



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

**Europos Sąjungos šalių patrauklumo užsienio investicijoms  
vertinimas laiko priežastinių ryšių nustatymo metodu**  
Baigiamasis magistro studijų projektas

---

**Vladas Verkėlis**  
Projekto autorius

Prof. Dr. Jurgita Bruneckienė  
Vadovė

Doc. Dr. Mantas Landauskas  
Vadovas

---

**Kaunas, 2024**



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

# **Europos Sąjungos šalių patrauklumo užsienio investicijoms vertinimas laiko priežastinių ryšių nustatymo metodu**

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

---

**Vladas Verkelis**

Projekto autorius

**Prof. Dr. Jurgita Bruneckienė**

Vadovė

**Doc. Dr. Ineta Zykienė**

Recenzentė

**Doc. Dr. Mantas Landauskas**

Vadovas

**Prof. Dr. Robertas Alzbutas**

Recenzentas

**Kaunas, 2024**



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

**Europos Sąjungos šalių patrauklumo užsienio investicijoms  
vertinimas laiko priešastinių ryšių nustatymo metodu**  
Akademinio sąžiningumo deklaracija

Patvirtinu, kad:

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

Vladas Verkelis

*Patvirtinta elektroniniu būdu*

Verkelis, Vladas. Europos Sąjungos šalių patrauklumo užsienio tiesioginėms investicijoms vertinimas laiko priežastinių ryšių nustatymo metodu. Magistro studijų baigiamasis projektas / vadovė prof. dr. Jurgita Bruneckienė, vadovas doc. dr. Mantas Landauskas; Kauno technologijos universitetas, Matematikos ir gamtos mokslų fakultetas.

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

Reikšminiai žodžiai: laiko priežastinių ryšių nustatymo metodas, priežastingumas.

Kaunas, 2024. 65p.

## Santrauka

Kiekviena šalis stengiasi pritraukti užsienio tiesioginių investicijų, kurios padeda sukurti naujas darbo vietas, vystyti naujas technologijas ir darbuotojų kompetencijas. Tačiau, yra sunku identifikuoti, kurie veiksniai kiekvienai šaliai padeda pritraukti užsienio tiesioginių investicijų. Veiksniai darantys įtaką užsienio tiesioginėms investicijoms taip pat gali kisti. Jiems gali daryti įtaką, pavyzdžiui, kintantis geopolitinis kontekstas ar aplinkosaugos politika.

Šiame darbe siekiama rasti priežastinius ryšius ir veiksnius, lemiančius Europos Sąjungos šalių patrauklumą užsienio investicijoms, naudojant laiko priežastinių ryšių nustatymo metodą. Koreliacija nurodo, kad egzistuoja ryšys tarp kintamųjų, bet jo nepaaiškina. Priežastingumas nurodo ryšio kryptį, vieno kintamojo priklausomumą nuo kito [17]. Šiame darbe naudojamas laiko priežastinių ryšių nustatymo metodas (angl. *Temporal Causal Discovery Framework*), kuris buvo pristatytas 2019 m. Šis metodas naudoja sąsūkų neuroninius tinklus ir dėmesio taškus priežastiniams ryšiams tarp kintamųjų rasti. Metodas randa tiesioginį, netiesioginį, savaiminį priežastingumą, geba identifikuoti klaidinančius veiksnius [17].

Šiame darbe buvo išnagrinėta mokslinė literatūra susijusi su šalies patrauklumu užsienio tiesioginėms investicijoms. Identifikuoti mokslinėje literatūroje minimi veiksniai ir rodikliai, darantys įtaką užsienio tiesioginėms investicijoms. Susipažinome su įvairiais metodais priežastiniams ryšiams identifikuoti. Taip pat detaliau aptarėme laiko priežastinių ryšių nustatymo ir Granger metodus.

Tyrimo metu buvo surinkti Airijos, Danijos, Ispanijos, Lietuvos ir Vokietijos duomenys iš įvairių šaltinių. Šalys reprezentuoja Europos Sąjungos šalis, suskirstytas pagal socialinės (valstybės) gerovės modelius. Duomenys buvo surinkti už 1986-2022 m. laikotarpį. Tirta kaip kito veiksniai darantys įtaką užsienio tiesioginėms investicijoms 1986-2003 m. ir 2004-2022 m. laikotarpiais. Taip pat palyginta, kokie veiksniai daro įtaką užsienio tiesioginėms investicijoms kiekvienoje šalyje. Nustatyta, kad vyrauja netiesiniai priežastingumo ryšiai tarp veiksmų darančių įtaką užsienio tiesioginėms investicijoms ir užsienio tiesioginių investicijų. Taip pat identifikuota, kad veiksniai minėtais laikotarpiais kito. Nagrinėjant šalis atskirai, randamas priežastinis ryšys tarp užsienio tiesioginių investicijų ir prekybos (% BVP). Šis ryšys išlieka ir skirtingais laikotarpiais.



Verkelis, Vldas. Evaluation of European Union Countries Attractiveness to Foreign Direct Investment by Using Temporal Causal Discovery Framework. Master's Final Degree Project / supervisor prof. dr. Jurgita Bruneckienė, supervisor doc. dr. Mantas Landauskas; Faculty of Mathematics and Natural Sciences, Kaunas University of Technology.

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

Keywords: Temporal Causal Discovery Framework, Causality.

Kaunas, 2024. 65.

### **Summary**

Every country strives to attract foreign direct investment, which helps create new jobs, develop new technologies, and enhance employee competencies and productivity. However, it is difficult to identify the factors that help each country attract foreign direct investment. The factors influencing foreign direct investments can also change. They may be influenced by, for example, changing geopolitical contexts or environmental policies.

This research aims to find causal relationships and factors determining the attractiveness of European Union countries to foreign direct investment, using the temporal causal discovery framework. Correlation indicates that there is a relationship between variables but does not explain it. Causality indicates the direction of the relationship, the dependence of one variable on another [17]. The Temporal Causal Discovery Framework method (TCDF), introduced in 2019, is used in this research. This method uses convolutional neural networks and attention scores to find causal relationships between variables. The method finds direct, indirect, and intrinsic causality, and can identify confounders [17].

Also, we examined the scientific literature related to a country's attractiveness to foreign direct investments. Factors and indicators mentioned in the scientific literature that influence foreign direct investments were identified. It was familiarized with various methods for identifying causal relationships. Moreover, it was discussed in more detail the temporal causal discovery framework and standard pairwise Granger method.

During the research, data were collected from various sources for Ireland, Denmark, Spain, Lithuania, and Germany. The countries represent European Union countries, divided according to social (state) welfare models. Data were collected for the period 1986-2022. The study examined how factors influencing foreign direct investments changed during the periods 1986-2003 and 2004-2022. It was also compared which factors influence foreign direct investments in each country. It was determined that there are nonlinear causality relationships between factors influencing foreign direct investments and foreign direct investments themselves. It was also identified that the factors changed during these periods. Examining countries individually, a causal relationship is found between foreign direct investments and trade (% of GDP). This relationship persists across different periods.

## TURINYS

<b>Lentelių sąrašas .....</b>	<b>8</b>
<b>Paveikslų sąrašas .....</b>	<b>9</b>
<b>Santrumpų ir terminų sąrašas .....</b>	<b>11</b>
<b>Įvadas.....</b>	<b>13</b>
<b>1. Literatūros apžvalga .....</b>	<b>14</b>
1.1. Investicinio patrauklumo sampratos ir jį lemiančių veiksnių analizė.....	14
1.1.1. Investicinio patrauklumo sampratos analizė .....	14
1.1.2. Tiesioginių užsienio investicijų daromas poveikis ekonomikai .....	14
1.1.3. Naujas požiūris į šalies investicinį patrauklumą: žaliosios transformacijos ir geopolitinės rizikos kontekstas.....	15
1.1.4. Investicinio patrauklumo vertinimo metodai.....	17
1.1.5. Šalies investicinį patrauklumą lemiantys veiksniai .....	17
1.1.6. Apibendrinimas .....	20
1.2. Priežastingumo aptikimo ir vertinimo metodai .....	20
1.2.1. Granger grįsti metodai .....	22
1.2.2. Apribojimais grįsti metodai .....	23
1.2.3. Triukšmu grįsti metodai .....	25
1.2.4. Taškais grįsti metodai.....	26
1.2.5. Apibendrinimas .....	27
<b>2. Tyrimo objektas ir metodai .....</b>	<b>29</b>
2.1. Matematiniai metodai .....	29
2.1.1. Granger porinis priežastingumas .....	29
2.1.2. Laiko priežastinių ryšių nustatymo metodas .....	29
2.2. Šalių pasirinkimas pagal socialinės (valstybės) gerovės modelius .....	36
2.3. Tyrimo objektas.....	37
2.3.1. Investicijų Lietuvoje istoriniai duomenys .....	37
2.3.2. Investicijų Vokietijoje istoriniai duomenys.....	38
2.3.3. Investicijų Danijoje istoriniai duomenys.....	39
2.3.4. Investicijų Arijose istoriniai duomenys .....	39
2.3.5. Investicijų Ispanijoje istoriniai duomenys.....	40
<b>3. Rezultatai.....</b>	<b>41</b>
3.1. Priežastinių ryšių paieška Lietuvos atveju.....	41
3.2. Priežastinių ryšių paieška Vokietijos atveju.....	43
3.3. Priežastinių ryšių paieška Danijos atveju .....	48
3.4. Priežastinių ryšių paieška Airijos atveju .....	52
3.5. Priežastinių ryšių paieška Ispanijos atveju .....	57
3.6. Apibendrinimas .....	61

<b>Išvados .....</b>	<b>63</b>
<b>Literatūros sąrašas .....</b>	<b>64</b>
<b>Priedai.....</b>	<b>66</b>
1    priedas. Granger priežastingumo analizės rezultatai .....	66

## Lentelių sąrašas

<b>1 lentelė.</b> Užsienio tiesioginių investicijų privalumai ir trūkumai [7] .....	15
<b>2 lentelė.</b> Užsienio tiesiogines investicijas lemiantys veiksniai [3, 9, 15, 16] .....	19
<b>3 lentelė.</b> Triukšmo panaudojimas priežastingumui nustatyti [18] .....	25
<b>4 lentelė.</b> Peržvelgtų priežastingumo metodų savybės [18]. .....	28
<b>5 lentelė.</b> Šalys pagal socialinės (valstybės) gerovės modelius [23].....	36
<b>6 lentelė.</b> TUI darančių įtaką rodiklių kitimas Vokietijoje. ....	47
<b>7 lentelė.</b> TUI darančių įtaką rodiklių kitimas Danijoje.....	51
<b>8 lentelė.</b> TUI darančių įtaką rodiklių kitimas Airijoje. ....	56
<b>9 lentelė.</b> TUI darančių įtaką rodiklių kitimas Ispanijoje.....	60
<b>10 lentelė.</b> Visos šalys su rodikliais, pradėtais rinkti po 2000 metų. Skaičiai nurodo vėlinimą. ....	61

## Paveikslų sąrašas

<b>1 pav.</b>	Šalys aplinkos griežtumo indekso ir užsienio tiesioginių investicijų kontekste [11].....	16
<b>2 pav.</b>	Investicinių patrauklumą lemiantys veiksniai [15] .....	18
<b>3 pav.</b>	Viso laiko priežastinio grafo pavyzdys [18] .....	21
<b>4 pav.</b>	Langinio priežastingumo grafo pavyzdys [18].....	22
<b>5 pav.</b>	Apibendrinančio priežastingumo grafo pavyzdys [18] .....	22
<b>6 pav.</b>	Trys lygios struktūros [18] .....	24
<b>7 pav.</b>	Praktinis pavyzdys: deimanto struktūra išgaunama naudojant DYNOTEARS [18].....	27
<b>8 pav.</b>	„grangercausalitytests“ funkcijos antraštė iš „statsmodels“ bibliotekos [21] .....	29
<b>9 pav.</b>	Priežastingumo grafiko pavyzdys [17].....	30
<b>10 pav.</b>	TCDF metodo architektūra [17] .....	31
<b>11 pav.</b>	$\chi_2$ prognozavimas išplėstiniu TCN [17].....	32
<b>12 pav.</b>	Priežastingumo iš dėmesio taškų nustatymas [17].....	35
<b>13 pav.</b>	Užsienio įtekančios tiesioginės investicijos procentais BVP Lietuvoje (2004-2022 m.)....	38
<b>14 pav.</b>	Užsienio įtekančios tiesioginės investicijos % BVP Vokietijoje palyginimas .....	38
<b>15 pav.</b>	Užsienio įtekančios tiesioginės investicijos % BVP Danijoje palyginimas.....	39
<b>16 pav.</b>	Užsienio įtekančios tiesioginės investicijos % BVP Airijoje palyginimas .....	40
<b>17 pav.</b>	Užsienio įtekančios tiesioginės investicijos % BVP Ispanijoje palyginimas.....	40
<b>18 pav.</b>	Lietuvos rodiklių koreliacijų matrica .....	41
<b>19 pav.</b>	Lietuvos rodiklių klasteriai pagal koreliaciją .....	42
<b>20 pav.</b>	Lietuvos rodiklių priežastingumo grafas 2004-2022 m. ....	42
<b>21 pav.</b>	Lietuvos visų rodiklių dėmesio taškų grafikas .....	43
<b>22 pav.</b>	Vokietijos rodiklių koreliacijų matrica (1986-2022 m.) .....	44
<b>23 pav.</b>	Vokietijos rodiklių klasteriai pagal koreliaciją (1986-2022 m.) .....	44
<b>24 pav.</b>	Vokietijos rodiklių koreliacijų matrica (2004-2022 m.) .....	45
<b>25 pav.</b>	Vokietijos rodiklių klasteriai pagal koreliaciją (2004-2022 m.) .....	45
<b>26 pav.</b>	Vokietijos rodiklių priežastingumo grafas 1986-2003 m.....	46
<b>27 pav.</b>	Vokietijos rodiklių priežastingumo grafas 2004-2022 m.....	46
<b>28 pav.</b>	Vokietijos rodiklių priežastingumo grafas 2004-2022 m. su visais rodikliais.....	47
<b>29 pav.</b>	Vokietijos visų rodiklių dėmesio taškų grafikas .....	47
<b>30 pav.</b>	Danijos rodiklių koreliacijų matrica (1986-2022 m.).....	48
<b>31 pav.</b>	Danijos rodiklių klasteriai pagal koreliaciją (1986-2022 m.).....	49
<b>32 pav.</b>	Danijos rodiklių koreliacijų matrica (2004-2022 m.).....	49
<b>33 pav.</b>	Danijos rodiklių klasteriai pagal koreliaciją (2004-2022 m.).....	50
<b>34 pav.</b>	Danijos rodiklių priežastingumo grafas 1986-2003 m. ....	50
<b>35 pav.</b>	Danijos rodiklių priežastingumo grafas 2004-2022 m. ....	51
<b>36 pav.</b>	Danijos rodiklių priežastingumo grafas 2004-2022 m. su visais rodikliais .....	52
<b>37 pav.</b>	Danijos visų rodiklių dėmesio taškų grafikas .....	52
<b>38 pav.</b>	Airijos rodiklių koreliacijų matrica (1986-2022 m.).....	53
<b>39 pav.</b>	Airijos rodiklių klasteriai pagal koreliaciją (1986-2022 m.).....	53
<b>40 pav.</b>	Airijos rodiklių matrica (2004-2022 m.) .....	54
<b>41 pav.</b>	Airijos rodiklių klasteriai pagal koreliaciją (2004-2022 m.).....	54
<b>42 pav.</b>	Airijos rodiklių priežastingumo grafas 1986-2003 m. ....	55
<b>43 pav.</b>	Airijos rodiklių priežastingumo grafas 2004-2022 m. ....	55
<b>44 pav.</b>	Airijos rodiklių priežastingumo grafas 2004-2022 m. su visais rodikliais .....	56

<b>45 pav.</b> Airijos visų rodiklių dėmesio taškų grafikas .....	56
<b>46 pav.</b> Ispanijos rodiklių koreliacijų matrica (1986-2022 m.).....	57
<b>47 pav.</b> Ispanijos rodiklių klasteriai pagal koreliaciją (1986-2022 m.).....	58
<b>48 pav.</b> Ispanijos rodiklių koreliacijų matrica (2004-2022 m.).....	58
<b>49 pav.</b> Ispanijos rodiklių klasteriai pagal koreliaciją (2004-2022m.).....	59
<b>50 pav.</b> Ispanijos rodiklių priežastingumo grafas 1986-2003 m. ....	59
<b>51 pav.</b> Ispanijos rodiklių priežastingumo grafas 2004-2022 m. ....	60
<b>52 pav.</b> Ispanijos rodiklių priežastingumo grafas 2004-2022 m.su visais rodikliais .....	60
<b>53 pav.</b> Ispanijos visų rodiklių dėmesio taškų grafikas .....	61

## Santrumpų ir terminų sąrašas

### Santrumpos:

AUKŠT\_IŠS - Aukštąjį išsilavinimą įgiję studentai pagal išsilavinimo lygį.

ARM\_Ž - Ariamos žemės dalis visoje teritorijoje (%).

ATS\_ENG\_S - Elektros energijos pagamintos iš atsinaujinančių energijos išteklių dalis visoje suvartotoje energijoje.

BVP\_G - BVP gyventojui.

CO2 - CO<sub>2</sub> emisijos (metrinės tonos gyventojui).

DARB\_S - Darbuotojų sąnaudos LCI (darbuotojų atlyginimai plius mokesčiai minus subsidijos).

DVDA – Didžiųjų verslo duomenų analitika.

ENERG\_IŠKAST - Energijos suvartojimas iš iškastinių resursų.

ENG\_S - Pirminės energijos sąnaudos (TWh).

FIKS\_RV - Fiksuoto ryšio vartotojų skaičius.

GEL\_K - Geležinkelių infrastruktūros kokybė.

INFL – Metinė infliacija vartotojų kainomis (%).

KEL\_K - Kelių kokybė.

KOR\_K - Korupcijos kontrolė: procentilės rangas.

MIŠK\_D - Miško dalis bendroje teritorijoje (%).

MOB\_RV - Mobiliojo ryšio vartotojų skaičius.

MOK - Mokesčiai nuo pajamų, pelno ir kapitalo prieaugio (procentais nuo pajamų).

NAT\_R\_N - Natūralių resursų nuoma (% BVP).

NEDAR - Nedarbingumas (% darbo jėgos).

O\_KEL\_S - Oru keliaujančių keleivių skaičius.

O\_UOST\_K - Oro uostų infrastruktūros kokybė.

PAG\_KAP - Pagrindinio kapitalo dalis šalyje.

PAT\_P - Rezidentų patentų paraiškos.

POL\_S - Politinio stabilumo ir smurto nebuvimas: procentilės rangas.

POP – Populiacija.

PREKYBA - Prekyba (% BVP).

PRIEIG\_E - Populiacijos dalis, turinti prieigą prie elektros (% populiacijos).

PROP\_R - Nuosavybės teisių indeksas (1-100).

SHAD\_E - Šešėlinė ekonomika (% BVP).

TEIS\_V - Teisinė valstybė: procentilės rangas.

T\_P\_SAV - Tyrimų ir projektų vystymo savikaina (% BVP).

TUI - Užsienio tiesioginės investicijos (% BVP į vidų).

UOST\_K - Uostų infrastruktūros kokybė.

UŽ\_T - Atvykstantys užsienio turistai.

VER\_P\_D - Verslui pradėti reikalingas laikas (dienos).

VER\_P\_IŠ - Verslo steigimo procedūrų išlaidos.

VER\_P\_S - Verslo registravimo procedūros (skaičiai).

VID\_IŠS - Mokiniai, besimokantys pagal vidurinio ugdymo programą.

VYR\_EF - Vyriausybės veiklos efektyvumas: procentilės rangas.

ŽŪŽM – Žemės ūkio, miškininkystės ir žuvininkystės dalis (BVP %).



## Įvadas

**Darbo problematika ir aktualumas** - šalys stengiasi pritraukti užsienio tiesiogines investicijas, kurios padeda sukurti naujas darbo vietas, vystyti naujas technologijas ir darbuotojų kompetencijas. Tačiau yra sunku identifikuoti, kurie veiksniai kiekvienai šaliai padeda pritraukti užsienio tiesiogines investicijas ir kaip tie veiksniai gali kisti.

**Tyrimo objektas** - Europos Sąjungos šalių užsienio tiesioginės investicijos.

**Tyrimo tikslas** - Rasti priežastinius ryšius ir veiksnius, lemiančius Europos Sąjungos šalių patrauklumą užsienio investicijoms naudojant laiko priežastinių ryšių nustatymo metodą.

### **Tyrimo uždaviniai:**

1. Identifikuoti veiksnius, galimai lemiančius užsienio tiesioginių investicijų pritraukimą.
2. Pasirinkti Europos Sąjungos šalis tyrimui naudojant socialinės (valstybės) gerovės modelius.
3. Rasti priežastinius ryšius naudojant laiko priežastinių ryšių nustatymo metodą.
4. Rastus priežastinius ryšius patvirtinti naudojant Granger priežastinio ryšio nustatymo metodą.
5. Gautus rezultatus palyginti.
6. Palyginus rezultatus nustatyti veiksnius lemiančius tiesiogines užsienio investicijas.

**Tyrimo metodai** - statistinių duomenų analizė, laiko priežastinių ryšių nustatymo metodas, Granger priežastinių ryšių metodas.

**Darbo struktūra** - pirmoje dalyje apžvelgsime mokslinę literatūrą apie investicinį patrauklumą ir užsienio tiesiogines investicijas, taip pat susipažinsime su įvairiais priežastingumo nustatymo metodais. Antroje dalyje giliau panagrinėsime laiko priežastinių ryšių nustatymo ir Granger metodus, pristatysime socialinės (valstybės) gerovės modelius, taip pat atliksime pirminę tiesioginių užsienio investicijų analizę. Trečioje dalyje pateiksime tyrimo rezultatus ir išvadas.

## **1. Literatūros apžvalga**

### **1.1. Investicinio patrauklumo sampratos ir jį lemiančių veiksnių analizė**

Šioje literatūros apžvalgos dalyje bus apžvelgti moksliniai straipsniai, susiję su šalies investiciniu patrauklumu. Pirmiausia peržvelgsime investicinio patrauklumo sampratą. Panagrinėsime, kokius pranašumus ir trūkumus tiesioginės užsienio investicijos teikia šalies ekonomikai. Aptarsime kaip šalies investicinis patrauklumas kinta žaliosios transformacijos ir geopolitinių rizikų kontekste. Taip pat panagrinėsime kaip šalies investicinis patrauklumas yra vertinamas ir kokie veiksniai daro įtaką užsienio tiesioginių investicijų pritraukimui.

#### **1.1.1. Investicinio patrauklumo sampratos analizė**

Kiekvienos šalies visuomenės gerovė priklauso nuo daugelio veiksnių. Vienas jų yra ekonominis augimas. Ekonominiam augimui daro įtaką daug veiksnių, tarp jų - tiesioginės užsienio investicijos [1]. Ekonominio bendradarbiavimo ir plėtros organizacija [2] tiesiogines užsienio investicijas apibūdina kaip investicijų kategoriją, kuri atspindi įmonės, reziduojančios vienoje ekonomikoje (tiesioginio investuotojo), tikslą sukurti ilgalaikį santykį su įmone, reziduojančia kitoje ekonomikoje (tiesioginių investicijų įmone). Tai taip pat apima kapitalo srautus tarp šių įmonių, tokius kaip pelno perinvestavimas, vidinis skolinimasis ir akcijų įsigijimai [2]. Dang'as ir Nguyen'as [3] apibūdina užsienio tiesiogines investicijas kiek paprasčiau, kaip įmonių ar asmenų vienoje šalyje investicijas į verslą kitoje, priimančioje, šalyje. Šalys ir įmonės, kurios sugeba pritraukti daugiau užsienio tiesioginių investicijų, pasižymi didesne konkurencija, inovacija ir techniniu progresu.

Bruneckienė ir kt. [4] 2019 m. straipsnyje apibrėžia šalies investicinį patrauklumą kaip šalies gebėjimą kurti investicijų pritraukimo mechanizmus ir strategijas, siekiant sukurti investuotojams palankias sąlygas arba jiems pritaikyti esamas sąlygas. Marchewka'as [5] 2022 m. straipsnyje šalies investicinį patrauklumą apibūdina kaip šalies gebėjimą paskatinti investuotojus savo investicijoms pasirinkti tą šalį. Šis gebėjimas yra suprantamas kaip šalies pranašumas vykdyti tam tikrą verslo veiklą. Šiuos pranašumus gali sudaryti daug veiksnių, kurie padeda įmonėje susimąžinti kaštus. Tokios šalys, kurios pasiūlo geriausias kombinacijas optimalių naudų, yra patraukliausios verslui ir investuotojams. Roszko-Wojtowicz ir Grzelak [6] 2021 m. straipsnyje investicinį patrauklumą apibūdina kaip šalies, užsienio tiesioginių investicijų gavėjos, politiką, priklausančią nuo aibės sąlygų, skatinančių investuotojus investuoti toje šalyje arba ne.

#### **1.1.2. Tiesioginių užsienio investicijų daromas poveikis ekonomikai**

Šalies ir įmonių gebėjimas pritraukti tiesiogines užsienio investicijas, jas užsitikrinti ir net planuoti, atneša nemažai naudos šalies ekonomikai (žiūr. 1 lentelė). Šalys pritraukiančios daugiau investicijų pritraukia žinių, technologijų ir inovacijų, kurių trūksta šalyje. Padidėjęs konkurencingumas skatina vietinius tiekėjus ir konkurentus siekti didesnio konkurencingumo ir produktyvumo. Tiesioginės užsienio investicijos sukuria nemažai darbo vietų. Įkuriamos naujos darbo vietos ir investicijos į darbuotojus padeda darbuotojams įgyti unikalias kompetencijas ir padidina jų produktyvumą. Taip pat vietiniai verslai įgyja naujų kompetencijų ir naudų bendradarbiaudami su investuojančiomis įmonėmis. Dažniausiai ateinančios užsienio investicijos pritraukia daugiau investicijų tame regione ar šalyje [7].

Kita vertus, investicinis patrauklumas turi ir neigiamų pasekmių (žiūr. 1 lentelė). Vietiniams tiekėjams gali būti sunku prisitaikyti prie didėjančių užsienio investuotojų poreikių. Užsienio investicijos gali pasitraukti iš šalies ar regiono į kitas šalis ar regionus. Dažniausiai užsienio investuotojų technologijos ir kompetencijos yra naudojamos įmonės viduje ir neperduodamos už jos ribų. Investuotojai nėra suinteresuoti investuoti į vietinius darbuotojus dėl jų menkų kompetencijų ir įgūdžių. Dažniausiai investuojančios įmonės naudojami priimančių šalių mažesniais mokesčiais, o jų uždirbami pelnai yra pervedami į „motines“ įmones kitose šalyse [7, 8]. Vietinėms įmonėms gali taip pat būti sunku konkuruoti dėl vietinių talentų su užsienio investuotojais [9].

**1 lentelė.** Užsienio tiesioginių investicijų privalumai ir trūkumai [7]

Aspektas	Teigiama įtaka	Neigiama įtaka
Santykis su vietos ekonomika	Užsienio investuotojų valdymo patirtis, žinios ir kompetencija, valdomos rinkos ir paskirstymo tinklai leidžia iš karto pradėti stambų verslą regione.	Stambūs verslai gali turėti menkus ryšius su vietos ekonomika.
	Dėl padidėjusios konkurencijos vietiniai tiekėjai ir konkurentai yra skatinami dirbti produktyviau ir labiau patenkinti kliento poreikius.	
	Kuriamos naujos darbo vietos įkurtose įmonėse. Sukuria naujas darbo vietas vietos tiekimo grandinėse, jeigu investuotojo verslas auga lėtai.	Sukuria mažai darbo vietų vietos tiekėjams, jei investuotojo verslas auga labai greitai (vietiniai tiekėjai nesugeba prisitaikyti prie greit kintančių reikalavimų).
	Apmoko regiono darbo jėgą naujų kompetencijų ir pagerina darbuotojų produktyvumą.	Regiono ekonomika gali tapti priklausoma nuo investuotojo ir nukentėti pasitraukus investicijoms.
Technologijos	Pristato naujas inovacijas, tokias kaip pažangius vadybos metodus ir kitas inovacijas.	Technologijos retai pasklinda už kompanijos ribų.
	Vietos įmonės supažindinamos su konkrečiais investuotojo privalumais, siekiant skatinti žinių perdavimą tiesiogiai bendradarbiaujant su vietos bendruomene.	Investuojančios kompanijos nepritaiko savo naudojamų technologijų mažiau išsivysčiusioms šalims ir regionams.
Finansai	Padidina pajamas iš mokesčių ir padeda pritraukti daugiau užsienio tiesioginių investicijų. Tai įveda daugiau stabilumo per krizes.	Didelės perlaidos iš regioninių fondų, pelnas, darbo užmokesčio pervedimas motininei bendrovei, perlaidų įkainių nustatymas siekiant sumažinti mokesčius priimančiajame regione.

### 1.1.3. Naujas požiūris į šalies investicinį patrauklumą: žaliosios transformacijos ir geopolitinės rizikos kontekstas

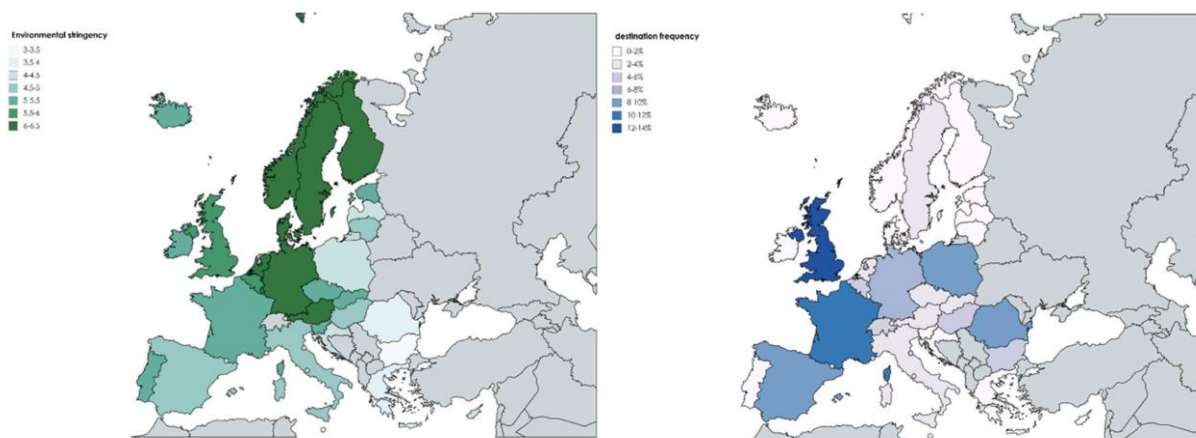
#### *Žaliosios transformacijos kontekstas*

Politiniai veiksniai ir kontekstas taip pat daro įtaką šalies investiciniam patrauklumui. Investuotojai yra linkę investuoti į demokratines valstybes, kuriose veikia įstatymo viršenybė, yra įteisintos nuosavybės teisės, vyrauja mažas korupcijos lygis ir politinis stabilumas. Taip pat užsienio tiesioginės investicijos veikia šalies politinį stabilumą. Investuojančios įmonės dažniausiai renkasi

šalis, kuriose gali derėtis dėl geresnių sąlygų. Investuodamos įmonės taip pat siekia didesnės naudos sau [10].

ES taiko keletą priemonių CO<sub>2</sub> sumažinimui. Viena iš taikomų priemonių CO<sub>2</sub> sumažinimui yra Europos Sąjungos apyvartinių taršos leidimų prekybos sistema (angl. *European Union Emission Trading Scheme*), toliau vadinsime trumpiniu EU ETS. Tai yra vienas iš didžiausių tarptautinių bandymų pasaulyje sumažinti išmetamų, šiltnamio efektą sukeliančių, dujų kiekį [11]. Taikant šį reguliavimą įmonės privalo pirkti taršos leidimus, kuriuos gali perparduoti. Reguliavimas liečia elektrines, gamybos sritis, reikalaujančias daug energijos (pavyzdžiui geležies, aliuminio gamyba), ir civilinę aviaciją. Reguliavimas siekia priversti įmones naudoti švaresnę energiją ir švaresnius gamybos būdus, pakeliant savikainą esamai gamybai [12].

Beule'as ir kt. [11] atliko tyrimą kaip EU ETS paveikė užsienio tiesiogines investicijas skirtingose ES šalyse. Tyrėjai koncentravosi tik į EU ETS pirmą ir antrą įgyvendinimo etapus (2005-2012 m.), kai buvo ES šalyse įgyvendinti nacionaliniai CO<sub>2</sub> paskirstymo planai. Tokiu būdu jie galėjo palyginti kaip kito užsienio tiesioginių investicijų srautai tarp šalių, įgyvendinant šiuos etapus.



**1 pav.** Šalys aplinkos griežtumo indekso ir užsienio tiesioginių investicijų kontekste [11]

Prieš atliekant tyrimą jau buvo žinoma, kad investuotojai užsienio tiesioginėms investicijoms dažniau renkasi šalis su mažiau griežtais taršos reikalavimais. Kaip pavaizduota kairėje pusėje, paveikslėlyje, tyrėjai suskirstė ES šalis pagal aplinkosaugos griežtumo indeksą, o dešinėje - pagal šalies pasirinkimą užsienio tiesioginėms investicijoms 2005-2012 m. Kaip matome, kai kurios šalys, kuriose aplinkosaugos politika griežčiausia, kaip, pavyzdžiui, Švedija, Suomija, Danija, Nyderlandai, yra rečiau pasirenkamos užsienio tiesioginėms investicijoms [11].

Tyrimas patvirtino, kad esant tam tikroms sąlygoms ir tam tikrose industrijose ES susidaro taršos „rojai“. Tarptautinės įmonės, dirbančios labai taršiose industrijose, kurios išskiria daug CO<sub>2</sub>, pasirenka investuoti į šalis, turinčias mažesnius taršos reikalavimus. Ypač jei tos industrijos ir įmonės nesulaukia ES paramos sprendžiant taršos klausimus. Šis reiškinys ypač pasireiškė įgyvendinant ankstesnius EU ETS etapus. Tai parodo, kad griežtų aplinkosaugos reikalavimų įgyvendinimas gali priversti investicijas pasitraukti iš šalies. Kita vertus, tai taip pat parodo, kad skirtingas aplinkosaugos reikalavimų įgyvendinimas ES nebūtinai išsprendžia problemas, nes taršios įmonės nemažina taršos, o persikelia į šalis kur taršos reikalavimai yra mažesni [11].

Šioje dalyje aptarsime kaip investicinį patrauklumą veikia geopolitinės rizikos, o konkrečiau - Rusijos-Ukrainos karas. Kaip jau žinome, investuotojai siekia investuoti ten, kur jų investicijos būtų saugios. Kalotay [13] 2023 m. straipsnyje diskutuoja kaip karas paveikė tiesiogines užsienio investicijas į agresorę Rusiją. Daugelis, užsienio investuotojų, prasidėjus karui nusprendė pasitraukti iš Rusijos naftos, dujų, finansų ir kitų sektorių. Prie to taip pat prisidėjo ir Europos Sąjungos sankcijos. Tyrimas rodo tolesnį įtekančių tiesioginių užsienio investicijų mažėjimą, nepaisant bandymų jų pritraukti iš konfliktui neutralių šalių kaip Kinija ir Indija.

Rusijos užpultoje Ukrainoje investuotojai nėra linkę investuoti dėl savo investicijų saugumo. Ekonomikos vystymasis yra sustojęs. Sunaikinta nemažai infrastruktūros. Šiuo metu sunku prognozuoti kada karas baigsis. Prasidėjus karui ženkliai sumažėjo užsienio tiesioginių investicijų. Šiuo metu verslo investicijų klimatas šalyje yra gan nestabilus. [14]. Neabejotinai Rusijos-Ukrainos karas paveiks ir visą Rytų Europos regioną. Tačiau geopolitines pasekmes dar sudėtinga vertinti. Šiandien sunku rasti straipsnių šia tema.

#### **1.1.4. Investicinio patrauklumo vertinimo metodai**

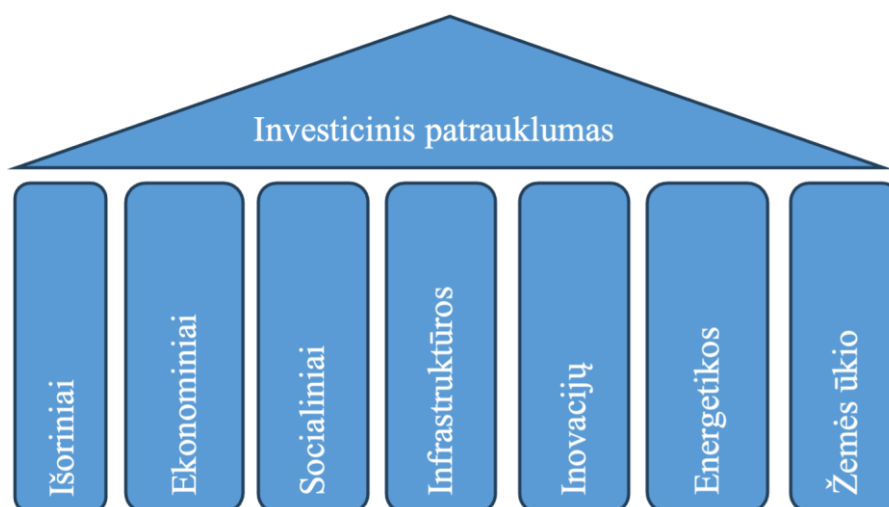
Šalių investiciniam patrauklumui įvertinti yra naudojami indeksai. Indeksai vertinamai šaliai priskiria atitinkamą investicinį patrauklumą nurodančią vertę. Populiariausi indeksai yra pasaulinis tiesioginių užsienio investicijų šalies patrauklumo indeksas (angl. *Global Foreign Direct Investment Country Attractiveness Index*), sutrumpintai GFICA, tiesioginių užsienio investicijų pasitikėjimo indeksas (angl. *Foreign Direct Investment Confidence Index*), sutrumpintai FDICI, rizikos kapitalo ir privataus kapitalo šalies patrauklumo indeksas (angl. *Venture Capital & Private Equity Country Attractiveness Index*), sutrumpintai VPCE, ir pasaulinis patrauklumo indeksas (angl. *Global Attractiveness Index*), sutrumpintai GAI [9].

GFICA yra plačiai investuotojų naudojamas indeksas prieš priimant investavimo sprendimus. Indeksas vertina 109 šalis, kurios sudaro 97% pasaulinių tiesioginių užsienio investicijų. Šis indeksas taip padeda šalims rasti sritis, kurias galima pagerinti. VPCE indeksas taikomas panašiam tikslui kaip GFICA. Indeksas vertina 125 šalis. Indeksas vertindamas atsižvelgia ekonominės veiklos, rinkos dydžio, mokestinės aplinkos, žmoniškųjų išteklių, socialinės aplinkos, investicijų apsaugos, įmonių valdymo ir verslumo sritis. GAI indeksas apima 144 šalis. Jo tikslas yra investuotojams padėti rasti tinkamiausią šalį jų investicijoms. FDICI indeksas apima 25 šalis. Šis indeksas orientuotas tik į išsivysčiusias šalis ir numato šalis, kurios pritrauks didžiausias investicijas per ateinančius 3 metus [9].

#### **1.1.5. Šalies investicinį patrauklumą lemiantys veiksniai**

Šalies investicinio patrauklumo vertinimas yra sudėtingas procesas, kuris susideda iš daugelio etapų. Vertinimą apsunkina tai, kad kiekvienos šalies ekonomika ir specializacija skiriasi, taip pat kiekviena šalis turi skirtingus prioritetus [15]. Literatūroje yra nurodoma nemažai veiksnių, turinčių įtakos šalies investiciniam patrauklumui. Juos galime suskirstyti į ekonominius, teisinius, technologinius, politinius, geografinius ir infrastruktūrinius. Tačiau šių dienų kontekste, pasauliui susiduriant su klimato kaitos problemomis, investicinis patrauklumas turėtų būti vertinamas ir per tvarumo prizmę [4]. Moskalenko ir kt. [15] 2023 m. straipsnyje taip pat aptaria veiksnius, turinčius

įtakos šalies investiciniam patrauklumui. Straipsnyje veiksniai suskirstomi į išorinius, ekonominius, socialinius, infrastruktūros, inovacijos, energetikos ir žemės ūkio (žiūr. 2 pav.).



**2 pav.** Investicinį patrauklumą lemiantys veiksniai [15]

Trumpai aptarkime kiekvieną grupę. Verti paminėti išoriniai veiksniai, darantys įtaką investiciniam patrauklumui, yra šalies integracija į finansų rinkas, tarptautinė prekyba ir turizmas. Šalies ir jos įmonių dalyvavimas finansų rinkose yra vienas iš svarbiausių faktorių. Tai padeda ne tik šalies įmonėms pritraukti finansinių investicijų, bet ir formuoja atitinkamą įvaizdį apie šalį ir jos įmonių būklę. Veiksniai, darantys įtaką finansinių investicijų pasitraukimui, tokie kaip korupcija, šešėlinė ekonomika ir taip toliau, gali įtakoti ir užsienio tiesioginių investicijų pasitraukimą. Taip pat labai svarbus šalies atvirumas prekybai. Galimybė laisvai judėti prekėms ir jomis prekiauti tarptautiniu mastu. Tai gerina šalies investicinį klimatą ir didina ekonominį bendradarbiavimą. Išvystyta turizmo infrastruktūra ir atvykstančių turistų skaičius taip pat teigiamai veikia ekonomiką. Tyrimai parodė, kad gerai išvystytas turizmo sektorius teigiamai veikia ir investicinį patrauklumą [15].

Galime rasti nemažai pavyzdžių kai investuotojai yra linkę investuoti į stiprias ir stabilias ekonomikas. Augančios ekonomikos pritraukia investuotojų dėmesį. Tačiau investuotojai taip pat vengia šalių, kurios turi socialinių problemų. Nemažai investuotojų remiasi „Globaliu tvarumo ir konkurencingumo indeksu“ prieš darydami investavimo sprendimus. Ekonominės ir socialinės problemos, kaip didelis nedarbo lygis, skurdas, nelygybė ir taip toliau, daro neigiamą įtaką šalies investiciniam patrauklumui. Kita vertus, tyrimai rodo, kad šalys su mažesniu nedarbo užmokesčiu pritraukia didesnę investuotojų dėmesį [15].

Šalies infrastruktūra ir jos vystymas taip pat svarbus siekiant pritraukti daugiau užsienio tiesioginių investicijų. Investuotojams svarbu esamos infrastruktūros būklė. Ypač svarbus transportui skirtos infrastruktūros tinklo kūrimas, vystymas ir priežiūra. Gera kelių ir geležinkelių būklė yra labai svarbi prekių judėjimui. Šalies ekonominis augimas teigiamai koreliuoja su šalies transporto infrastruktūros vystymu. Investuotojai taip pat atkreipia dėmesį į šalies komunikacijų infrastruktūrą ir jos vystymą [15].

Inovatyvumas taip pat yra svarbi veiksnių grupė, lemianti šalies investicinį patrauklumą. Šalies skaitmeninimas, informacinių technologijų paplitimas ir gebėjimas jas naudoti bei vystyti gali pritraukti nemažai tiesioginių užsienio investicijų. Atlikti tyrimai patvirtino, kad egzistuoja teigiamas ryšys tarp šalies skaitmeninimo ir dirbtinio intelekto įrankių paplitimo [15].

Šalies gebėjimas apsirūpinti energijos resursais yra labai svarbus veiksnys užtikrinant ekonominį augimą. Investuotojams yra svarbi energijos tiekimo infrastruktūra, šalies atvirumas vystyti atsinaujinančių išteklių energetiką ir šalies valdžios atvirumas ir parama vystyti ir remti energetikos projektus. Šalies ekonomikos augimas ir investicinis patrauklumas yra labai susijęs su šalies energetiniu saugumu. Šalys, pasižyminčios didesniu energetiniu saugumu, pasižymi ir didesniu investiciniu patrauklumu. Manoma, kad šalies orientavimasis į atsinaujinančių išteklių energetiką gali pritraukti dar daugiau užsienio tiesioginių investicijų [15].

Šalys, turtingos žemės ūkio ištekliais, taip pat pritraukia investuotojų dėmesį. Dažnai užsienio investicijos žemės ūkiui padidina žemės ūkio sektoriaus efektyvumą ir užtikrina šalies gebėjimą apsirūpinti maistu. Investuotojai taip pat vertina šalies gebėjimą apsirūpinti maistu prieš priimdami investavimo sprendimus. Nemažai tyrimų patvirtina abipusį ryšį tarp žemės ūkio ir šalies investicinio patrauklumo [15].

Žemiau esančioje lentelėje pateikiami literatūroje randami investicinį patrauklumą lemiantys veiksniai.

**2 lentelė.** Užsienio tiesiogines investicijas lemiantys veiksniai [3, 9, 15, 16]

Veiksmų grupės	Veiksniai	Rodikliai	
Išoriniai veiksniai	Ekonomikos atvirumas	Prekyba (% BVP)	
	Turizmas	Atvykstantys užsienio turistai	
Ekonominiai	BVP	BVP gyventojui	
	Nedarbingumo lygis	Nedarbingumas (% darbo jėgos)	
	Rinkos dydis	Rinkos dydis	
	Infliacija	Metinė infliacija vartotojų kainomis (%)	
	Pajamų mokesčiai	Mokesčiai nuo pajamų, pelno ir kapitalo prieaugio (procentais nuo pajamų)	
	Darbo jėgos sąnaudos	Darbuotojų sąnaudos LCI (darbuotojų atlyginimai plus mokesčiai minus subsidijos)	
	Verslo valdymo lengvumas		Verslo registravimo procedūros (skaičiais)
			Verslui pradėti reikalingas laikas (dienomis)
			Verslo steigimo procedūrų išlaidos
	Pagrindinio kapitalo dalis šalyje	Pagrindinio kapitalo dalis šalyje	
Šešėlinė ekonomika	Šešėlinė ekonomika		
Socialiniai	Išsilavinimas	Mokiniai, besimokantys pagal vidurinio ugdymo programą	
		Aukštąjį išsilavinimą įgiję studentai pagal išsilavinimo lygį	
	Kyšininkavimas ir korupcija	Korupcijos kontrolė: procentilės rangas	
	Politinis stabilumas	Politinio stabilumo ir smurto nebuvimas: procentilės rangas	
	Nuosavybės teisės	Nuosavybės teisių indeksas	
	Vyriausybės veiklos efektyvumas	Vyriausybės veiklos efektyvumas: procentilės rangas	

	Teisinė valstybė	Teisinė valstybė: procentilės rangas
	Populiacija	Populiacija
Infrastruktūros	Komunikacijos infrastruktūra	Mobiliojo ryšio vartotojų skaičius
		Interneto vartotojų skaičius (% populiacijos)
		Fiksuoto ryšio vartotojų skaičius
	Transporto infrastruktūra	Oru keliaujančių keleivių skaičius
		Uostų infrastruktūros kokybė
		Oro uostų infrastruktūros kokybė
		Geležinkelių infrastruktūros kokybė
Kelių kokybė		
Inovacijų	Registruotų patentų skaičius	Rezidentų patentų paraiškos
	Tyrimų ir projektų vystymo savikaina	Tyrimų ir projektų vystymo savikaina (% BVP)
Energetikos	Populiacijos dalis turinti prieigą prie elektros	Populiacijos dalis turinti prieigą prie elektros (% populiacijos)
	Energijos suvartojimas	Pirminės energijos sąnaudos (TWh)
		Elektros energijos, pagamintos iš atsinaujinančių energijos išteklių, dalis visoje suvartotoje energijoje
Energijos suvartojimas iš iškastinių resursų		
Žemės ūkis	Natūralių resursų nuoma	Natūralių resursų nuoma (% BVP)
	Ariamos žemės dalis visoje teritorijoje	Ariamos žemės dalis visoje teritorijoje (%)
	Žemės ūkis, miškininkystė, žuvininkystė	Žemės ūkio, miškininkystės ir žuvininkystės dalis (% BVP)
	Šalies miškingumas	Miško dalis bendroje teritorijoje (%)
	CO <sub>2</sub> emisijos	CO <sub>2</sub> emisijos (metrinės tonos gyventojui)

Atlikus mokslinės literatūros analizę buvo identifikuoti 40 rodiklių, kurie daro įtaką užsienio tiesioginėms investicijoms.

### 1.1.6. Apibendrinimas

Šioje literatūros apžvalgos dalyje susipažinome su investicinio patrauklumo samprata ir ją išnagrinėjome. Susipažinome su investicinio patrauklumo vertinimu ir jį lemiančiais veiksniais. Trumpai aptarėme kaip investicinis patrauklumas kinta politiniame kontekste, ypač įgyvendinant CO<sub>2</sub> sumažinimo politiką. Tačiau lieka neatsakytas klausimas, kurie veiksniai lemia užsienio tiesioginių investicijų patrauklumą Europos Sąjungoje ir kaip jie kinta. Į šį klausimą atsakymus pateikia šiame projekte atlikti tyrimai.

### 1.2. Priežastingumo aptikimo ir vertinimo metodai


Mašininio mokymosi algoritmai yra sėkmingai pritaikyti įvairių reiškinių prognozavimui. Tačiau paprastai jie nepajėgia nurodyti priežastingumo ir remiasi koreliaciniais ryšiais. Koreliacija nurodo, kad egzistuoja ryšys tarp kintamųjų, bet jo nepaaiškina. Priežastingumas nurodo ryšio kryptį, vieno kintamojo priklausomumą nuo kito. Nepaisant to, nemažai mašininio mokymosi algoritmų puikiai veikia naudodami koreliacinius ryšius. Tačiau yra labai sunku nuspėti kada modelis nustos veikti, nebent yra koku nors būdu užtikrinamas stabilumas modeliuojant koreliacijos funkciją. Jeigu



mašininio mokymosi algoritmai išminktų priežastinius ryšius, tai padėtų sukurti patikimesnius prognozavimo modelius, kuriuos naudojant būtų paprasčiau nuspėti ir paaiškinti prognozuojamus reiškinius. Taip pat tai padėtų suprasti kaip, pavyzdžiui, neuroniniai tinklai prieina prie vieno ar kito rezultato. Tai yra nauja, pakankamai progresyvi sritis - paaiškinamasis dirbtinis intelektas [17].


Paskutiniu metu buvo sukurta daug modelių ir metodų priežastingumui atrasti. Jei pirmieji bandymai buvo skirti ne laike kintantiems duomenims, tai vis daugiau jų sukuriama laiko eilutėms. Dažnai laiko eilučių priežastiniai ryšiai yra atvaizduojami grafais. Grafai yra skirstomi į viso laiko priežastingumo grafus (žiūr. 3 pav.), langinius priežastingumo grafus (žiūr. 4 pav.), ir apibendrinančius priežastingumo grafus (žiūr. 5 pav.) [18].

Galime pateikti tokį viso laiko priežastingumo grafo apibrėžimą. Tarkim  $\mathcal{X}$  yra daugiamatis diskrečiojo laiko stochastinis procesas ir  $\mathcal{G} = (V, E)$  – jo viso laiko priežastinis grafas. Grafo viršūnių aibę sudaro komponentų aibė  $\mathcal{X}^1, \dots, \mathcal{X}^d$ , kai kiekvienas laiko momentas  $t \in \mathbb{Z}$ . Grafo briaunas galime apibrėžti taip: kintamuosius  $\mathcal{X}_{t-i}^p$  ir  $\mathcal{X}_t^q$  jungia vėluojanti kryptinga jungtis  $\mathcal{X}_{t-i}^p \rightarrow \mathcal{X}_t^q$  grafe  $\mathcal{G}$ , nukreiptam į priekį, tada ir tik tada, kai  $\mathcal{X}^p$  yra priežastis  $\mathcal{X}^q$  laiko momentu  $t$ , kai vėlinimas  $i > 0$ , kai  $p=q$  ir laiko vėlinimu  $i \geq 0$ , kai  $p \neq q$ . Sudaryti viso laiko priežastinius laiko grafus yra neįmanoma, nes kiekvienu laiko momentu kiekviena laiko eilutė turi tik vieną stebėjimą. Todėl įprasta remtis vadinamąja laiko nuoseklumo prielaida [18].




3 pav. Viso laiko priežastinio grafo pavyzdys [18]

Langinį priežastingumo grafą galime apibrėžti taip: tarkim  $\mathcal{X}$  yra daugiamatis diskrečiojo laiko stochastinis procesas ir  $\mathcal{G} = (V, E)$  – jo langinis priežastingumo grafas lango dydžiui  $\tau$ . Grafo viršūnių aibę sudaro komponentų aibė  $\mathcal{X}^1, \dots, \mathcal{X}^d$ , kai kiekvienas laiko momentas  $t, \dots, t + \tau$ . Grafo briaunas galime apibrėžti taip: kintamuosius  $\mathcal{X}_{t-i}^p$  ir  $\mathcal{X}_t^q$  jungia vėluojanti kryptinga jungtis  $\mathcal{X}_{t-i}^p \rightarrow \mathcal{X}_t^q$  grafe  $\mathcal{G}$  nukreiptame į priekį, tada ir tik tada, kad  $\mathcal{X}^p$  yra priežastis  $\mathcal{X}^q$  laiko momentu  $t$ , kai vėlinimas  $0 \leq i \leq \tau$ , kai  $p \neq q$  ir laiko vėlinimu  $0 < i \leq \tau$ , kai  $p=q$ . Viso laiko ir langiniai priežastingumo grafai yra ekvivalentūs, jeigu apsvairstome laiko nuoseklumo prielaidą [18].



4 pav. Langinio priežastingumo grafo pavyzdys [18]

Apibendrinantis priežastingumo grafas apibendrina langinį priežastingumo grafą. Apibendrinantį priežastingumo grafą galime apibrėžti taip: tarkim  $\mathcal{X}$  yra daugiamatis diskrečiojo laiko stochastinis procesas ir  $\mathcal{G} = (V, E)$  – jo apibendrinantis priežastingumo grafas. Grafo viršūnių aibę sudaro laiko eilučių aibė  $\mathcal{X}^1, \dots, \mathcal{X}^d$ . Grafo briaunas galime apibrėžti taip: kintamieji  $\mathcal{X}^p$  ir  $\mathcal{X}^q$  yra sujungti tada ir tik tada, kai yra laiko momentas  $t$  ir laiko vėlinimas  $i$ , taip kad  $\mathcal{X}_{t-i}^p$  sukelia  $\mathcal{X}_t^q$  laiko momentu  $t$ , kai vėlinimas  $0 \leq i$ , kai  $p \neq q$  ir laiko vėlinimu  $0 < i$ , kai  $p = q$  [18].



5 pav. Apibendrinančio priežastingumo grafo pavyzdys [18]

Pagrindinius priežastingumo metodus galima skirstyti į Granger grįstus, apribojimais grįstus (vieni populiariausių), triukšmu grįstus ir taškais grįstus (susiję su Bajeso tinklais). Šie metodai yra išsamiai aptariami Assaad'o ir kt. 2022 m. straipsnyje [18]. Toliau trumpai aptarsime kiekvieną grupę ir bent vieną metodą iš grupės.

### 1.2.1. Granger grįsti metodai

Granger priežastingumas yra viena seniausių priežastingumo idėjų. Granger priežastingumas yra pagrįstas filosofo Hume'o dėsningumo teorija, kuri teigia, kad priežastiniai ryšiai gali būti nustatomi remiantis nuolatinių jungčių tarp priežasčių ir pasekmių patirtimi, kai priežastis eina prieš pasekmes. Granger priežastingumas buvo tyrinėtas daugelio mokslininkų. Šiuo metu Granger priežastingumą galime apibrėžti taip: laiko eilutė  $\mathcal{X}^p$  yra priežastis laiko eilutes  $\mathcal{X}^q$ , jeigu praeities vertės  $\mathcal{X}^p$  turi unikalios ir statistiškai reikšmingos informacijos apie  $\mathcal{X}^q$  ateities vertes. Dėl to  $\mathcal{X}^q$  galime prognozuoti iš  $\mathcal{X}^p$ . Tačiau Granger priežastingumo metodas turi ir problemų. Jį naudojant negalime nustatyti priežastingumo, kai priežastis ir efektas įvyksta tuo pačiu metu, be to, duomenys turi būti stacionarūs. Granger priežastingumas nėra tinkamas dinaminėse sistemose, kur tarp kintamųjų yra silpnas arba vidutiniškas susietumas, nes ne visada yra užtikrinamas atskiriamumas. Paprastai matematiniuose programavimo paketuose realizuotas tik tiesinis Granger priežastingumas.

Tačiau Granger priežastingumas buvo sėkmingai taikomas ekonometrijoje, neurologijoje ar klimatologijoje [18].


Patys paprasčiausi metodai yra standartinis porinis Granger priežastingumas ir daugiamatis Granger priežastingumas. Taikant porinį Granger priežastingumą galima gauti gan dviprasmiškus rezultatus, atskiriant tiesioginius ir tarpinius ryšius. Būtent šią problemą sprendžia daugiamatis Granger priežastingumas. Daugiamatis Granger priežastingumas dažniausiai pateikia geresnius rezultatus, bet yra labai imlus skaičiavimams. Dėl šios priežasties dažniausiai yra naudojamas standartinis porinis Granger priežastingumas. Tačiau yra sukuriama daugiau Granger idėjomis grįstų metodų, kurie geba spręsti duomenų stacionarumo ir momentinio priežastingumo problemas, tokių kaip laiko priežastinių ryšių nustatymo metodas [18].

Laiko priežastinių ryšių nustatymo metodas (angl. *Temporal Causal Discovery Framework*), sutrumpintai TCDF, naudoja dėmesio taškus ir sąsūkų neuroninius tinklus duomenų stacionarumo problemoms spręsti ir netiesiniams ryšiams rasti. Šis metodas buvo pristatytas Nauta'os ir kt. 2019 m. Metodą sudaro  $d$  tos pačios architektūros dėmesio taškais grįsti sąsūkų neuroniniai tinklai, kur  $(N_q)_{1 \leq q \leq d}$ , taikantys skirtingas laiko eilutes  $\mathcal{X}^q$ . Kiekvienas neuroninis tinklas pateikia savo prognozes, dėmesio taškus ir branduolio svorius. Juos interpretuojant randami priežastiniai ryšiai. Aukštas įvertinimas dėmesio taškais  $\mathcal{X}^p$  prognozuojant  $\mathcal{X}^q$  reiškia, kad  $\mathcal{X}^p$  yra priežastis  $\mathcal{X}^q$ . TCDF geba atrasti momentinius priežastinius ryšius, tiek paslėptąjį klaidinantį veiksnį (kai sukeltantis efektą veiksnys nėra aiškiai pastebimas). Tačiau šis metodas yra kritikuojamas dėl parametru gausos ir poreikio juos atitinkamai kalibruoti. Taip pat nėra aiškaus būdo kaip padidinti maksimalų vėlinimų skaičių [18]. Minima, kad vieno sąsūkų branduolio gali neužtekti sudėtingam netiesiniam priežastingumui atrasti [19].

### 1.2.2. Apribojimais grįsti metodai

Apribojimais grįsti metodai naudoja sąlygines priklausomybes tam, kad būtų sudarytas kintamųjų karkasas. Karkasas yra orientuojamas pagal atitinkamą taisyklių rinkinį, kuris apibrėžia atitinkamus apribojimus. Pagrindė yra naudojamos  $v$  formos struktūros arba susikertančios struktūros. Šios struktūros padeda išvengti dviprasmybių. Apribojimais grįsti metodai yra skirstomi į su priežastiniu pakankamumu (kai visi bendri priežastiniai ryšiai tarp kintamųjų yra atrasti) ir be priežastinio pakankamumo [18].

Metoduose su priežastiniu pakankamumu yra išnaudojamos sąlyginės priklausomybės tam, kad būtų galima sudaryti pagrindinį priežastingumo grafą, kuris yra atvaizduojamas kaip tiesioginis aciklinis grafas (angl. *direct acyclic graph*), sutrumpintai DAG. Tačiau pagrindinis priežastingumo grafas nėra unikalus, nes gali būti naudojama keletas DAG tai pačiai sąlyginių nepriklausomybių aibei atvaizduoti., 6 pav. parodomi modeliai, kurie turi nepriklausomus ryšius. Laiko eilutė  $\mathcal{X}^p$  yra nepriklausoma nuo  $\mathcal{X}^q$  kai yra duota  $\mathcal{X}^f$ . O tai patvirtina Markov'o klasių lygybę.



6 pav. Trys lygios struktūros [18]

DAG'ai, atvaizduojantys tą pačią aibę, gali skirtis, bet yra ekvivalentūs, jei išlaiko tuos pačius sąlyginius priklausomybių ryšius. Du DAG'ai atitinka Markov'o lygybę, jei turi tą patį karkasą ir  $\nu$ -struktūras. Ši lygybės sąvoka priklauso nuo priverstinių briaunų orientacijos. Šios briaunos dalyvauja  $\nu$ -struktūrose arba gali sudaryti naujas struktūras pasikeitus orientacijai. Tai galima atvaizduoti daliniu tiesioginiu acikliniu grafu (angl. *partial direct acyclic graph*). Tai ypač naudinga kai orientacijos negalima nustatyti. Taip pat yra naudojamas ir išbaigtas tiesioginis aciklinis grafas (angl. *completed partial direct acyclic graph*), sutrumpintai CPDAG, kuris yra PDAG, kur kryptinė briauna skirta kiekvienai lygiavertiškumo klasės briaunai, ir nekryptinė briauna skirta visoms kitoms briaunoms. Taigi, apribojimu grįstų algoritmų tikslas iš gautų duomenų sukonstruoti CPDAG, kuris atitiktų Markov'o klasių lygybę [18, 20].

Vienas metodų su priešastiniu pakankamumu yra Peter'io Clark'o algoritmas ne laike kintantiems duomenims. Sutrumpintai dar vadinamas PC algoritmu. PC algoritmas optimizuoja reikalingą kiekį skaičiavimų tam, kad būtų nustatyta ar du kintamieji yra sąlyginai priklausomi, ar ne. To siekiama įvertinant tėvinius kintamųjų elementus. Tokiu būdu PC algoritmas gali sudaryti didelius, eksponentinius grafus. PC algoritmas išbaigtame netiesioginiame grafe  $\mathcal{G}$  tikrina priklausomybes visoms poroms viršūnių ir palieka arba pašalina ryšius, vertindamas ar abi viršūnės yra nepriklausomos. Tada algoritmas tikrina sąlyginę priklausomybę tarp priklausomų viršūnių. Pirmiausia apskaičiuodamas tai kiekvienai gretimai porai  $X^p$  ir  $X^q$  grafe  $\mathcal{G}$  ir kiekvienai viršūnei  $X^r$  (ar kitai, bet tik ne  $X^p$ ) gretimai  $X^q$ . Jeigu  $X^r$  geba panaikinti priklausomybę tarp  $X^p$  ir  $X^q$ , briauna tarp jų pašalinama ir  $X^r$  pridedama į jų atsiskyrimo aibę  $\text{Sepset}(p, q)$ . Tada palaipsniui yra didinamas sąlygojamų kintamųjų skaičius, kol randamas sąlyginis priklausomumas, arba kol nustatoma sąlyga, atsižvelgiant į visus su  $X^q$  besiribojančius viršūnių rinkinius. Kai skeletas yra pabaigiamas, tada algoritmas pritaiko taisyklės  $\nu$ -struktūroms identifikuoti. Priežastinių ryšių atitikimas Markov'o klasių lygybei patvirtina ryšių tikrumą. Dažniausiai PC algoritmas yra kritikuojamas dėl priklausomybės nuo eilės tvarkos, dėl to laikomas nestabiliu [18].

Laiko eilutėms analizuoti PC metodas yra išplėtojamasis į PCMCi metodą. PCMCi metodas gali atrasti vėluojančius priešastinius ryšius priešastingumo grafe. Algoritmas yra padalintas į tris dalis. Pirmiausia yra sukuriama dalinai sujungtas grafas  $\mathcal{G}$  taip, kad visos mazgų poros  $(\mathcal{X}_{t-i}^p, \mathcal{X}_t^q)$  yra nukreiptos taip, kad  $\mathcal{X}_{t-i}^p \rightarrow \mathcal{X}_t^q$ , jei  $i > 0$ . Antrame žingsnyje pašalinamos visos nereikalingos briaunos pagal sąlygines priklausomybes kaip ir PC metode. Taip pat atsižvelgiama į nuoseklumo per visą laiką prielaidą tam, kad būtų pašalintos homologinės briaunos. Kiekvienai  $\mathcal{X}_{t-1}^p \rightarrow \mathcal{X}_t^q$  pašalintai briaunai visos briaunos  $\text{Hom}(\mathcal{X}_{t-i}^p, \mathcal{X}_t^q, \mathcal{G})$  yra taip pat pašalinamos, kur  $\text{Hom}(\mathcal{X}_{t-i}^p, \mathcal{X}_t^q, \mathcal{G})$  yra momentų aibė  $\mathcal{X}_{t-i}^p$  ir  $\mathcal{X}_t^q$ . Tai reiškia, kad momentai  $\mathcal{X}^p$  ir  $\mathcal{X}^q$  pastumiami per  $i$  vėlavimą nuo  $p$  į  $q$ . Kadangi sąlygojimas grįstas  $\mathcal{X}_t^q$  tėviniais elementais, tai negalime kontroliuoti neigiamai teigiamų rezultatų su didelėmis  $\mathcal{X}_{t-i}^p$  autokoreliacijomis. Trečiame žingsnyje

šioms autokoreliacijoms panaudojamas momentinio sąlyginio nepriklausomumo testas (angl. *Momentary Conditional Independence test*), sutrumpintai MCI. MCI sąlygoja tėvinius elementus  $\mathcal{X}_t^q$  ir  $\mathcal{X}_{t-i}^p$  kai testuoja  $\mathcal{X}_{t-i}^p \rightarrow \mathcal{X}_t^q$ . Tai galime apibrėžti kaip  $m$  priklausomumo išmatavimą

$$MCI(\mathcal{X}_{t-i}^p; \mathcal{X}_t^q) = m(\mathcal{X}_{t-i}^p; \mathcal{X}_t^q | Par(\mathcal{X}_t^q) \setminus \{\mathcal{X}_{t-i}^p\}, Par(\mathcal{X}_{t-i}^p)),$$

ir įvertinimą interpretuojamos priežastingumo stiprumo sąvokos, kai kiekybiškai įvertinamas  $\mathcal{X}_t^q$  hipotetinio  $\mathcal{X}_{t-\tau}^p$  trikdžio. Tokiu būdu MCI įvertis leidžia reitinguoti priežastinius ryšius. Taip pat metodas priklauso nuo  $\alpha$  reikšmės, kurią galime parinkti naudodami Akaike informacijos kriterijų ar kryžminį patvirtinimą. Šio metodo skaičiavimo laikas yra polinominis laiko eilučių skaičiaus  $d$  ir didžiausio vėlavimo  $\tau_{max}$  atžvilgiu [18].

### 1.2.3. Triukšmu grįsti metodai

Triukšmu grįsti metodai apima funkcinius priežastinius modelius (angl. *Functional Causal Models*), sutrumpintai FCM, dar kitaip vadinamus struktūrinių lygčių modeliais. Šiais atvejais priežastiniai ryšiai yra aprašomi lygčių rinkiniais, kur kiekviena lygtis paaiškina vieną vieno kintamojo ryšį ir su juo susijusį triukšmą. Pavyzdžiui,  $X^p$  yra priežastis  $X^q$ , kai egzistuoja funkcija  $f_q$ , kuri sieja  $X^p$  su  $X^q$  su papildomu triukšmu  $\xi^q$ :  $X^q = f_q(X^p, \xi^q)$ . Ilga laiką manyta, kad statistinis triukšmas paslepia priežastinius ryšius, tačiau paskutiniu metu atrasta, kad triukšmas gal padėti rasti priežastinius ryšius [18].

Tai galima paaiškinti šiuo pavyzdžiu: tarkime, turime du atsitiktinius kintamuosius  $X^p$  ir  $X^q$ , kurie susieti ryšiu  $X^q = 2X^p + \xi^q$ ,  $\xi^q$  - reprezentuoja triukšmą. Turint pakankamai informacijos, galima identifikuoti ryšį tarp  $X^p$  ir  $X^q$ . Neturint informacijos, negalime pasakyti ar  $X^p \rightarrow X^q$ , ar  $X^p \leftarrow X^q$ , nes ryšiai gali būti apibrėžti vienu iš modelių:  $X^q = 2X^p + \xi^q$  ar  $X^p = X^q/2 + \xi^q$ . Jei darome prielaidą, kad triukšmas vienodai pasiskirstęs  $\{-1, 0, 1\}$ , tai galima pasirinkti tarp dviejų modelių, apskaičiuodami paklaidas  $\xi^q = X^q - 2X^p$  ir  $\xi^p = X^p - X^q/2$ .

**3 lentelė.** Triukšmo panaudojimas priežastingumui nustatyti. Pirmi du stulpeliai – stebėjimų rezultatai [18]

$X^p$	$X^q$	$\xi^q = X^q - 2X^p$	$\xi^p = X^p - X^q/2$
1	2	$0 \in \{-1, 0, 1\}$	$0 \in \{-1, 0, 1\}$
3	6	$0 \in \{-1, 0, 1\}$	$0 \in \{-1, 0, 1\}$
4	9	$1 \in \{-1, 0, 1\}$	$-0,5 \notin \{-1, 0, 1\}$

Priežastingumą galime nusakyti pagal tai, kuris modelis nesutampa su triukšmo pasiskirstymo prielaida (3 lentelė). Šiuo atveju  $X^p$  yra priežastis  $X^q$  [18].

Vienas iš triukšmu grįstų metodų yra tiesinis negausinis aciklinis metodas (angl. *Linear Non-Gaussian Acyclic Model*), sutrumpintai LiNGAM. Šis metodas randa unikalias priežastingumo struktūras. Tačiau jis reikalauja, kad duomenys būtų tęstiniai ir tenkintų tiesiškumo, acikliškumo ir ne Gauss'o paklaidų prielaidas. LiNGAM modelį galima išreikšti dvejais kintamaisiais:

$$X^p = \xi^p,$$

$$X^q = a_{p,q}X^p + \xi^q,$$

kur  $X^p$  nepriklauso nuo  $\xi^q$ .  $\xi^p, \xi^q$  yra ne Gauss'o paklaidos.

Tam, kad rastų priežastinius ryšius, LiNGAM algoritmas pirmiausia iš  $X = AX + \xi$  gauna  $X = B \xi$ , kur  $B = (I - A)^{-1}$ . LiNGAM gauna maišymo matricos B įvertį naudodamas standartinę nepriklausomo komponento analizę. Sumaišymo matrica B naudojama matricai A apskaičiuoti. Priežastiniai ryšiai yra randami konstruojant regresijos modelį, tikrinant ar liekanos ir regresoriai yra nepriklausomi ar ne. Pirmiausia randamas regresorius, kuris labiausiai nepriklausomas nuo prognozuojamo kintamojo liekanų. Tada ta pati analizė yra atliekama ant tų pačių liekanų tam, kad būtų panaikinta identifikuotų regresorių įtaka. Tada sudaroma griežta apatinė trikampė matrica A, laikantis pirmiau nurodytų žingsnių. Ryšių  $A_{i,j}$  stiprumas įvertinamas taikant mažiausių kvadratų metodą. Norint gauti retus priežastinius modelius, galima dar labiau apkarpyti A matricą taikant Lasso regresiją [18].

Išplėstas LiNGAM metodas VarLiNGAM naudojamas priežastingumui laiko eilutėse ieškoti. VarLiNGAM modelis yra grindžiamas struktūrinių vektorių autoregresiniu modeliu:

$$\mathcal{X}_t = \sum_{i=0}^{\tau} A_i \mathcal{X}_{t-1} + e_t,$$

kur įtaka gali būti momentinė ( $\tau = 0$ ) arba vėluojanti su maksimaliu vėlavimu  $\tau_{max}$ . Šį modelį galime perrašyti į modelį be momentinio poveikio, su  $i > 0$ :

$$\mathcal{X}_t = \sum_{i=0}^{\tau} M_i \mathcal{X}_{t-1} + e_t.$$

Šis modelis yra vertinamas mažiausių kvadratų metodu, kuris yra panaudojamas prognozuojamo  $\mathcal{X}_t$  paklaidoms. Tuomet LiNGAM algoritmu analizuojamos liekanos, rasti momentiniam priežastingumo modeliui  $A_0$ . Galiausiai,  $(A_i)_{i>0}$  yra nustatomas per  $(M_i)_{i>0}$  perparametrizavimą:

$$A_i = (I - A_0)M_i \text{ visiems } i \in \{1, \dots, d\}.$$

VarLiNGAM modelis turi ir daugiau įvairių išplėtojimų, kurių šiame darbe neaptarsime [18].

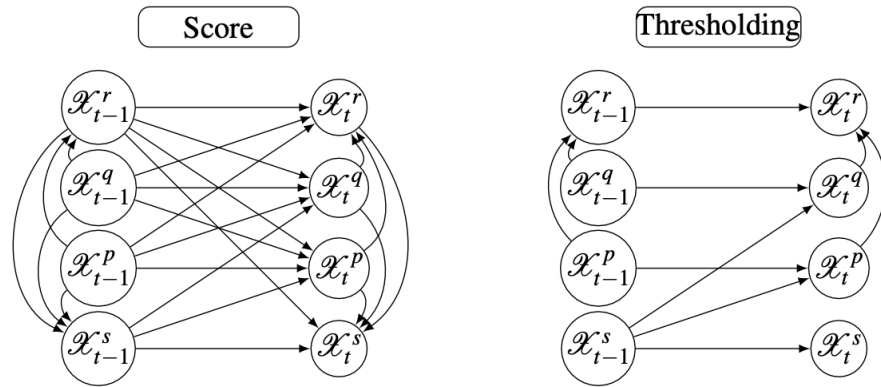
#### 1.2.4. Taškais grįsti metodai

Taškais grįstuose metoduose priežastingumo grafikas atitinka tikimybinį tinklą (arba Bajeso tinklą). Šie metodai padeda surasti retus struktūrinių lygčių modelius, kurie geriausiai paaiškina duomenis ir tai nebūtinai turi sutapti su DAG, o tai yra priešinga apribojimais grįstiems metodams. Taškais grįstų metodų užduotis yra duomenų rinkinyje rasti geriausią tinklą, kuris geriausiai juos atitinka. Geriausias tinklas yra įvertinamas įverčiu (taškais), kuris suderina duomenų tikimybę, atsižvelgiant į tinklą ir baudą, vertinant tinklo sudėtingumą. Taškais grįsti metodai yra labiau vertinami nei apribojimais grįsti metodai, nes gautą tinklą įvertina taškais. Įvertis vėliau gali būti naudojamas tinklo validumui patvirtinti. Tačiau gautas sprendimas vis tiek nėra optimalus, rasti globaliai optimalų tinklą yra pakankamai sudėtinga [18].

Vienas iš naudojamų taškais grįstų metodų yra DYNOTEARS. Šis metodas vienu metu geba nustatyti momentinius ir vėluojančius ryšius tarp laiko eilučių per  $d \times d$  gretimas matricas,  $W, A_1, \dots, A_{\tau_{max}}$ , kas parodo ryšio svarbą tarp dviejų laiko eilučių su 0 vėlavimu (momentiniai ryšiai, W), 1 ( $A_1$ ), ...,  $\tau_{max}$  ( $A_{\tau_{max}}$ ). Šios matricos yra išmokstamos minimizuojant nurodytus baudžiamuosius nuostolius pagal tiesinio modelio liekanų Frobenijaus (*angl.* Frobenius) normą:

$$f(W, A) = \frac{1}{2d(T+1-\tau_{max})} \|\mathcal{X}_t - \mathcal{X}_t^T W - \mathcal{X}_{t+1:t+\tau_{max}}^T A\|_F^2 + \lambda_W \|W\|_1 + \lambda_A \|A\|_1,$$

kur  $T$  reiškia transponuota,  $\|\cdot\|_1$  reiškia  $\ell_1$  normą pagal elementus ir  $\lambda_W$  ir  $\lambda_A$  reiškia reguliavimo konstantas. Priežastingumo grafikas yra sudaromas peržiūrint visus ryšius skirtinguose vėlavimuose. Tam, kad būtų išvengta cikliškumo, momentinei gretimybių matricai  $W$  taikomas acikliškumo apribojimas. Tai yra padaroma panaudojant lygiavertę formuluotę, pagrįstą eksponentinės funkcijos pėdsaku (7 pav.). Tada, pirmiausia naudojant taškus, atrenkamas geriausio reto lango DAG. Atitinkamas slenkstis yra naudojamas atsikratyti netikrų koreliacijų [18].



7 pav. Praktinis pavyzdys: deimanto struktūra išgaunama naudojant DYNOTEARS [18]

### 1.2.5. Apibendrinimas

Apžvelgėme Granger priežastingumo vertinimą, atitinkamus apribojimus, triukšmais ir taškais grįstus metodus ir jų pavyzdžius. Kiekvienas jų turi pranašumų ir trūkumų. Peržvelgtus metodus galime apibendrinti šia lentele:

**4 lentelė.** Peržvelgtų priežastingumo metodų savybės. S – apibendrintas priežastingumo grafikas; W- lango priežastingumo grafikas; F – ištikimybė; M – minimalumas, × - savybė netenkinama; V - savybė tenkinama [18].

Metodų grupė	Metodas	Priežastingumo grafas	Ištikimybė/minimalumas	Priežastinis Markovo sąlygotumas	Momentiniai ryšiai	Vėlinimas > 1	Savaiminis priežastingumas	Klaidinantys veiksniai	Momentiniai paslėpti klaidinantys veiksniai	Uždelsti paslėpti klaidinantys veiksniai	Modeliu grįsti	Linijiniai	< 5 hyper - parametrai
Granger	Porinis Granger	S			×	V	×	×	×	×	V	V	V
	TCDF	W			V	V	V	V	V	×	V	×	×
Apribojimais grįsti	PCMCi	W	F	V	×	V	V	V	×	×	×	×	V
Triukšmu grįsti	VarLiNGA M	W	M	V	V	V	V	V	×	×	V	V	V
Taškais grįsti	DYNOTEARS	W			V	V	V	V	×	×	V	V	V

Toliau šiame darbe taikysime TCDF metodą. Kadangi yra naudojami neuroniniai tinklai, jis nereikalauja duomenų stacionarumo. Be to, jis gali rasti momentinius ryšius, savaiminį priežastingumą, klaidinantį veiksnį ir momentinį paslėptą klaidinantį veiksnį. Taip pat rastus ryšius patikrinsime poriniu Granger metodu tam, kad nustatytume ar ryšiai yra tiesiniai ir vėlinimai sutampa.



## 2. Tyrimo objektas ir metodai

### 2.1. Matematiniai metodai

Šioje darbo dalyje detaliau peržvelgsime matematinius metodus, kuriuos naudosime šiame darbe. Tyrimė naudosime Granger porinį priežastingumo metodą ir laiko priežastinių ryšių nustatymo metodą.

#### 2.1.1. Granger porinis priežastingumas

Granger porinį priežastingumą trumpai jau pristatėme literatūros apžvalgoje. Tam, kad būtų galima panaudoti standartinį porinį Granger priežastingumą, reikia, kad duomenys būtų stacionarūs. Granger porinį priežastingumą galime išreikšti šia formule:

$$X_t^q = a_{q,0} + \sum_{i=1}^{\tau} a_{q,i} X_{t-i}^q + \xi_t^q. \text{ (Mres)}$$

Papildyta versija būtų:

$$X_t^q = a_{q,0} + \sum_{i=1}^{\tau} a_{q,i} X_{t-i}^q + \sum_{i=1}^{\tau} a_{p,i} X_{t-i}^p + \xi_t^q, \text{ (Mfull)}$$

kur  $(\xi_t^q)_i$  yra nekoreliuojantys atsitiktiniai kintamieji su vidurkiu ir standartiniu nuokrypiu  $\sigma^2$  lygiu 0,  $(a_{q,i})_{1 \leq i \leq \tau}$  ir  $(a_{p,i})_{1 \leq i \leq \tau}$  yra tikrieji koeficientai ir  $\tau$  atitinka optimalią vėlavimo vertę. Mres modelis yra autoregresinis modelis ir dar kitaip vadinamas ribotu modeliu. Šis modelis naudoja tik  $X^q$  praeities vertes prognozuoti dabartines vertes. Mfull yra papildytas ir vadinamasis pilnasis modelis. Šiame modelyje naudojamos tiek  $X^q$ , tiek  $X^p$  vertės prognozuoti dabartines  $X^q$  vertes. Pilnasis modelis paprastai veikia geriau nei ribotas. Modeliams palyginti gali būti panaudota F – testo statistika. Paprastai yra sudaroma nulinė hipotezė, kad  $X^p$  nesukelia  $X^q$ . Praktikoje optimalus vėlavimas  $\tau$  gali būti vertinamas naudojant Akaike arba Schwartz informacijos kriterijus [18].

```
statsmodels.tsa.stattools.grangercausalitytests(  
    x,  
    maxlag,  
    addconst=True,  
    verbose=None  
)
```

**8 pav.** „grangercausalitytests“ funkcijos antraštė iš „statsmodels“ bibliotekos [21]

Šiame darbe naudosime Python „grangercausalitytests“ funkciją iš „statsmodels“ bibliotekos (pav. 8) Granger poriniam priežastingumui nustatyti. Funkcijai reikia paduoti norimas laiko eilutes X ir vėlinimų skaičių „maxlag“ [21].


#### 2.1.2. Laiko priežastinių ryšių nustatymo metodas

Detaliau peržvelkime laiko priežastinių ryšių nustatymo metodą: TCN įtaką ir dėmesio mechanizmus. Metodo programinį kodą galima rasti [17].

## TCDF

Laiko priežastinių ryšių nustatymo metodas (angl. *Temporal Causal Discovery Framework*) sudarytas iš kelių sąsūkų neuroninių tinklų (CNNs), kur kiekvienas tinklas gauna visas laiko eilutes kaip įvestį. Kiekvienas tinklas yra naudojamas skirtingoms laiko eilutėms prognozuoti. Tuo metu CNN atlieka prižiūrimą prognozavimą, apmokydamas visus vidinius parametrus atgalinio sklidimo (angl. *backpropagation*) pagalba. Šiuos vidinius parametrus galime panaudoti neprižiūrimam mokymuisi, priežastingumui ir vėlinimui atrasti. Kitaip sakant, laiko priežastinių ryšių nustatymo metodas pritaiko dėmesio mechanizmus (angl. *attention mechanisms*) suprasti kokias laiko eilutes CNN naudoja prognozavimui. Po dėmesiu grįstų CNNs apmokymų, TCDF patvirtina ar rasti priežastiniai ryšiai yra tikrai susiję su naudojamomis laiko eilutėmis. Tada visi patvirtinti priežastiniai ryšiai yra pavaizduojami laikinojo priežastingumo grafe. TCDF taip pat nustato vėlavimą tarp priežasties ir efekto, tai atlieka CNN interpretuodamas vidinius parametrus [17].

Laikinąjį priežastingumo atradimą, naudodami stebėjimų duomenis, galime paaiškinti taip. Duotas duomenų rinkinys  $X$ , kuris turi  $N$  tos pačios trukmės  $T$  laiko eilučių (tai yra  $X = \{X_1, X_2, \dots, X_N\} \in \mathbb{R}^{N \times T}$ ). Tikslas yra surasti priežastinius ryšius tarp  $N$  laiko eilučių  $X$  duomenų rinkinyje, priežasties ir pasekmės vėlavimą ir atvaizduoti abu grafe. Kryptingame priežastingumo grafe,  $\mathcal{G} = (V, E)$ , viršūnė  $v_i \in V$  vaizduoja laiko eilutę  $X_i$ , ir kraštai  $e_{i,j} \in E$  iš viršūnės  $v_i$  į  $v_j$  nurodo priežastinius ryšius, kurios priežastis yra laiko eilutė  $X_i$ , o pasekmė - laiko eilutė  $X_j$ . Laikinojo priežastingumo grafe kiekvienas kraštas  $e_{i,j}$  turi svorius  $d(e_{i,j})$ , kurie nurodo vėlavimą tarp priežasties  $X_i$  ir pasekmės  $X_j$ , kaip parodyta paveikslėlyje [17].

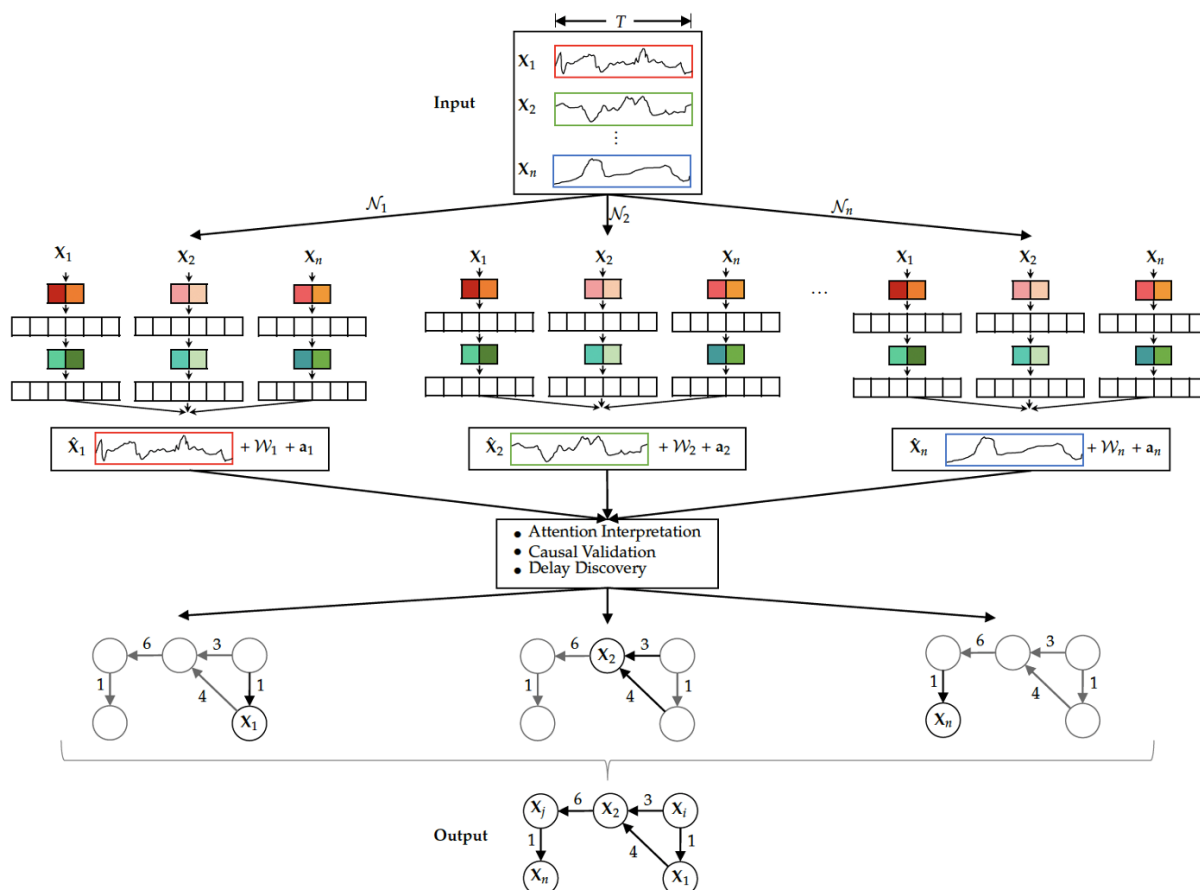


9 pav. Priežastingumo grafiko pavyzdys [17]

Tačiau kuriant sudėtingus modelius galimos šios problemos:

- Modelis turi skirti tiesioginį ir netiesioginį priežastingumą. Viršūnė  $v_i$  yra netiesioginė priežastis  $v_j$  jeigu  $e_{i,j} \notin \mathcal{G}$ , ir jeigu yra dvikraštis takas  $p = \langle v_i, v_k, v_j \rangle \in \mathcal{G}$ . Modeliai, kurie ieško ryšių tarp dviejų kintamųjų, paprastai nėra pajėgūs tai padaryti.
- Modelis turėtų išmokti ir momentinį priežastingumą, kur vėlavimas tarp priežasties ir pasekmės yra 0. Momentinio priežastingumo nepripažinimas gali lemti klaidingas interpretacijas. Praktikoje tai dažniausiai pasireiškia, kai priežastis ir pasekmė pasireiškia tuo pačiu metu.
- Klaidinančio veiksnio buvimas, bendra mažiausiai dviejų kintamųjų priežastis, yra gerai žinoma problema priežastingumo ieškojime. Klaidinantis veiksnys yra gan paplitęs reiškinys. Tai apsunkina priežastingumo nustatymą, nes klaidinantis veiksnys gali koreliuoti, bet neturėti priežastingumo.
- Klaidinančio veiksnio nepastebėjimas (paslėpti klaidinantys veiksniai). Gali būti sudėtinga nustatyti kiek klaidinančių veiksnių egzistuoja [17].

Kaip jau buvo minėta, TCDF naudoja sąsūkų neuroninius tinklus (CNNs) laiko eilutės prognozuoti. Sąsūkų neuroniniai tinklai yra „*feed-forward*“ tipo neuroniniai tinklai, sudaryti iš eilės sąsūkų sluoksnių. Sąsūkų sluoksnis apriboja jungčių skaičių tik prie kai kurių įvesties neuronų, slankiodamas branduolį (svorių matricą) per įvestį ir kiekvienu žingsniu apskaičiuodamas įvesties ir branduolio skalariinę sandaugą. Tada branduolys išmoksta specifinių pasikartojančių įvesties eilučių modelių, kad galėtų prognozuoti būsimas tikslinės laiko eilutės vertes [17].




10 pav. TCDF metodo architektūra [17]

TCDF susideda iš  $N$  nepriklausomų dėmesiu grįstų CNNs. Visi CNNs turi tą pačią architektūrą, bet prognozuoja skirtingas tikslingas laiko eilutes. Kaip pavaizduota Pav. 10, metodą sudaro dirbtinių neuroninių tinklų architektūra su kelias tinklais. Paveikslėlyje matome, kad  $N_j$  tinklo tikslas prognozuoti numatytas laiko eilutes  $X_j$ , minimizuojant nuostolį  $L$  tarp verčių  $X_j$  ir prognozuojamos vertės  $\hat{X}_j$ . Tinklo įvestį  $N_j$  sudaro  $N \times T$  duomenų rinkinys  $X$ , sudarytas iš  $N$  to pačio dydžio ir ilgio laiko eilučių  $T$ . Eilutės  $X_j$  iš duomenų rinkinio atitinka atitinkamas laiko eilutes, kitos duomenų rinkinio eilutės  $X_{-j}$  yra eksogeninės laiko eilutės. Kai tinklas  $N_j$  yra apmokytas pranašauti  $X_j$ , dėmesio balai  $a_j$  paaiškina kur  $N_j$  pranašauja  $X_j$  [17].

### TCN įtaka TCDF

Ši architektūra yra grįsta laikiniu sąsūkų tinklu (angl. *temporal convolutional network*), toliau projekte žymėsime TCN. TCN apima kelias svarbias idėjas, kaip išplėstinės sąsūkos, savaiminis priešastingumas ir dėmesio taškai. Išplėstinė sąsūka pritaiko savo branduolį prie srities, kuri yra didesnė nei pats branduolys, praleisdama įvesties vertes su tam tikru žingsnio dydžiu  $f$  (išplėtimo

faktorius). Išplėtimo faktorius didėja eksponentiškai ir priklauso nuo išplėtimo koeficiento  $c$ . Tarp išplėtimo faktoriaus ir koeficiento galime nustatyti tokį ryšį  $f = c^l$ , kur  $l$  yra sluoksnis. Tai galime iliustruoti šiuo paveikslu:



11 pav.  $X_2$  prognozavimas išplėstiniais TCN [17]

Šiame paveiksle išplėstas TCN naudojamas prognozuoti  $X_2$ .  $L = 3$ , tai reiškia, kad yra 3 paslėptieji sluoksniai. Branduolio dydis  $K = 2$  (vaizduojamas rodyklėmis). Plėtimosi koeficientas  $c = 2$ , kas reiškia, kad receptinis laukas  $R = 16$ . Po kiekvienos sąsūkos panaudojama PReLU aktyvavimo funkcija. Pirmų verčių prognozavimas pavaizduotas punktyrinėmis rodyklėmis. Svoriai veikia per visus sluoksnius ir yra pavaizduoti skirtingomis spalvomis. Receptinį lauką 1D išplėstame TCN galime aprašyti šią formulę:

$$R_{D-TCN} = 1 + \sum_{l=0}^L (K - 1) \cdot c^l$$

Tai parodo, kad yra galimas eksponentinis didėjimas receptinio lauko su išplėstinėmis sąsūkomis, kai parametrų skaičius auga tiesiškai. Tai ypač praverčia kai tarp priežasties ir pasekmės yra didelis vėlavimas [17].

Taip pat galime nustatyti savaiminį priežastingumą. Tam reikia, kad įvesties ir prognozuojamos laiko eilutės būtų vienodos, kas padeda modeliuoti pasikartojantį elgesį. Dėl šių priežasčių turime šiek tiek pakeisti architektūrą. Į įvestį neturėtume įtraukti dabartinės tikslinės laiko eilutės vertės. Su  $K$  dydžio slankiojančiu branduoliu, kai įvestis yra egzogeninė laiko eilutė, galime pasiekti  $[X_i^{t-K+1}, X_i^{t-K+2}, \dots, X_i^{t-1}, X_i^t]$ , kai  $i \neq j$  ir pranašauti  $X_j^t$  laiko žingsniui  $t$ . Tačiau branduolys turi pasiekti tik tikslinės laiko eilutės  $X_j$  praeities vertes ir neįtraukti dabarties  $X_j^t$ , kadangi ši vertė bus prognozuojama. TCDF tai išsprendžia tikslinių įvesties duomenų perkėlimu vienu žingsniu į priekį su kairiuoju nuliniu užpildymu taip, kad tikslinė įvesties laiko eilutė duomenų rinkinyje yra lygi  $[0, X_j^1, X_j^2, \dots, X_j^{T-1}]$  ir tokiu būdu branduolys gali pasiekti  $[X_j^{t-K}, X_j^{t-K+1}, \dots, X_j^{t-2}, X_j^{t-1}]$  tam, kad būtų galima prognozuoti  $X_j^t$  [17].

TCN architektūros ribotumas yra tai, kad ji yra pritaikyta vienmačiam laiko eilučių modeliavimui. Tam, kad galėtume pritaikyti daugiamačiam laiko eilučių modeliavimui, TCN architektūrą išplečiame iki vienmatės giluminės atskiriamos architektūros, kurioje įvesties laiko eilutės yra atskirtos. Giluminėje sąsūkoje įvesties kanalai yra atskirti taikant atskirą branduolį kiekvienam įvesties kanalui, tada taikoma  $1 \times 1$  taškinė sąsūka, kuri sujungia gautus išvesties kanalus. Šie architektūros pokyčiai padidina tikslumą ir konvergavimo greitį. Atskiri kanalai taip pat leidžia teisingai interpretuoti įvesties laiko eilučių ir tikslinės laiko eilutės ryšį nesumaišant įėjimų. Taip pat TCDF architektūra yra sudaryta iš  $N$  kanalų, kiekvienas kanalas yra skirtas atskirai laiko eilutei. Tinkle  $N_j$  kanalas  $j$  susijęs su tikslinę laiko eilute  $\mathcal{X}_j = [0, \mathcal{X}_j^1, \mathcal{X}_j^2, \dots, \mathcal{X}_j^{T-1}]$  ir visi kiti kanalai yra susiję su egzogeninėmis laiko eilutėmis  $\mathcal{X}_{i \neq j} = [\mathcal{X}_i^1, \mathcal{X}_i^2, \dots, \mathcal{X}_i^{T-1}, \mathcal{X}_i^T]$  [17].

### *Dėmesio mechanizmai*

Toliau TCDF yra patobulinamas pridendant dėmesio mechanizmus. Dėmesio mechanizmai padeda suprasti kada tinklas prognozuoja. Kitaip tai yra vadinami dėmesiu grįsti išplėstiniai giluminiai atskiriamieji laikinieji sąsūkų tinklai (angl. *Attention-based Dilated Depthwise Separable Temporal Convolutional Networks, AD-DSTCN*). Dėmesio mechanizmą TCDF metode galime aprašyti šia formule:

$$a = a_{i,j} \times \mathcal{X}_i,$$

kur  $\mathcal{X}_i$  yra laiko eilutė tinkle  $N_j$ , kur  $a_{i,j} \in a_j$ , o  $a_j = [a_{1,j}, a_{2,j}, \dots, a_{j,j}, \dots, a_{N,j}]$  yra dėmesio taškų vektorius tinkle  $N_j$ . Aukšta  $a_{i,j} \in a_j$  vertė reiškia, kad  $\mathcal{X}_i \rightarrow \mathcal{X}_j$  ir atvirkščiai, maža vertė rodyt, kad nėra priežastingumo. Taip pat galima situacija kai  $i=j$ , kadangi yra galimas savaiminis priežastingumas. Dėmesio taškai vėliau yra panaudojami nustatyti, kurios laiko eilutės sukelia prognozuojamas laiko eilutes [17].

Panagrinėkime kiek giliau kaip TCDF interpretuoja dėmesio taškus. Kai tinklas pradeda apsimokymą, visi dėmesio taškai yra lygūs 1,  $a_j = [1, 1, \dots, 1]$ . Dėmesio taškai yra pakeičiami tinklui vykdant atgalinę sklaidą. Taškai yra padidinami arba sumažinami po kiekvienos epochos. Galimas tiek minkštas, tiek kietas dėmesys. Minkštą galime išreikšti  $a_j \in [0, 1]^N$ , o kietą  $a_j \in \{0, 1\}^N$ . Minkštas dėmesys yra realizuojamas pritaikant Softmax funkciją  $\sigma$  taip, kad dėmesio taškai būtų  $\sum_{i=1}^N a_{i,j} = 1$ . Softmax funkcija  $\sigma$  yra pritaikoma kiekvienai  $a \in a_j$  kiekvienoje epochoje. Tinklui  $N_j$  apsimokius, taikoma paprasta pusiau binarizacijos funkcija HardSoftmax, kuri visus dėmesio taškus mažesnius už ribą  $\tau_j$  sutrumpina iki 0:

$$h = \text{HardSoftmax}(a) = \begin{cases} \sigma(a) & \text{if } a \geq \tau_j \\ 0 & \text{if } a < \tau_j \end{cases}$$

$h_j$  nustato dėmesio taškus  $a_j$ , kai HardSoftmax funkcija yra pritaikoma. TCDF sukuria aibę galimų priežasčių  $P_j$  kiekvienai laiko eilutei  $\mathcal{X}_j \in X$ . Laiko eilutė  $\mathcal{X}_i$  yra galima priežastis tikslinės laiko eilutės  $\mathcal{X}_j$ , jeigu  $h_{i,j} \in h_j > 0$ . Algoritmas randa  $\tau_j$ , ieškodamas didžiausio atotrūkio tarp dėmesio taškų  $a_j$ . Dėmesio taškai yra išreitinguojami nuo didžiausio iki mažiausio, tada randamas didžiausias atotrūkis  $g$  tarp dėmesio taškų  $a_{i,j}$  ir  $a_{k \neq i,j}$ . Tada slenkstis  $\tau_j$  yra lygus dėmesio taškams kairėje atotrūkio pusėje. Galima sudaryti  $G$  sąrašą atotrūkių  $[g_0, \dots, g_{N-1}]$  [17].

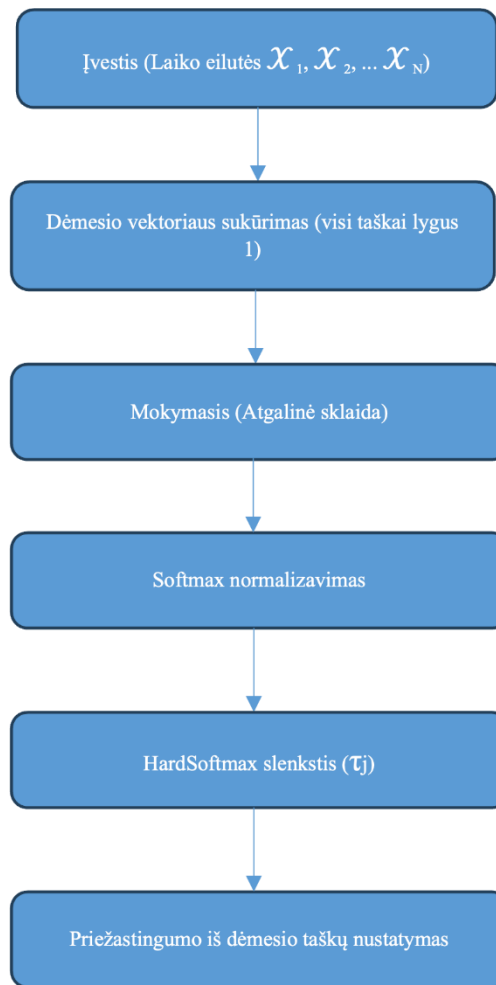
Slenksčiui  $\tau_j$  rasti yra keletas reikalavimų:

- $\tau_j > 1$ , kadangi visi taškai inicijuojami lygūs 1, tai dėmesio taškai tik didės taikant atgalinį sklidimą.
- Atrinktas  $\tau_j$  turi būti pirmoje G sąrašo pusėje (jeigu  $N > 5$ ), siekiant užtikrinti, kad nebūtų įtraukti labai maži dėmesio taškai ir išlaikyti priežastingumo grafo aiškia formą. Taip pat tik 50% įvesties laiko eilučių gali būti potencialios priežastys tikslinės laiko eilutės  $\mathcal{X}_j$ . Šis parametras gali būti konfigūruojamas.
- $\tau_j$  negali būti pirmas atotrūkis. Tai užtikrina, kad algoritmas nesumažintų taškų iki 0 laiko eilutei, kuri yra priežastis prognozuojamos laiko eilutės, bet priežastingumas yra silpnėsnis nei aukščiausią įvertinimą turinčios laiko eilutės. Dėl to galimos priežastys  $P_j$  mažiausiai turės dvi priežastis [17].

Kai  $\tau_j$  yra rasta, pritaikome HardSoftmax funkciją. Laiko eilutė  $\mathcal{X}_i$  yra nustatoma kaip potenciali priežastis  $P_j$  jeigu  $a_{i,j} \in a_j > \tau_j$ , ir jeigu  $h_{i,j} \in h_j > 0$ . Galimi tokie atvejai  $h_{i,j}$  ir  $h_{j,i}$ :

1.  $h_{i,j} = 0$  ir  $h_{j,i} = 0$ :  $\mathcal{X}_i$  nekoreliuoja su  $\mathcal{X}_j$  ir atvirkščiai.
2.  $h_{i,j} = 0$  ir  $h_{j,i} > 0$ :  $\mathcal{X}_j$  pridedama prie  $P_i$ ,  $\mathcal{X}_j$  yra galima priežastis  $\mathcal{X}_i$ , nes:
  - Egzistuoja tiesioginis ar netiesioginis priežastinis ryšys tarp  $\mathcal{X}_j$  ir  $\mathcal{X}_i$ , arba
  - Egzistuoja paslėptas arba ne klaidinantis veiksnys tarp  $\mathcal{X}_j$  ir  $\mathcal{X}_i$ , kur vėlavimas klaidinančio veiksnio nuo  $\mathcal{X}_j$  yra mažesnis nei nuo  $\mathcal{X}_i$ .
3.  $h_{i,j} > 0$  ir  $h_{j,i} = 0$ :  $\mathcal{X}_j$  pridedama prie  $P_j$ ,  $\mathcal{X}_i$  yra galima priežastis  $\mathcal{X}_j$ , nes:
  - Egzistuoja tiesioginis ar netiesioginis priežastinis ryšys tarp  $\mathcal{X}_i$  ir  $\mathcal{X}_j$ , arba
  - Egzistuoja paslėptas arba ne klaidinantis veiksnys tarp  $\mathcal{X}_i$  ir  $\mathcal{X}_j$ , kur vėlavimas klaidinančio veiksnio nuo  $\mathcal{X}_i$  yra mažesnis nei nuo  $\mathcal{X}_j$ .
4.  $h_{i,j} > 0$  ir  $h_{j,i} > 0$ :  $\mathcal{X}_i$  pridedama prie  $P_j$ ,  $\mathcal{X}_j$  pridedama prie  $P_i$ , nes
  - Egzistuoja dvigubas ciklas, kur  $\mathcal{X}_i$  sukelia  $\mathcal{X}_j$  ir  $\mathcal{X}_j$  sukelia  $\mathcal{X}_i$ , arba
  - Egzistuoja paslėptas arba ne klaidinantis veiksnys tarp  $\mathcal{X}_j$  ir  $\mathcal{X}_i$ , su vienodu vėlavimu.

Taip pat turime nepamiršti, kad HardSoftmax  $> 0$ , gali būti dėl retos koreliacijos. Galiausiai reikalinga eksperto nuomonė priežastingumui paaiškinti. Dėmesio mechanizmų veikimą galime iliustruoti žemiau pateikta diagrama [17].



**12 pav.** Prižastingumo iš dėmesio taškų nustatymas [17]

### *Priežasčių radimas*

Tam, kad surastume galimas priežastis, TCDF apmoko tinklą  $N_j$ , naudodamas įvesties duomenų rinkinį ir matuodamas pagrindo nuostolį  $L_G$ . Priežastims patvirtinti yra sukuriamas intervencinis duomenų rinkinys kiekvienai galimai priežasčiai  $X_i \in P_j$  [17]. Tai panašu į Kim 2019 m. straipsnyje minimus „slopinamuosius“ kintamuosius, kur papildomas kintamasis sustiprina regresinį ryšį tarp kintamųjų [22]. Rinkinys skiriasi nuo originalaus įvesties rinkinio tik tuo, kad  $X_i \in P_j$  galimos priežasties vertės yra atsitiktinai perrenkamos. Kadangi perrinkimas nepakeičia duomenų rinkinio pasiskirstymo, tinklo  $N_j$  nereikia apmokyti. TCDF tiesiog panaudoja intervencinį duomenų rinkinį su apmokytu tinklu  $N_j$   $X_j$  prognozavimui ir išmatuoja intervencijos nuostolį  $L_I$ . Jeigu galima priežastis  $X_i$  yra tikroji priežastis,  $X_j$  prognozavimo rezultatai su intervenciniu rinkiniu bus prastesni, nes  $X_i$  chronologija yra panaikinta. Dėl šios priežasties intervencijos nuostolis  $L_I$  tinkle bus didesnis nei pagrindo nuostolis  $L_G$ , kur yra naudojamas originalus duomenų rinkinys. Jeigu  $L_I$  nėra reikšmingai didesnis nei  $L_G$ , tai  $X_i$  nėra priežastis  $X_j$ . Tiksliai laiko eilutės  $P_j$  yra laikomos tikrosiomis priežastimis prognozuojamų laiko eilučių  $X_j$ . Tikrųjų priežasčių aibė yra žymima  $C_j$  [17].

## 2.2. Šalių pasirinkimas pagal socialinės (valstybės) gerovės modelius

Europos Sąjunga vienija labai skirtingas šalis su skirtingomis kapitalistinėmis sistemomis ir skirtingais gerovės modeliais. Socialinės (valstybės) gerovės modeliai yra gan svarbūs nustatant šalies socialinį, politinį ir ekonominį vystymąsi. Šalyje vykdomos reformos dažniausiai priklauso nuo šalies gerovės modelio. Europos Sąjunga dažniausiai yra skirstoma pagal šiuos modelius: šiaurietišką (angl. *Nordic*), anglosaksų (angl. *Anglo-Saxon*), žemyninį (angl. *Continental*), pietinį/Viduržemio (angl. *Southern/Mediterranean*) ir centro ir rytų Europos (angl. *Central and East European*) (žiūr. 5 lentelė) [23].

**5 lentelė.** Šalys pagal socialinės (valstybės) gerovės modelius [23]

Modelis	Šalys
Šiaurietiškas	Danija, Švedija ir Suomija.
Anglosaksų	Airija, Kipras ir Malta.
Žemyninis	Austrija, Belgija, Liuksemburgas, Prancūzija, Vokietija ir Nyderlandai
Pietinis/Viduržemio	Graikija, Italija, Portugalija ir Ispanija.
Centro ir rytų Europos	Bulgarija, Kroatija, Čekija, Estija, Latvija, Lietuva, Vengrija, Lenkija, Rumunija, Slovakija ir Slovėnija.

Šiaurietiškam modeliui priklauso Danija, Švedija ir Suomija [23]. Šiaurietiškas modelis pasižymi socialine lygybe ir dideliu makroekonominiu efektyvumu, taip pat turto persikirstymu. Visuomenė yra įtraukta į valstybės valdymą. Socialinės paslaugos yra garantuojamos valstybės visoms piliečių grupėms. Nuolatos vyksta dialogas tarp visuomenės ir valstybės [24].

Anglosaksų modeliui priklauso Airija, Kipras ir Malta [18]. Anglosaksų modelis pasižymi liberaliu požiūriu į socialinę gerovę. Socialinės paslaugos yra perduotos privačioms draudimo įmonėms. Valstybė mažai reguliuoja piliečių gyvenimą. Nedarbą siekiama eliminuoti mažomis nedarbo išmokomis. Kita vertus, taikomi mažesni pajamų mokesčiai. Dėl to šios šalys pasižymi mažu nedarbu [24].

Žemyniniam modeliui priklauso Austrija, Belgija, Liuksemburgas, Prancūzija, Vokietija ir Nyderlandai [23]. Šio modelio šalyse piliečių socialinė gerovė priklauso nuo darbo santykių trukmės. Socialinės garantijos paprastai yra mažesnės ir priklauso nuo prieš tai buvusių pajamų. Valstybė pakankamai stipriai reguliuoja darbo rinką, kas riboja darbuotojų lankstumą. Šios šalys pasižymi aukštais mokesčiais ir mažesne nelygybe lyginant su anglosaksų modeliu [24].

Pietiniam/Viduržemio modeliui priklauso Graikija, Italija, Portugalija ir Ispanija [23]. Šio modelio šalyse valstybė suteikia minimalias socialines garantijas ir tai tik kai kurioms visuomenės grupėms. Darbo rinka yra kontroliuojama valstybės ir pakankamai fragmentuota. Šeima šiose šalyse perima nemažai valstybės funkcijų. Kadangi darbo rinka yra stipriai reguliuojama, tai šios šalys pasižymi ilgalaikiu jaunimo nedarbu [24].

Centro ir rytų Europos modeliui priklauso Bulgarija, Kroatija, Čekija, Estija, Latvija, Lietuva, Vengrija, Lenkija, Rumunija, Slovakija ir Slovėnija [23]. Šis modelis dar vadinamas „besivejančiu“ ir vienija šalis, kurios persiorientavo nuo planinės ekonomikos į rinkos ekonomiką. Šalys šiame modelyje gan skiriasi. Vengrija ir Slovėnija pasirinko didesnes išlaidas socialinei rūpybai, kai



Baltijos šalys pasirinko atvirkščiai. Tačiau šių šalių darbo rinkos yra pakankamai reguliuotos ir pasižymi menku socialiniu dialogu [24].

Šioje dalyje peržvelgėme socialinės (valstybės) gerovės modelius Europos Sąjungoje. Atlikti mūsų tyrimą kiekvienai šaliai gali būti gan sudėtingas uždavinys. Tai darbui reikalingas šalis atsirinksimė pagal socialinės (valstybės) gerovės modelius. Pasirinksimė po viena šalį iš kiekvienos socialinės (valstybės) gerovės modelių grupės. Tai šiame darbe naudosimė šias šalis: Lietuva, Vokietija, Danija, Airija ir Ispanija. Šalys pasirinktos atsitiktinai.

### 2.3. Tyrimo objektas

Šioje darbo dalyje apžvelgsimė naudojamą duomenų rinkinį. Kadangi atlikti analizę kiekvienai ES šaliai gali būti gan nemažas uždavinys, tai paimsimė po vieną šalį iš kiekvienos socialinės (valstybės) gerovės grupės. Tai bus Lietuva, Vokietija, Danija, Airija ir Ispanija. Vokietijai, Danijai, Airijai ir Ispanijai imsime laikotarpį nuo 1986 iki 2022 metų ir ieškosimė priežastinių ryšių iki 2004 metų ir po, jiems palyginti. 2004 metais ES pradėjo vieningą politiką. Lietuvos duomenis naudosimė nuo 2004 metų iki 2022. Šiame darbe naudojame duomenis iš Pasaulio banko, Eurostat, „*The Global Economy*“ ir „*Our World in Data*“.

**Pasaulio bankas** – (angl. *World bank*) teikia atvirų duomenų platformą, kur galima rasti atvirą prieigą prie šalių vystymosi duomenų. Platforma teikia ne tik galimybę duomenis parsisiųsti, bet ir juos vizualizuoti. Pasaulio bankas taip pat bendradarbiauja su Jungtinių tautų organizacija, Tarptautiniu valiutos fondu ir Ekonominio bendradarbiavimo ir plėtros organizacija.


**Eurostat** – Europos Sąjungos agentūra, renkanti statistinius duomenis apie šalis nares.

„*The Global Economy*“ - renka ir teikia duomenis apie 300 įvairių rodiklių. Duomenys yra nuolatos atnaujinami. Duomenys yra gaunami iš Pasaulio banko, Tarptautinio valiutos fondo, Jungtinių tautų organizacijos ir Pasaulio ekonomikos forumo. Norint parsisiųsti duomenis reikia sumokėti vienkartinį mokestį.

„**Our World in Data**“ – organizacija teikianti duomenis ir tyrimus didžiausioms pasaulio problemoms tirti. Platformoje pateikiamos įvairios indikatorių vizualizacijos ir yra galimybė duomenis parsisiųsti. Duomenys yra teikiami nemokamai.

#### 2.3.1. Investicijų Lietuvoje istoriniai duomenys

Trumpai susipažinkimė su Lietuvos duomenimis nuo 2004 iki 2022 metų. Pirmiausia panagrinėkimė įtekančias užsienio tiesiogines investicijas (% BVP).




**13 pav.** Užsienio įtekančios tiesioginės investicijos procentais BVP Lietuvoje (2004-2022 m.)

Kaip matome, grafikas gan dinamiškas. Mažiausia vertė 2009 metais – 0,96%, didžiausia vertė 7,91% 2020 metais. Vėlesniais metais užsienio tiesioginės investicijos mažėja. Tiesioginių užsienio investicijų vidurkis yra 3,52%. 2009 metų tiesioginių užsienio investicijų sumažėjimą galime paaiškinti pasauline ekonomine krize, o 2021-2022 metais - Covid pandemija.

### 2.3.2. Investicijų Vokietijoje istoriniai duomenys

Kadangi lyginsime du laikotarpius, 1986-2003 m. ir 2004-2022 m., pasižiūrėkime kaip tiesioginės užsienio investicijos kito šiais laikotarpiais.

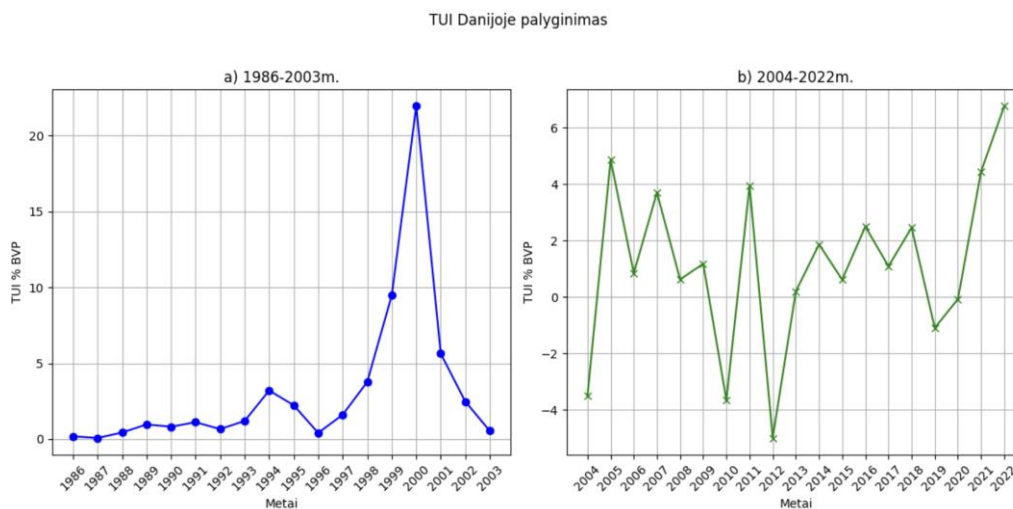


**14 pav.** Užsienio įtekančios tiesioginės investicijos % BVP Vokietijoje palyginimas

Žvelgdami į 1986-2003 (pav. 14a) metų laikotarpį matome, kad tiesioginės užsienio investicijos ypač didėjo nuo 1993 iki 2000 metų. Mažiausios užsienio investicijos -0,11% 1988 metais, didžiausios 12,73% 2000 metais. Šiuo laikotarpiu vidutinės užsienio tiesioginės investicijos buvo 1,61%. Kaip matome 2004-2022 metų (pav. 14b) grafikas yra žymiai dinamiškesnis. Mažiausios užsienio tiesioginės investicijos -0,73% 2004 metais, didžiausios tiesioginės užsienio investicijos 4,19% 2018 metais. Vidutinės užsienio tiesioginės investicijos šiuo laikotarpiu yra 1,99%.

### 2.3.3. Investicijų Danijoje istoriniai duomenys

Kadangi lyginsime du laikotarpius, 1986-2003 m. ir 2004-2022 m., pasižiūrėkime kaip tiesioginės užsienio investicijos kito šiais laikotarpiais.




**15 pav.** Užsienio įtekančios tiesioginės investicijos % BVP Danijoje palyginimas

Žvelgdami į 1986-2003 (pav. 15a) metų laikotarpį matome, kad tiesioginės užsienio investicijos ypač didėjo nuo 1996 iki 2000 metų. Grafikas labai panašus į Vokietijos grafiką tuo pačiu periodu. Mažiausios užsienio investicijos 0,08% 1987 metais, didžiausios - 21,94% 2000 metais. Šiuo laikotarpiu vidutinės užsienio tiesioginės investicijos buvo 3,15%. Kaip matome 2004-2022 metų (pav. 15b) grafikas yra žymiai dinamiškesnis. Mažiausios užsienio tiesioginės investicijos yra 4,99% 2012 metais, didžiausios tiesioginės užsienio investicijos 2022 metais: 6,76%. Vidutinės užsienio tiesioginės investicijos šiuo laikotarpiu yra 1,14%.

### 2.3.4. Investicijų Arijoje istoriniai duomenys

Žvelgdami į 1986-2003 metų laikotarpį (pav. 16a), matome, kad tiesioginės užsienio investicijos ypač didėjo nuo 1997 iki 2000 metų. Mažiausios užsienio investicijos 0,49% 1989 metais, didžiausios - 25,73% 2000 metais. Šiuo laikotarpiu vidutinės užsienio tiesioginės investicijos buvo 6,70%.

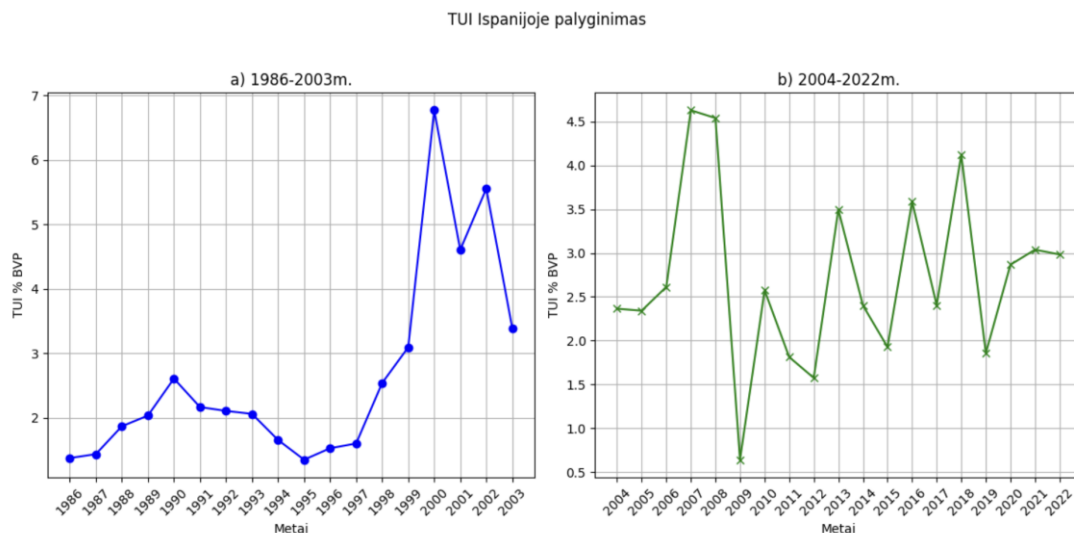


**16 pav.** Užsienio įtekančios tiesioginės investicijos % BVP Airijoje palyginimas

Kaip matome, 2004-2022 metų (pav. 16b) grafikas yra žymiai dinamiškesnis. Mažiausios užsienio tiesioginės investicijos - 2019 metais: -11,69%, didžiausios tiesioginės užsienio investicijos - 81,08% 2018 metais. Vidutinės užsienio tiesioginės investicijos šiuo laikotarpiu yra 19,21%.

### 2.3.5. Investicijų Ispanijoje istoriniai duomenys

Žvelgdami į 1986-2003 (pav. 17a) metų laikotarpį matome, kad tiesioginės užsienio investicijos ypač didėjo nuo 1993 iki 2000 metų. Mažiausios užsienio investicijos - 1,35% 1995 metais, didžiausios - 6,77% 2000 metais. Šiuo laikotarpiu vidutinės užsienio tiesioginės investicijos buvo 2,65%.



**17 pav.** Užsienio įtekančios tiesioginės investicijos % BVP Ispanijoje palyginimas


Kaip matome, 2004-2022 metų (pav. 17b) grafikas yra žymiai dinamiškesnis. Mažiausios užsienio tiesioginės investicijos - 0,64% 2009 metais, didžiausios tiesioginės užsienio investicijos - 4,63% 2007 metais. Vidutinės užsienio tiesioginės investicijos šiuo laikotarpiu yra 2,72%.

### 3. Rezultatai

Granger ir laiko priežastinių ryšių nustatymo metodai buvo panaudoti analizuojant Lietuvos, Vokietijos, Danijos, Airijos ir Ispanijos duomenis. Geriausi rezultatai buvo gauti laiko priežastinių ryšių metodu, naudojant šiuos parametrus: optimizatorius – „Adam,“ mokymosi greitis - 0,01, priežastiniams ryšiams ieškoti naudojome 1000 epochų, jiems patvirtinti – 500 epochų. Su didesniu ar mažesniu skaičiumi epochų, reikalingų priežastiniams ryšiams atrasti ir patvirtinti, ir didesniu ar mažesniu mokymosi greičiu, gauti geresnių rezultatų nepavyko.


#### 3.1. Priežastinių ryšių paieška Lietuvos atveju

Atliekant literatūros apžvalgą įvardinti 40 rodiklių, darančių įtaką tiesioginėms užsienio investicijoms. Pašalinome šiuos rodiklius dėl duomenų trūkumo: ENERGI\_IŠKAST, AUKŠT\_IŠS, VID\_IŠS ir GEL\_K.



18 pav. Lietuvos rodiklių koreliacijų matrica

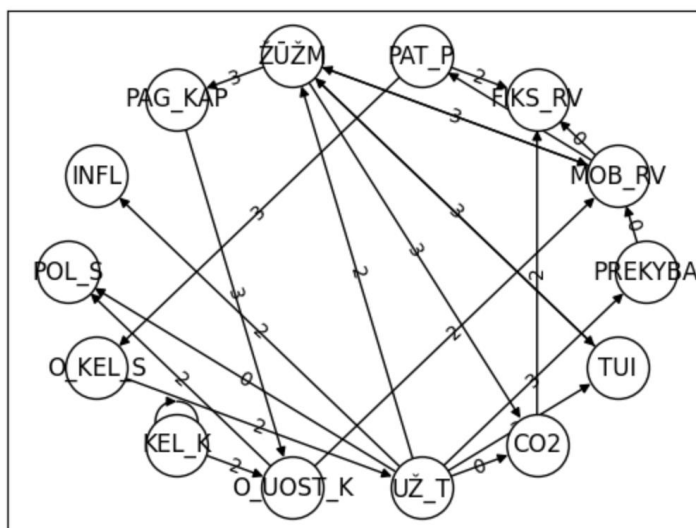
18 pav. galime matyti koreliacijų matricą. Taip pat 19 pav. matome rodiklių klasterius pagal koreliaciją.



**19 pav.** Lietuvos rodiklių klasteriai pagal koreliaciją

Pašaliname visus rodiklius kurie turi su kitais kintamaisiais aukštesnes koreliacijas nei 0,8. Tyrimui bus naudojami šie rodikliai: PREKYBA, MOB\_RV, FIKS\_RV, PAT\_P, ŽŪŽM, PAG\_KAP, INFL POL\_S, O\_KEL\_S, KEL\_K, O\_UOST\_K, UŽ\_T, CO2.

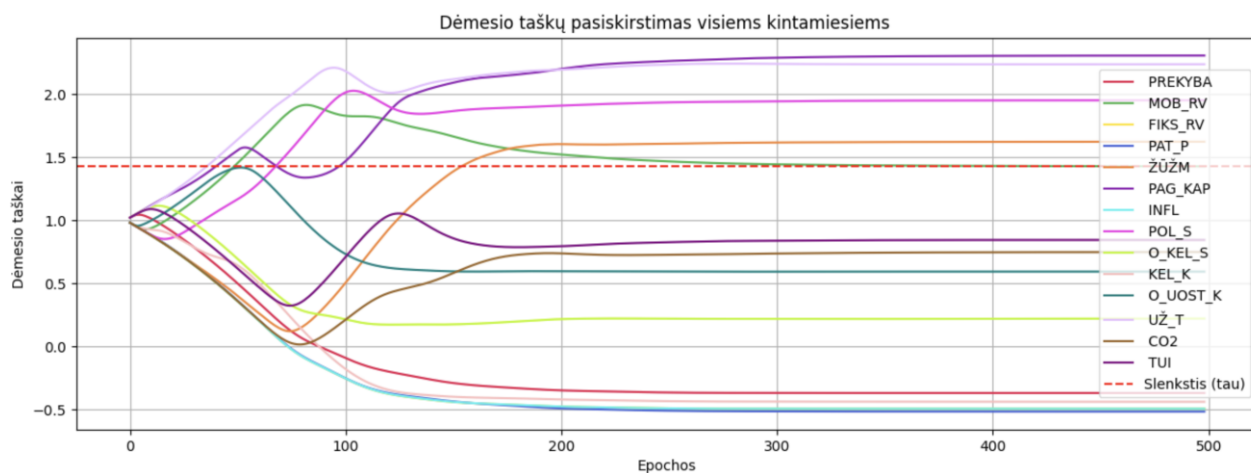
Naudodami laiko priežastinių ryšių metodą, radome šiuos priežastinius ryšius (žiūr. 20 pav.): ŽŪŽM sukelia TUI su trejų metų vėlinimu, taip pat TUI sukelia ŽŪŽM su tuo pačiu vėlinimu, UŽ\_T sukelia TUI su trejų metų vėlinimu. Modelio tikslumas yra 95,8%, patvirtinti visi vėlinimi. Granger metodas šių ryšių neaptinka. Taip pat gauname ir vidutinę absoliutinę skalės klaidą (angl. *Mean absolute scale error*), sutrumpintai MASE. Bendras MASE vidurkis yra 9,62, o standartinis nuokrypis - 15,7.



**20 pav.** Lietuvos rodiklių priežastingumo grafas 2004-2022 m.

Panagrinėkime, kaip dėmesio taškai padėjo rasti priežastingumą. Interpretuojat dėmesio taškus yra svarbus slenkstis. Jei taškai yra didesni negu paskaičiuotas slenkstis, ryšys gali būti įtrauktas kaip potenciali priežastis. Slenkstis yra nustatomas randant didžiausią atotrūkį tarp dėmesio taškų.

Dėmesio taškai išrikiuojami nuo mažiausio iki didžiausio, tada yra ieškoma didžiausio atotrūkio taro dviejų gretimų taškų [17].



**21 pav.** Lietuvos visų rodiklių dėmesio taškų grafikas


Lietuvos atveju (žiūr. 21 pav.) matome, kad slenkstis yra apie 1,4. Slenkstį viršija penki rodikliai: UŽ\_T, MOB\_RV, POL\_S, PAG\_KAP ir ŽŪŽM, tačiau algoritmas galiausiai atrinko tik UŽ\_T ir ŽŪŽM. Matome, kad dėmesio taškų vertės kito iki 200 epochų trukmės. UŽ\_T įvertis vienas aukščiausių, priešingai yra su ŽŪŽM.

Atlikus užsienio tiesioginių investicijų Lietuvos priežastingumo analizę, sunku gautus rezultatus susieti su socialinės (valstybės) gerovės modeliais. Išsamesniems rezultatams gauti reiktų priežastingumo analizę atlikti visoms šalims. Dalis rodiklių, kurie identifikuotų socialinės (valstybės) gerovės modelius (nedarbingumas, mokesčiai...) [24], buvo pašalinti dėl multikolinearumo. Tačiau rasti priežastingumo ryšiai tarp TUI ir UŽ\_T, ŽŪŽM patvirtina Moskalenko ir kt. [15] darytus tyrimus. Patvirtinti rezultatams reikalinga eksperto nuomonė. Rezultatus taip pat galėtų patvirtinti TUI srautų analizė pagal investicijų sritis.

### 3.2. Priežastinių ryšių paieška Vokietijos atveju


Pažvelkime į rodiklius kurie lemia tiesiogines užsienio investicijas. Turime atmesti šiuos rodiklius dėl duomenų trūkumo: ENERGIŠKAST, AUKŠT\_IŠS, VID\_IŠS, SHAD\_E ir GEL\_K.





**22 pav.** Vokietijos rodiklių koreliacijų matrica (1986-2022 m.)


Pirmiausia pažvelgime į rodiklius, kuriuos naudosime siekdami nustatyti, kaip veiksniai, veikiantys tiesioginės užsienio investicijos, kito 1986-2003 metais ir 2004-2022 metais. Pav. 22 galime matyti koreliacijų matricą 1986-2022 m. Taip pat pav. 23 matome rodiklių klasterius pagal koreliaciją.



**23 pav.** Vokietijos rodiklių klasteriai pagal koreliaciją (1986-2022 m.)


Pašaliname visus rodiklius, kurie turi su kitais kintamaisiais aukštesnes koreliacijas nei 0,8. Tyrimui lyginant 1986-2003 ir 2004-2022 m. laikotarpius bus naudojami šie rodikliai: PREKYBA, PAT\_P, PRIEIG\_E, NAT\_R\_N, ARM\_Ž, ŽŪŽM, NEDAR, INFL, MOK, POP.





24 pav. Vokietijos rodiklių koreliacijų matrica (2004-2022 m.)


Pažiūrėkime kokius rodiklius gautume nagrinėdami 2004-2022 metų duomenis. Pav. 24 matome koreliacijų matricą. Taip pat pav. 25 matome rodiklių klasterius pagal koreliaciją.



25 pav. Vokietijos rodiklių klasteriai pagal koreliaciją (2004-2022 m.)

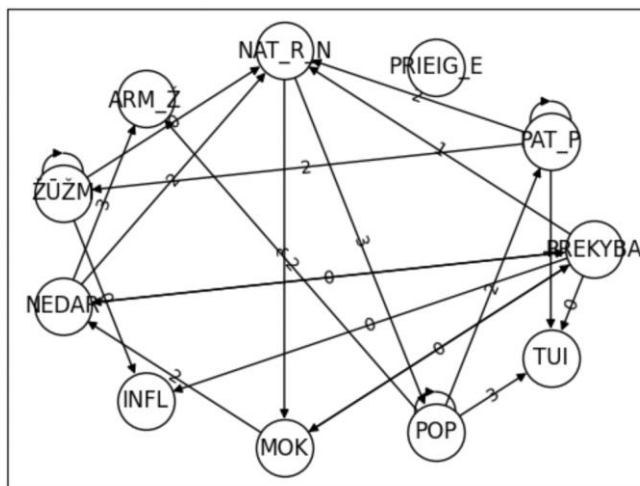
Atliekant 2004-2022 m. priežastingumo analizę bus naudojami šie rodikliai: PREKYBA, MOB\_RV, PAT\_P, PRIEIG\_E, NAT\_R\_N, ŽŪŽM, MIŠK\_D, DARB\_S, INFL, VER\_P\_S, VER\_P\_IŠ, VYR\_EF, POP, PROP\_R.

Aptarkime Vokietijos duomenų analizės rezultatus. Pirmiausia palyginkime laikotarpius 1986-2003 ir 2004-2022 m. (žiūr. 26 ir 27 pav.). Kaip matome, laikotarpiu 1986-2003 m. randami dveji priežastiniai ryšiai. NEDAR ir PREKYBA sukelia TUI su trejų ir vienerių metų vėlinimu, atitinkamai. Ryšys PREKYBA – TUI yra abipusis, TUI sukelia PREKYBA su vienerių metų vėlinimu. Modelio tikslumas yra 100%, patvirtinti visi vėlinimai. MASE vidurkis yra 6,36 su standartiniu nuokrypiu 9,20. Granger metodu priežastingumo ryšių negalėjome aptikti.



26 pav. Vokietijos rodiklių priežastingumo grafas 1986-2003 m.

2004-2022 m. laikotarpiu randame trejus priežastinius ryšius. PREKYBA sukelia TUI su vėlinimu iki vienerių metų. PAT\_P sukelia TUI su vienerių metų vėlinimu. POP sukelia TUI su trejų metų vėlinimu. Modelio tikslumas yra 95,7%, patvirtinti 90,9 % visų vėlinimų. MASE vidurkis yra 2,71 su standartiniu nuokrypiu 2,42. Granger metodu priežastingumo negalėjome aptikti.



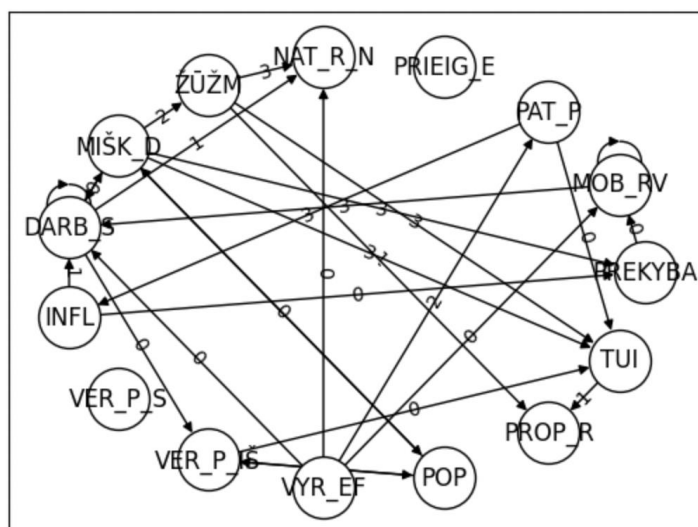
27 pav. Vokietijos rodiklių priežastingumo grafas 2004-2022 m.

Kaip matome, 2004-2022 m. laikotarpiu yra daugiau rodiklių sukeliančių TUI. PREKYBA daro įtaką TUI abiem laikotarpiais, tik pasikeičia vėlinimas. 2004-2022 m. laikotarpiu PAT\_P ir POP sukelia TUI, vietoj NEDAR.

**6 lentelė.** TUI darančių įtaką rodiklių kitimas Vokietijoje.


Laikotarpiai\Rodikliai	NEDAR	PREKYBA	PAT_P	POP
1986-2003	3	1		
2004-2022		0	1	3

Su rodikliais, kurie pradėti rinkti po 2000 m., gauname šį priežastingumo grafą (28 pav.). MIŠK\_D sukelia TUI su trejų metų vėlinimu. ŽŪŽM sukelia TUI su trejų metų vėlinimu. PAT\_P sukelia TUI su vėlinimu iki vienerių metų. VER\_P\_IŠ sukelia TUI su vėlinimu iki vienerių metų. Modelio tikslumas 100%, patvirtinti visi vėlinimai. Granger metodu negalime aptikti šių priežastinių ryšių.



**28 pav.** Vokietijos rodiklių priežastingumo grafas 2004-2022 m. su visais rodikliais

MASE vidurkis yra 3,61 su standartiniu nuokrypiu 7,47.




**29 pav.** Vokietijos visų rodiklių dėmesio taškų grafikas

Žvelgiant į Vokietijos dėmesio taškų grafiką (žiūr. 29 pav.), matome, kad slenkstis yra 1,3. Slenkstį viršija MIŠK\_D, ŽŪŽM, PAT\_P, VER\_P\_IŠ, ir DARB\_S. Galiausiai, metodas atrinko MIŠK\_D, ŽŪŽM, PAT\_P ir VER\_P\_IŠ. MIŠK\_D įvertis yra aukščiausias, PAT\_P mažiausias. Atliekant Vokietijos priežastingumo analizę, taškai nustojo kisti po 300 epochų.

Atlikus Vokietijos 1986-2003 m. laikotarpių priežastingumo analizę, matome, kad NEDAR daro įtaką TUI. Žemyninis modelis pasižymi didesniu nedarbu, nei anglosaksų modelis [24]. Šis ryšys išnyksta atliekant 2004-2022 m. analizę. Įtraukus po 2000 m. pradėtus rinkti rodiklius, turėjome pašalinti rodiklius, kurie gali daugiau nupasakoti apie socialinės (valstybės) gerovės modelius, dėl multikolinearumo. Rastus priežastinius ryšius patvirtina literatūros apžvalgoje apžvelgti tyrimai. Eksperto nuomonė ir detalesnė TUI srautų analizė reikalinga rezultatams patvirtinti.


### 3.3. Priežastinių ryšių paieška Danijos atveju

Pažvelkime į rodiklius, kurie lemia tiesiogines užsienio investicijas. Turime atmesti šiuos rodiklius dėl duomenų trūkumo: ENERGI\_IŠKAST, AUKŠT\_IŠS, VID\_IŠS, O\_KEL\_S, SHAD\_E ir GEL\_K.




30 pav. Danijos rodiklių koreliacijų matrica (1986-2022 m.)

Pirmiausia pažvelgime į rodiklius, kuriuos naudosime siekdami nustatyti, kaip veiksniai, veikiantys tiesiogines užsienio investicijas, kito 1986-2003 metais ir 2004-2022 metais. Pav. 30 galime matyti koreliacijų matricą 1986-2022 m. Taip pat pav. 31 matome rodiklių klasterius pagal koreliaciją.




31 pav. Danijos rodiklių klasteriai pagal koreliaciją (1986-2022 m.)

Tyrimui lyginant 1986-2003 ir 2004-2022 m. laikotarpius bus naudojami šie rodikliai: PREKYBA, PAT\_P, PRIEIG\_E, NAT\_R\_N, ARM\_Ž, PAG\_KAP, NEDAR, INFL, ENG\_S.



32 pav. Danijos rodiklių koreliacijų matrica (2004-2022 m.)

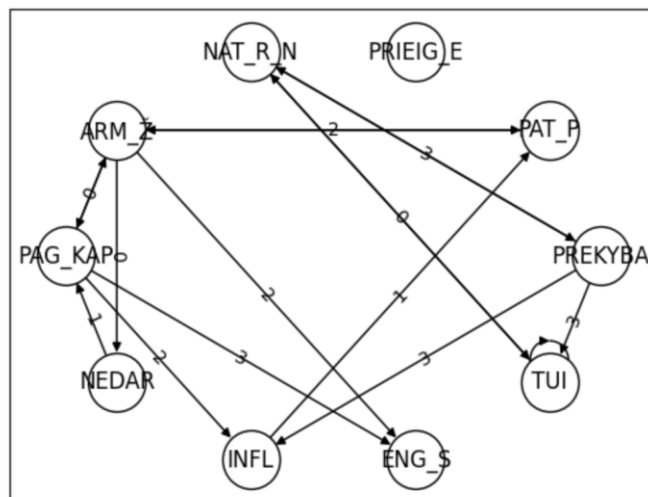
Pažiūrėkime kokius rodiklius gautume nagrinėdami 2004-2022 metų duomenis. Pav. 32 matome koreliacijų matricą. Taip pat pav. 33 matome rodiklių klasterius pagal koreliaciją.



**33 pav.** Danijos rodiklių klasteriai pagal koreliaciją (2004-2022 m.)

Atliekant 2004-2022 m. priežastingumo analizę bus naudojami šie rodikliai: PREKYBA, MOB\_RV, PRIEIG\_E, ARM\_Ž, ŽŪŽM, PAG\_KAP, DARB\_S, BVP\_G, INFL, VER\_P\_S, KOR\_K, VYR\_EF, TEIS\_V, UŽ\_T.

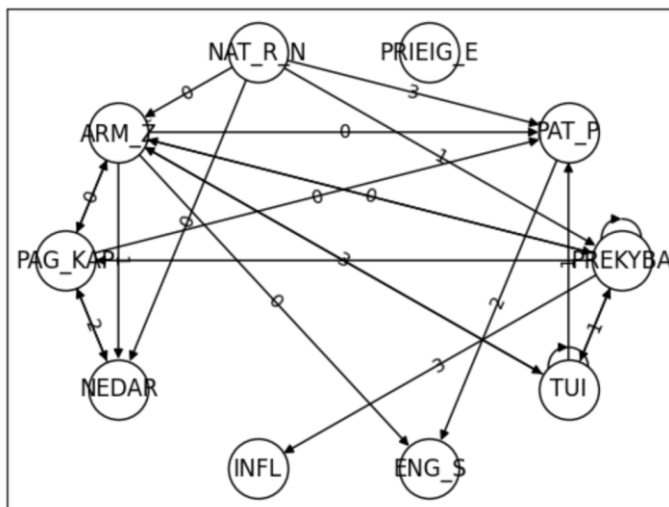
1986-2003 m. priežastingumo grafe (žiūr. 34 pav.) matome tris priežastinius ryšius. TUI sukelia TUI su vienerių metų vėlinimu. NAT\_R\_N sukelia TUI su vienerių metų vėlinimu. Šis ryšys yra abipusis, TUI sukelia NAT\_R\_N su vėlinimu iki vienerių metų. PREKYBA sukelia TUI su trejų metų vėlinimu. Modelio tikslumas šiuo atveju yra 100%, patvirtinti visi vėlinimai. MASE vidurkis yra 6,25, o standartinis nuokrypis 5,79. Granger priežastingumas patvirtina, kad NAT\_R\_N sukelia TUI su trejų ir ketverių metų vėlinimu. Kitų ryšių negalime patvirtinti Granger metodu.



**34 pav.** Danijos rodiklių priežastingumo grafas 1986-2003 m.

2004-2022 m. priežastingumo grafe (žiūr. 35 pav.) matome tris priežastinius ryšius. TUI sukelia TUI su vienerių metų vėlinimu. ARM\_Ž sukelia TUI su vėlinimu iki vienerių metų. Šis ryšys yra abipusis, TUI sukelia ARM\_Ž su trejų metų vėlinimu. PREKYBA sukelia TUI su trejų metų vėlinimu. Šis ryšys abipusis, TUI sukelia PREKYBA su vienerių metų vėlinimu. Modelio tikslumas šiuo atveju yra 100%, patvirtinti 95,8% visų vėlinimų. MASE vidurkis yra 2,04, o standartinis

nuokrypis 1,78. Granger priežastingumas patvirtina, kad TUI sukelia PREKYBA su ketverių metų vėlinimu. Taip pat, kad TUI sukelia ARM\_Ž su vienerių, trejų ir ketverių metų vėlinimais. Kitų ryšių negalime aptikti Granger metodu.




35 pav. Danijos rodiklių priežastingumo grafas 2004-2022 m.

Kaip matome 7 lentelėje, abiejuose laikotarpiuose rodiklių, darančių įtaką TUI, skaičius išlieka tas pats. TUI ir PREKYBA kartojasi abiejuose laikotarpiuose ir turi tuos pačius vėlavimus. 2004-2022 metų laikotarpyje NAT\_R\_N pakeičiamas ARM\_Ž.

7 lentelė. TUI darančių įtaką rodiklių kitimas Danijoje.


Laikotarpiai\Rodikliai	TUI	PREKYBA	NAT_R_N	ARM_Ž
1986-2003	1	3	1	
2004-2022	1	3		0

Su rodikliais, kurie pradėti rinkti po 2000 m., gauname šį priežastingumo grafą (36 pav.). Randami treji priežastiniai ryšiai, kurie sukelia TUI. TUI sukelia TUI su vienerių metų vėlinimu. BVP\_G sukelia TUI su dviejų metų vėlinimu. UŽ\_T sukelia TUI su dviejų metų vėlinimu. Modelio tikslumas šiuo atveju yra 100% ir patvirtinti visi vėlinimai. Granger metodas patvirtina, kad TUI sukelia UŽ\_T su vienerių metų vėlinimu. Kitų ryšių negalime aptikti Granger metodu.



36 pav. Danijos rodiklių priežastingumo grafas 2004-2022 m. su visais rodikliais

MASE vidurkis yra 1,66, o standartinis nuokrypis yra 1,53.



37 pav. Danijos visų rodiklių dėmesio taškų grafikas


Danijos atveju slenkstis yra 1,7 (žiūr. 37 pav.). Rodikliai kurie viršija slenkstį yra TUI, MOB\_RV, UŽ\_T, ARM\_Ž ir BVP\_G. Metoda atrinko tik TUI, UŽ\_T ir BVP\_G. TUI ir BVP\_G gauna aukščiausią įvertį. Įdomu, kad jų įverčiai galiausiai yra vienodi. Dėmesio taškams nustatyti prirėikė 300 epochų.

Danijos situaciją taip pat sunkoką išskirti iš kitų šalių. BVP\_G yra vienas rodiklių, darančių įtaką TUI. Teigiama, kad šiaurietiškas modelis pasižymi didesniu produktyvumu ir konkurencingumu [6]. Rasti priežastiniai ryšiai analizuojant skirtingus laikotarpius ir pridėjus papildomus rodiklius patvirtina literatūros apžvalgoje aptariamus tyrimus. Kiek įdomiau, kad šiuo atveju randamas savaiminis priežastingumas. Galima daryti logišką prielaidą, kad ateinančios investicijos pritraukia daugiau investicijų. Tačiau, kaip ir ankstesniais atvejais, reikalingas eksperto vertinimas.

### 3.4. Priežastinių ryšių paieška Airijos atveju


Pažvelkime į rodiklius, kurie lemia tiesiogines užsienio investicijas. Turime atmesti šiuos rodiklius dėl duomenų trūkumo: ENER\_G\_IŠKAST, AUKŠT\_IŠS, VID\_IŠS, ir GEL\_K.






38 pav. Airijos rodiklių koreliacijų matrica (1986-2022 m.)

Pirmiausia pažvelgime į rodiklius, kuriuos naudosime siekdami nustatyti, kaip veiksniai, veikiantys tiesiogines užsienio investicijas, kito 1986-2003 metais ir 2004-2022 metais. Pav. 38 galime matyti koreliacijų matricą 1986-2022 m. Taip pat pav. 39 matome rodiklių klasterius pagal koreliaciją.




39 pav. Airijos rodiklių klasteriai pagal koreliaciją (1986-2022 m.)

Tyrimui lyginant 1986-2003 ir 2004-2022 m. laikotarpius bus naudojami šie rodikliai: PREKYBA, PRIEIG\_E, NAT\_R\_N, PAG\_KAP, NEDAR, INFL, MOK, CO2.



40 pav. Airijos rodiklių matrica (2004-2022 m.)

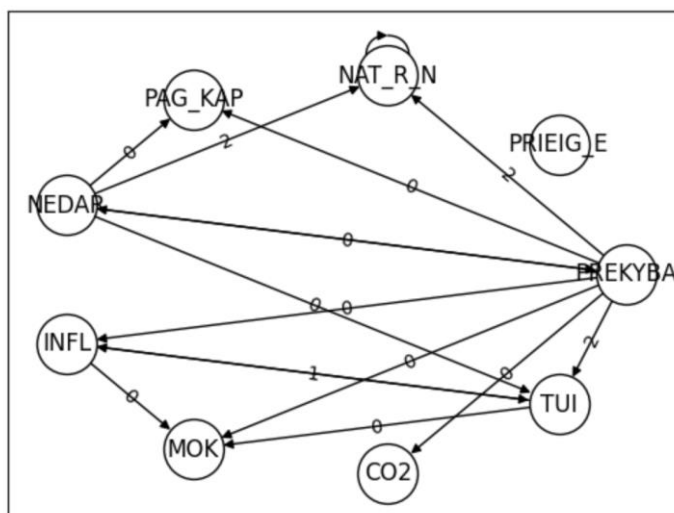
Pažiūrėkime kokius rodiklius gautume nagrinėdami 2004-2022 metų duomenis. Pav. 40 matome korelacių matricą. Taip pat pav. 41 matome rodiklių klasterius pagal korelacią.



41 pav. Airijos rodiklių klasteriai pagal korelacią (2004-2022 m.)


Atliekant 2004-2022 m. priežastingumo analizę bus naudojami šie rodikliai: PREKYBA, MOB\_RV, T\_P\_SAV, PRIEIG\_E, NAT\_R\_N, ARM\_Ž, ŽŪŽM, PAG\_KAP, DARB\_S, INF, VER\_P\_S, KOR\_K, VYR\_EF, O\_KEL\_S, ENG\_S ir PROP\_R.

Pirmiausia palyginkime Airijos analizės duomenų rezultatus 1986-2003 m. ir 2004-2022 m. laikotarpiais. Randami trys ryšiai sukeliantys TUI (žiūr. 42 pav.). NEDAR sukelia TUI su vėlinimu iki vienerių metų. INFL sukelia TUI su dviejų metų vėlinimu. Šis ryšys yra abipusis, TUI sukelia INFL su vienerių metų vėlinimu. PREKYBA sukelia TUI su dviejų metų vėlinimu. Modelio tikslumas yra 100%, patvirtinti 70,6% visų vėlinimų. MASE vidurkis yra 6,85, o standartinis nuokrypis - 7,18. Granger metodas randa, kad TUI sukelia NEDAR su vienerių ir dviejų metų vėlinimais. Taip pat TUI sukelia PREKYBA su vienerių metų vėlinimu. Kiti priežastiniai ryšiai buvo Granger metodo nepatvirtinti.



42 pav. Airijos rodiklių priežastingumo grafas 1986-2003 m.

Panagrinėkime 2004-2022 m. laikotarpį (žiūr. 43 pav). Randami tik du priežastiniai ryšiai, sukeliantys TUI. NEDAR sukelia TUI su trejų metų vėlinimu. PREKYBA sukelia TUI su trejų metų vėlinimu. Modelio tikslumas - 100%, bet patvirtinta tik 82,4% visų vėlinimų. MASE vidurkis yra 5,67, o standartinis nuokrypis yra 6,95. Granger metodu nepavyko šių ryšių patvirtinti.




43 pav. Airijos rodiklių priežastingumo grafas 2004-2022 m.

Kaip matome 8 lentelėje, rodiklių, darančių įtaką TUI sumažėjo 2004-2022 m. lyginant su 1986-2003 m. Išlieka NEDAR ir PREKYBA, bet su didesniais vėlinimais.

**8 lentelė.** TUI darančių įtaką rodiklių kitimas Airijoje.

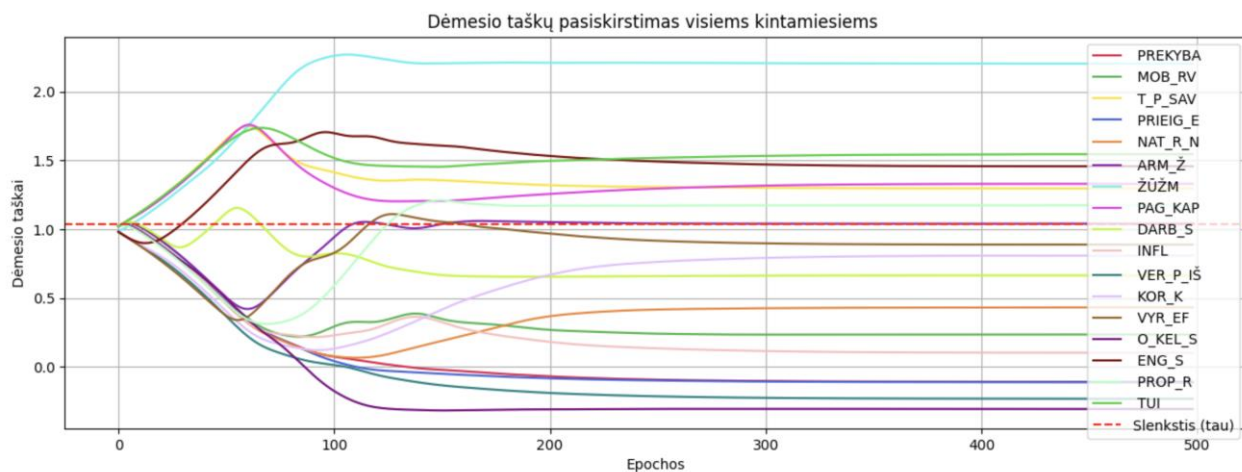
Laikotarpiai\Rodikliai	NEDAR	INFL	PREKYBA
1986-2003	0	2	2
2003-2022	3		3

Panagrinėkime 2004-2022 m. grafą su rodikliais, kur duomenys pradėti rinkti po 2000 metų (žiūr. 44 pav.). Kaip matome, yra randamas tik vienas priežastinis ryšys. ŽŪŽM sukelia TUI su vėlinimu iki vienerių metų. Modelio tikslumas yra 100%, patvirtinti visi vėlinimai. Granger metodas nepatvirtino šio priežastinio ryšio.



**44 pav.** Airijos rodiklių priežastingumo grafas 2004-2022 m. su visais rodikliais

MASE vidurkis yra 5,52, o standartinis nuokrypis - 15,18.




**45 pav.** Airijos visų rodiklių dėmesio taškų grafikas

Žvelgiant į Airijos dėmesio taškų grafiką matome, kad slenkstis šiek tiek daugiau nei 1. Slenkstį viršija šie rodikliai: ŽŪŽM, T\_P\_SAV, PAG\_KAP, TUI, PROP\_R ir ENG\_S. TCDF Metodas patvirtino tik ŽŪŽM. ŽŪŽM išsiskiria iš kitų rodyklių pagal savo aukštą įvertį. Dėmesio taškams nustatyti prireikė 250 epochų.

Airijos situacija yra panaši į Vokietijos 1986-2003 m. NEDAR daro įtaką TUI. Tačiau šiek tiek vėliau šis ryšys išnyksta. Analizuojant rezultatus nematome ryšio tarp socialinės (valstybės) gerovės modelio ir užsienio tiesioginių investicijų. Reikalinga eksperto nuomonė ar TUI srautų gilesnė analizė rezultatams patvirtinti.


### 3.5. Priežastinių ryšių paieška Ispanijos atveju

Pažvelkime į rodiklius, kurie lemia tiesiogines užsienio investicijas. Turime atmesti šiuos rodiklius dėl duomenų trūkumo: ENERĖ\_IŠKAST, AUKŠT\_IŠS, VID\_IŠS, MOK, SHAD\_E, POL\_S ir GEL\_K.




46 pav. Ispanijos rodiklių koreliacijų matrica (1986-2022 m).

Pirmiausia pažvelgime į rodiklius, kuriuos naudosime siekdami nustatyti, kaip veiksniai, veikiantys tiesiogines užsienio investicijas, kito 1986-2003 metais ir 2004-2022 metais. Pav. 46 galime matyti koreliacijų matricą 1986-2022 m. Taip pat pav. 47 matome rodiklių klasterius pagal koreliaciją.




47 pav. Ispanijos rodiklių klasteriai pagal koreliaciją (1986-2022 m.)

Tyrimui lyginant 1986-2003 ir 2004-2022 m. laikotarpius bus naudojami šie rodikliai: PREKYBA, PAT\_P, PRIEIG\_E, NAT\_R\_N, PAG\_KAP, NEDAR ir INFL.



48 pav. Ispanijos rodiklių koreliacijų matrica (2004-2022 m.)

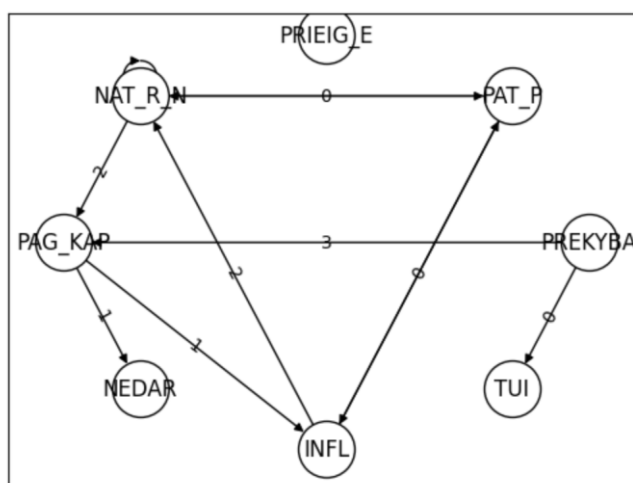
Pažiūrėkime kokius rodiklius gautume nagrinėdami 2004 – 2022 metų duomenis. Pav. 48 matome koreliacijų matricą. Taip pat pav. 49 matome rodiklių klasterius pagal koreliaciją.



49 pav. Ispanijos rodiklių klasteriai pagal koreliaciją (2004-2022m.)

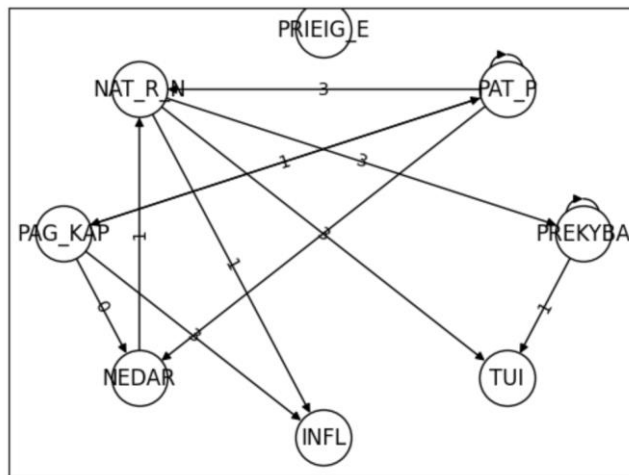
Atliekant 2004-2022 m. priežastingumo analizę bus naudojami šie rodikliai: PREKYBA, MOB\_RV, PAT\_P, PRIEIG\_E, NAT\_R\_N, ŽŪŽM, DARB\_S, BVP\_G, INFL, VER\_P\_S, VYR\_EF, O\_KEL\_S, KEL\_K, UŽ\_T, PROP\_R.

Panagrinėkime, kokie rodikliai daro įtaką TUI Ispanijoje. Pirmiausia palyginkime 1986-2003 m. ir 2004-2022 m. laikotarpius. 1986-2003 m. laikotarpiu randamas tik vienas priežastinis ryšys (žiūr. 50 pav.). PREKYBA sukelia TUI su vėlavimu iki vienerių metų. Modelio tikslumas - 100%, patvirtinti 81,8% visų vėlinimų. MASE vidurkis yra 6,27, o standartinis nuokrypis - 8,11. Granger metodas patvirtina, kad PREKYBA sukelia TUI ir TUI sukelia PREKYBA su vienerių metų vėlavimu.



50 pav. Ispanijos rodiklių priežastingumo grafas 1986-2003 m.

2004-2022 m. randami dveji priežastiniai ryšiai (žiūr. 51 pav.). PREKYBA sukelia TUI su vienerių metų vėlinimu. NAT\_R\_N sukelia TUI su trejų metų vėlinimu. Modelio tikslumas 92,3%, patvirtinti 91,7% visų vėlinimų. MASE vidurkis yra 5,30, o standartinis nuokrypis 7,65. Šių ryšių Granger metodas nepatvirtino.



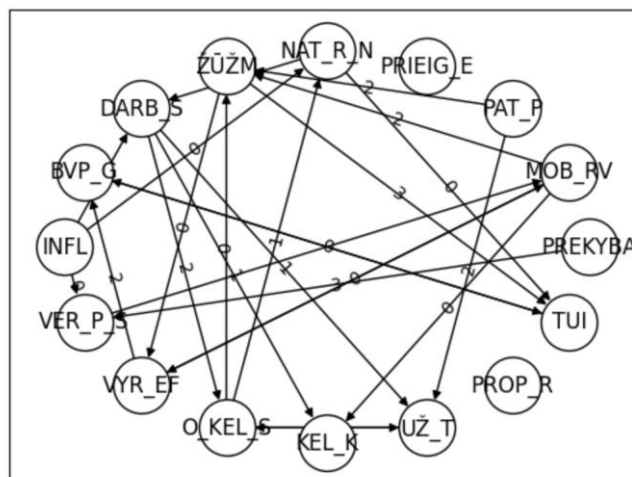
**51 pav.** Ispanijos rodiklių priežastingumo grafas 2004-2022 m.

Kaip matome, 1986-2003 m. ir 2004-2022 m. išlieka priežastinis ryšys tarp PREKYBA ir TUI, tik pasikeičia vėlinimas (žiūr. 9 lentelė). 2004-2022 m. laikotarpiu prisideda priežastinis ryšys tarp NAT\_R\_N ir TUI.

**9 lentelė.** TUI darančių įtaką rodiklių kitimas Ispanijoje

Laikotarpiai\Rodikliai	PREKYBA	NAT_R_N
1986-2003	0	
2003-2022	1	3


Panagrinėkime 2004-2022 m. grafą su visais rodikliais (žiūr. 52 pav.). Randami treji priežastiniai ryšiai. NAT\_R\_N sukelia TUI su vėlinimu iki vienerių metų. BVP\_G sukelia TUI su vėlinimu iki vienerių metų. TUI sukelia BVP\_G su tokiu pačiu vėlinimu. ŽŪŽM sukelia TUI su vėlinimu iki trejų metų. Modelio tikslumas yra 100%, patvirtinti visi vėlinimai. Granger metodas patvirtina, kad TUI sukelia BVP\_G su trejų metų vėlinimu. ŽŪŽM sukelia TUI su vienerių metų vėlinimu. Taip pat TUI sukelia ŽŪŽM su trejų metų vėlinimu. Kitų ryšių negalime patvirtinti Granger metodu.



**52 pav.** Ispanijos rodiklių priežastingumo grafas 2004-2022 m. su visais rodikliais

MASE vidurkis yra 2,29, o standartinis nuokrypis 3,63.





**53 pav.** Ispanijos visų rodiklių dėmesio taškų grafikas

Ispanijos rodiklių slenkstis yra 1,2 (žiūr. 53 pav.). Slenkstį viršija šie rodikliai: BVP\_G, ŽŪŽM, NAT\_R\_N, TUI ir MOB\_RV. Metodas atrenka tik BVP\_G, ŽŪŽM ir NAT\_R\_N. Aukščiausias įvertis BVP\_G. Įdomu, kad ŽŪŽM ir NAT\_R\_N dėmesio taškai galiausiai sutampa. Dėmesio taškams nustatyti prireikė 300 epochų.

Ispanija taip pat neišsiskiria iš kitų šalių. Rasti priežastiniai ryšiai pasikartoja ir kitose šalyse. Tačiau pietinis / Viduržemio modelis pasižymi maža valstybės įtaka [24]. Šiuo atveju reiktų atlikti ir kitų pietinio / Viduržemio modelio šalių analizę. Gali būti, kad Ispanijos valstybė neturi jokių strategijų TUI pritraukti. Šiuo atveju eksperto nuomonė leistų patvirtinti ar paneigti tyrimo rezultatus.

### 3.6. Apibendrinimas

Lyginant šalis atskirai, kaip kito rodikliai darantys įtaką 1986-2003 m. ir 2004-2022 m. laikotarpiais, galime matyti, kad rodikliai kito visais laikotarpiais. Visose šalyse PREKYBA sukelia TUI abiem laikotarpiais. Ispanijoje ir Vokietijoje TUI sukeliančių rodiklių padaugėjo 2004-2022 m. laikotarpiu. Airijoje šiuo laikotarpiu sukeliančių TUI rodiklių sumažėjo. 1986-2003 m. laikotarpiu Airijoje ir Vokietijoje rodikliai, sukeliančys TUI, yra panašesni. Danijoje ir Ispanijoje TUI sukelia rodikliai, susiję su žemės ūkiu. Granger metodas daugelio priežastinių ryšių nepatvirtino.

**10 lentelė.** Visos šalys su rodikliais, pradėtai rinkti po 2000 metų. Skaičiai nurodo vėlinimą.

Šalis/ Rodikliai	ŽŪŽM	UŽ_T	MIŠK_D	PAT_P	VER_P_IŠ	BVP_G	TUI	NAT_R_N
Lietuva	3	3						
Vokietija	3		3	0	0			
Danija		2				2	1	
Airija	0							
Ispanija	3					0		0

Lyginant šalis 2004-2022 m. laikotarpiu su rodikliais, kurie pradėti rinkti po 2000 m., matome, kad PREKYBA įtaka TUI išnyko (žiūr. 8 lentelė). Visose šalyse skirtingi rodikliai sukelia TUI. Lietuvoje, Vokietijoje, Airijoje ir Ispanijoje galime matyti, kad TUI sukelia ŽŪŽM, dažniausiai

pasikartojantis rodiklis. Lietuvoje ir Danijoje UŽ\_T sukelia TUI. TUI sukeliančių rodiklių gausa galime išskirti Vokietiją. Airija turi mažiausiai TUI sukeliančių rodiklių. Granger metodas daugelio priežastinių ryšių nepatvirtino.

Rezultatams patvirtinti taip pat reikalinga eksperto nuomonė, kadangi TCDF rezultatams gali daryti įtaką klaidinančios koreliacijos [17]. Kaip matome, MASE vertės yra pakankamai mažos. Sprendžiant multikolinearumo problemą, buvo pašalinti rodikliai, kurie stipriai koreliuoja tarpusavyje. Priežastinis laiko metodas naudoja neuroninius tinklus, kuriems nereikia duomenų stacionarumo. Kai kuriuose šaltiniuose yra minima, kad TCDF veikia ne taip gerai, kai yra pateikiama mažai duomenų [20]. Šiame tyrime naudojamos laiko eilutės yra pakankamai trumpos. Galime daryti prielaidą, kad, turint daugiau duomenų, rezultatai būtų skirtingi.

## Išvados

1. Išnagrinėjus mokslinę literatūrą galime teigti, kad yra tiesioginis ryšys tarp šalies patrauklumo investicijoms ir užsienio tiesioginių investicijų. Užsienio tiesioginės investicijos teikia šaliai nemažai naudos: padeda vystyti inovacijas, sukurti naujas darbo vietas, kelti darbuotojų kompetencijas ir produktyvumą. Kiekviena šalis kuria ir naudoja atitinkamas strategijas užsienio tiesioginėms investicijoms pritraukti. Tačiau, pasikeitus politiniam ar aplinkosaugos kontekstui, šalis gali prarasti užsienio tiesiogines investicijas arba jas pritraukti.
2. Atlikus mokslinės literatūros analizę identifikuoti veiksniai ir rodikliai, darantys įtaką užsienio tiesioginėms investicijoms. Rasti 40 rodiklių. Tam, kad galėtume išvengti multikolinearumo problemos, koreliacijų analizės metu pašalinti rodikliai, kurių koreliacijos tarpusavyje yra didesnės nei, 0,8.
3. Atlikus priežastinių ryšių analizę laiko priežastinių ryšių nustatymo metodu tarp mokslinėje literatūroje identifikuotų rodiklių ir tiesioginių užsienio investicijų laiko priežastinių ryšių nustatymo metodu, galime teigti, kad tik dalis rodiklių daro įtaką užsienio tiesioginėms investicijoms. Neįtraukus rodiklių, kurie pradėti rinkti po 2000 metų, tokie rodikliai sukelia užsienio tiesiogines investicijas: prekyba (% BVP), rezidentų patentų paraiškos, natūralių resursų nuoma (% BVP), ariamos žemės dalis visoje teritorijoje (%), nedarbingumas (% darbo jėgos), infliacija vartotojų kainomis (%) metinė, populiacija ir pačios užsienio tiesioginės investicijos. Įtraukus rodiklius, kurie pradėti rinkti po 2000 metų, šie rodikliai daro įtaką užsienio tiesioginėms investicijoms: žemės ūkio, miškininkystės ir žuvininkystės dalis BVP (%), atvykstantys užsienio turistai, miško dalis bendroje teritorijoje (%), rezidentų patentų paraiškos, verslo steigimo procedūrų išlaidos, BVP gyventojui, tiesioginės užsienio investicijos ir natūralių resursų nuoma (% BVP).
4. Tyrimo metu buvo nustatyta, kad skirtingi rodikliai daro įtaką užsienio tiesioginėms investicijoms skirtingose šalyse. Taip pat, kad priežastiniai ryšiai kinta skirtingai skirtingais laikotarpiais kiekvienoje šalyje. Tačiau rodiklis prekyba (% BVP) nuolatos pasikartojo lyginant skirtingus laikotarpius. Skirtingus rezultatus gali lemti šalies savitumas. Tam išsiaiškinti reiktų atlikti išsamesnę šalių analizę.
5. Įdomu ir tai, kad, pridėjus daugiau rodiklių, priežastiniai ryšiai kinta. Analizuojant šalis, įtraukus rodiklius pradėtus rinkti po 2000 metų, matome, kad prekybos (% BVP) įtaka užsienio tiesioginėms investicijoms sumažėjo. Tokie rodikliai, kaip žemės ūkio, miškininkystės ir žuvininkystės dalis BVP %, atvykstantys užsienio turistai ir BVP gyventojui, daro didesnę įtaką užsienio tiesioginėms investicijoms.
6. Tarp rodiklių, darančių įtaką užsienio tiesioginėms investicijoms, ir užsienio tiesioginių investicijų vyrauja nelinijiniai priežastingumo ryšiai. Išskyrus Ispanijos analizės kai kuriuos atvejus. Taip pat laiko priežastinių ryšių metodas identifikavo savaiminį užsienio tiesioginių investicijų priežastingumą kai kuriais atvejais. Galime neabejoti, kad laiko priežastinių ryšių nustatymo metodas randa daugiau priežastinių ryšių nei Granger metodas.
7. Rastų priežastinių ryšių MASE įvertinimai yra maži. Tai galime daryti prielaidą, kad modelis yra patikimas.
8. Priežastinių ryšių vėlinimai daugiausia buvo iki trejų metų.
9. Tyrimo metu nepavyko rasti ryšio tarp priežastinių ryšių ir socialinės (valstybės) gerovės modelių.

## Literatūros sąrašas

1. WANG, Y. C. and M. V. CHEN. The role of foreign direct investment in east and Southeast Asia: Evidence before and after 2009 global financial crisis. *International Review of Economics & Finance* [interaktyvus]. Elsevier, March 2024, vol. 92, 1405-1415 [žiūrėta 2024-04-01]. Prieiga per Science Direct.
2. Glossary of foreign direct investment terms, OECD. [Tinkle] [Cituota: 2024m. 04 14d.] <https://www.oecd.org/daf/inv/investment-policy/2487495.pdf>
3. DANG, V. C. and Q, NGUYEN. (2021, January 1). Determinants of FDI attractiveness: Evidence from ASEAN-7 countries. *Cogent Social Sciences* [Interaktyvus]. Tandfonline, December 2021, vol. 7, 1-15 [žiūrėta 2024-04-01]. doi: 10.1080/23311886.2021.2004676
4. BRUNECKIENE, Jurgita, et al. Assessment of Investment Attractiveness in European Countries by Artificial Neural Networks: What Competences are Needed to Make a Decision on Collective Well-Being? *Sustainability* [interaktyvus]. MPDI, December 2019, vol. 11, 1-23 [žiūrėta 2023-02-07]. doi: 10.3390/su11246892
5. MARCHEWKA, A. Applying TOPSIS to evaluate labour market resources as a factor of regional investment attractiveness. *Procedia Computer Science* [Interaktyvus]. Elsevier, January 2022, vol. 207, 3116-3123 [žiūrėta 2024-04-13], Prieiga per: Scince Direct.
6. ROSZKO-WOJTOWICZ, E. and M. M. GRZELAK (2021, March 31). Multi-dimensional analysis of regional investment attractiveness in Poland. *Equilibrium* [interaktyvus]. Journals.economic-research.pl, vol. 16 (1), 103-138 [žiūrėta 2024-04-10]. doi: 10.24136/eq.2021.004
7. BRUNECKIENE, J. (2022) *Regional Economics* [interaktyvus]. Praha: 2022 [žiūrėta 2024-04-13]. Prieiga per: <https://vscht.futurebooks.cz/book/regional-economics/?/title-page/>
8. ZHOU, YUJIE, et al. (2022, July 18). Root cause diagnosis in multivariate time series based on modified temporal convolution and multi-head self-attention. *Journal of Process Control* [interaktyvus]. Elsevier, September 2022, vol. 117, 14-25 [žiūrėta 2024-01-01]. Prieiga per: Scince Direct.
9. KANAPIENYTĖ, L. and R. ČINČIKAITĖ. Evaluation of attractiveness of the EU member states for foreign direct investment. *Advanced Economic Development* [Interaktyvus]. ReaserchGate, May, 2022 [žiūrėta 2024-02-20]. doi: 10.3846/bm.2022.821
10. OKARA, A. Does foreign direct investment promote political stability? Evidence from developing economies. *Economic Modeling* [Interaktivus]. Elsevier, June 2023, vol. 123, 1-19 [žiūrėta 2023-05-16]. Prieiga per: Scince Direct.
11. BEULE, Filip, D., et al. The influence of environmental regulation on the FDI location choice of EU. *Journal of Environmental Management* [interaktyvus]. Elsevier, November 2022, vol. 321, 1-15 [žiūrėta 2023-03-15]. Prieiga per: Scince Direct.
12. APPUNN, K. and J. WETTENGEL. Understanding the European Union's Emissions Trading Systems (EU ETS). *Journalism for the energy transition* [interaktyvus]. May 2023 [žiūrėta 2023-05-05]. <https://www.cleanenergywire.org/factsheets/understanding-european-unions-emissions-trading-system>
13. KALOTAY. (2023, October 10). War, sanctions, and foreign direct investment to and from Russia. *Medunarodna Politika* [Interaktyvus]. real.mtak.hu, October 2023, vol. 1189, 133-153 [žiūrėta 2024-04-13]. doi: 0.18485/iipe\_mp.2023.74.1189.6

14. PUZIKOVA, V. Foreign direct investment in Ukraine. Hannover Economic Papers [Interaktivus]. ECONSTOR, April 2023, vol. 706, 1-47 [žiūrėta 2023-04-14]. <https://hdl.handle.net/10419/283157>
15. MOSKALENKO, Bogdan, et al. (2022, April 4). The investment attractiveness of countries: Coupling between core dimensions. Forum Scientiae Oeconomia [Interaktyvus]. October, 2022, vol. 10, 153-172 [žiūrėta 2023-05-01]. doi: 10.23762/FSO\_VOL10\_NO2\_8
16. DOROZYNSKI, T. and A. KUNA-MARSZALEK. Investment Attractiveness. The Case Of The Visegrad Group Countries. Comperative Economic Reasearch. ReasearchGate, November 2016, vol. 19, 119-140 [žiūrėta 2024-04-01]. doi: 10.1515/cer-2016-0007
17. NAUTA, Meike, et al. (2019, January 7). Causal Discovery with Attention-Based Convolutional Neural Networks. Machine Learning & Knowledge Extraction [Interaktivus]. MDPI, January 2019, vol. 1(1), 312-340 [žiūrėta 2023-08-30]. doi: 10.3390/make1010019
18. ASSAAD, Charles K., et al. Survey and Evaluation of Causal Discovery Methods for Time Series. Journal of Artificial Intelligence Research [interaktyvus]. February 2022, vol. 73, 767-819 [žiūrėta 2023-10-10]. doi: 10.1613/jair.1.13428
19. ZHOU, YUJIE, et al. (2022, July 18). Root cause diagnosis in multivariate time series based on modified temporal convolution and multi-head self-attention. Journal of Process Control [interaktyvus]. Elsevier, September 2022, vol. 117, 14-25 [žiūrėta 2024-01-01]. Prieiga per: Scince Direct.
20. HASAN, Umza, et al. (2023, September 5). A Survey on Causal Discovery Methods for I.I.D and Time Series Data. Transactions on Machine Learning Research [Interaktyvus]. ResearchGate, September, 2023, 1-62 [žiūrėta 2024-04-27]. doi: 10.48550/arXiv.2303.15027
21. statsmodels.tsa.stattools.grangercausalitytests. [Tinkle] [Cituota: 2024m. 03 20 d.] <https://www.statsmodels.org/stable/generated/statsmodels.tsa.stattools.grangercausalitytests.html>
22. KIM, Y. The Causal Structure of Suppressor Variables. Journal of Educational and Behavioral Statistics [Interaktyvus]. ResearchGate, February 2019, vol. 44(4), 367-389 [žiūrėta 2024-04-27]. doi: 10.3102/107699861982
23. RAPSIKEVIČIUS, Jonas, et al. The Impact of Structural Reforms on Sustainable Development Performance: Evidence from European Union Countries. Sustainability [Interaktivus]. MDPI, October 2022, vol. 14(19), 1-18 [žiūrėta 2024-04-10]. doi: 10.3390/su141912583
24. BURGHELEA, Cristina, Ene, et al. Impact of economic models on European Union economies development. Theoretical and Applied Economics [interaktyvus]. January 2023, vol. 0(4(581)), 89-100 [žiūrėta 2024-04-10]. <https://store.ectap.ro/articole/853.pdf>

## Priedai

### 1 priedas. Granger priežastingumo analizės rezultatai

Lietuva

$H_0$ : ŽŪŽM → TUI

$H_a$ : ŽŪŽM ⇌ TUI

```
Granger Causality
number of lags (no zero) 1
ssr based F test:      F=0.0376 , p=0.8488 , df_denom=15, df_num=1
ssr based chi2 test:  chi2=0.0451 , p=0.8318 , df=1
likelihood ratio test: chi2=0.0451 , p=0.8319 , df=1
parameter F test:     F=0.0376 , p=0.8488 , df_denom=15, df_num=1
```

```
Granger Causality
number of lags (no zero) 2
ssr based F test:      F=0.1232 , p=0.8852 , df_denom=12, df_num=2
ssr based chi2 test:  chi2=0.3491 , p=0.8398 , df=2
likelihood ratio test: chi2=0.3455 , p=0.8413 , df=2
parameter F test:     F=0.1232 , p=0.8852 , df_denom=12, df_num=2
```

```
Granger Causality
number of lags (no zero) 3
ssr based F test:      F=0.3510 , p=0.7896 , df_denom=9, df_num=3
ssr based chi2 test:  chi2=1.8721 , p=0.5994 , df=3
likelihood ratio test: chi2=1.7704 , p=0.6214 , df=3
parameter F test:     F=0.3510 , p=0.7896 , df_denom=9, df_num=3
```

```
Granger Causality
number of lags (no zero) 4
ssr based F test:      F=1.7519 , p=0.2568 , df_denom=6, df_num=4
ssr based chi2 test:  chi2=17.5187 , p=0.0015 , df=4
likelihood ratio test: chi2=11.6065 , p=0.0205 , df=4
parameter F test:     F=1.7519 , p=0.2568 , df_denom=6, df_num=4
```

$H_0$ : TUI → ŽŪŽM

$H_a$ : TUI ⇌ ŽŪŽM

```
Granger Causality
number of lags (no zero) 1
ssr based F test:      F=0.0015 , p=0.9700 , df_denom=15, df_num=1
ssr based chi2 test:  chi2=0.0018 , p=0.9666 , df=1
likelihood ratio test: chi2=0.0018 , p=0.9666 , df=1
parameter F test:     F=0.0015 , p=0.9700 , df_denom=15, df_num=1
```

```
Granger Causality
number of lags (no zero) 2
ssr based F test:      F=0.9331 , p=0.4201 , df_denom=12, df_num=2
ssr based chi2 test:  chi2=2.6437 , p=0.2666 , df=2
likelihood ratio test: chi2=2.4572 , p=0.2927 , df=2
parameter F test:     F=0.9331 , p=0.4201 , df_denom=12, df_num=2
```

```
Granger Causality
number of lags (no zero) 3
ssr based F test:      F=1.2920 , p=0.3354 , df_denom=9, df_num=3
ssr based chi2 test:  chi2=6.8909 , p=0.0755 , df=3
likelihood ratio test: chi2=5.7304 , p=0.1255 , df=3
parameter F test:     F=1.2920 , p=0.3354 , df_denom=9, df_num=3
```

```
Granger Causality
number of lags (no zero) 4
ssr based F test:      F=2.4369 , p=0.1580 , df_denom=6, df_num=4
ssr based chi2 test:  chi2=24.3687 , p=0.0001 , df=4
likelihood ratio test: chi2=14.4738 , p=0.0059 , df=4
parameter F test:     F=2.4369 , p=0.1580 , df_denom=6, df_num=4
```

$H_0: U\check{Z}_T \rightarrow TUI$

$H_a: U\check{Z}_T \nrightarrow TUI$

Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=3.6288 , p=0.0761 , df\_denom=15, df\_num=1  
ssr based chi2 test: chi2=4.3546 , p=0.0369 , df=1  
likelihood ratio test: chi2=3.8999 , p=0.0483 , df=1  
parameter F test: F=3.6288 , p=0.0761 , df\_denom=15, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=1.1857 , p=0.3389 , df\_denom=12, df\_num=2  
ssr based chi2 test: chi2=3.3595 , p=0.1864 , df=2  
likelihood ratio test: chi2=3.0657 , p=0.2159 , df=2  
parameter F test: F=1.1857 , p=0.3389 , df\_denom=12, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=1.6208 , p=0.2523 , df\_denom=9, df\_num=3  
ssr based chi2 test: chi2=8.6440 , p=0.0344 , df=3  
likelihood ratio test: chi2=6.9111 , p=0.0748 , df=3  
parameter F test: F=1.6208 , p=0.2523 , df\_denom=9, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=1.0539 , p=0.4535 , df\_denom=6, df\_num=4  
ssr based chi2 test: chi2=10.5385 , p=0.0323 , df=4  
likelihood ratio test: chi2=7.9821 , p=0.0922 , df=4  
parameter F test: F=1.0539 , p=0.4535 , df\_denom=6, df\_num=4

$H_0: TUI \rightarrow U\check{Z}_T$

$H_a: TUI \nrightarrow U\check{Z}_T$

Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=2.6901 , p=0.1218 , df\_denom=15, df\_num=1  
ssr based chi2 test: chi2=3.2282 , p=0.0724 , df=1  
likelihood ratio test: chi2=2.9692 , p=0.0849 , df=1  
parameter F test: F=2.6901 , p=0.1218 , df\_denom=15, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=0.4591 , p=0.6425 , df\_denom=12, df\_num=2  
ssr based chi2 test: chi2=1.3009 , p=0.5218 , df=2  
likelihood ratio test: chi2=1.2535 , p=0.5343 , df=2  
parameter F test: F=0.4591 , p=0.6425 , df\_denom=12, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=0.7273 , p=0.5610 , df\_denom=9, df\_num=3  
ssr based chi2 test: chi2=3.8788 , p=0.2748 , df=3  
likelihood ratio test: chi2=3.4731 , p=0.3243 , df=3  
parameter F test: F=0.7273 , p=0.5610 , df\_denom=9, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=0.9732 , p=0.4865 , df\_denom=6, df\_num=4  
ssr based chi2 test: chi2=9.7316 , p=0.0452 , df=4  
likelihood ratio test: chi2=7.5005 , p=0.1117 , df=4  
parameter F test: F=0.9732 , p=0.4865 , df\_denom=6, df\_num=4

## Vokietija

1986-2003 m.

$H_0$ : NEDAR  $\rightarrow$  TUI

$H_a$ : NEDAR  $\nrightarrow$  TUI

Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=0.0795 , p=0.7822 , df\_denom=14, df\_num=1  
ssr based chi2 test: chi2=0.0965 , p=0.7561 , df=1  
likelihood ratio test: chi2=0.0962 , p=0.7564 , df=1  
parameter F test: F=0.0795 , p=0.7822 , df\_denom=14, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=0.9919 , p=0.4018 , df\_denom=11, df\_num=2  
ssr based chi2 test: chi2=2.8854 , p=0.2363 , df=2  
likelihood ratio test: chi2=2.6528 , p=0.2654 , df=2  
parameter F test: F=0.9919 , p=0.4018 , df\_denom=11, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=0.4443 , p=0.7279 , df\_denom=8, df\_num=3  
ssr based chi2 test: chi2=2.4993 , p=0.4754 , df=3  
likelihood ratio test: chi2=2.3116 , p=0.5103 , df=3  
parameter F test: F=0.4443 , p=0.7279 , df\_denom=8, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=0.7385 , p=0.6042 , df\_denom=5, df\_num=4  
ssr based chi2 test: chi2=8.2710 , p=0.0821 , df=4  
likelihood ratio test: chi2=6.4992 , p=0.1648 , df=4  
parameter F test: F=0.7385 , p=0.6042 , df\_denom=5, df\_num=4

$H_0$ : TUI  $\rightarrow$  NEDAR

$H_a$ : TUI  $\nrightarrow$  NEDAR

Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=2.6771 , p=0.1241 , df\_denom=14, df\_num=1  
ssr based chi2 test: chi2=3.2508 , p=0.0714 , df=1  
likelihood ratio test: chi2=2.9747 , p=0.0846 , df=1  
parameter F test: F=2.6771 , p=0.1241 , df\_denom=14, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=3.3088 , p=0.0750 , df\_denom=11, df\_num=2  
ssr based chi2 test: chi2=9.6257 , p=0.0081 , df=2  
likelihood ratio test: chi2=7.5361 , p=0.0231 , df=2  
parameter F test: F=3.3088 , p=0.0750 , df\_denom=11, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=1.7267 , p=0.2385 , df\_denom=8, df\_num=3  
ssr based chi2 test: chi2=9.7125 , p=0.0212 , df=3  
likelihood ratio test: chi2=7.4889 , p=0.0578 , df=3  
parameter F test: F=1.7267 , p=0.2385 , df\_denom=8, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=1.2349 , p=0.4024 , df\_denom=5, df\_num=4  
ssr based chi2 test: chi2=13.8311 , p=0.0079 , df=4  
likelihood ratio test: chi2=9.6193 , p=0.0474 , df=4  
parameter F test: F=1.2349 , p=0.4024 , df\_denom=5, df\_num=4



$H_0: PREKYBA \rightarrow TUI$

$H_a: PREKYBA \nrightarrow TUI$

```
Granger Causality
number of lags (no zero) 1
ssr based F test:      F=0.3403 , p=0.5689 , df_denom=14, df_num=1
ssr based chi2 test:  chi2=0.4133 , p=0.5203 , df=1
likelihood ratio test: chi2=0.4083 , p=0.5228 , df=1
parameter F test:     F=0.3403 , p=0.5689 , df_denom=14, df_num=1

Granger Causality
number of lags (no zero) 2
ssr based F test:      F=0.1938 , p=0.8266 , df_denom=11, df_num=2
ssr based chi2 test:  chi2=0.5638 , p=0.7544 , df=2
likelihood ratio test: chi2=0.5541 , p=0.7580 , df=2
parameter F test:     F=0.1938 , p=0.8266 , df_denom=11, df_num=2

Granger Causality
number of lags (no zero) 3
ssr based F test:      F=0.0577 , p=0.9805 , df_denom=8, df_num=3
ssr based chi2 test:  chi2=0.3246 , p=0.9553 , df=3
likelihood ratio test: chi2=0.3211 , p=0.9560 , df=3
parameter F test:     F=0.0577 , p=0.9805 , df_denom=8, df_num=3

Granger Causality
number of lags (no zero) 4
ssr based F test:      F=0.2206 , p=0.9159 , df_denom=5, df_num=4
ssr based chi2 test:  chi2=2.4708 , p=0.6499 , df=4
likelihood ratio test: chi2=2.2754 , p=0.6852 , df=4
parameter F test:     F=0.2206 , p=0.9159 , df_denom=5, df_num=4
```

$H_0: TUI \rightarrow PREKYBA$

$H_a: TUI \nrightarrow PREKYBA$

```
Granger Causality
number of lags (no zero) 1
ssr based F test:      F=1.2787 , p=0.2771 , df_denom=14, df_num=1
ssr based chi2 test:  chi2=1.5527 , p=0.2127 , df=1
likelihood ratio test: chi2=1.4859 , p=0.2229 , df=1
parameter F test:     F=1.2787 , p=0.2771 , df_denom=14, df_num=1

Granger Causality
number of lags (no zero) 2
ssr based F test:      F=0.9288 , p=0.4239 , df_denom=11, df_num=2
ssr based chi2 test:  chi2=2.7019 , p=0.2590 , df=2
likelihood ratio test: chi2=2.4966 , p=0.2870 , df=2
parameter F test:     F=0.9288 , p=0.4239 , df_denom=11, df_num=2

Granger Causality
number of lags (no zero) 3
ssr based F test:      F=1.5247 , p=0.2811 , df_denom=8, df_num=3
ssr based chi2 test:  chi2=8.5766 , p=0.0355 , df=3
likelihood ratio test: chi2=6.7831 , p=0.0791 , df=3
parameter F test:     F=1.5247 , p=0.2811 , df_denom=8, df_num=3

Granger Causality
number of lags (no zero) 4
ssr based F test:      F=0.5293 , p=0.7213 , df_denom=5, df_num=4
ssr based chi2 test:  chi2=5.9277 , p=0.2046 , df=4
likelihood ratio test: chi2=4.9427 , p=0.2932 , df=4
parameter F test:     F=0.5293 , p=0.7213 , df_denom=5, df_num=4
```

2004-2022m.

$H_0: PREKYBA \rightarrow TUI$

$H_a: PREKYBA \rightarrow TUI$

Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=3.1669 , p=0.0954 , df\_denom=15, df\_num=1  
ssr based chi2 test: chi2=3.8003 , p=0.0512 , df=1  
likelihood ratio test: chi2=3.4479 , p=0.0633 , df=1  
parameter F test: F=3.1669 , p=0.0954 , df\_denom=15, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=1.3164 , p=0.3042 , df\_denom=12, df\_num=2  
ssr based chi2 test: chi2=3.7299 , p=0.1549 , df=2  
likelihood ratio test: chi2=3.3722 , p=0.1852 , df=2  
parameter F test: F=1.3164 , p=0.3042 , df\_denom=12, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=1.3298 , p=0.3244 , df\_denom=9, df\_num=3  
ssr based chi2 test: chi2=7.0925 , p=0.0690 , df=3  
likelihood ratio test: chi2=5.8707 , p=0.1181 , df=3  
parameter F test: F=1.3298 , p=0.3244 , df\_denom=9, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=0.6543 , p=0.6451 , df\_denom=6, df\_num=4  
ssr based chi2 test: chi2=6.5432 , p=0.1621 , df=4  
likelihood ratio test: chi2=5.4301 , p=0.2459 , df=4  
parameter F test: F=0.6543 , p=0.6451 , df\_denom=6, df\_num=4

$H_0: TUI \rightarrow PREKYBA$

$H_a: TUI \rightarrow PREKYBA$

Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=0.0577 , p=0.8133 , df\_denom=15, df\_num=1  
ssr based chi2 test: chi2=0.0693 , p=0.7924 , df=1  
likelihood ratio test: chi2=0.0692 , p=0.7926 , df=1  
parameter F test: F=0.0577 , p=0.8133 , df\_denom=15, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=0.1326 , p=0.8771 , df\_denom=12, df\_num=2  
ssr based chi2 test: chi2=0.3757 , p=0.8287 , df=2  
likelihood ratio test: chi2=0.3716 , p=0.8304 , df=2  
parameter F test: F=0.1326 , p=0.8771 , df\_denom=12, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=0.6835 , p=0.5842 , df\_denom=9, df\_num=3  
ssr based chi2 test: chi2=3.6452 , p=0.3024 , df=3  
likelihood ratio test: chi2=3.2839 , p=0.3499 , df=3  
parameter F test: F=0.6835 , p=0.5842 , df\_denom=9, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=1.1181 , p=0.4290 , df\_denom=6, df\_num=4  
ssr based chi2 test: chi2=11.1808 , p=0.0246 , df=4  
likelihood ratio test: chi2=8.3546 , p=0.0794 , df=4  
parameter F test: F=1.1181 , p=0.4290 , df\_denom=6, df\_num=4

$H_0: PAT\_P \rightarrow TUI$

$H_a: PAT\_P \rightarrow TUI$

Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=0.1295 , p=0.7240 , df\_denom=15, df\_num=1  
ssr based chi2 test: chi2=0.1553 , p=0.6935 , df=1  
likelihood ratio test: chi2=0.1547 , p=0.6941 , df=1  
parameter F test: F=0.1295 , p=0.7240 , df\_denom=15, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=0.4981 , p=0.6197 , df\_denom=12, df\_num=2  
ssr based chi2 test: chi2=1.4113 , p=0.4938 , df=2  
likelihood ratio test: chi2=1.3557 , p=0.5077 , df=2  
parameter F test: F=0.4981 , p=0.6197 , df\_denom=12, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=0.8509 , p=0.5004 , df\_denom=9, df\_num=3  
ssr based chi2 test: chi2=4.5380 , p=0.2089 , df=3  
likelihood ratio test: chi2=3.9950 , p=0.2620 , df=3  
parameter F test: F=0.8509 , p=0.5004 , df\_denom=9, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=1.2928 , p=0.3701 , df\_denom=6, df\_num=4  
ssr based chi2 test: chi2=12.9278 , p=0.0116 , df=4  
likelihood ratio test: chi2=9.3236 , p=0.0535 , df=4  
parameter F test: F=1.2928 , p=0.3701 , df\_denom=6, df\_num=4

$H_0: TUI \rightarrow PAT\_P$

$H_a: TUI \nrightarrow PAT\_P$

Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=1.0481 , p=0.3222 , df\_denom=15, df\_num=1  
ssr based chi2 test: chi2=1.2578 , p=0.2621 , df=1  
likelihood ratio test: chi2=1.2158 , p=0.2702 , df=1  
parameter F test: F=1.0481 , p=0.3222 , df\_denom=15, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=0.5401 , p=0.5962 , df\_denom=12, df\_num=2  
ssr based chi2 test: chi2=1.5303 , p=0.4653 , df=2  
likelihood ratio test: chi2=1.4653 , p=0.4806 , df=2  
parameter F test: F=0.5401 , p=0.5962 , df\_denom=12, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=0.5241 , p=0.6765 , df\_denom=9, df\_num=3  
ssr based chi2 test: chi2=2.7951 , p=0.4243 , df=3  
likelihood ratio test: chi2=2.5761 , p=0.4617 , df=3  
parameter F test: F=0.5241 , p=0.6765 , df\_denom=9, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=0.7167 , p=0.6104 , df\_denom=6, df\_num=4  
ssr based chi2 test: chi2=7.1667 , p=0.1273 , df=4  
likelihood ratio test: chi2=5.8581 , p=0.2100 , df=4  
parameter F test: F=0.7167 , p=0.6104 , df\_denom=6, df\_num=4

$H_0: POP \rightarrow TUI$

$H_a: POP \nrightarrow TUI$

Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=0.0628 , p=0.8056 , df\_denom=15, df\_num=1  
ssr based chi2 test: chi2=0.0753 , p=0.7838 , df=1  
likelihood ratio test: chi2=0.0751 , p=0.7840 , df=1  
parameter F test: F=0.0628 , p=0.8056 , df\_denom=15, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=0.4040 , p=0.6764 , df\_denom=12, df\_num=2  
ssr based chi2 test: chi2=1.1446 , p=0.5642 , df=2  
likelihood ratio test: chi2=1.1077 , p=0.5747 , df=2  
parameter F test: F=0.4040 , p=0.6764 , df\_denom=12, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=0.7825 , p=0.5330 , df\_denom=9, df\_num=3  
ssr based chi2 test: chi2=4.1732 , p=0.2434 , df=3  
likelihood ratio test: chi2=3.7083 , p=0.2947 , df=3  
parameter F test: F=0.7825 , p=0.5330 , df\_denom=9, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=1.5783 , p=0.2937 , df\_denom=6, df\_num=4  
ssr based chi2 test: chi2=15.7831 , p=0.0033 , df=4  
likelihood ratio test: chi2=10.7837 , p=0.0291 , df=4  
parameter F test: F=1.5783 , p=0.2937 , df\_denom=6, df\_num=4

$H_0: TUI \rightarrow POP$

$H_a: TUI \nrightarrow POP$

Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=2.1017 , p=0.1677 , df\_denom=15, df\_num=1  
ssr based chi2 test: chi2=2.5221 , p=0.1123 , df=1  
likelihood ratio test: chi2=2.3603 , p=0.1245 , df=1  
parameter F test: F=2.1017 , p=0.1677 , df\_denom=15, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=0.9448 , p=0.4159 , df\_denom=12, df\_num=2  
ssr based chi2 test: chi2=2.6770 , p=0.2622 , df=2  
likelihood ratio test: chi2=2.4860 , p=0.2885 , df=2  
parameter F test: F=0.9448 , p=0.4159 , df\_denom=12, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=0.4905 , p=0.6975 , df\_denom=9, df\_num=3  
ssr based chi2 test: chi2=2.6158 , p=0.4547 , df=3  
likelihood ratio test: chi2=2.4228 , p=0.4894 , df=3  
parameter F test: F=0.4905 , p=0.6975 , df\_denom=9, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=0.7588 , p=0.5880 , df\_denom=6, df\_num=4  
ssr based chi2 test: chi2=7.5884 , p=0.1079 , df=4  
likelihood ratio test: chi2=6.1408 , p=0.1889 , df=4  
parameter F test: F=0.7588 , p=0.5880 , df\_denom=6, df\_num=4

2004-2022 m. visi rodikliai

$H_0: MIŠK\_D \rightarrow TUI$

$H_a: MIŠK\_D \nrightarrow TUI$

Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=0.2771 , p=0.6063 , df\_denom=15, df\_num=1  
ssr based chi2 test: chi2=0.3325 , p=0.5642 , df=1  
likelihood ratio test: chi2=0.3295 , p=0.5660 , df=1  
parameter F test: F=0.2771 , p=0.6063 , df\_denom=15, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=0.4775 , p=0.6316 , df\_denom=12, df\_num=2  
ssr based chi2 test: chi2=1.3530 , p=0.5084 , df=2  
likelihood ratio test: chi2=1.3019 , p=0.5216 , df=2  
parameter F test: F=0.4775 , p=0.6316 , df\_denom=12, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=0.2584 , p=0.8536 , df\_denom=9, df\_num=3  
ssr based chi2 test: chi2=1.3782 , p=0.7106 , df=3  
likelihood ratio test: chi2=1.3221 , p=0.7239 , df=3  
parameter F test: F=0.2584 , p=0.8536 , df\_denom=9, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=0.1125 , p=0.9734 , df\_denom=6, df\_num=4  
ssr based chi2 test: chi2=1.1254 , p=0.8902 , df=4  
likelihood ratio test: chi2=1.0852 , p=0.8966 , df=4  
parameter F test: F=0.1125 , p=0.9734 , df\_denom=6, df\_num=4

$H_0: TUI \rightarrow MIŠK\_D$

$H_a: TUI \nrightarrow MIŠK\_D$

Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=0.5120 , p=0.4853 , df\_denom=15, df\_num=1  
ssr based chi2 test: chi2=0.6144 , p=0.4331 , df=1  
likelihood ratio test: chi2=0.6041 , p=0.4370 , df=1  
parameter F test: F=0.5120 , p=0.4853 , df\_denom=15, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=0.2301 , p=0.7979 , df\_denom=12, df\_num=2  
ssr based chi2 test: chi2=0.6519 , p=0.7219 , df=2  
likelihood ratio test: chi2=0.6397 , p=0.7263 , df=2  
parameter F test: F=0.2301 , p=0.7979 , df\_denom=12, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=0.8583 , p=0.4970 , df\_denom=9, df\_num=3  
ssr based chi2 test: chi2=4.5774 , p=0.2055 , df=3  
likelihood ratio test: chi2=4.0257 , p=0.2587 , df=3  
parameter F test: F=0.8583 , p=0.4970 , df\_denom=9, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=0.5904 , p=0.6825 , df\_denom=6, df\_num=4  
ssr based chi2 test: chi2=5.9041 , p=0.2064 , df=4  
likelihood ratio test: chi2=4.9784 , p=0.2895 , df=4  
parameter F test: F=0.5904 , p=0.6825 , df\_denom=6, df\_num=4

$H_0: ŽŮŽM \rightarrow TUI$

$H_a: ŽŮŽM \nrightarrow TUI$

Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=2.0585 , p=0.1719 , df\_denom=15, df\_num=1  
ssr based chi2 test: chi2=2.4702 , p=0.1160 , df=1  
likelihood ratio test: chi2=2.3147 , p=0.1282 , df=1  
parameter F test: F=2.0585 , p=0.1719 , df\_denom=15, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=1.2234 , p=0.3284 , df\_denom=12, df\_num=2  
ssr based chi2 test: chi2=3.4662 , p=0.1767 , df=2  
likelihood ratio test: chi2=3.1546 , p=0.2065 , df=2  
parameter F test: F=1.2234 , p=0.3284 , df\_denom=12, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=0.8153 , p=0.5171 , df\_denom=9, df\_num=3  
ssr based chi2 test: chi2=4.3481 , p=0.2262 , df=3  
likelihood ratio test: chi2=3.8464 , p=0.2785 , df=3  
parameter F test: F=0.8153 , p=0.5171 , df\_denom=9, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=0.6926 , p=0.6236 , df\_denom=6, df\_num=4  
ssr based chi2 test: chi2=6.9261 , p=0.1398 , df=4  
likelihood ratio test: chi2=5.6944 , p=0.2232 , df=4  
parameter F test: F=0.6926 , p=0.6236 , df\_denom=6, df\_num=4

$H_0: TUI \rightarrow \check{Z}\check{U}\check{Z}M$

$H_a: TUI \nrightarrow \check{Z}\check{U}\check{Z}M$

Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=0.7727 , p=0.3932 , df\_denom=15, df\_num=1  
ssr based chi2 test: chi2=0.9273 , p=0.3356 , df=1  
likelihood ratio test: chi2=0.9042 , p=0.3417 , df=1  
parameter F test: F=0.7727 , p=0.3932 , df\_denom=15, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=1.2497 , p=0.3213 , df\_denom=12, df\_num=2  
ssr based chi2 test: chi2=3.5409 , p=0.1703 , df=2  
likelihood ratio test: chi2=3.2165 , p=0.2002 , df=2  
parameter F test: F=1.2497 , p=0.3213 , df\_denom=12, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=0.9976 , p=0.4373 , df\_denom=9, df\_num=3  
ssr based chi2 test: chi2=5.3203 , p=0.1498 , df=3  
likelihood ratio test: chi2=4.5931 , p=0.2041 , df=3  
parameter F test: F=0.9976 , p=0.4373 , df\_denom=9, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=0.5086 , p=0.7329 , df\_denom=6, df\_num=4  
ssr based chi2 test: chi2=5.0856 , p=0.2786 , df=4  
likelihood ratio test: chi2=4.3793 , p=0.3571 , df=4  
parameter F test: F=0.5086 , p=0.7329 , df\_denom=6, df\_num=4

$H_0: PAT\_P \rightarrow TUI$

$H_a: PAT\_P \nrightarrow TUI$

Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=0.1295 , p=0.7240 , df\_denom=15, df\_num=1  
ssr based chi2 test: chi2=0.1553 , p=0.6935 , df=1  
likelihood ratio test: chi2=0.1547 , p=0.6941 , df=1  
parameter F test: F=0.1295 , p=0.7240 , df\_denom=15, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=0.4981 , p=0.6197 , df\_denom=12, df\_num=2  
ssr based chi2 test: chi2=1.4113 , p=0.4938 , df=2  
likelihood ratio test: chi2=1.3557 , p=0.5077 , df=2  
parameter F test: F=0.4981 , p=0.6197 , df\_denom=12, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=0.8509 , p=0.5004 , df\_denom=9, df\_num=3  
ssr based chi2 test: chi2=4.5380 , p=0.2089 , df=3  
likelihood ratio test: chi2=3.9950 , p=0.2620 , df=3  
parameter F test: F=0.8509 , p=0.5004 , df\_denom=9, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=1.2928 , p=0.3701 , df\_denom=6, df\_num=4  
ssr based chi2 test: chi2=12.9278 , p=0.0116 , df=4  
likelihood ratio test: chi2=9.3236 , p=0.0535 , df=4  
parameter F test: F=1.2928 , p=0.3701 , df\_denom=6, df\_num=4

$H_0: TUI \rightarrow PAT\_P$

$H_a: TUI \nrightarrow PAT\_P$

Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=1.0481 , p=0.3222 , df\_denom=15, df\_num=1  
ssr based chi2 test: chi2=1.2578 , p=0.2621 , df=1  
likelihood ratio test: chi2=1.2158 , p=0.2702 , df=1  
parameter F test: F=1.0481 , p=0.3222 , df\_denom=15, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=0.5401 , p=0.5962 , df\_denom=12, df\_num=2  
ssr based chi2 test: chi2=1.5303 , p=0.4653 , df=2  
likelihood ratio test: chi2=1.4653 , p=0.4806 , df=2  
parameter F test: F=0.5401 , p=0.5962 , df\_denom=12, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=0.5241 , p=0.6765 , df\_denom=9, df\_num=3  
ssr based chi2 test: chi2=2.7951 , p=0.4243 , df=3  
likelihood ratio test: chi2=2.5761 , p=0.4617 , df=3  
parameter F test: F=0.5241 , p=0.6765 , df\_denom=9, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=0.7167 , p=0.6104 , df\_denom=6, df\_num=4  
ssr based chi2 test: chi2=7.1667 , p=0.1273 , df=4  
likelihood ratio test: chi2=5.8581 , p=0.2100 , df=4  
parameter F test: F=0.7167 , p=0.6104 , df\_denom=6, df\_num=4

$H_0: VER\_P\_I\check{S} \rightarrow TUI$

$H_a: VER\_P\_I\check{S} \nrightarrow TUI$

Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=1.3675 , p=0.2605 , df\_denom=15, df\_num=1  
ssr based chi2 test: chi2=1.6410 , p=0.2002 , df=1  
likelihood ratio test: chi2=1.5704 , p=0.2101 , df=1  
parameter F test: F=1.3675 , p=0.2605 , df\_denom=15, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=0.1451 , p=0.8664 , df\_denom=12, df\_num=2  
ssr based chi2 test: chi2=0.4111 , p=0.8142 , df=2  
likelihood ratio test: chi2=0.4062 , p=0.8162 , df=2  
parameter F test: F=0.1451 , p=0.8664 , df\_denom=12, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=0.0654 , p=0.9769 , df\_denom=9, df\_num=3  
ssr based chi2 test: chi2=0.3490 , p=0.9506 , df=3  
likelihood ratio test: chi2=0.3452 , p=0.9513 , df=3  
parameter F test: F=0.0654 , p=0.9769 , df\_denom=9, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=0.1034 , p=0.9771 , df\_denom=6, df\_num=4  
ssr based chi2 test: chi2=1.0341 , p=0.9046 , df=4  
likelihood ratio test: chi2=1.0000 , p=0.9098 , df=4  
parameter F test: F=0.1034 , p=0.9771 , df\_denom=6, df\_num=4

$H_0: TUI \rightarrow VER\_P\_I\check{S}$

$H_a: TUI \nrightarrow VER\_P\_I\check{S}$

Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=0.6500 , p=0.4327 , df\_denom=15, df\_num=1  
ssr based chi2 test: chi2=0.7799 , p=0.3772 , df=1  
likelihood ratio test: chi2=0.7635 , p=0.3822 , df=1  
parameter F test: F=0.6500 , p=0.4327 , df\_denom=15, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=0.6450 , p=0.5419 , df\_denom=12, df\_num=2  
ssr based chi2 test: chi2=1.8276 , p=0.4010 , df=2  
likelihood ratio test: chi2=1.7359 , p=0.4198 , df=2  
parameter F test: F=0.6450 , p=0.5419 , df\_denom=12, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=1.8275 , p=0.2123 , df\_denom=9, df\_num=3  
ssr based chi2 test: chi2=9.7466 , p=0.0208 , df=3  
likelihood ratio test: chi2=7.6114 , p=0.0548 , df=3  
parameter F test: F=1.8275 , p=0.2123 , df\_denom=9, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=1.9509 , p=0.2214 , df\_denom=6, df\_num=4  
ssr based chi2 test: chi2=19.5092 , p=0.0006 , df=4  
likelihood ratio test: chi2=12.4976 , p=0.0140 , df=4  
parameter F test: F=1.9509 , p=0.2214 , df\_denom=6, df\_num=4

*Danija*

1986-2003 m.

$H_0: PREKYBA \rightarrow TUI$

$H_a: PREKYBA \nrightarrow TUI$



Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=3.6649 , p=0.0762 , df\_denom=14, df\_num=1  
ssr based chi2 test: chi2=4.4503 , p=0.0349 , df=1  
likelihood ratio test: chi2=3.9529 , p=0.0468 , df=1  
parameter F test: F=3.6649 , p=0.0762 , df\_denom=14, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=2.8769 , p=0.0989 , df\_denom=11, df\_num=2  
ssr based chi2 test: chi2=8.3693 , p=0.0152 , df=2  
likelihood ratio test: chi2=6.7317 , p=0.0345 , df=2  
parameter F test: F=2.8769 , p=0.0989 , df\_denom=11, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=1.8603 , p=0.2146 , df\_denom=8, df\_num=3  
ssr based chi2 test: chi2=10.4640 , p=0.0150 , df=3  
likelihood ratio test: chi2=7.9383 , p=0.0473 , df=3  
parameter F test: F=1.8603 , p=0.2146 , df\_denom=8, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=1.1131 , p=0.4432 , df\_denom=5, df\_num=4  
ssr based chi2 test: chi2=12.4664 , p=0.0142 , df=4  
likelihood ratio test: chi2=8.9155 , p=0.0632 , df=4  
parameter F test: F=1.1131 , p=0.4432 , df\_denom=5, df\_num=4

$H_0: TUI \rightarrow PREKYBA$

$H_a: TUI \nrightarrow PREKYBA$

Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=0.2527 , p=0.6230 , df\_denom=14, df\_num=1  
ssr based chi2 test: chi2=0.3068 , p=0.5796 , df=1  
likelihood ratio test: chi2=0.3041 , p=0.5813 , df=1  
parameter F test: F=0.2527 , p=0.6230 , df\_denom=14, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=1.3358 , p=0.3024 , df\_denom=11, df\_num=2  
ssr based chi2 test: chi2=3.8860 , p=0.1433 , df=2  
likelihood ratio test: chi2=3.4788 , p=0.1756 , df=2  
parameter F test: F=1.3358 , p=0.3024 , df\_denom=11, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=1.8920 , p=0.2094 , df\_denom=8, df\_num=3  
ssr based chi2 test: chi2=10.6425 , p=0.0138 , df=3  
likelihood ratio test: chi2=8.0430 , p=0.0451 , df=3  
parameter F test: F=1.8920 , p=0.2094 , df\_denom=8, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=1.5187 , p=0.3248 , df\_denom=5, df\_num=4  
ssr based chi2 test: chi2=17.0090 , p=0.0019 , df=4  
likelihood ratio test: chi2=11.1331 , p=0.0251 , df=4  
parameter F test: F=1.5187 , p=0.3248 , df\_denom=5, df\_num=4

$H_0: NAT\_R\_N \rightarrow TUI$

$H_a: NAT\_R\_N \nrightarrow TUI$

```

Granger Causality
number of lags (no zero) 1
ssr based F test:      F=2.8709 , p=0.1123 , df_denom=14, df_num=1
ssr based chi2 test:  chi2=3.4860 , p=0.0619 , df=1
likelihood ratio test: chi2=3.1710 , p=0.0750 , df=1
parameter F test:     F=2.8709 , p=0.1123 , df_denom=14, df_num=1

Granger Causality
number of lags (no zero) 2
ssr based F test:      F=2.0144 , p=0.1797 , df_denom=11, df_num=2
ssr based chi2 test:  chi2=5.8602 , p=0.0534 , df=2
likelihood ratio test: chi2=4.9932 , p=0.0824 , df=2
parameter F test:     F=2.0144 , p=0.1797 , df_denom=11, df_num=2

Granger Causality
number of lags (no zero) 3
ssr based F test:      F=10.1762 , p=0.0042 , df_denom=8, df_num=3
ssr based chi2 test:  chi2=57.2414 , p=0.0000 , df=3
likelihood ratio test: chi2=23.5794 , p=0.0000 , df=3
parameter F test:     F=10.1762 , p=0.0042 , df_denom=8, df_num=3

Granger Causality
number of lags (no zero) 4
ssr based F test:      F=7.3444 , p=0.0253 , df_denom=5, df_num=4
ssr based chi2 test:  chi2=82.2577 , p=0.0000 , df=4
likelihood ratio test: chi2=26.9916 , p=0.0000 , df=4
parameter F test:     F=7.3444 , p=0.0253 , df_denom=5, df_num=4

```

---

$H_0: TUI \rightarrow NAT\_R\_N$

$H_a: TUI \nrightarrow NAT\_R\_N$

```

Granger Causality
number of lags (no zero) 1
ssr based F test:      F=3.5124 , p=0.0819 , df_denom=14, df_num=1
ssr based chi2 test:  chi2=4.2651 , p=0.0389 , df=1
likelihood ratio test: chi2=3.8055 , p=0.0511 , df=1
parameter F test:     F=3.5124 , p=0.0819 , df_denom=14, df_num=1

Granger Causality
number of lags (no zero) 2
ssr based F test:      F=1.5900 , p=0.2474 , df_denom=11, df_num=2
ssr based chi2 test:  chi2=4.6253 , p=0.0990 , df=2
likelihood ratio test: chi2=4.0629 , p=0.1311 , df=2
parameter F test:     F=1.5900 , p=0.2474 , df_denom=11, df_num=2

Granger Causality
number of lags (no zero) 3
ssr based F test:      F=2.7110 , p=0.1153 , df_denom=8, df_num=3
ssr based chi2 test:  chi2=15.2495 , p=0.0016 , df=3
likelihood ratio test: chi2=10.5215 , p=0.0146 , df=3
parameter F test:     F=2.7110 , p=0.1153 , df_denom=8, df_num=3

Granger Causality
number of lags (no zero) 4
ssr based F test:      F=1.3789 , p=0.3603 , df_denom=5, df_num=4
ssr based chi2 test:  chi2=15.4433 , p=0.0039 , df=4
likelihood ratio test: chi2=10.4077 , p=0.0341 , df=4
parameter F test:     F=1.3789 , p=0.3603 , df_denom=5, df_num=4

```

2004-2022 m.

$H_0: PREKYBA \rightarrow TUI$

$H_a: PREKYBA \nrightarrow TUI$

Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=1.6428 , p=0.2194 , df\_denom=15, df\_num=1  
ssr based chi2 test: chi2=1.9714 , p=0.1603 , df=1  
likelihood ratio test: chi2=1.8707 , p=0.1714 , df=1  
parameter F test: F=1.6428 , p=0.2194 , df\_denom=15, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=1.0028 , p=0.3956 , df\_denom=12, df\_num=2  
ssr based chi2 test: chi2=2.8412 , p=0.2416 , df=2  
likelihood ratio test: chi2=2.6273 , p=0.2688 , df=2  
parameter F test: F=1.0028 , p=0.3956 , df\_denom=12, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=0.8354 , p=0.5076 , df\_denom=9, df\_num=3  
ssr based chi2 test: chi2=4.4555 , p=0.2163 , df=3  
likelihood ratio test: chi2=3.9306 , p=0.2691 , df=3  
parameter F test: F=0.8354 , p=0.5076 , df\_denom=9, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=0.3633 , p=0.8269 , df\_denom=6, df\_num=4  
ssr based chi2 test: chi2=3.6326 , p=0.4580 , df=4  
likelihood ratio test: chi2=3.2530 , p=0.5164 , df=4  
parameter F test: F=0.3633 , p=0.8269 , df\_denom=6, df\_num=4

$H_0: TUI \rightarrow PREKYBA$

$H_a: TUI \nrightarrow PREKYBA$

Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=0.0613 , p=0.8077 , df\_denom=15, df\_num=1  
ssr based chi2 test: chi2=0.0736 , p=0.7861 , df=1  
likelihood ratio test: chi2=0.0735 , p=0.7864 , df=1  
parameter F test: F=0.0613 , p=0.8077 , df\_denom=15, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=0.6295 , p=0.5496 , df\_denom=12, df\_num=2  
ssr based chi2 test: chi2=1.7835 , p=0.4099 , df=2  
likelihood ratio test: chi2=1.6960 , p=0.4283 , df=2  
parameter F test: F=0.6295 , p=0.5496 , df\_denom=12, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=1.6265 , p=0.2511 , df\_denom=9, df\_num=3  
ssr based chi2 test: chi2=8.6748 , p=0.0339 , df=3  
likelihood ratio test: chi2=6.9311 , p=0.0741 , df=3  
parameter F test: F=1.6265 , p=0.2511 , df\_denom=9, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=7.9790 , p=0.0140 , df\_denom=6, df\_num=4  
ssr based chi2 test: chi2=79.7905 , p=0.0000 , df=4  
likelihood ratio test: chi2=27.6543 , p=0.0000 , df=4  
parameter F test: F=7.9790 , p=0.0140 , df\_denom=6, df\_num=4

$H_0: ARM_{\check{Z}} \rightarrow TUI$

$H_a: ARM_{\check{Z}} \nrightarrow TUI$

Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=1.4017 , p=0.2549 , df\_denom=15, df\_num=1  
ssr based chi2 test: chi2=1.6821 , p=0.1947 , df=1  
likelihood ratio test: chi2=1.6080 , p=0.2048 , df=1  
parameter F test: F=1.4017 , p=0.2549 , df\_denom=15, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=1.3421 , p=0.2978 , df\_denom=12, df\_num=2  
ssr based chi2 test: chi2=3.8027 , p=0.1494 , df=2  
likelihood ratio test: chi2=3.4318 , p=0.1798 , df=2  
parameter F test: F=1.3421 , p=0.2978 , df\_denom=12, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=3.4950 , p=0.0630 , df\_denom=9, df\_num=3  
ssr based chi2 test: chi2=18.6398 , p=0.0003 , df=3  
likelihood ratio test: chi2=12.3586 , p=0.0063 , df=3  
parameter F test: F=3.4950 , p=0.0630 , df\_denom=9, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=0.5058 , p=0.7346 , df\_denom=6, df\_num=4  
ssr based chi2 test: chi2=5.0581 , p=0.2814 , df=4  
likelihood ratio test: chi2=4.3587 , p=0.3596 , df=4  
parameter F test: F=0.5058 , p=0.7346 , df\_denom=6, df\_num=4

$H_0: TUI \rightarrow ARM_{\check{Z}}$

$H_a: TUI \nrightarrow ARM_{\check{Z}}$

Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=8.8330 , p=0.0095 , df\_denom=15, df\_num=1  
ssr based chi2 test: chi2=10.5995 , p=0.0011 , df=1  
likelihood ratio test: chi2=8.3343 , p=0.0039 , df=1  
parameter F test: F=8.8330 , p=0.0095 , df\_denom=15, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=3.2285 , p=0.0755 , df\_denom=12, df\_num=2  
ssr based chi2 test: chi2=9.1475 , p=0.0103 , df=2  
likelihood ratio test: chi2=7.3192 , p=0.0257 , df=2  
parameter F test: F=3.2285 , p=0.0755 , df\_denom=12, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=6.4479 , p=0.0127 , df\_denom=9, df\_num=3  
ssr based chi2 test: chi2=34.3885 , p=0.0000 , df=3  
likelihood ratio test: chi2=18.3548 , p=0.0004 , df=3  
parameter F test: F=6.4479 , p=0.0127 , df\_denom=9, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=6.1209 , p=0.0260 , df\_denom=6, df\_num=4  
ssr based chi2 test: chi2=61.2089 , p=0.0000 , df=4  
likelihood ratio test: chi2=24.3814 , p=0.0001 , df=4  
parameter F test: F=6.1209 , p=0.0260 , df\_denom=6, df\_num=4

2004-2022 m. visi rodikliai

$H_0: U\check{Z}_T \rightarrow TUI$

$H_a: U\check{Z}_T \nrightarrow TUI$

Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=0.1591 , p=0.6956 , df\_denom=15, df\_num=1  
ssr based chi2 test: chi2=0.1909 , p=0.6621 , df=1  
likelihood ratio test: chi2=0.1899 , p=0.6630 , df=1  
parameter F test: F=0.1591 , p=0.6956 , df\_denom=15, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=0.2692 , p=0.7685 , df\_denom=12, df\_num=2  
ssr based chi2 test: chi2=0.7627 , p=0.6830 , df=2  
likelihood ratio test: chi2=0.7460 , p=0.6887 , df=2  
parameter F test: F=0.2692 , p=0.7685 , df\_denom=12, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=0.4249 , p=0.7399 , df\_denom=9, df\_num=3  
ssr based chi2 test: chi2=2.2664 , p=0.5190 , df=3  
likelihood ratio test: chi2=2.1196 , p=0.5480 , df=3  
parameter F test: F=0.4249 , p=0.7399 , df\_denom=9, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=0.9417 , p=0.5001 , df\_denom=6, df\_num=4  
ssr based chi2 test: chi2=9.4170 , p=0.0515 , df=4  
likelihood ratio test: chi2=7.3084 , p=0.1205 , df=4  
parameter F test: F=0.9417 , p=0.5001 , df\_denom=6, df\_num=4

$H_0: TUI \rightarrow U\check{Z}_T$

$H_a: TUI \nrightarrow U\check{Z}_T$

Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=6.7170 , p=0.0204 , df\_denom=15, df\_num=1  
ssr based chi2 test: chi2=8.0604 , p=0.0045 , df=1  
likelihood ratio test: chi2=6.6608 , p=0.0099 , df=1  
parameter F test: F=6.7170 , p=0.0204 , df\_denom=15, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=3.5528 , p=0.0614 , df\_denom=12, df\_num=2  
ssr based chi2 test: chi2=10.0662 , p=0.0065 , df=2  
likelihood ratio test: chi2=7.9062 , p=0.0192 , df=2  
parameter F test: F=3.5528 , p=0.0614 , df\_denom=12, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=1.7711 , p=0.2224 , df\_denom=9, df\_num=3  
ssr based chi2 test: chi2=9.4458 , p=0.0239 , df=3  
likelihood ratio test: chi2=7.4234 , p=0.0596 , df=3  
parameter F test: F=1.7711 , p=0.2224 , df\_denom=9, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=1.3134 , p=0.3638 , df\_denom=6, df\_num=4  
ssr based chi2 test: chi2=13.1344 , p=0.0106 , df=4  
likelihood ratio test: chi2=9.4342 , p=0.0511 , df=4  
parameter F test: F=1.3134 , p=0.3638 , df\_denom=6, df\_num=4

$H_0: BVP_G \rightarrow TUI$

$H_a: BVP_G \nrightarrow TUI$

Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=0.2120 , p=0.6518 , df\_denom=15, df\_num=1  
ssr based chi2 test: chi2=0.2544 , p=0.6140 , df=1  
likelihood ratio test: chi2=0.2526 , p=0.6153 , df=1  
parameter F test: F=0.2120 , p=0.6518 , df\_denom=15, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=1.0719 , p=0.3730 , df\_denom=12, df\_num=2  
ssr based chi2 test: chi2=3.0369 , p=0.2190 , df=2  
likelihood ratio test: chi2=2.7942 , p=0.2473 , df=2  
parameter F test: F=1.0719 , p=0.3730 , df\_denom=12, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=1.2122 , p=0.3601 , df\_denom=9, df\_num=3  
ssr based chi2 test: chi2=6.4652 , p=0.0910 , df=3  
likelihood ratio test: chi2=5.4300 , p=0.1429 , df=3  
parameter F test: F=1.2122 , p=0.3601 , df\_denom=9, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=1.8591 , p=0.2369 , df\_denom=6, df\_num=4  
ssr based chi2 test: chi2=18.5915 , p=0.0009 , df=4  
likelihood ratio test: chi2=12.0933 , p=0.0167 , df=4  
parameter F test: F=1.8591 , p=0.2369 , df\_denom=6, df\_num=4

$H_0: TUI \rightarrow BVP\_G$

$H_a: TUI \nrightarrow BVP\_G$

Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=0.0734 , p=0.7901 , df\_denom=15, df\_num=1  
ssr based chi2 test: chi2=0.0881 , p=0.7666 , df=1  
likelihood ratio test: chi2=0.0879 , p=0.7669 , df=1  
parameter F test: F=0.0734 , p=0.7901 , df\_denom=15, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=0.7325 , p=0.5010 , df\_denom=12, df\_num=2  
ssr based chi2 test: chi2=2.0754 , p=0.3543 , df=2  
likelihood ratio test: chi2=1.9582 , p=0.3757 , df=2  
parameter F test: F=0.7325 , p=0.5010 , df\_denom=12, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=1.3716 , p=0.3127 , df\_denom=9, df\_num=3  
ssr based chi2 test: chi2=7.3153 , p=0.0625 , df=3  
likelihood ratio test: chi2=6.0243 , p=0.1104 , df=3  
parameter F test: F=1.3716 , p=0.3127 , df\_denom=9, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=2.6237 , p=0.1400 , df\_denom=6, df\_num=4  
ssr based chi2 test: chi2=26.2371 , p=0.0000 , df=4  
likelihood ratio test: chi2=15.1693 , p=0.0044 , df=4  
parameter F test: F=2.6237 , p=0.1400 , df\_denom=6, df\_num=4

Airija

1986-2003 m.

$H_0: NEDAR \rightarrow TUI$

$H_a: NEDAR \nrightarrow TUI$

Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=0.0846 , p=0.7754 , df\_denom=14, df\_num=1  
ssr based chi2 test: chi2=0.1027 , p=0.7486 , df=1  
likelihood ratio test: chi2=0.1024 , p=0.7490 , df=1  
parameter F test: F=0.0846 , p=0.7754 , df\_denom=14, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=0.3694 , p=0.6994 , df\_denom=11, df\_num=2  
ssr based chi2 test: chi2=1.0747 , p=0.5843 , df=2  
likelihood ratio test: chi2=1.0402 , p=0.5945 , df=2  
parameter F test: F=0.3694 , p=0.6994 , df\_denom=11, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=0.6744 , p=0.5916 , df\_denom=8, df\_num=3  
ssr based chi2 test: chi2=3.7933 , p=0.2847 , df=3  
likelihood ratio test: chi2=3.3818 , p=0.3364 , df=3  
parameter F test: F=0.6744 , p=0.5916 , df\_denom=8, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=0.4846 , p=0.7487 , df\_denom=5, df\_num=4  
ssr based chi2 test: chi2=5.4278 , p=0.2461 , df=4  
likelihood ratio test: chi2=4.5871 , p=0.3323 , df=4  
parameter F test: F=0.4846 , p=0.7487 , df\_denom=5, df\_num=4

$H_0: TUI \rightarrow NEDAR$

$H_a: TUI \nrightarrow NEDAR$

Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=16.5035 , p=0.0012 , df\_denom=14, df\_num=1  
ssr based chi2 test: chi2=20.0400 , p=0.0000 , df=1  
likelihood ratio test: chi2=13.2393 , p=0.0003 , df=1  
parameter F test: F=16.5035 , p=0.0012 , df\_denom=14, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=4.4892 , p=0.0375 , df\_denom=11, df\_num=2  
ssr based chi2 test: chi2=13.0595 , p=0.0015 , df=2  
likelihood ratio test: chi2=9.5481 , p=0.0084 , df=2  
parameter F test: F=4.4892 , p=0.0375 , df\_denom=11, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=2.9027 , p=0.1014 , df\_denom=8, df\_num=3  
ssr based chi2 test: chi2=16.3278 , p=0.0010 , df=3  
likelihood ratio test: chi2=11.0468 , p=0.0115 , df=3  
parameter F test: F=2.9027 , p=0.1014 , df\_denom=8, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=1.4224 , p=0.3487 , df\_denom=5, df\_num=4  
ssr based chi2 test: chi2=15.9312 , p=0.0031 , df=4  
likelihood ratio test: chi2=10.6378 , p=0.0310 , df=4  
parameter F test: F=1.4224 , p=0.3487 , df\_denom=5, df\_num=4

$H_0: INFL \rightarrow TUI$

$H_a: INFL \nrightarrow TUI$

Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=4.0708 , p=0.0632 , df\_denom=14, df\_num=1  
ssr based chi2 test: chi2=4.9431 , p=0.0262 , df=1  
likelihood ratio test: chi2=4.3391 , p=0.0372 , df=1  
parameter F test: F=4.0708 , p=0.0632 , df\_denom=14, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=3.0949 , p=0.0858 , df\_denom=11, df\_num=2  
ssr based chi2 test: chi2=9.0033 , p=0.0111 , df=2  
likelihood ratio test: chi2=7.1427 , p=0.0281 , df=2  
parameter F test: F=3.0949 , p=0.0858 , df\_denom=11, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=2.9389 , p=0.0990 , df\_denom=8, df\_num=3  
ssr based chi2 test: chi2=16.5315 , p=0.0009 , df=3  
likelihood ratio test: chi2=11.1441 , p=0.0110 , df=3  
parameter F test: F=2.9389 , p=0.0990 , df\_denom=8, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=2.3507 , p=0.1869 , df\_denom=5, df\_num=4  
ssr based chi2 test: chi2=26.3274 , p=0.0000 , df=4  
likelihood ratio test: chi2=14.8116 , p=0.0051 , df=4  
parameter F test: F=2.3507 , p=0.1869 , df\_denom=5, df\_num=4

$H_0: TUI \rightarrow INFL$

$H_a: TUI \nrightarrow INFL$

Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=1.1990 , p=0.2920 , df\_denom=14, df\_num=1  
ssr based chi2 test: chi2=1.4559 , p=0.2276 , df=1  
likelihood ratio test: chi2=1.3969 , p=0.2372 , df=1  
parameter F test: F=1.1990 , p=0.2920 , df\_denom=14, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=2.7144 , p=0.1101 , df\_denom=11, df\_num=2  
ssr based chi2 test: chi2=7.8965 , p=0.0193 , df=2  
likelihood ratio test: chi2=6.4183 , p=0.0404 , df=2  
parameter F test: F=2.7144 , p=0.1101 , df\_denom=11, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=2.5902 , p=0.1253 , df\_denom=8, df\_num=3  
ssr based chi2 test: chi2=14.5698 , p=0.0022 , df=3  
likelihood ratio test: chi2=10.1806 , p=0.0171 , df=3  
parameter F test: F=2.5902 , p=0.1253 , df\_denom=8, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=0.5053 , p=0.7359 , df\_denom=5, df\_num=4  
ssr based chi2 test: chi2=5.6595 , p=0.2261 , df=4  
likelihood ratio test: chi2=4.7531 , p=0.3136 , df=4  
parameter F test: F=0.5053 , p=0.7359 , df\_denom=5, df\_num=4

$H_0: PREKYBA \rightarrow TUI$

$H_a: PREKYBA \nrightarrow TUI$



Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=0.4224 , p=0.5263 , df\_denom=14, df\_num=1  
ssr based chi2 test: chi2=0.5129 , p=0.4739 , df=1  
likelihood ratio test: chi2=0.5053 , p=0.4772 , df=1  
parameter F test: F=0.4224 , p=0.5263 , df\_denom=14, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=0.3009 , p=0.7461 , df\_denom=11, df\_num=2  
ssr based chi2 test: chi2=0.8752 , p=0.6456 , df=2  
likelihood ratio test: chi2=0.8521 , p=0.6531 , df=2  
parameter F test: F=0.3009 , p=0.7461 , df\_denom=11, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=2.6331 , p=0.1217 , df\_denom=8, df\_num=3  
ssr based chi2 test: chi2=14.8110 , p=0.0020 , df=3  
likelihood ratio test: chi2=10.3024 , p=0.0162 , df=3  
parameter F test: F=2.6331 , p=0.1217 , df\_denom=8, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=1.6708 , p=0.2912 , df\_denom=5, df\_num=4  
ssr based chi2 test: chi2=18.7134 , p=0.0009 , df=4  
likelihood ratio test: chi2=11.8822 , p=0.0182 , df=4  
parameter F test: F=1.6708 , p=0.2912 , df\_denom=5, df\_num=4

$H_0: TUI \rightarrow PREKYBA$

$H_a: TUI \nrightarrow PREKYBA$

Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=9.7595 , p=0.0075 , df\_denom=14, df\_num=1  
ssr based chi2 test: chi2=11.8508 , p=0.0006 , df=1  
likelihood ratio test: chi2=8.9917 , p=0.0027 , df=1  
parameter F test: F=9.7595 , p=0.0075 , df\_denom=14, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=2.9641 , p=0.0934 , df\_denom=11, df\_num=2  
ssr based chi2 test: chi2=8.6229 , p=0.0134 , df=2  
likelihood ratio test: chi2=6.8974 , p=0.0318 , df=2  
parameter F test: F=2.9641 , p=0.0934 , df\_denom=11, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=2.3435 , p=0.1492 , df\_denom=8, df\_num=3  
ssr based chi2 test: chi2=13.1824 , p=0.0043 , df=3  
likelihood ratio test: chi2=9.4597 , p=0.0238 , df=3  
parameter F test: F=2.3435 , p=0.1492 , df\_denom=8, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=2.5537 , p=0.1658 , df\_denom=5, df\_num=4  
ssr based chi2 test: chi2=28.6010 , p=0.0000 , df=4  
likelihood ratio test: chi2=15.5795 , p=0.0036 , df=4  
parameter F test: F=2.5537 , p=0.1658 , df\_denom=5, df\_num=4

2004-2022 m.

$H_0: PREKYBA \rightarrow TUI$

$H_a: PREKYBA \nrightarrow TUI$

Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=1.5477 , p=0.2326 , df\_denom=15, df\_num=1  
ssr based chi2 test: chi2=1.8573 , p=0.1729 , df=1  
likelihood ratio test: chi2=1.7676 , p=0.1837 , df=1  
parameter F test: F=1.5477 , p=0.2326 , df\_denom=15, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=0.4755 , p=0.6328 , df\_denom=12, df\_num=2  
ssr based chi2 test: chi2=1.3472 , p=0.5099 , df=2  
likelihood ratio test: chi2=1.2964 , p=0.5230 , df=2  
parameter F test: F=0.4755 , p=0.6328 , df\_denom=12, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=1.0111 , p=0.4319 , df\_denom=9, df\_num=3  
ssr based chi2 test: chi2=5.3924 , p=0.1452 , df=3  
likelihood ratio test: chi2=4.6471 , p=0.1995 , df=3  
parameter F test: F=1.0111 , p=0.4319 , df\_denom=9, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=1.7005 , p=0.2671 , df\_denom=6, df\_num=4  
ssr based chi2 test: chi2=17.0046 , p=0.0019 , df=4  
likelihood ratio test: chi2=11.3674 , p=0.0227 , df=4  
parameter F test: F=1.7005 , p=0.2671 , df\_denom=6, df\_num=4

$H_0: TUI \rightarrow PREKYBA$

$H_a: TUI \nrightarrow PREKYBA$

Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=0.2712 , p=0.6101 , df\_denom=15, df\_num=1  
ssr based chi2 test: chi2=0.3254 , p=0.5684 , df=1  
likelihood ratio test: chi2=0.3225 , p=0.5701 , df=1  
parameter F test: F=0.2712 , p=0.6101 , df\_denom=15, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=0.2491 , p=0.7835 , df\_denom=12, df\_num=2  
ssr based chi2 test: chi2=0.7057 , p=0.7027 , df=2  
likelihood ratio test: chi2=0.6914 , p=0.7077 , df=2  
parameter F test: F=0.2491 , p=0.7835 , df\_denom=12, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=0.1830 , p=0.9053 , df\_denom=9, df\_num=3  
ssr based chi2 test: chi2=0.9762 , p=0.8070 , df=3  
likelihood ratio test: chi2=0.9476 , p=0.8139 , df=3  
parameter F test: F=0.1830 , p=0.9053 , df\_denom=9, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=0.2760 , p=0.8834 , df\_denom=6, df\_num=4  
ssr based chi2 test: chi2=2.7598 , p=0.5988 , df=4  
likelihood ratio test: chi2=2.5333 , p=0.6387 , df=4  
parameter F test: F=0.2760 , p=0.8834 , df\_denom=6, df\_num=4

$H_0: NEDAR \rightarrow TUI$

$H_a: NEDAR \nrightarrow TUI$

Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=2.1757 , p=0.1609 , df\_denom=15, df\_num=1  
ssr based chi2 test: chi2=2.6109 , p=0.1061 , df=1  
likelihood ratio test: chi2=2.4380 , p=0.1184 , df=1  
parameter F test: F=2.1757 , p=0.1609 , df\_denom=15, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=0.3612 , p=0.7042 , df\_denom=12, df\_num=2  
ssr based chi2 test: chi2=1.0233 , p=0.5995 , df=2  
likelihood ratio test: chi2=0.9937 , p=0.6085 , df=2  
parameter F test: F=0.3612 , p=0.7042 , df\_denom=12, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=0.1063 , p=0.9543 , df\_denom=9, df\_num=3  
ssr based chi2 test: chi2=0.5671 , p=0.9039 , df=3  
likelihood ratio test: chi2=0.5572 , p=0.9061 , df=3  
parameter F test: F=0.1063 , p=0.9543 , df\_denom=9, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=0.1126 , p=0.9734 , df\_denom=6, df\_num=4  
ssr based chi2 test: chi2=1.1264 , p=0.8901 , df=4  
likelihood ratio test: chi2=1.0861 , p=0.8965 , df=4  
parameter F test: F=0.1126 , p=0.9734 , df\_denom=6, df\_num=4

$H_0: TUI \rightarrow NEDAR$

$H_a: TUI \nrightarrow NEDAR$

Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=2.1994 , p=0.1588 , df\_denom=15, df\_num=1  
ssr based chi2 test: chi2=2.6393 , p=0.1043 , df=1  
likelihood ratio test: chi2=2.4628 , p=0.1166 , df=1  
parameter F test: F=2.1994 , p=0.1588 , df\_denom=15, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=1.9446 , p=0.1856 , df\_denom=12, df\_num=2  
ssr based chi2 test: chi2=5.5096 , p=0.0636 , df=2  
likelihood ratio test: chi2=4.7724 , p=0.0920 , df=2  
parameter F test: F=1.9446 , p=0.1856 , df\_denom=12, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=1.7996 , p=0.2173 , df\_denom=9, df\_num=3  
ssr based chi2 test: chi2=9.5979 , p=0.0223 , df=3  
likelihood ratio test: chi2=7.5188 , p=0.0571 , df=3  
parameter F test: F=1.7996 , p=0.2173 , df\_denom=9, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=1.9417 , p=0.2229 , df\_denom=6, df\_num=4  
ssr based chi2 test: chi2=19.4174 , p=0.0007 , df=4  
likelihood ratio test: chi2=12.4577 , p=0.0143 , df=4  
parameter F test: F=1.9417 , p=0.2229 , df\_denom=6, df\_num=4

2004-2022 m. visi rodikliai

$H_0: \check{Z}\check{U}\check{Z}M \rightarrow TUI$

$H_a: \check{Z}\check{U}\check{Z}M \nrightarrow TUI$

Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=0.2450 , p=0.6278 , df\_denom=15, df\_num=1  
ssr based chi2 test: chi2=0.2940 , p=0.5877 , df=1  
likelihood ratio test: chi2=0.2916 , p=0.5892 , df=1  
parameter F test: F=0.2450 , p=0.6278 , df\_denom=15, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=0.4508 , p=0.6475 , df\_denom=12, df\_num=2  
ssr based chi2 test: chi2=1.2773 , p=0.5280 , df=2  
likelihood ratio test: chi2=1.2316 , p=0.5402 , df=2  
parameter F test: F=0.4508 , p=0.6475 , df\_denom=12, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=0.6282 , p=0.6148 , df\_denom=9, df\_num=3  
ssr based chi2 test: chi2=3.3505 , p=0.3407 , df=3  
likelihood ratio test: chi2=3.0420 , p=0.3852 , df=3  
parameter F test: F=0.6282 , p=0.6148 , df\_denom=9, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=1.5473 , p=0.3010 , df\_denom=6, df\_num=4  
ssr based chi2 test: chi2=15.4729 , p=0.0038 , df=4  
likelihood ratio test: chi2=10.6318 , p=0.0310 , df=4  
parameter F test: F=1.5473 , p=0.3010 , df\_denom=6, df\_num=4

$H_0: TUI \rightarrow \check{Z}\check{U}\check{Z}M$

$H_a: TUI \nrightarrow \check{Z}\check{U}\check{Z}M$

Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=3.6317 , p=0.0760 , df\_denom=15, df\_num=1  
ssr based chi2 test: chi2=4.3581 , p=0.0368 , df=1  
likelihood ratio test: chi2=3.9027 , p=0.0482 , df=1  
parameter F test: F=3.6317 , p=0.0760 , df\_denom=15, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=1.4832 , p=0.2657 , df\_denom=12, df\_num=2  
ssr based chi2 test: chi2=4.2024 , p=0.1223 , df=2  
likelihood ratio test: chi2=3.7553 , p=0.1529 , df=2  
parameter F test: F=1.4832 , p=0.2657 , df\_denom=12, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=1.1025 , p=0.3974 , df\_denom=9, df\_num=3  
ssr based chi2 test: chi2=5.8801 , p=0.1176 , df=3  
likelihood ratio test: chi2=5.0079 , p=0.1712 , df=3  
parameter F test: F=1.1025 , p=0.3974 , df\_denom=9, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=0.7493 , p=0.5930 , df\_denom=6, df\_num=4  
ssr based chi2 test: chi2=7.4931 , p=0.1120 , df=4  
likelihood ratio test: chi2=6.0774 , p=0.1934 , df=4  
parameter F test: F=0.7493 , p=0.5930 , df\_denom=6, df\_num=4

*Ispanija*

1986-2003 m.

$H_0: PREKYBA \rightarrow TUI$

$H_a: PREKYBA \nrightarrow TUI$

Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=8.4243 , p=0.0116 , df\_denom=14, df\_num=1  
ssr based chi2 test: chi2=10.2296 , p=0.0014 , df=1  
likelihood ratio test: chi2=8.0085 , p=0.0047 , df=1  
parameter F test: F=8.4243 , p=0.0116 , df\_denom=14, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=3.0049 , p=0.0910 , df\_denom=11, df\_num=2  
ssr based chi2 test: chi2=8.7414 , p=0.0126 , df=2  
likelihood ratio test: chi2=6.9742 , p=0.0306 , df=2  
parameter F test: F=3.0049 , p=0.0910 , df\_denom=11, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=1.7775 , p=0.2291 , df\_denom=8, df\_num=3  
ssr based chi2 test: chi2=9.9983 , p=0.0186 , df=3  
likelihood ratio test: chi2=7.6614 , p=0.0536 , df=3  
parameter F test: F=1.7775 , p=0.2291 , df\_denom=8, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=1.7968 , p=0.2668 , df\_denom=5, df\_num=4  
ssr based chi2 test: chi2=20.1246 , p=0.0005 , df=4  
likelihood ratio test: chi2=12.4735 , p=0.0142 , df=4  
parameter F test: F=1.7968 , p=0.2668 , df\_denom=5, df\_num=4

$H_0: TUI \rightarrow PREKYBA$

$H_a: TUI \nrightarrow PREKYBA$

Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=5.1983 , p=0.0388 , df\_denom=14, df\_num=1  
ssr based chi2 test: chi2=6.3122 , p=0.0120 , df=1  
likelihood ratio test: chi2=5.3680 , p=0.0205 , df=1  
parameter F test: F=5.1983 , p=0.0388 , df\_denom=14, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=2.0202 , p=0.1790 , df\_denom=11, df\_num=2  
ssr based chi2 test: chi2=5.8768 , p=0.0529 , df=2  
likelihood ratio test: chi2=5.0054 , p=0.0819 , df=2  
parameter F test: F=2.0202 , p=0.1790 , df\_denom=11, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=3.7356 , p=0.0604 , df\_denom=8, df\_num=3  
ssr based chi2 test: chi2=21.0127 , p=0.0001 , df=3  
likelihood ratio test: chi2=13.1373 , p=0.0043 , df=3  
parameter F test: F=3.7356 , p=0.0604 , df\_denom=8, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=1.4872 , p=0.3324 , df\_denom=5, df\_num=4  
ssr based chi2 test: chi2=16.6570 , p=0.0023 , df=4  
likelihood ratio test: chi2=10.9732 , p=0.0269 , df=4  
parameter F test: F=1.4872 , p=0.3324 , df\_denom=5, df\_num=4

2004-2022 m.

$H_0: PREKYBA \rightarrow TUI$

$H_a: PREKYBA \nrightarrow TUI$

Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=1.0047 , p=0.3321 , df\_denom=15, df\_num=1  
ssr based chi2 test: chi2=1.2056 , p=0.2722 , df=1  
likelihood ratio test: chi2=1.1669 , p=0.2800 , df=1  
parameter F test: F=1.0047 , p=0.3321 , df\_denom=15, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=2.0325 , p=0.1737 , df\_denom=12, df\_num=2  
ssr based chi2 test: chi2=5.7588 , p=0.0562 , df=2  
likelihood ratio test: chi2=4.9596 , p=0.0838 , df=2  
parameter F test: F=2.0325 , p=0.1737 , df\_denom=12, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=2.3517 , p=0.1403 , df\_denom=9, df\_num=3  
ssr based chi2 test: chi2=12.5425 , p=0.0057 , df=3  
likelihood ratio test: chi2=9.2609 , p=0.0260 , df=3  
parameter F test: F=2.3517 , p=0.1403 , df\_denom=9, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=2.4336 , p=0.1584 , df\_denom=6, df\_num=4  
ssr based chi2 test: chi2=24.3357 , p=0.0001 , df=4  
likelihood ratio test: chi2=14.4612 , p=0.0060 , df=4  
parameter F test: F=2.4336 , p=0.1584 , df\_denom=6, df\_num=4

$H_0: TUI \rightarrow PREKYBA$

$H_a: TUI \nrightarrow PREKYBA$

Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=0.5004 , p=0.4902 , df\_denom=15, df\_num=1  
ssr based chi2 test: chi2=0.6004 , p=0.4384 , df=1  
likelihood ratio test: chi2=0.5906 , p=0.4422 , df=1  
parameter F test: F=0.5004 , p=0.4902 , df\_denom=15, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=0.2191 , p=0.8064 , df\_denom=12, df\_num=2  
ssr based chi2 test: chi2=0.6207 , p=0.7332 , df=2  
likelihood ratio test: chi2=0.6096 , p=0.7373 , df=2  
parameter F test: F=0.2191 , p=0.8064 , df\_denom=12, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=0.1226 , p=0.9444 , df\_denom=9, df\_num=3  
ssr based chi2 test: chi2=0.6541 , p=0.8840 , df=3  
likelihood ratio test: chi2=0.6410 , p=0.8870 , df=3  
parameter F test: F=0.1226 , p=0.9444 , df\_denom=9, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=0.2652 , p=0.8902 , df\_denom=6, df\_num=4  
ssr based chi2 test: chi2=2.6521 , p=0.6176 , df=4  
likelihood ratio test: chi2=2.4421 , p=0.6550 , df=4  
parameter F test: F=0.2652 , p=0.8902 , df\_denom=6, df\_num=4

$H_0: NAT\_R\_N \rightarrow TUI$

$H_a: NAT\_R\_N \nrightarrow TUI$

Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=0.2493 , p=0.6248 , df\_denom=15, df\_num=1  
ssr based chi2 test: chi2=0.2991 , p=0.5844 , df=1  
likelihood ratio test: chi2=0.2967 , p=0.5860 , df=1  
parameter F test: F=0.2493 , p=0.6248 , df\_denom=15, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=1.0779 , p=0.3711 , df\_denom=12, df\_num=2  
ssr based chi2 test: chi2=3.0540 , p=0.2172 , df=2  
likelihood ratio test: chi2=2.8087 , p=0.2455 , df=2  
parameter F test: F=1.0779 , p=0.3711 , df\_denom=12, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=0.5243 , p=0.6764 , df\_denom=9, df\_num=3  
ssr based chi2 test: chi2=2.7964 , p=0.4241 , df=3  
likelihood ratio test: chi2=2.5772 , p=0.4615 , df=3  
parameter F test: F=0.5243 , p=0.6764 , df\_denom=9, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=0.3696 , p=0.8227 , df\_denom=6, df\_num=4  
ssr based chi2 test: chi2=3.6959 , p=0.4487 , df=4  
likelihood ratio test: chi2=3.3038 , p=0.5083 , df=4  
parameter F test: F=0.3696 , p=0.8227 , df\_denom=6, df\_num=4

$H_0: TUI \rightarrow NAT\_R\_N$

$H_a: TUI \nrightarrow NAT\_R\_N$

Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=0.2520 , p=0.6230 , df\_denom=15, df\_num=1  
ssr based chi2 test: chi2=0.3024 , p=0.5824 , df=1  
likelihood ratio test: chi2=0.2998 , p=0.5840 , df=1  
parameter F test: F=0.2520 , p=0.6230 , df\_denom=15, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=0.8241 , p=0.4620 , df\_denom=12, df\_num=2  
ssr based chi2 test: chi2=2.3351 , p=0.3111 , df=2  
likelihood ratio test: chi2=2.1880 , p=0.3349 , df=2  
parameter F test: F=0.8241 , p=0.4620 , df\_denom=12, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=0.8382 , p=0.5063 , df\_denom=9, df\_num=3  
ssr based chi2 test: chi2=4.4703 , p=0.2150 , df=3  
likelihood ratio test: chi2=3.9422 , p=0.2678 , df=3  
parameter F test: F=0.8382 , p=0.5063 , df\_denom=9, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=0.8746 , p=0.5306 , df\_denom=6, df\_num=4  
ssr based chi2 test: chi2=8.7463 , p=0.0678 , df=4  
likelihood ratio test: chi2=6.8906 , p=0.1418 , df=4  
parameter F test: F=0.8746 , p=0.5306 , df\_denom=6, df\_num=4

2004-2022 m. visi rodikliai

$H_0: NAT\_R\_N \rightarrow TUI$

$H_a: NAT\_R\_N \nrightarrow TUI$

Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=0.2493 , p=0.6248 , df\_denom=15, df\_num=1  
ssr based chi2 test: chi2=0.2991 , p=0.5844 , df=1  
likelihood ratio test: chi2=0.2967 , p=0.5860 , df=1  
parameter F test: F=0.2493 , p=0.6248 , df\_denom=15, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=1.0779 , p=0.3711 , df\_denom=12, df\_num=2  
ssr based chi2 test: chi2=3.0540 , p=0.2172 , df=2  
likelihood ratio test: chi2=2.8087 , p=0.2455 , df=2  
parameter F test: F=1.0779 , p=0.3711 , df\_denom=12, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=0.5243 , p=0.6764 , df\_denom=9, df\_num=3  
ssr based chi2 test: chi2=2.7964 , p=0.4241 , df=3  
likelihood ratio test: chi2=2.5772 , p=0.4615 , df=3  
parameter F test: F=0.5243 , p=0.6764 , df\_denom=9, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=0.3696 , p=0.8227 , df\_denom=6, df\_num=4  
ssr based chi2 test: chi2=3.6959 , p=0.4487 , df=4  
likelihood ratio test: chi2=3.3038 , p=0.5083 , df=4  
parameter F test: F=0.3696 , p=0.8227 , df\_denom=6, df\_num=4

$H_0: TUI \rightarrow NAT\_R\_N$

$H_a: TUI \nrightarrow NAT\_R\_N$

Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=0.2520 , p=0.6230 , df\_denom=15, df\_num=1  
ssr based chi2 test: chi2=0.3024 , p=0.5824 , df=1  
likelihood ratio test: chi2=0.2998 , p=0.5840 , df=1  
parameter F test: F=0.2520 , p=0.6230 , df\_denom=15, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=0.8241 , p=0.4620 , df\_denom=12, df\_num=2  
ssr based chi2 test: chi2=2.3351 , p=0.3111 , df=2  
likelihood ratio test: chi2=2.1880 , p=0.3349 , df=2  
parameter F test: F=0.8241 , p=0.4620 , df\_denom=12, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=0.8382 , p=0.5063 , df\_denom=9, df\_num=3  
ssr based chi2 test: chi2=4.4703 , p=0.2150 , df=3  
likelihood ratio test: chi2=3.9422 , p=0.2678 , df=3  
parameter F test: F=0.8382 , p=0.5063 , df\_denom=9, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=0.8746 , p=0.5306 , df\_denom=6, df\_num=4  
ssr based chi2 test: chi2=8.7463 , p=0.0678 , df=4  
likelihood ratio test: chi2=6.8906 , p=0.1418 , df=4  
parameter F test: F=0.8746 , p=0.5306 , df\_denom=6, df\_num=4

$H_0: BVP\_G \rightarrow TUI$

$H_a: BVP\_G \nrightarrow TUI$



Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=2.6725 , p=0.1229 , df\_denom=15, df\_num=1  
ssr based chi2 test: chi2=3.2071 , p=0.0733 , df=1  
likelihood ratio test: chi2=2.9513 , p=0.0858 , df=1  
parameter F test: F=2.6725 , p=0.1229 , df\_denom=15, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=1.4004 , p=0.2840 , df\_denom=12, df\_num=2  
ssr based chi2 test: chi2=3.9677 , p=0.1375 , df=2  
likelihood ratio test: chi2=3.5661 , p=0.1681 , df=2  
parameter F test: F=1.4004 , p=0.2840 , df\_denom=12, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=3.5207 , p=0.0620 , df\_denom=9, df\_num=3  
ssr based chi2 test: chi2=18.7769 , p=0.0003 , df=3  
likelihood ratio test: chi2=12.4219 , p=0.0061 , df=3  
parameter F test: F=3.5207 , p=0.0620 , df\_denom=9, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=0.9772 , p=0.4847 , df\_denom=6, df\_num=4  
ssr based chi2 test: chi2=9.7724 , p=0.0444 , df=4  
likelihood ratio test: chi2=7.5252 , p=0.1106 , df=4  
parameter F test: F=0.9772 , p=0.4847 , df\_denom=6, df\_num=4

$H_0: TUI \rightarrow BVP\_G$

$H_a: TUI \nrightarrow BVP\_G$

Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=1.8854 , p=0.1899 , df\_denom=15, df\_num=1  
ssr based chi2 test: chi2=2.2625 , p=0.1325 , df=1  
likelihood ratio test: chi2=2.1312 , p=0.1443 , df=1  
parameter F test: F=1.8854 , p=0.1899 , df\_denom=15, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=1.5310 , p=0.2557 , df\_denom=12, df\_num=2  
ssr based chi2 test: chi2=4.3378 , p=0.1143 , df=2  
likelihood ratio test: chi2=3.8635 , p=0.1449 , df=2  
parameter F test: F=1.5310 , p=0.2557 , df\_denom=12, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=4.3162 , p=0.0381 , df\_denom=9, df\_num=3  
ssr based chi2 test: chi2=23.0195 , p=0.0000 , df=3  
likelihood ratio test: chi2=14.2636 , p=0.0026 , df=3  
parameter F test: F=4.3162 , p=0.0381 , df\_denom=9, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=2.6818 , p=0.1349 , df\_denom=6, df\_num=4  
ssr based chi2 test: chi2=26.8185 , p=0.0000 , df=4  
likelihood ratio test: chi2=15.3793 , p=0.0040 , df=4  
parameter F test: F=2.6818 , p=0.1349 , df\_denom=6, df\_num=4

$H_0: \check{Z}\check{U}\check{Z}M \rightarrow TUI$

$H_a: \check{Z}\check{U}\check{Z}M \nrightarrow TUI$

Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=5.1626 , p=0.0382 , df\_denom=15, df\_num=1  
ssr based chi2 test: chi2=6.1951 , p=0.0128 , df=1  
likelihood ratio test: chi2=5.3240 , p=0.0210 , df=1  
parameter F test: F=5.1626 , p=0.0382 , df\_denom=15, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=3.0303 , p=0.0860 , df\_denom=12, df\_num=2  
ssr based chi2 test: chi2=8.5859 , p=0.0137 , df=2  
likelihood ratio test: chi2=6.9501 , p=0.0310 , df=2  
parameter F test: F=3.0303 , p=0.0860 , df\_denom=12, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=3.2492 , p=0.0741 , df\_denom=9, df\_num=3  
ssr based chi2 test: chi2=17.3290 , p=0.0006 , df=3  
likelihood ratio test: chi2=11.7414 , p=0.0083 , df=3  
parameter F test: F=3.2492 , p=0.0741 , df\_denom=9, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=0.5593 , p=0.7013 , df\_denom=6, df\_num=4  
ssr based chi2 test: chi2=5.5933 , p=0.2316 , df=4  
likelihood ratio test: chi2=4.7538 , p=0.3135 , df=4  
parameter F test: F=0.5593 , p=0.7013 , df\_denom=6, df\_num=4

$H_0: TUI \rightarrow \check{Z}\check{U}\check{Z}M$

$H_a: TUI \nrightarrow \check{Z}\check{U}\check{Z}M$

Granger Causality  
number of lags (no zero) 1  
ssr based F test: F=0.1855 , p=0.6728 , df\_denom=15, df\_num=1  
ssr based chi2 test: chi2=0.2226 , p=0.6370 , df=1  
likelihood ratio test: chi2=0.2213 , p=0.6381 , df=1  
parameter F test: F=0.1855 , p=0.6728 , df\_denom=15, df\_num=1

Granger Causality  
number of lags (no zero) 2  
ssr based F test: F=0.3090 , p=0.7399 , df\_denom=12, df\_num=2  
ssr based chi2 test: chi2=0.8754 , p=0.6455 , df=2  
likelihood ratio test: chi2=0.8536 , p=0.6526 , df=2  
parameter F test: F=0.3090 , p=0.7399 , df\_denom=12, df\_num=2

Granger Causality  
number of lags (no zero) 3  
ssr based F test: F=5.0316 , p=0.0256 , df\_denom=9, df\_num=3  
ssr based chi2 test: chi2=26.8352 , p=0.0000 , df=3  
likelihood ratio test: chi2=15.7563 , p=0.0013 , df=3  
parameter F test: F=5.0316 , p=0.0256 , df\_denom=9, df\_num=3

Granger Causality  
number of lags (no zero) 4  
ssr based F test: F=2.5216 , p=0.1495 , df\_denom=6, df\_num=4  
ssr based chi2 test: chi2=25.2164 , p=0.0000 , df=4  
likelihood ratio test: chi2=14.7934 , p=0.0051 , df=4  
parameter F test: F=2.5216 , p=0.1495 , df\_denom=6, df\_num=4