=FALSE, col.names=TRUE)
```

Regionams latentiniai X FNN
```{r, message=FALSE, warning=FALSE}

myData <- reglatdata
countries <- c("GBR","IRL","ISL","SKN","BLT")
normalize <- function(x) {return ((x - min(x)) / (max(x) - min(x)))}
m <- 11
myResults <- NULL
aggResults <- NULL
df <- NULL
MSE <- NULL
NRMSE <- NULL
for (p in 1:(length(countries)))
{
  data <-as.data.frame(myData[p])
  data<-data[,c(-1,-2)]
  datanorm <- as.data.frame(lapply(data, normalize))
  colY <- "FDI"
  variables <- colnames(data)
  variables <- variables[- which(variables %in% "FDI")]
  formula <- as.formula(paste(paste(colY , " ~
",sep=""),paste(variables,collapse=" + ")))

  for(i in seq(1,10,1))
  {
    for(j in seq(1,10,1))
    {
      for(k in seq(1,10,1))
      {
        for(sig in c("logistic","tanh"))
        {
          err <- NULL
          hiddenLayer <- c(i,j,k)
          for(m in 1:m)
          {
            train.cv <- datanorm[c(-m),]
            test.cv <- datanorm[m,]
            set.seed(1)
            nn <-
neuralnet(formula,data=train.cv,hidden=hiddenLayer,linear.output=TRUE)
            prediction <- compute(nn,test.cv[,c(-1)])
            prediction <- prediction$net.result*(max(data$FDI) -
min(data$FDI))+min(data$FDI)
            actual <- (test.cv$FDI)*(max(data$FDI) -
min(data$FDI))+min(data$FDI)
            df <-data.frame(countries[p],i,j,k,m,prediction,actual)
            myResults <-rbind(myResults,df)
            err <-rbind(err,data.frame(prediction,actual))

```

```

    }
    acc <- accuracy(err$prediction,err$actual)
    MASE <- calculateMASE(err$prediction,err$actual)
    NRMSE <- nrmse(err$prediction,err$actual)
    df <-
data.frame(countries[p],i,j,k,sig,acc[1],acc[2],NRMSE,acc[3],acc[4],acc[5],MA
SE)
        colnames(df) <-
c("Country","i","j","k","sigmoid","ME","RMSE","NRMSE","MAE","MPE","MAPE","MAS
E")
        aggResults <-rbind(aggResults,df)
    }
}
}
}
}
write.table(aggResults, file="D:\\Mano
duomenys\\Desktop\\07_Rezultatai_Prognozavimas\\Regionams_LatentiniaiX_FNN.tx
t", row.names=FALSE, col.names=TRUE)
```

```