



**Kauno technologijos universitetas**

Matematikos ir gamtos mokslų fakultetas

**OBLIGACIJŲ PELNINGUMŲ IR SUSIJUSIŲ VEIKSNIŲ  
ĮTAKOS AKCIJŲ RINKOMS ANALIZĖ TAIKANT MAŠININIO  
MOKYMO METODUS**

Baigiamasis magistro projektas

---

**Lukas Holšanskis**  
Projekto autorius

**Doc. Dr. Aura Drakšaitė**  
Vadovė  
**Prof. Dr. Robertas Alzbutas**  
Vadovas

---

**Kaunas, 2018**



**Kauno technologijos universitetas**

Matematikos ir gamtos mokslų fakultetas

**OBLIGACIJŲ PELNINGUMŲ IR SUSIJUSIŲ VEIKSNIŲ  
ĮTAKOS AKCIJŲ RINKOMS ANALIZĖ TAIKANT MAŠININIO  
MOKYMO METODUS**

Baigiamasis magistro projektas

Didžiųjų verslo duomenų analitika (621G12002)

---

**Lukas Holšanskis**  
Projekto autorius

**Doc. Dr. Aura Drakšaitė**  
Vadovė  
**Prof. Dr. Robertas Alzbutas**  
Vadovas

**Doc. Dr. Audrius Kabašinskas**  
Recenzentas  
**Doc. Dr. Lina Sinevičienė**  
Recenzentė

---

**Kaunas, 2018**



**Kauno technologijos universitetas**

Matematikos ir gamtos mokslų fakultetas

Lukas Holšanskis

**OBLIGACIJŲ PELNINGUMŲ IR SUSIJUSIŲ VEIKSNIŲ  
ĮTAKOS AKCIJŲ RINKOMS ANALIZĖ TAIKANT MAŠININIO  
MOKYMO METODUS**

Akademinio sąžiningumo deklaracija

Patvirtinu, kad mano, Luko Holšanskio, baigiamasis projektas tema „Obligacijų pelningumų ir susijusių veiksnių įtakos akcijų rinkoms analizė taikant mašininio mokymo metodus“ yra parašytas visiškai savarankiškai ir visi pateikti duomenys ar tyrimų rezultatai yra teisingi ir gauti sąžiningai. Šiame darbe nei viena dalis nėra plagijuota nuo jokių spausdintinių ar internetinių šaltinių, visos kitų šaltinių tiesioginės ir netiesioginės citatos nurodytos literatūros nuorodose. Įstatymų nenumatytų piniginių sumų už šį darbą niekam nesu mokėjęs.

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

---

(vardą ir pavardę įrašyti ranka)

---

(parašas)

# TURINYS

Įvadas .....	11
1. Literatūros apžvalga .....	13
1.1. Turto klasių kainų ypatumai .....	13
1.2. Prognozavimo misinterpretacijos ir taikymas turto klasių kainų kontekste .....	16
1.3. Akcijų ir su jomis siejamų veiksnių aktualumas .....	17
1.4. Su obligacijomis susijusių veiksnių aktualumas akcijų rinkose .....	22
1.5. Regiono ir laikotarpio aktualumas .....	25
1.6. Literatūros apžvalgos apibendrinimas .....	27
2. Tyrimo metodai ir metodika .....	30
2.1. Akcijų rinkos tyrimams taikomos metodikos ir programinės įranga .....	30
2.2. Aprašomosios analizės metodai .....	33
2.3. Regresijos tyrimams taikomos metodikos ir jautrumo analizės įverčiai .....	35
2.4. Mašininio mokymosi metodai .....	38
2.4.1. Neuroninių tinklų metodas .....	41
2.4.2. Atraminių vektorių metodas .....	42
2.4.3. Atsitiktinių miškų metodas .....	44
2.4.4. Artimiausio kaimyno metodas .....	45
2.5. Mašininio mokymosi metodų taikymas .....	46
3. Tyrimų rezultatai ir jų aptarimas .....	50

3.1. Tyrimo esmė ir veiksniai .....	50
3.2. Duomenų grafinis ir statistinis vertinimas .....	56
3.3. Duomenų tarpusavio ryšių vertinimas grafiškai .....	63
3.4. Mašininio mokymosi algoritmų taikymas tyrime .....	66
3.5. Metodų taikytų išskirčių šalinimui ir suskirstymui į apmokymo bei testavimo imtis apžvalga.....	69
3.6. Mašininio mokymosi algoritmų analizės rezultatai .....	71
3.7. Nepriklausomų kintamųjų įtakingumo palyginimas ir rezultatų interpretacija .....	78
Išvados .....	80
Šaltiniai .....	82
Priedai .....	87

## Paveikslų sąrašas

1 pav. BVP augimas (traukimasis) pasaulyje 2009 m.

2 pav. Pasaulio ieškojimo variklyje „Google“ atliktų paieškų pagal turto klasių angliškus pavadinimus palyginimas 2004.01.— 2017.12.

3 pav. Didžiausių turto klasių verčių trilijonais JAV dolerių palyginimas pasaulyje.

4 pav. „S&P 500“ indekso judėjimas 2003-2017 m.

5 pav. Įvairių valstybių vietinių kompanijų rinkos vertės palyginimas 1998-2017 m.

6 pav. „S&P 500“ indekso (juoda linija, dešinė vertikali ašis) kintančio režimo modelio vieni iš rezultatų (signalų tikimybės ašis vertikaliai kairėje), kur raudonai pažymėti — modelio signalai prognozuojant labai kintančius neigiamos grąžos periodus, geltonai — labai kintančius teigiamos grąžos periodus ir žaliai — nesmarkiai kintančius laikotarpius.

7 pav. Aprašomosios analizės pagrindiniai žingsniai.

8 pav. Pagrindiniai mašininio mokymosi algoritmai ir jų taikymo sritys.

9 pav. Algoritminės prekybos dalis nuo rinkos sandorių Europos ir JAV biržose 2005-2014 m.

10 pav. Neuroninių tinklų veikimo principo schema.

11 pav. Atraminių vektorių mašininio algoritmo optimalios hyperplokštės radimo grafikas.

12 pav. Atsitiktinių medžių algoritmo veikimo principas.

13 pav. Artimiausio kaimyno algoritmo veikimo principas.

14 pav. Kryžminio tikrinimo metodo veikimo principas.

15 pav. „S&P 500“ ir „Bloomberg Barclays“ pasaulio obligacijų indeksų santykis.

16 pav. „S&P 500“ indeksai (kairė y ašis) ir jų prekybos apimtys (dešinė y ašis).

17 pav. Visų nepriklausomų ir priklausomo VIX veiksnio linijiniai grafikai.

18 pav. Priklausomų veiksmų reikšmių dažnio histogramos.

19 pav. Nepriklausomų veiksmų reikšmių dažnio histogramos.

20 pav. Akcijų rinkos ir su obligacijomis susijusių dalies veiksmų sklaidos diagramos.

21 pav. Akcijų rinkos veiksmų naudojamų tyrime tarpusavio sklaidos diagramos.

22 pav. Logaritmuotų dieninių pokyčių veiksmų dalyvavusių tyrime grafikai 2003-2017 m.

23 pav. BAMLH0A0HYM2EY logaritmuota dieninių pokyčių reikšmių pasiskirstymo diagrama.

24 pav. Mašininio mokymosi algoritmų mokymo ir vertinimo metodas naudotas tyrime. Šaltinis: sudaryta autoriaus.

25 pav. Priklausomo kintamo SPX ir keturių nepriklausomų kintamų dvidešimties dienų slenkančios koreliacijos grafikai.

## Lentelių sąrašas

- 1 lentelė. Dvi pusės — akcijų nuspėjamumą ir nenuspėjamumą — palaikančių autorių darbų apibendrinimas.
- 2 lentelė. Mašininio mokymo algoritmų rezultatų gerinimo metodai ir jų suskirstymas pagal grupes.
- 3 lentelė. Priklausomi kintamieji naudojami tyrime.
- 4 lentelė. Nepriklausomi kintamieji naudojami tyrime.
- 5 lentelė. Kintamųjų naudojamų tyrime pagrindinės statistikos..
- 6 lent. Pradinio duomenų rinkinio priklausomų ir nepriklausomų kintamų koreliacijos lentelė .
- 7 lentelė. Pradinių duomenų paskutinės testavimo imties pritaikytos mašininio mokymosi algoritmams tikslumo rezultatai .
- 8 lentelė. Pradinio duomenų rinkinio, pritaikyto mašininio mokymosi algoritmams, priklausomų kintamų pagrindinės statistikos.
- 9 lent. Duomenų rinkinio priklausomų ir nepriklausomų kintamų (su vienos dienos lagu) koreliacijos lentelė .
- 10 lent. Suvidurkintų paskutinių dvidešimties stebinių reikšmių duomenų rinkinio priklausomų ir nepriklausomų kintamų koreliacijos lentelė.
- 11 lentelė. Suvidurkintų paskutinių dvidešimties stebinių reikšmių duomenų rinkinio paskutinės testavimo imties pritaikytos mašininio mokymosi algoritmams tikslumo rezultatai.
- 12 lentelė. Suvidurkintų paskutinių dvidešimties stebinių reikšmių duomenų rinkinio paskutinės testavimo imties pritaikytos mašininio mokymosi algoritmams tikslumo rezultatai 2003-2014-04-14 laikotarpiui (pirmiesiems 2800 stebinių).
- 13 lentelė. Atsitiktinių miškų svarbumo koeficientai priskirti kiekvienam iš naudotų nepriklausomų kintamų SPX ir VIX kintamų atžvilgiu.



Holšanskis, Lukas. Obligacijų pelningumų ir susijusių veiksnių įtakos akcijų rinkoms analizė taikant mašininio mokymo metodus. Magistro baigiamasis projektas / vadovas Doc. Dr. Aura Drakšaitė, Prof. Dr. Robertas Alzbutas; Kauno technologijos universitetas, Matematikos ir gamtos mokslų fakultetas. Studijų kryptis ir sritis (studijų krypčių grupė): Taikomoji matematika (A02), Matematikos mokslai (A).

Reikšminiai žodžiai: mašininio mokymosi algoritmai, akcijos, obligacijos, laikotarpiai, grafikai. Kaunas, 2018. 86 p.

## Santrauka

Akcijos yra dažnas tyrimų objektas stengiantis nagrinėti sąryšius su kitais veiksniais ir taip turėti geresnių galimybių aplenkti rinkos pelningumą, neišauginant rizikos. Tarp tiriamų rodiklių ne taip dažnai pasirodo su obligacijų rinka susiję veiksniai, nepaisant šios rinkos nenuginčijamos svarbos pasaulio ekonomikai. Kai obligacijų rinka paliečiama, tokiose darbuose kaip D'Arcy, Poole (2010) arba Kang (2007), visas obligacijų rinkos kompleksiskumas ir įvairialypumas nevisada lieka atspindėtas.

Dar daugiau nepaisant mašininio mokymosi algoritmų vis garsiau skambančios sėkmės ir plataus taikymo, šie algoritmai dar neturi nusistovėjusių praktikų ir akademiniuose darbuose nėra sulaukę tokios plataus pripažinimo su finansinėmis eilutėmis. Netgi atsižvelgiant į tokius pavyzdžius kaip Zankova (2016), Sheta, Ahmed'as, Faris (2015).

Šiame darbe siekiama prisidėti ir apjungti šias dvi nišas — akcijų ir obligacijų ryšių analizę, taikant mašininio mokymosi algoritmus. Analizuojama buvo labai įvairūs, privatų ir viešą sektorių atstovaujantys, JAV obligacijų pelningumų ir susiję veiksniai su įvairiomis akcijų rinkos metrikomis. Dar geresniam situacijos pažinimui buvo taikomi ir dažniau sutinkami statistiniai metodai kaip koreliacijos koeficientai, bei įvairūs grafikai pasirodę 4-ių pasirinktų mašininio mokymosi algoritmų taikymui.

Darbe buvo nustatyta, kad pasirinkti obligacijų veiksniai turi įtakos akcijų rinkai, tačiau įtaka yra labai nepastovi ir modeliai reikalauja disciplinuoto atnaujinimo, kad būtų efektyvus ilgesnį laikotarpį. Neuroniniai tinklai įvairiose situacijose pasirodė sudarantys tiksliausius modelius. Veiksniai susiję su rizikingų kompanijų obligacijomis pasirodė turintys daugiausiai įtakos visiems tirtiems akcijų rinkos indeksams, kol indeksų prekybos apimtys pasirodė beveik visai nepriklausomos nuo pasirinkto obligacijų veiksnių rinkinio.

Holšanskis, Lukas. Bond yield and related variables influence to equities analysis applying machine learning methods. Master's Final Degree Project / supervisor Assoc. prof. Aura Drakšaitė, Prof. Dr. Robertas Alzbutas; Faculty of Mathematics and Natural Sciences, Kaunas University of Technology. Study field and area (study field group): Applied mathematics (A02), Mathematics sciences (A).  
Keywords: machine learning algorithms, stocks, bonds, timeframes, graphs.  
Kaunas, 2018. 86 pages.

### **Summary**

Stocks is an often seen subject in academic research trying to investigate relationships with other indicators and so have better odds at beating the market without growing the risk. Despite its undeniable influence on global economy, bond market linked variables are not so often met among those indicators. When bond market is involved, in such work papers as D'Arcy, Poole (2010) or Kang (2007), the whole complexity and diversity of bond market may not necessarily be showcased.

What is more, despite growing success and diverse use of machine learning algorithms, these algorithms still do not have established best practices and are not so often accepted in subjects concerning financial time series. Even counting in such examples as Zankova (2016), Sheta, Ahmed, Faris (2015).

In this research, what is sought is adding and uniting these 2 niche subjects — stocks and bonds relationship analysis, utilizing machine learning algorithms. A variety of indicators, representing both private and government sector, including USA bond yields and related factors were analyzed with multiple stock market metrics. To even better understand the situation, more traditional statistical methods, like correlation coefficients and various visualizing techniques were used in preparation for the appliance of 4 machine learning algorithms.

To summarize, it was confirmed that chosen bond variables do have influence on the stock market, however it is very unstable and requires disciplined model calibrating to maintain effectiveness for a long time horizon. Neural networks showcased best results no matter the circumstances. Factors related to more risky corporate bonds, were most influential to all stock indexes, while indexes trading volumes seemed to be unaffected by selected bond dataset at all.

## IVADAS

Nėra daug sričių, kur mokslininkų požiūriai ir tyrimų rezultatai skirtųsi taip stipriai ir taip ilgai kaip akcijų rinkose. „Senoji mokykla“ vedama Fama (1965) ir Malkiel'is (2007) jau virš penkiasdešimt metų atstovauja poziciją, kad nuosavybės popierių rinka yra idealiai efektyvi, kur kiekvienas papildomas gražos punktas virš rinkos normos yra proporcingas lygiareikšmiškam rizikos išaugimui. Tačiau, kitoje pusėje yra investuotojai kaip Varenas Bufetas, dešimtmetis po dešimtmečio prie skirtingų kapitalų, cikliškumo, ekonomikų, geopolitinių situacijų ir konkurentu ar bendražygių sugebantys stipriai gerinti rinkos rezultatus. Tokie pavyzdžiai rodo, kad yra sėkmingų formulių akcijų rinkose ir tai tyrinėjantys autoriai kaip Alesii (2006), Hosseini, et al. (2011) bei Verner'is (2017) neatlieka bergždžio darbo.

Mokslinėje literatūroje nepakankamai išnaudojama atrodo dviejų iš svarbiausių turto klasių pasaulyje — akcijų ir obligacijų ryšiai. Tyrimuose, obligacijų rinka dažnai marginalizuojama iki keletos antraštėse dominuojančių veiksnių ir įvairovė kuri sutinkama skolos popierių rinkoje lieka neišpildyta. Tai palieka vakuumą tolimesniems šių ryšių tyrinėjimams.

Paskutinius pora dešimtmečių aiškiai išaugo akcijų rinkos analitikos. Matematiniai modeliai, kompleksiški išvestiniai instrumentai ir kompiuterinės galios pažabojimas iš finansų ir akcijų rinkos šešėlio išlindo į priekį ir tapo kertine sistemos dalimi. Vis didėjančią rolę įgyja vadinamieji mašininio mokymosi algoritmai, kurių populiarumas finansuose išgyveno eksponentinį tobulėjimą. Ir nors, mašininio mokymosi algoritmų pritaikymai gausėja, tačiau panašu, kad laikas nebuvo pakankamas suformuoti vieningoms ir universalioms praktikoms su finansinėmis laiko eilutėmis. Dėl to, pasilieka nemažai erdvės eksperimentuoti su įvairiomis praktikomis ir kintamais bei prisidėti prie mašininio mokymosi algoritmų aplikacijų Zankova (2016), Sheta, Ahmed'as, Faris (2015) ir kitų autorių darbuose.

Taigi tyrimo tikslas yra įvairiai ištirti akcijų ir su obligacijomis susijusių veiksnių ryšius, tam pritaikant inovatyvius matematinius metodus — mašininio mokymosi algoritmus. Papildomai, tikslo link bus siekiami sekantys uždaviniai:

- Apibendrinti akcijų rinkos kaip turto klasės aktualumą ir subtilumus.
- Įvertinti aktualiausius veiksnius naudojamus akcijų rinkos mokslinėse analizėse ir su obligacijų rinka siejamų veiksnių poziciją tarp jų.

- Išsiaiškinti įprastas praktikas aprašamosios analizės, mašininio mokymosi algoritmų taikyme ir kelyje iki to su finansinėmis eilutėmis;
- Apibrėžti kiekvienos iš kintamų grupių savybes ir situaciją;
- Lyginti rezultatus skirtingais laikotarpiais, skirtingoms akcijų rinkos metrikoms;
- Įvertinti skirtingų mašininio mokymosi algoritmų potencialą ir tinkamumą finansinėms eilutėms.
- Palyginti pasirinktų su obligacijomis susijusių veiksnių įtaką akcijų rinkoms.

Pasiekus tyrimo tikslą ir uždavinius, stipriai papildėtų obligacijų ir akcijų rinkų tyrimų įvairovė, o mašininio mokymosi algoritmai būtų pritaikyti palyginti plataus spektro ir kompleksiško situacijose, kuriose jų efektyvumas turėtų potencialą atsiskleisti .

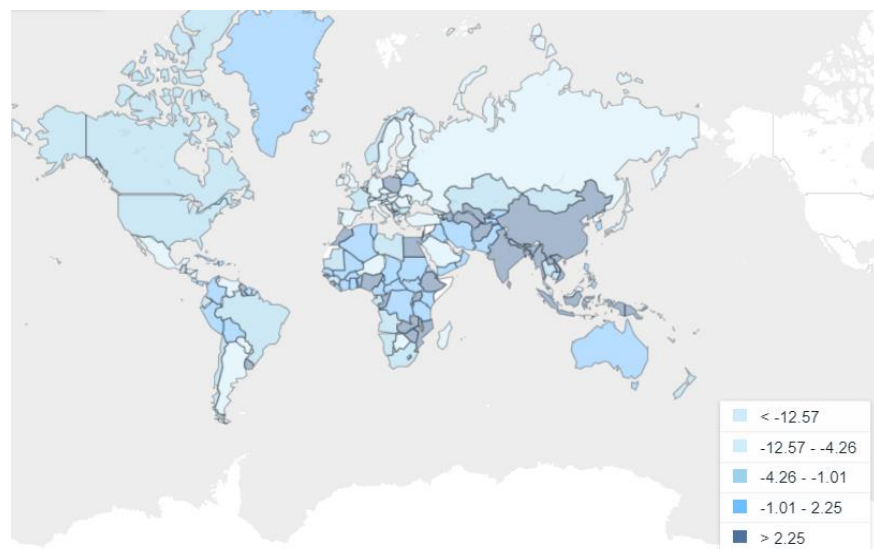
# 1. LITERATŪROS APŽVALGA

## 1.1. Turto klasių kainų ypatumai

Prognozavimas ir bandymas iš to pasipelnyti yra viena iš labai sena žmonijos veiklos dalių. Prieš kelis tūkstantmečius, daugiausiai prognozių turbūt atlikdavo žmonės susiję su religija ar stebėdami gamtos reiškinius. Nuo tada viskas gana sparčiai ir įvairiai keitėsi. Ryškėjo laikui atsparios sritys, kuriose prognozavimas nuolat skatinamas ir reikšmingesnis nei kitose srityse. Ryškėjo laikui atsparios apdovanojimo formos ir jų proporcingumas prognozės tikslumui. Ryškėjo laikui atsparios metodikos, priemonės ir argumentai, kurie būdavo efektyviausi siekiant sėkmingo prognozavimo ar įtaigumo veikiant sprendimų priėmėjus ar visuomenės mases (nes prognozės sėkmingumas ir įtaigumas labai skirtingi dalykai). Visa tai, skatina imtis išsamių analizių ir įtaigingų argumentų paremtų prognozėmis. Bet tai nevienodai aktualu visose srityse. Yra argumentų, kad dalyje sričių prognozių tikslumas išlieka toks pats (ne)patikimas kaip senais, senais laikais kai tos sritys dar turėjo visai kitus dalyvius ir formas. Istorija ir stipriai išaugusios galimybės nebūtinai reiškia, kad jos jau pajėgios, visais atvejais, susidoroti su tokiais veiksniais kaip žmonių psichologija, gamtos reiškiniais ir panašiai. Be to, vyksta natūrali prognozavimo evoliucija, kai geresnės prognozės susilaukia dėmesio, daugiau konkurencijos ir stebėtojų, kas veikia prognozuojamą objektą ar reiškinį ir iškreipia prognozių rezultatus. Tai sukelia tolimesnį prognozavimo proceso adaptavimą. Dėl šių ir daug kitų priežasčių, galima teigti, kad nors prognozavimas šiais laikais vertinamas kaip niekad, prognozių „menas“ gali būti toks pat subtilus, aistras keliantis ir kartais katastrofiškai nesėkmingas kaip būdavo daug ankstesniais laikais. Kaip yra pasakęs, garsus ekonomistas Džonas Kenetas Galbraitas: „yra dviejų tipų prognozuotojai: tie kurie nežino ir tie kurie nežino, kad nežino“ [35].

Vertinant retrospektyviai, sritis kurioje prognozių kiekis ir žmonių susidomėjimas jomis buvo didžiausias buvo turto klasių kainų prognozė. Nors kalbant apie tai, dažniausiai gali būti prisiminta akcijos ir nekilnojamas turtas, turto klasės dažniausiai asocijuojamos su spekuliacija, tačiau kaip istorija rodo prognozėms nemažiau aktualios gali būti pačios įvairiausios turto klasės. Laiko prasme artimas pavyzdys būtų virtualios valiutos. Turto klasė, kurios daug kas net nežinojo prieš pora metų, netgi dabar nuslūgus didesnei daliai ažiotažo, galima rasti labai platų spektrą prognozių šios turto klasės artimai ar tolimai ateičiai. Štai labai žinomas ir pasiekęs rizikingo kapitalo pasaulio atstovas Čamatas Palihapitija prognozuoja populiariausios iš kriptovaliutų — bitkoino, vertę siekiančią 1 milijoną JAV dolerių per artimiausius 20 metų arba maždaug 58 kartus siekiantį prieaugį [18]. Kita vertus, praėjus vos porai mėnesių nuo investuotojo pasisakymo, Agustin'as Karstenas, generalinis tarptautinių atsiskaitymų banko vadovas, prognozavo niūrią ateitį finansiniam stabilumui, jeigu

kripto valiutos nebus sustabdytos ir paminėjo, kad šis produktas dažniausiai yra spekuliatyvios manijos rezultatas [32]. Tai tik keletas iš daug prognozių poliarizacijos pavyzdžių ir tai tik vienoje turto klasėje. Šitai galioja universaliai, visoms turto klasių kainoms — rinkos dalyvių prognozės būna labai skirtingos ir dažnai prieštaraujančios vienos kitoms. Tačiau, staigus ir smarkus kripto valiutų kainų kritimas pradedant 2018 metus buvo geras priminimas, kad prognozės turto klasėse būna ypač sudėtingos. Dėl įvairių priežasčių, priežasčių kurios yra atskiras daugelio akademinų veikalų objektas ir vis tiek nelieka visiškai aiškios, turto klasės kone cikliškai užklumpa staigius ir stiprius kainos nuvertėjimus. Kitaip sakant sprogska kainų „burbulas“. Literatūroje randami įvairūs „burbulų“ apibrėžimai, tarp jų (Evanoff, Kaufman, Malliaris, 2012) apibrėžia: „burbulas egzistuoja, kai turto rinkos kaina stipriai viršija savo vertę, nustatytą fundamentalių rodiklių, ilgesnį laikotarpį“. Kiekvienas „burbulo“ sproginimas dažniausiai ateina su skaudžiomis pasekmėmis. Pavyzdžiui 2008 m. finansinė krizė, kurios metu smuko dauguma turto klasių, bet ypatingai akcijos ir nekilnojamas turtas, Malkiel (2010) skaičiuoja, kad nekilnojamo turto (toliau — NT) kainos JAV tuomet smuko beveik trečdaliu, JAV vyriausybė turėjo priimti vadinamąją TARP (sudėtingos būklės turto vienetų palaikymo) programą, kurios dydis siekė 700 milijardų JAV dolerių (5% tuometinio JAV bendro vidaus produkto — BVP) buvo nukreiptas į prie bankroto ribos atsidūrusias finansines institucijas (Lipsy, Takinami, 2013). Dar daugiau, nors krizės epicentras buvo vienas regionas (JAV), tačiau pasekmės buvo globalios. Tai netrukus išryškino kitų šalių finansinės veiklos trūkumus ir šalia smukusių ekonominių rodiklių 1-ame paveiksle, padidintų valstybinių išlaidų ir skolinimosi situacijos stabilizavimui, galima skaičiuoti ir netiesiogines išlaidas sveikatos priežiūrai, bei prarastas pajamas ir ekonominę gerovę, kuri vietomis neatstatyta iki šių dienų.



**1 pav. BVP augimas (traukimasis) pasaulyje 2009 m. . Šaltinis: Pasaulio bankas [93].**

Ir tai toli gražu ne vienkartinis ir ne blogiausias „burbulo“ sprogimo pavyzdys. Malkiel'is (2010) išskiria keletą tokių „burbulų“ pavyzdžių:

- **Tulpių manija.** Jos viršūnėje 1637 m. sausio mėnesį kainos buvo išaugę 20 kartų, o vienas retas tulpių žiedas Olandijoje buvo vertas panašiai kiek kilmingo žmogaus pilis. Džeremis Siegel'is (2003) žvelgdamas nuo 1634 m. suskaičiavo net 60 kartų siekusių prieaugį. B. Malkiel'is teigimu jau po poros mėnesių nuo 1937 m., svogūnų vertė prilygo tulpių žiedų, kas simbolizuoja visišką manijos griuvimą ir žinoma, po to sekusį ekonominės gerovės suprastėjimą.
- **„Pietų jūros“ bendrovės akcijų „burbulas“.** 18 a. pradžioje įsteigta bendrovė Anglijoje, turėjo monopolines prekybos teises perspektyviam, neseniai atrastam regione, kas smarkiai išaugino investuotojų lūkesčius ir per maždaug pusmečio laikotarpį bendrovės akcijos išaugo beveik 10 kartų. Entuziazmas persinešė į kitų ir vis gausiau naujai besikuriančių bendrovių akcijas ir jas stipriai brangino, nors jos niekuo nesisiejo su minėta bendrove. Nepamatuotas entuziazmas baigėsi ir Anglijos akcijų rinka grįžo į prieš tai buvusią būklę per kiek daugiau negu metus.
- **Japonijos nekilnojamo turto ir akcijų „burbulas“.** Praeito šimtmečio, 9 dešimtmety „užkaitęs“ „burbulas“ buvo istorinių proporcijų. Vienas iškalbingiausių faktų pateiktas B. Malkiel'io, kad 1990 m. visas Japonijos nekilnojamasis turtas buvo vertinamas 20 trilijonų JAV dolerių arba maždaug 20% viso pasaulio turto. Ričardas Verner'is (2003) mini, kad 3 metais anksčiau Japonija buvo atsakinga už maždaug 86% kapitalo investicijų pasaulyje. Viskas labai pasikeitė per pora metų, kai Japonijos akcijų biržos indeksas „Nikkei 225“ per tą laikotarpį smuko beveik pusiau (o per kitus pora metų dar daugiau), o Japonija šiai dienai yra labai toli nuo įtakos, kurią tuo metu turėjo pasaulyje.

Tai tik keletas iš ryškiausių istorinių pavyzdžių, kaip labai skirtingo turto vertės gali staigiai, sunkiai suvokiamai išaugti ir paskui nemenkiau staiga nukristi į prieš tai buvusį lygį ir dar žemiau. Tai turto klasių vertinimą daro labai svarbiu ir sunkiai nuspėjamu, su galimai galingomis pasekmėmis. Laiku ir tinkamai nesureagavusiems žmonėms, institucijoms ir kartais net valstybėms, tokie epizodai prišaukdavo bankrotus ar smarkų ekonominį nuopuolį ir su tuo ateinančiomis kitomis mažiau tiesioginėmis pasekmėmis. Wahlbeck'as, Awolin'as (2009) išskiria tokias mažiau akivaizdžias pasekmes kaip padidėjusią socialinę atskirtį, padaugėjusius protinių ligų atvejus, išaugusias savižudybes ir alkoholizmą sumažėjusį vaikų aktyvumą ir išsilavinimą.

Turto klasių kainas veikiančių veiksnių stebėjimas, tarpusavio susiejimas ir prognozavimas remiantis atrastais ryšiais gali padėti tinkamu laiku, atlikti reikiamus veiksmus ir taip sumažinti patirtus piniginius ir su tuo ateinančius kitus nuostolius, o galbūt netgi didinti pelningumą pasinaudojant kritinių situacijų sudarytomis galimybėmis.

## **1.2. Prognozavimo misinterpretacijos ir taikymas turto klasių kainų kontekste**

Jeigu yra rizikuojama nors kuo, prognozavimas dažnam žmogui apie, bet kokią mažiau artimą sritį atrodo nepriimtinas ir sudėtingas. Pirmiausia, veikia psichologiniai faktoriai — žmonės nenori jaustis apsikvailinę, jaučiasi neturintys pakankamai konteksto ar motyvacijos. Antra, prisideda žiniasklaidos „ekspertų“ kultas, kai bandoma sumenkinti įprastų žmonių nuovokumą ir iškelti tariamų srities ekspertų neprilygstamumą. Žmonėms gali pasirodyti, kad be ilgamečių, labai specifinių žinių ir išsilavinimo neįmanoma žinoti pakankamai apie kažkokią sritį, kad joje atlikti prasmingų įžvalgų. Tačiau Filipas Tetlokas ir Gardner savo knygoje „Superprognozavimas: prognozavimo menas ir mokslas“ (2015), skleidžia kitokią žinią. Autorius pastebi, kad taiklus prognozavimas nebūtinai yra savo srities žinomiausių ekspertų reikalas. Netgi atvirkščiai, autoriaus tyrimai atskleidžia, kad maždaug 2% eilinių žmonių, įvairių biografijų, su šiek tiek išankstinio pasiruošimo, sugeba demonstruoti žymiai geresnę taiklumą įvairiomis ir atsitiktinėmis temomis negu ekspertai mirgantys medijų platformose. To pačio autoriaus kitoje knygoje (Tetlock, 2005) detalizuojama kokie tikslūs gali būti ekspertai ir iš 284 eksperimento dalyvių, bei daugiau nei 28 000 spėjimų, tyrimas parodė, kad ekspertai garantavo tik vos geresnę taiklumo procentą nei šansas. Šie ir kiti panašūs akademikų tyrimai rodo, kad ilgalaikis ir reikšmingas veikimas kažkokoje srityje negarantuoja labai tikslių prognozių toje srityje, kaip ir patirties trūkumas toje srityje nebūtinai atitolina žmones nuo galimybės pastoviai ir tiksliai daryti išvadas apie tą sritį, formuoti prognozes ir atradinėti svarbias sąsajas.

Prognozavimas vykdomas įvairiausiai būdais. Modernusis priėjimas prie prognozavimo buvo gana tiksliai aprašytas Čambers'o, Mullick'o ir Smito dar 1971 m., kai jie rašė, kad metodo pasirinkimas nustatinėjant veiksnių ryšius ir prognozuojant yra labai svarbu, ir dažnai priklauso nuo keletos faktorių: prognozės konteksto, istorinių duomenų aktualumo ir prieinamumo, reikalingo tikslumo, laikotarpio į priekį kurį siekiama prognozuoti, prognozės galimos vertės ir laiko resursų, kurie prieinami. Autoriai taip pat išskiria 3-is pagrindines metodikų grupes — kiekybinių duomenų, laiko eilučių tendencijų ir tarpusavyje susijusių ryšių analizavimą. Nors norisi sakyti, kad per beveik



50-imt metų daug kas pasikeitė, tačiau atitraukus ir į prognozes žvelgiant ne taip detalai, prognozavimo procesą lemiantys veiksniai ir naudojamos analizės būdų grupės išlieka tos pačios.

Iš minėtų metodikų, turto klasių kainų kontekste, išvados apie ateities kainas dažniausiai atliekamos radus ryšius su kitais veiksniais. Veiksnių aibė gali būti pati įvairiausia:

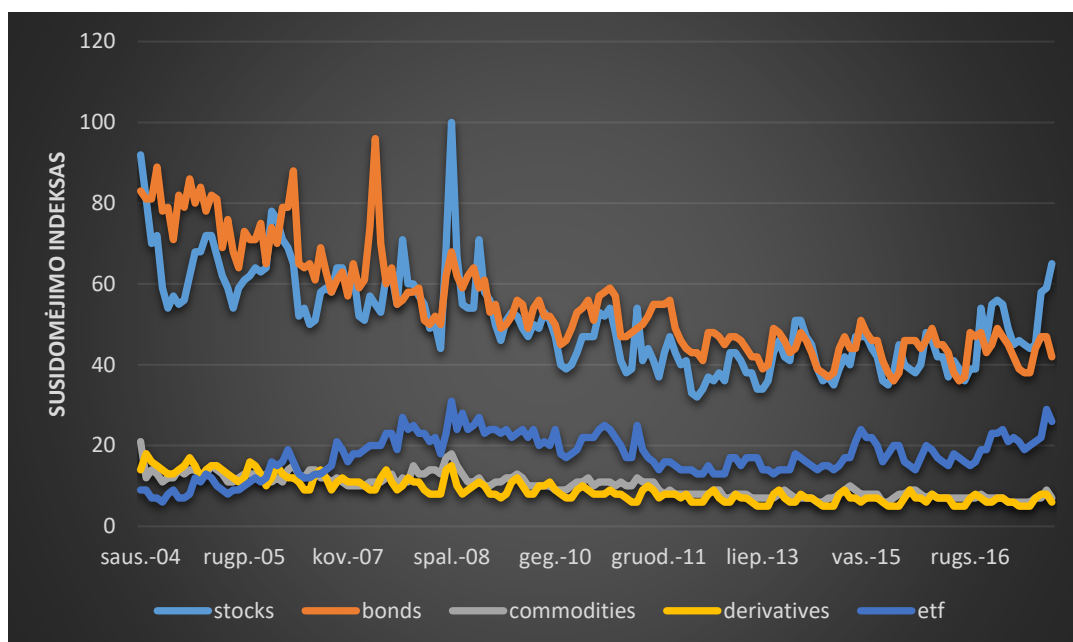
- Vidiniai to pačio turto veiksniai;
- Kitų turto rūšių rodikliai ar kainos;
- Makroekonominiai, visuotiniai veiksniai;
- Retais atvejais — ir iš pažiūros visai nesusiję ir mažai ką bendro turintys kitų sričių rodikliai.

Apibendrinus, nors akademinėje bendruomenėje kartais, ypatingai turto klasių kainų tyrimuose, galima išgirsti prognozavimo diskreditavimą, bei perdėta kompleksavimą, tačiau šios tezės dažnai įtakojamos išankstinių nusistatymų. Prognozavimo procesas išlieka artimas principams suformuotiems per šimtmečius, kuriuos sėkmingai pritaikius galima pasiekti geresnių rezultatų negu nusistovėjusio visuomenės požiūrio ar net profesionalų pozicijos „gaudymas“. Siekiant sėkmingesnio principų pritaikymo, galima rinktis iš įvairiausių veiksnių ir jiems tinkamų metodų, kurių parinkimas dažnai būna sudėtingiausia analizių dalis.

### **1.3. Akcijų ir su jomis siejamų veiksnių aktualumas**

Iš visų turto klasių, neabejotinai tarp populiariausių ir įtakingiausių yra įmonių nuosavybės popieriai arba akcijos. Dėl to nors akcijos ir nėra pati pagrindinė pasaulio turto dalis, jų žinomumas yra platus net ir tarp finansiškai mažiau įsitraukusių visuomenės sluoksnių (2paveikslas). „Google“ platformos apskaičiuotame „susidomėjimo indekse“ 100 yra didžiausia reikšmė, kuri parenkama pagal didžiausio elemento, didžiausių paieškų skaičių. 2-o paveikslo atveju tai akcijos pasaulinės ekonominės krizės įkarštyje. Kaip gali kristi į akis, akcijos (angl. *stocks*) beveik viso laikotarpio metu nenusileidžia paieškų skaičiumi obligacijoms (angl. *bonds*) ir netgi turi didžiausią paieškų skaičiaus mėnesį, nepaisant pastarųjų žymiai didesnės įtakos pasaulinei ekonomikai. Žymiai mažiau populiarios turto rūšys yra žaliavos (angl. *commodities*), išvestiniai finansiniai instrumentai (angl. *derivatives*) ir biržoj kotiruojamo fondo vienetai (angl. *exchange traded fund – etf*). Netgi savo populiariausiais momentais priartėja daugiausiai 50% to momento obligacijų ar akcijų paieškų skaičiaus. Iš šių trijų turto vienetų, ETF yra populiariausias, kas kiek stebina turint omeny šios turto klasės jauną amžių, lyginant su konkurentų amžiumi ir sąvoku apimtimi. Konteksto dėlei vertėtų paminėti, kad tokios turto

klasės kaip auksas ar nekilnojamas turtas buvo dar populiarsnės nei obligacijos ar akcijos, tačiau tam ženklia įtaką galėjo turėti šių sąvokų dviprasmiškumas (jų reikšmė nebūtinai gretinama tik kaip turto klasė).



**2 pav. Pasaulio ieškojimo variklyje „Google“ atliktų paieškų pagal turto klasių angliškus pavadinimus palyginimas 2004.01.— 2017.12. Šaltinis: atlikta autoriaus pagal „Google Trends“ duomenis [36].**

Akcijų populiarumas, nors dalinai turi būti siejamas su jų pelningumu. Neseniai pasirodžiusioje ir labai visapusiškoje Jorda, et al. (2017) analizėje, buvo tiriami vyriausybinių obligacijų, trumpalaikių vyriausybinių skolos popierių, nekilnojamo turto ir akcijų duomenys iš 16-os labiausiai pažengusių pasaulio ekonomikų (tarp kurių JAV, Vokietija ir kitos). Analizės laikotarpis siekė, netgi 145 metus (1970-2015 m.). Išvadose, buvo nustatyta, kad akcijos tik maždaug 0.2% nusileidžia nekilnojamam turtui, vos ne trigubai lenkia obligacijas ir maždaug septynis kartus lenkia trumpalaikius skolos popierius. Tai sutinka su Balke ir Wohar (2001) ir daugeliu kitų akademikų darbais, kur akcijos išryškėja kaip vertingiausi vertybiniai popieriai ir viena vertingiausių turto klasių per bet kokį atsitiktinį 10-ies metų ar ilgesnį laikotarpį. Šie ir susiję faktai parodo, kodėl akcijos yra vienas dažniausių finansinių publikacijų tyrimų subjektų ir išlaiko labai didelę aktualumą visuomenėje.

Tiesa, tai, kad akcijos labai mėgstamos medijose ir yra sąlyginai lengvai suprantamos žmonėms priveda ir prie dviejų ekstremumų. Dalis visuomenės gali būti linkę visiškai supaprastinti rinkas ir stipriai pervertinti tikimybę jose uždirbti norimą investicinę grąžą, kiti — visiškai „sumistifikuoti“

akcijų rinkas ir priskirti joms gerokai aukštesnį rizikos profilį negu jis yra istoriškai. Kiekviena pusė turi savo argumentų, dalis garsiausių ir įdomiausių yra sistemizuota 1-oje lentelėje žemiau.

**1 lentelė. Dvi pusės — akcijų nuspėjamumą ir nenuspėjamumą — palaikančių autorių darbų apibendrinimas. Šaltinis: sudaryta autoriaus.**

Argumentai <i>už</i> akcijų rinkos grąžų nuspėjamumo paprastumą		Argumentai <i>prieš</i> akcijų rinkos grąžų nuspėjamumo paprastumą	
Autoriai	Tyrimų, teorijos apibendrinimas	Autoriai	Tyrimų, teorijos apibendrinimas
<b>Santa-Clara P. ir Valkanov, R. (2003)</b>	JAV akcijų rinkos investicinė grąža žymiai didesnė, JAV prezidentui esant demokratui, o ne respublikonui.	<b>Arnott Robert D., Cornell, Bradford ir Kalesnik, Vitali (2017)</b>	Ištyrus Australijos, Kanados, Vokietijos, Prancūzijos ir Didžiosios Britanijos ne mažiau 30-ies metų akcijų rinkų grąžas ir tuo metu valdžiusias partijas nebuvo rasta jokio pastovumo tarp šių dviejų veiksnių.
<b>Veronesi, P. ir Pastor, L. (2017)</b>	Patvirtina Santa-Clara ir Valkanov (2003) išvadas ir papildomai minima, kad remiantis duomenimis nuo 1925 m. iki 2015 m. investuojant tik valdant demokratų prezidentui grąža akcijų rinkose siekia, net 10.7%, o valdant tik respublikonų prezidentui -0.2%.	<b>Fama, E. F. (1965)</b>	Autoriaus pristatyta, efektyvios rinkos teorija (angl. <i>Efficient Market Hypothesis</i> ) teigia, kad rinkos dalyviai negali tikėtis aukštesnės negu vidutinės grąžos nepriimdami aukštesnės negu vidutinės rizikos.
<b>George Taylor (1926)</b>	Teorija teigia, kad moterų sijonų ilgiai koreliuoja su akcijų rinkų grąža. Teorija paremta, tuo kad sijonų ilgiai gerai atspindi vartotojų pasitikėjimą ekonomika ir turimą biudžetą naujoms madoms.	<b>Ferson, W., Sarkissian, S. ir Simin, T. (2003)</b>	Įvardina, kad didelė dalis ryšių įrodytų tyrimuose susijusiuose su akcijų rinkomis gali būti klaidingi dėl atsitiktinių regresijų ir dėl to, kad veiksniai anksčiau demonstravę ryšį su akcijų rinkom nebūtinai jį išlaikys ateityje.
<b>Degenhardt, T. ir Benjamin, R.A. (2017)</b>	Autoriai savo tyrimuose įrodo, kad garsi teorija žinoma kaip „Parduok Geguže ir Eik“ (angl. „ <i>Sell in May and go Away</i> “) iš tiesų garantuoja geresnę investicinę grąžą žaliavų rinkose ir ypatingai akcijų rinkose.	<b>Malkiel, B. G. (2007)</b>	Net ir naujausioje savo knygos versijoje, autorius lieka prie tos pačios teorijos suformuotos dar 1973 m. — praeities akcijų rinkos judėjimai nėra tinkamas ateities rodiklis. Ypatingai autorius peikia techninės analizės efektyvumą.

Žvelgiant į lentelėje paminėtus literatūros šaltinius, sunku nesijausti dviprasmiškai. Atsižvelgiant į Veronesi ir Pastor (2017), bei Santa-Clara ir Valkanov (2003) darbus atrodo, kad viskas ko reikia norint aplenkti rinką ir demonstruoti labai stiprius rezultatus akcijų rinkoje yra sekti JAV tuometinio

prezidento partiją. Turint omeny, kad rinkimai vyksta kas keturis metus, tai būtų ypatingai laikui neintensyvus būdas demonstruoti išskirtinius rezultatus. Jeigu, dar pridėtume Degenhardt ir Benjamin (2017) pateiktus patarimus parduoti investicijas, kas gegužę ir grįžti į rinkas spalį, atrodo tokiu būdu investuojant ypač mažai laiko galima būtų pasiekti įspūdingus rezultatus. Žinoma, nuoširdžiai tuo vadovautis būtų naivu, tuo labiau kai autoriai kaip Arnott, et al. (2017) iškelia argumentuotą abejonių dėl tokių supaprastintų investavimo kriterijų kaip šalies vadovo partija. Tačiau, žinant apie tiek daug pastoviai pelningų investuotojų ir/ar fondų valdytojų kaip Varenas Bufetas, Rėjus Dalijus, Peteris Linčas, Davidas Teperis ar Džesis Livermoras kyla klausimų ir dėl antrosios grupės mokslininkų kaip Fama (1965) ir Malkiel (2007), kurie iš esmės bando nuginčyti, bet kokią galimybę, kad pastovus ir nebūtinai rizikingiau gaunamas pelnas akcijų rinkoje yra įmanomas. Minėti investuotojai įrodo, kad iš tikrųjų vadovaujantis tinkamais veiksniais, investavimo filosofija ir disciplina rezultatai gali būti ne tik pastovūs, tačiau ir labai pelningi. Tai viena priežasčių, dėl ko tų veiksmų ir jų panaudojimo metodologijų paieška yra tokia aktuali su finansais susijiuose akademiniuose darbuose.

Mokslininkų darbuose galima išvysti įvairių hipotezių apie akcijų rinkas įtakojančius veiksnius. Iš didesnio kiekio peržvelgtos literatūros galima išskirti dvi stovyklas: vienoje — autoriai akcentuojantys individualius veiksnius, kurie susiję tik su ta akcija ar jų grupe, kitoje pusėje — autoriai įrodinėjantys, kad visos šalies ar net pasaulio makroekonominiai rodikliai veikia išties akcijų rinkas ar sektorius. Dalis autorių bando apjungti abi grupes rodiklių ir tada ieškoti sąryšių su akcijų rinkų rodikliais. Kaip jau dalinai atskleidė minėtos publikacijos ir teorijos, kiekvienoje iš tų grupių veiksniai gali būti patys įvairiausi. Individualių veiksmų grupę atstovauja tokie tyrimai kaip G. Alesi (2006), Chen, et al. (2013) kurie randa, kad akcijų kainoms ypač svarbu su pačių įmonių pinigų srautais susijusios naujienos. Anot autorių efektas sustiprėja poros metų ir ilgesniuose investavimo horizontuose. Tarp kitų su individualiomis akcijomis susijusių rodiklių dažniau sutinkamų literatūroje, galima išskirti įvairius fundamentalius veiksnius kaip santykinius rodiklius tarp įmonės pelno, buhalterinės vertės, dividendų, tenkančių vienai akcijai ir tų akcijos kainos, taip pat kitus įvairesnius rodiklius kaip akcijos prekiavimo apyvarta, metų kiek dabartinis vadovas buvo su kompanija ir daug kitų galimų pavyzdžių.

Labiau susikoncentruojant į antrąją tyrimų grupę, kurioje tyrinėjami makroekonominių ar visuotinių rodiklių šalies, pasaulio mastu įtaką akcijų rinkoms, čia galima sutikti kiek mažiau įvairovės. Tačiau būtų sunku teigti, kad rezultatai čia mažiau ar daugiau sėkmingi. Tarp mėgstamų rodiklių šioje mokslinėje šakoje yra demografiniai rodikliai, tačiau Heaton ir Lucas (2000) žengia žingsniu detaliau ir savo darbe nustatinėja populiacijos aktyvumo ir portfelio formavimo sprendimų įtaką akcijų rinkai.


Autoriai darbe pažymi gerokai išpopuliarėjusią akcijų rinką, kas pasireiškia didesne vietinių gyventojų proporcija investuojančia į akcijas ir didesniu užsienio investuotojų pritraukimu į JAV rinkas. Tačiau eksperimentuodami su skirtingomis prielaidomis jie prieina išvados, kad gyventojų aktyvumo pokyčiai turėtų būti dar ekstremalesni, kad privestų prie tokio akcijų rinkos kylimo, koks buvo tuo metu. Autoriai akcentuoja portfelio sudėties įtaką jau investuojančioje publikoje ir argumentuoja, kad stipriai išaugusi akcijų dalis portfeliuose nusipelno didesnio dėmesio.

Kiek artimesnis standartiniam darbui šioje šakoje yra Hosseini, et al. (2011) tyrimas, kurio metu buvo ieškoma ryšių tarp makroekonominių rodiklių ir tokių skirtingų ekonomikų veikiamų akcijų rinkų kaip Kinija ir Indija. Nagrinėjant naftos kainos, pinigų kiekio rinkoje, industrinės gamybos ir infliacijos rodiklius nuo 1999 m. iki 2009 m., autoriai rado įtaką beveik visų šių rodiklių trumpuoju ir ilguoju laikotarpiu, tiesa įtakos dydžiai bei kryptys (neigiama ar teigiama) skyrėsi abiejuose rinkose beveik kiekvieno kintamo atžvilgiu. Visi minėti rodikliai yra labai dažnai sutinkami mokslininkų darbuose. Faktiškai identiškus rodiklius naudoja Mukhopadhyay ir Sarkar (2003) nagrinėdami Indijos akcijų rinką, pridurdami vietinės valiutos kursą ir keletą kitų indikatorių. Nafta buvo pagrindinis tyrimo objektas Gogineni (2008), Park ir Ratti (2008), Sadorsky (2008), o Ewing ir Thompson (2007) taipogi atsižvelgia į nedarbą, infliaciją bei industrinės produkcijos rodiklius. Pinigų pasiūla figuruoja Wongbangpo ir Sharma (2002), Alatiqi ir Fazel (2008) moksliniuose darbuose, infliacija — Locarno ir Massa (2005) bei Flannery, Protopapadakis (2002). Tarp dar nepaminėtų, bet akivaizdžiai labai populiarių rodiklių būtų nedarbas ir bendras vidaus produktas (BVP) ar jo augimas vertinamas Colacito, et al. (2015) projekte ar Lee, et al. (2006) Singapūro akcijos rinkos kontekste. Tarp rečiau sutinkamų pavyzdžių galima paminėti Lakonishok, et al. (1992) darbą kuriame akcijų kainų judėjimai aiškinami institucinių investuotojų veiksmais ir tendencijomis. Autoriai išskiria institucijų taikomų metodų įvairovę, kuri išskaido įtaką.

Apibendrinus literatūrą, kuri ieško akcijų rinkų ir makroekonominių-visuotinių rodiklių sąsajų galima išvelgti didelę įvairovę tarp regionų, kurių akcijų rinkos tyrinėjamos ir tam naudojamų nepriklausomų veiksnių laikotarpių, interpretacijų ir metodų pasirinkimų. Tačiau, kaip rodo minimi pavyzdžiai patys veiksniai gali kartotis ir labai detalai nevertinant tyrimų skirtumų, jų rezultatai gali pasirodyti prieštaringi. Šalia to, veiksnių pasirinkimai atrodo koreliuojantys ir su populiarioje spaudoje minimais labiau suprantamais ir daugiau dėmesio susilaukiančiais makroekonominiais veiksniais. Dėl to, kyla pagrįstos abejonės ar labiau kompleksiškos, bet ne mažiau svarbios ekonomikos dalys, kaip kredito rinkos, susilaukia pelnyto kruopštaus nagrinėjimo akademinėje literatūroje.

## 1.4. Su obligacijomis susijusių veiksnių aktualumas akcijų rinkose

Obligacijos yra didesnė turto klasė nei akcijos ir antra didžiausia pasaulyje, po nekilnojamo turto. Paveiksle nr. 3 žemiau matoma, kad tokių įsiskolinimo įrankių kaip obligacijų vertė pasaulyje lenkia net bendrą visą paslaugų ir produktų sukurtų 2015 m. vertę. Netoli dvigubai lenkiama ir visų pasaulio akcijų vertė, nors ilgalaikio įsiskolinimo instrumentų skirtumas nuo NT yra taip pat nemažas. Šios proporcijos labai panašios ne tik bendrame pasaulio kontekste, bet netgi didesnėje dalyje atskirų valstybių, tame tarpe JAV.



3 pav. Didžiausių turto klasių verčių trilijonais JAV dolerių palyginimas pasaulyje.

Šaltinis: „ValueWalk“ [95].

Kaip jau aptarta, akademikams bandant nustatinėti akcijų rinkų tendencijas su obligacijomis susiję veiksniai nedažnai būna pagrindinis tyrimų akcentas. Tiesa, vienas ar du su obligacijomis susiję veiksniai gana dažnai būna tarpe platesnio rato makroekonominių veiksnių, kurių ryšiai su akcijų rinka yra nustatinėjami. Tarp tokių pagrindinių rodiklių, kuriais dažnai bandoma apibendrintai atspindėti kredito rinkos poveikį, galima pažymėti palūkanų normą ir obligacijų pelningumus. Palūkanų norma literatūroje galima sutikti plačiausiu spektru pradedant vyriausybės trumpalaikių obligacijų kuponais,

LIBOR (Londono tarpbankinės rinkos palūkanų norma) ar vietinio centrinio banko nustatyta naktine palūkanų norma. Obligacijų pelningumai dažniausiai akademiniuose leidiniuose sutinkami, kaip JAV vyriausybės trumpalaikių (3-jų mėnesių) ar ilgalaikių (10-ies metų) obligacijų. Mukhopadhyay ir Sarkar (2003) savo tyrime naudoja netgi dvi palūkanų normas — vietinės Indijos rinkos trumpalaikio skolinimo vidutinę palūkanų normą ir LIBOR. Palūkanų normos svarbą vertinant akcijas, kaip kapitalo kainos katalizatorių, savo knygoje akcentuoja ir Koller, et al. (2005). Perry ir Herrera (2001) JAV trumpalaikių palūkanų normų pokyčius nurodo kaip svarbiausią veiksnių kapitalo judėjimuose Lotynų Amerikoje, kurie stipriai atsiliepia ir vietinių akcijų kainose. 3 mėnesių trukmės JAV obligacijų pelningumas buvo svarbus faktorius modelyje prognozuoti akcijų rinkas Binswanger (2004) 70 metų trukmės duomenis analizavusiame darbe, o 10 metų trukmės JAV išdo obligacijos rodė įtaką net Australijos akcijų rinkai D'Arcy ir Poole (2010) tyrime. Konsensuso šioje vietoje nėra, nes nors dauguma autorių, kaip jau minėti randa, kad kažkoks, nors ir labai netiesioginis ar silpnas, ryšis tarp akcijų ir pasirinktų palūkanų normų ar pelningumų egzistuoja, Alatiqi ir Fazel (2008) šį ryšį paneigia savo eksperimentuose su JAV vyriausybės trumpalaikių (3-jų mėnesių) ir vidutinės trukmės obligacijų pelningumais bei „S&P 500“ akcijų indeksu. Autoriai aiškina, kad nors obligacijoms palūkanų norma turėtų būti esminis veiksnys, akcijoms yra svarbu daug daugiau faktorių, kurių visumoje palūkanų normos įtaka tampa sunkiai pastebima.

Visi anksčiau minėti moksliniai darbai tiria mažą dalį su obligacijomis susijusių veiksnių kontekste su kitais pasirinktais makroekonominiais rodikliais, kurių tarpe dažnai pasikartojantys — infliacija, naftos kaina, BVP pokytis ir kiti minėti. Bandant ieškoti tyrimų, kuriuose obligacijų veiksniai būtų ne vienas iš akcentų, bet pagrindinis — papuolama į gana nišinę sritį. Iš pažiūros ši sritis buvo populiarsnė prieš keletą dešimtmečių, kol akcijų rinkos dar nebuvo išgyvenusios kelias dideles „bulių“ rinkas ir to pasakoje populiarsnės bei labiau mėgstamos institucinių investuotojų. Vienas tyrimų šioje nišoje buvo atliktas Saimono Kwan'o (1996), kuris rado neigiamą koreliaciją tarp tos pačios įmonės akcijų ir obligacijų, taip indikuojant, kad abi turto rūšys reaguoja skirtingai į įmonei specifines naujienas kaip ir turėtų (prie teigiamų naujienų — obligacijų pelningumai smukti, akcijų kainos kilti, prie neigiamų — atvirkščiai). Neigiamą koreliaciją lygindamas vienus žinomiausių akcijų indeksų Vokietijos „DAX“ ir JAV „S&P 500“ su atitinkamų valstybių 10-ies metų trukmės obligacijų pelningumais randa ir Verner (2017). Naudodamas dieninius duomenis, autorius pastebi, kad stipriausia koreliacija būna vidurkinant paskutinių 10-40 dienų reikšmes JAV, kai Vokietijoje analogiškiems rezultatams reikia 20-40 dienų. Tai be to, šiek tiek kertasi su Antti Ilmanen (2003) pastebėjimais, kad vyriausybės obligacijos yra linkusios teigiamai koreliuoti su akcijomis esant nors kokiam teigiamam infliacijai. Kadangi tokia infliacija buvo didesne laiko dalį per paskutinius 70-80

metų, tai teigiama koreliacija dominavo, nepaisant krizių metais atsiradusio negatyvaus ryšio. Andersson, et al. (2008) analizavo akcijų ir obligacijų ryšio skirtumus laiko tekmeje ir jų išvados artimos prieš tai minėtų autorių. Andersson, et al. (2008) pastebi, kad periodais, kai galima tikėtis didelės infliacijos akcijos ir obligacijos išlaiko gana stiprų ryšį, kuris tampa negatyvus arba labai susilpnėja periodais kai lūkesčiai infliacijai susilpnėja. Li Lingfeng (2002) irgi daro labai panašius pastebėjimus apie obligacijas ir akcijas, teigdamas, kad pagrindinis faktorius lemiantis šių dviejų faktorių tarpusavio ryšį yra infliacijos prognozuotumas, visose 7-iose labiausiai pažengusiuose ekonomikose, kurias tyrė autorius. Šių dviejų turto klasių tarpusavio ryšio visumą autorius grindžia makroekonominiais veiksniais, kurie įtakoja abi klases. Tačiau ir čia akademiniame lauke nėra konsensuso, nes šiai išvadai nepritarė Ghysels, et al. (2009), kurie įvardina, jog obligacijų ir akcijų tarpusavio ryšiai žymiai labiau formuojami likvidumo faktorių.

Kwan'as (1996) taip pat rodė, kad akcijos turi prognozuojamą efektą obligacijų pelningumams, bet ne atvirkščiai, kas vos neidentiška replikuoja Downing (2009), Campbell ir Taksler (2003) ir Hui-Ju Tsai (2014) išvadas. Ryšį tarp obligacijų ir akcijų rado ir Baker bei Wurgler (2012). Tirdami vyriausybines obligacijas ir akcijas autoriai pastebi, kad akcijos artimiausios obligacijoms turi stipriausią ryšį su obligacijomis. Bruožai, kuriais pasižymi tokios akcijos yra mažai rizikingos, didelių kompanijų, pelningos ir besidalinančios pelnu su akcininkais dividendų forma. Autoriai pastebi, kad vertės ieškančių investuotojų pamėgtos prie bankroto priartėjusios kompanijos arba tendencijų ieškančių investuotojų mėgstamos staiga augimo akcijos, turi gerokai silpnesnį ryšį su obligacijomis. Autoriai netgi randa bendrų kintamųjų, kurie remiantis jų eksperimentais tinkami prognozuoti tiek akcijas, tiek obligacijas. Panašiai kaip pastarieji autoriai, Kang (2007) irgi susidomėjęs vyriausybių obligacijų ir akcijų ryšiais. Keliais skirtingais modeliais tyrinėdamas JAV išdo 1-ųjų ir 10-ies metų trukmės obligacijų priklausomumą su dviem iš didžiausiais JAV akcijų indeksais „Nasdaq“ ir „S&P 500“ autorius neatrado stipresnio ryšio su nei vienu iš modelių. Durré ir Giot (2007) bei Struggs ir Glabadanidis (2003) išvados artimos Kang (2007), priduriant, kad ilgalaikių obligacijų pelningumai įtakoja akcijų kainas trumpuoju laikotarpiu. Norden ir Weber (2004) savo darbe per gana trumpą laikotarpį (2000-2002) tyrinėdami skirtingus kintamuosius pastebi stipriai neigiamą asociaciją tarp akcijų pokyčių ir aukštos bei žemesnės kokybės obligacijų pelningumų skirtumų (angl. *spread changes*). Skirtingai nei Malcolm Baker bei Wurgler (2012), autoriai neskaido akcijų į grupes, bet tai daro su obligacijomis, tačiau šiuo atveju nepastebi jokių skirtumų tarp finansiškai stipresnių ir mažiau stiprių korporacijų obligacijų tendencijų lyginant su akcijomis. Kaip ir kitų autorių darbuose išryškėja, kad akcijos lenkia pokyčius obligacijų rinkoje.




Nors, akademiniam lauke gana dažnai galima matyti, kai tam tikrų veiksmų įtaką matuojama ir tada lyginama paraleliai akcijoms ir obligacijoms, o pastarųjų stiprus tarpusavio ryšis preziumuojamas kaip savaime suprantamas, kaip rodo dalis šiame darbe apžvelgtų darbų tai nebūtinai tiesa. Dėl to, tokio ryšio aplinkybės ir stiprumas nėra galutinai aiškios ir visuotinai patvirtintos. Akcijos taip pat, dažniau randamos savo judėjimais lenkiančios obligacijas, o ne atvirkščiai, kas siūlytų, jog obligacijos neturi prognozuojančios įtakos akcijoms. Tai taip pat kertasi su kitų autorių rezultatais, kur akcijos ir obligacijų veiksniai atrodė judantys paraleliai arba net šiokiu toku lagu. Be to, žvelgdami į darbus sufokusuotus į tokio ryšio tyrinėjimą galime sutikti pasikartojančius kintamuosius, kaip aukštos bei žemesnės kokybės obligacijų pelningumų skirtumus ar valstybių ilgalaikių obligacijų pelningumus. Tiek akcijos, tiek obligacijos yra ne tokie paprasti finansiniai instrumentai, kurie šiai dienai gali būti pagrįstai atstovaujami didelės gausos ir įvairovės agreguojančių, apibendrinančių veiksmų, kurie neblogai nusakytų bendrą turto klasės būseną. Dėl to toks veiksmų pasikartojamumas moksliniuose tyrimuose palieka erdvę inovatyvumui dalyvaujančių veiksmų atrankoje.

### **1.5. Regiono ir laikotarpio aktualumas**

Šiame, darbe bus naudojami dieniniai duomenis iš laikotarpio nuo 2003.01.01 iki 2017.12.31. Iš šio laikotarpio buvo paimtos tik JAV prekybos (darbo) dienų veiksmų pokyčiai. Toks laikotarpis buvo pasirinktas dėl keletos priežasčių:

- Siekiant atspindėti finansinių eilučių cikliškumą;
- Siekiant duomenis turėti kuo artimesnius dabartiniam laikotarpiui;
- Siekiant kuo didesnio stebinių skaičiaus.

Pirmoji priežastis adresuojama pasirinktu laikotarpiu, dėl to, kad per pasirinktą laikotarpį išpuola 2-u ekonominio pakylimo (2003-2007 ir 2009-2017) ir 1-as ekonomikos susitraukimo periodas (2007-2009), tuo galima įsitikinti 4 paveiksle. Tai turėtų leisti tyrimo rezultatams būti aktualiams abiejuose ciklo pusėse. Cikliškumas akcijose tapęs mažai ginčytinas, ką savo tyrime patvirtina Ghysels, et al. (2009), o Koller, et al. (2005) taip pat rekomenduoja vertinant akcijas atsižvelgti į cikliškumą ir pabrėžia, kad dalis kompanijų gali būti labiau veikiamos cikliškumo nei kitos.




**4 pav. „S&P 500” indekso judėjimas 2003-2017 m. Šaltinis: sudaryta autoriaus pagal „Bloomberg Professional“ duomenis [12].**

Be to, kadangi duomenis buvo pasirinkti labai artimo laikotarpio, tai reiškia, kad tyrimo rezultatai turėtų būti artimi tendencijoms, kurių galima tikėtis artimiausiais metais. Šio tyrimo autoriaus nuomone, imti daug ilgesnį laikotarpį, kaip pavyzdžiui 50 metų, būtų netikslu, nes būtų sunku tikėtis, kad rinkos tendencijos vyravusios prie visiškai kitokios geopolitinės ir ekonominės situacijos būtų tiek pat aktualios dabar kaip paskutinių 15-os metų duomenis. Galiausiai, kadangi pasirinkti duomenis buvo dieniniai, 15-os metų laikotarpis sudaro 3776 stebinius (skaičiuojant tik JAV biržų darbo dienas), kas yra solidus skaičius, kuris neturėtų varžyti jokių modeliavimo ar tyrinėjimo aspektų. Didelė dalis mašininio mokymosi algoritmų tyrimų finansuose naudoja dvigubai mažiau stebinių.

Darbo aktualumą didina ir tai, kad tiek  $x$ , tiek  $y$  veiksniai naudojami darbe yra iš JAV rinkos. JAV rinka yra turbūt arčiausiai iš visų pasaulio akcijų rinkų prie Fama (1965) iškeltos efektyvios rinkos teorijos. Tai yra — nauja informacija atsispindi akcijų kainose greičiausiai, o pervertintų/nuvertintų akcijų taip pat yra sunkiausia rasti. Taip galima ryžtis teigti dėl didžiulio susidomėjimo, kurį gauna JAV akcijų rinka ir didžiulio dalyvių kiekio. Dalyvių kiekis ne tik didelis, bet ir patys dalyviai yra patys galingiausi ir didžiausi fondai pasaulyje kaip „Bridgewater Associates“ ar Vareno Bufeto „Berkshire Hathaway“. Šalia to, dabar jau ypatingai sunku nuneigti, kad JAV akcijų

rinkos būseną aktuali ne tik vietiniams gyventojams ir institucijoms, bet ir visame pasaulyje. Sąryšiai tarp JAV akcijų rinkos tendencijų ir judėjimų kitose akcijų rinkose kaip Australijoje, Kinijoje, Europoje, Lotynų Amerikoje yra daug kartų įrodyti. Pavyzdžiui D’Arcy ir Poole (2010) įrodė, kad kai kuriais atvejais JAV rinkos naujienos yra svarbesnės Australijos akcijų rinkos vertinimui, nei lygiavertiškos naujienos iš pačios Australijos.

Nors pastarasis laikotarpis rodo, kad JAV akcijų rinkos vaidmuo kaip vedančiosios sumenko, dėl bendrai didesnio suintegruotumo tarp visų akcijos rinkų aplink pasaulį, tačiau būtų sunku ginčyti, kad JAV neišlieka įtakingiausia tokia rinka pasaulyje. Tai aiškiai parodo ir 5 pav., kur nepaisant vis augančių kapitalizacijų aplink pasaulį, JAV išlieka absoliuti lyderė.



**5 pav. Įvairių valstybių vietinių kompanijų rinkos vertės palyginimas 1998-2017 m.**  
**Šaltinis:** sudaryta autoriaus pagal „World bank“ duomenis [94].

Stebint tai, tampa akivaizdu, kad įgavus geresnį supratimą apie JAV akcijų rinką veikiančius veiksnius, galima turėti geresnį supratimą ir apie pasaulines akcijų rinkų tendencijas.

## 1.6. Literatūros apžvalgos apibendrinimas

Apibendrinus literatūros apžvalgą, galima išskirti keletą bendrų tendencijų:

- Turto klasių kainos yra stipriai kintančios ir įžvalgos apie turto klasių tikrą vertę gali leisti priimti daugiau tinkamų sprendimų ir viršyti rinkos pelningumą bei išsaugoti savo kapitalo vertę mažiau nuspėjama, neramiais laikotarpiais.
- Nors akcijų rinka yra sudėtinga ir konkurencinga sritis priiminėti sprendimus, tačiau taip pat galima išvelgti sudėtingumo „pervertinimo“ apraiškų ir gana paprastos metodikos taip pat yra pelniusios sėkmės praeityje.
- Ryšių ieškojimas tarp turto klasių kainų ir įvairių veiksnių yra tarp dažniausiai sutinkamų turto klasių vertės aiškinimosi metodikų grupių.
- Akcijos yra viena populiariausių ir pelningiausių turto klasių, o dalyvavimo barjerai šioje rinkoje minimalūs.
- Akcijoms analizuoti dažniausiai pasitelkiami individualūs arba makroekonominiai veiksniai.
- Yra gausu tyrimų ir straipsnių bandančių nustatyti įvairių makroekonominių veiksnių įtaką individualioms akcijoms ar akcijų rinkoms, tačiau dažniausiai obligacijų veiksniai yra tik dalis platesnio tiriamų veiksnių sąrašo tokiose tyrimuose, o ne pagrindinis ar vienintelis jo akcentas. Kiti makroekonominiai veiksniai, kaip BVP, infliacija ar valiutų kursai daug dažniau sutinkami akademinuose darbuose. Tai signalizuoja, kad obligacijų, kaip antros pagal didumą turto klasės, įtaka akcijoms išlieka nepilnai išanalizuota.
- Prie prieš tai pateikto pastebėjimo verta pridurti, kad tai, jog obligacijų veiksniai dažnai būna tik dalis platesnio veiksnių sąrašo, priveda prie to, kad jų įtaką akcijų rinkoms nebūna nuodugniai ištyrinėta, nes:
  - Priklausomai nuo taikomos metodikos, obligacijų veiksniams būnant platesnio veiksnių komplekto dalimi, jų įtaka pasilieka neatskirta, neišgryninta nuo kitų komplekto veiksnių įtakos.
  - Taikant įvairias metrikas, laikotarpius ir veiksnis, su obligacijomis susijusių veiksnių įtaka gali nepraeiti autorių taikomų atrankos kriterijų ir išvis nepakliūti į veiksnių dalį, kuri toliau detaliau nagrinėjama.
- Obligaciniai veiksniai dažnai randami kaip reaguojantys vėliau nei akcijų veiksniai.
- Akademinuose tyrimuose, pagrinde dominuoja vyriausybės obligacijų pelningumai (ypač mėgstamas 10-ies metų laikotarpis). Taip yra dėl bandymo apibendrinti, suvesti obligacijų įtaką į vieną ar keletą lengvai suprantamų veiksnių. Tačiau, tokiais atvejais pasilieka erdvė įvertinti daugiau obligacijų rinkos niuansų ir/ar korporacinių obligacijų rinkos įtaką.

- JAV akcijų ir obligacijų rinkos yra bendrai pripažįstamos kaip pačios likvidžiausios ir svarbiausios. Jų įtaka Kinijos, Europos ir besivystančioms rinkoms yra gerai užfiksuota daugelyje tyrimų. Šalia to, JAV rinka dažnai yra vedanti ir šios rinkos reakcija į visą pasaulį palietusius įvykius būna svarbiausia ir kartais su uždelsimu replikuojama aplink pasaulį. Dėl to, įžvalgos šioje rinkoje turi didesnę potencialą kitose rinkose nei atvirkščiai.
- Buvo pastebėta, kad sutiktoje literatūroje, akcijų rinka gali būti reprezentuojama pasikartojančiais ir vienpusiais rodikliais. Akcijų rinka turi daug metrikų, kurios gali suteikti labiau pilnavertišką vaizdą apie akcijų rinkos būklę.
- Rinkdami duomenis finansų rinkose, autoriai dažniausiai stengiasi parinkti pakankamai ilgą laikotarpį, kuris atspindėtų finansų rinkų cikliškumą.
- Didesnė dalis finansų rinkas tyrinėjančių akademikų taiko įprastus tiesinius regresinius modelius, Granger priežastingumo testus ar vienmačius modelius kaip ARIMA. Inovacijoms šiame lauke yra erdvės augti.

Taigi, atsižvelgiant į anksčiau aptartas tendencijas sutiktas mokslinėje literatūroje šio darbo pagrindinė kryptis yra obligacijų pelningumą ir jį lemiančių veiksnių įtakos akcijų rinkoms analizė. Taip, bus tikrinama ar dalies autorių išvados, kad obligacijos yra daugiau sekantis, o ne akcijas vedantis veiksnys yra tikslios. Su obligacijomis susijusių veiksnių skaičius ir jų įvairovė turėtų labai gerai atspindėti tiek vyriausybių, tiek kompanijų lygmens obligacijų rinkų tendencijas. Taip pat, šių veiksnių įtaką akcijų rinkoms bus matuojama daugiau negu viena metrika, kas užtikrina, jog užfiksuoti ryšiai galės būti patikrinti ir lyginami tarp skirtingų akcijų rinkos sričių.

Tyrimė, taip pat bus bandoma išskirti veiksnių įtakos skirtumus pagal skirtingus metodus ir laikotarpius, taip kreipiant dėmesį į kintamųjų tarpusavio jautrumo vertinimą. Ypatingai finansų rinkose, neretais atvejais nepriklausomi kintamieji gali būti labai reikšmingi vienu laikotarpiu, tačiau daug mažiau svarbūs kitais laikotarpiais.

Tiek obligacijų, tiek akcijų kintamieji tyrimė bus iš JAV rinkos, kas rodo, kad tyrimo rezultatai turi potencialo būti aktualūs ir kitose akcijų rinkose turint omeny JAV rinkos statusą kaip vedantį.

Šių veiksnių tyryba bus vykdoma lanksčiai, agreguojant geriausias praktikas kitose akademinuose darbuose ir pritaikant inovatyvius, rečiau finansų darbuose sutinkamus metodus, kurie apžvelgti 2-oje šio darbo dalyje.

## 2. TYRIMO METODAI IR METODIKA

### 2.1. Akcijų rinkos tyrimams taikomos metodikos ir programinės įranga

Norintiems nuodugnumo tyrinėjant akcijų rinkas, iškyla nemažai sunkumų. Skepticizmas kyla iš tokių mokslininkų kaip Chris Kirby (1997) kurie argumentuoja, kad akcijų pokyčiai iš viso yra beveik neįmanomi prognozuoti, o tokie modelių tikslumo parametrai kaip  $R^2$  (determinacijos koeficientas) ne visada yra pagrįsti. Tai yra gana radikalus požiūris, didesnė dalis finansų rinkas tyrinėjančių autorių visgi ieško ir kai kurie iš pažiūros sėkmingai randa reikšmingus veiksnius, kurie gerai paaiškina akcijų judėjimus ir gali būti panaudoti prognozavimui. Dalis tokių pavyzdžių jau buvo paminėti šiame darbe. Tiesa, kaip savo darbe apibendrina Sheta, Ahmed ir Faris (2015), akcijų rinkos tyrinėjimo lauke išlieka daug įrodymų apie šio lauko dinamiškumą, netiesiškumą, komplikotiškumą ir chaotiškumą. Iš vienos pusės tai iššūkis, kuris skatina visuomenės ir mokslo susidomėjimą bei didina galimų atradimų monetizavimą, tačiau iš kitos pusės dėl to galima sutikti labai priešingų rezultatų, o konsensusai yra sunkiai pasiekiami. Gana skirtingą vaizdą, galima pamatyti pavyzdžiui vartotojų elgesio tyrinėjime, kur dažnai iškyla aiškios ir pasikartojančios tendencijos.

Bet kokios analizės įtraukiančios finansinius, turto klasių kintamuosius susiduria su šiomis problemomis:

**Cikliškumas.** Akcijų rinkų svarbus bruožas yra pasikartojantys kylimo ir nuosmukio laikotarpiai. Tačiau cikliškumas yra staigus ir pasikartojantis netolygiais periodais, o kiti rodikliai cikliškumo arba neturi, arba stipriai vėluoja. Dažna problema moksliniuose darbuose, kad rezultatai rasti dirbant su duomenimis vienoje ciklo pusėje menkai arba netgi visiškai nepritaikomi, ciklui pasikeitus.

**Laiko eilučių efektas.** Duomenys būna išsidėstę seka pagal laiką, kas reiškia, kad nėra tikslo juos imti atsitiktinai. Taip pat, dažnai susikoncentravus į labai ilgą laikotarpį galima matyti rezultatus, kurie žymiai geriau pritaikomi situacijai gerokai atgal praeityje, o ne tyrimo metu esančiai situacijai, kuri gali būti stipriai skirtinga istorinėms tendencijoms.

**Žmonių psichologija.** Žlugo teorija, kad finansinės transakcijos ir jų diktuojamos akcijų kainos yra visiškai teisingos, bet kuriuo laiko momentu, ką teigė efektyvioji rinkos teorija pristatyta Fama (1965 m.). Tam reikėtų, kad žmonės būtų idealiai racionalūs, kas senai paneigta tokiose veikaluose kaip Kahneman (2011) ir daug kitų. Tai reiškia, kad šalia visų kitų veiksnių, kurie gali turėti įtakos

akcijoms, galima pridurti žmonių psichologiją kuri nėra racionali ir yra labai sunkiai apibendrinama veiksniais ar jų grupėmis. Tai įveda daug „triukšmo“ į akcijų rinkų analizes.

Tai pagrindiniai faktoriai, iš kurių pirmieji du gali būti dažnai pritaikyti ne tik finansinėms laiko eilutėms. Tokių faktorių būtų galima pažymėti gerokai daugiau, priklausomai nuo sprendžiamos problemos. Visi minėti sunkumai aktualūs tiek rezultatų ieškant vienmačių atveju, kai gali būti pasirinktas kažkoks vienas su akcijomis siejamas kintamas ir ieškoma nuspėjamų savybių iš pačio kintamo istorinių duomenų, dažniausiai remiantis autokoreliacijos savybėmis. Tiek šie sunkumai aktualūs daugiamačiu atveju, kai su akcijomis susijęs kintamas yra priklausomas veiksnys, o kiti atrinkti veiksniai yra nepriklausomi ir bandoma ieškoti ryšių tarp abiejų grupių tuo pačiu ar kiek pavėlintu laikotarpiu. Pastarasis atvejis yra genokai dažniau sutinkamas, apibendrinus turi sėkmingesnius rezultatus ir dėl to yra labiau pripažintas. Šio darbo sprendžiama problema taip pat yra, daugiamatė, nes turimi 5 priklausomi kintamieji, iš kurių kiekvienas atskirai bus tiriamas 11-os nepriklausomų kintamųjų kontekste.

Daugiamatės laiko eilučių analizės problemos sprendimai ir tinkamiausia metodologija universaliu atveju nėra nusistovėję. Į būtent tokio pobūdžio problemas žvelgė Liu, et al. (1999), chemijos ir medicininių industrijų kontekste, kurios taip pat pasižymi dideliu aktualių laiko eilučių ir su jomis susijusių užduočių kiekiu. Autoriai nagrinėjo tokius duomenis iš skirtingų kampų, tiek bandydami tikslinti duomenų charakteristikas ieškodami išskirčių, tiek sprenddami skirtingas specifines problemas atsirandančias su mažai duomenų, tiek bandydami prognozuoti laiko eilutes. Autoriai reziūuoja, kad tai ką jie vadina „intelektualiai duomenų analizei“ reikia „atsargaus apgalvotumo kiekviename etape, intelektualaus industrijai specifinio konteksto pritaikymo tiek duomenims, tiek sprendžiamiems klausimams ir kritinio vertinimo tiek metodų atrankai, tiek jų integracijai“. Autoriai priduria, kad modelio parinkimas dažniausiai yra sudėtingiausia analizės dalis. Tai siejasi su Shah (2013) minimu faktu, kad dauguma finansinių eilučių nėra pasiskirstę pagal normalųjį arba Gauso skirstinį, kuris yra prielaida daugelyje dažniau naudojamų modelių. Savo darbe autorius palaiko pamėgta praktiką analizėje naudoti logaritmuotus pokyčius kaip būdą apeiti šią finansinių eilučių savybę ir priartinti ją prie stacionarumo ir tiesiškumo. Tą patį savo knygoje pataria ir Hilpisch (2015). Remiantis tuo, pasirinkti veiksniai tyrime buvo naudojami būtent tokia forma, kurios tiksli formulė pateikta žemiau.

$$r_t = \log\left(\frac{P_t}{P_{t-1}}\right) \quad (1)$$

Kai:

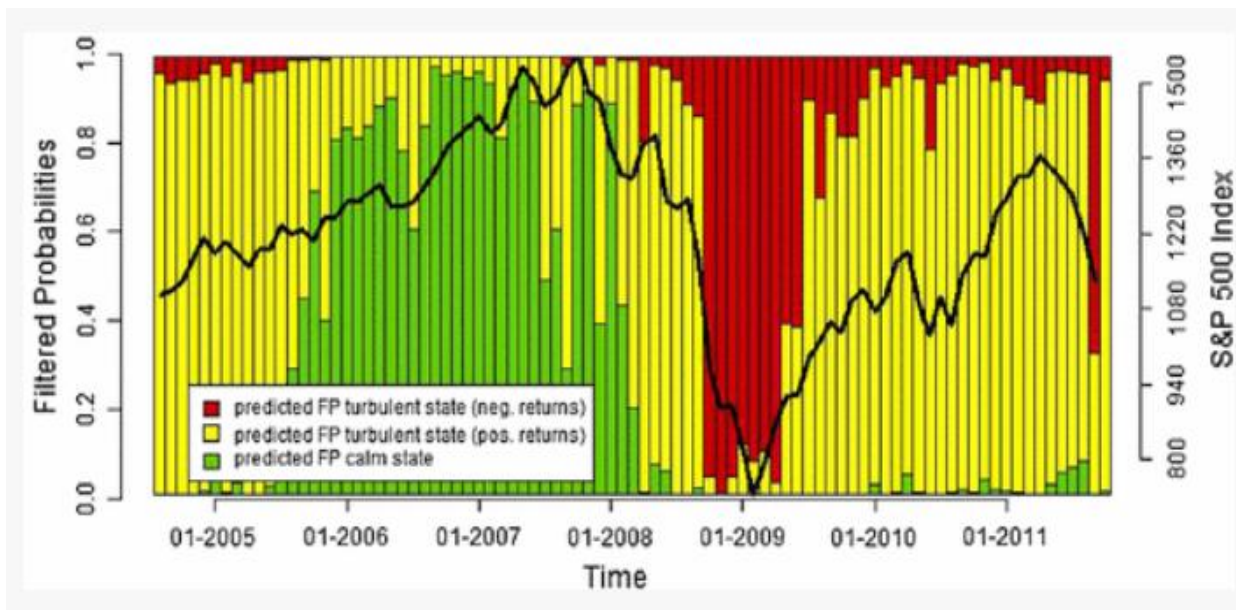
$r_t$  yra veiksnio logaritmuota graža (pokytis) lyginant su prieš tai buvusios dienos verte;

$P_t$  yra tos dienos prekybos pabaigos kaina;

$P_{t-1}$  yra prieš tai buvusios dienos prekybos pabaigos kaina.

Verta pažymėti ir laikotarpių išskaidymą priklausomų ir nepriklausomų kintamųjų. Tai iš tikrųjų yra pasikartojantis sprendimas nemažoje dalyje finansinių darbų, dėl anksčiau minėto cikliškumo finansinėse laiko eilutėse. Cikliškumas reiškia, kad pakilimo laikotarpio egzistavę stiprūs ir stabilūs ryšiai, ekonominio nuopolio laikotarpiais gali labai susilpnėti, keistis arba visai dingti ir atvirkščiai. Netgi prasidėjus naujam ciklui, ryšiai gali būti kitokie negu prieš tai buvo nustatyta. Kadangi tikėtis atrasti tarpusavio ryšius, finansų rinkose, kurie būtų vienodai pritaikomi ir tikslūs dešimtmečiais būtų naivu, tai pastebėdami mokslininkai neretai bando laiko eilutes iš karto suskaidyti pagal ekonominį cikliškumą. Tai atliekant galima pastebėti bei lyginti, kurie kintamieji įtakingiausi tiek ekonominio pakilimo, tiek nuopolio laikotarpiais bei kiekvienu iš laikotarpių atskirai. Ne retai pasitaiko, kai net toje pačioje ciklo pusėje skirtingais laikotarpiais dominuoja kiti kintamieji. Laikotarpių skaidymas pagal cikliškumą, rinkos situaciją yra viena iš alternatyvų, tačiau pakitusi situacija visiškai keičianti rinkos dėsnius yra toks dažnas atvejis finansuose, kad yra susiformavusi atskira mokslo sritis nagrinėjanti režimus keičiančius modelius. Tai modeliai, kurie pagal tam tikrus indikatorius iš duomenų gali keisti savo sudėti ir skaičiavimą vardan efektyvesnių rezultatų nepaisant didelių pokyčių rinkos situacijoje. Vienas populiariausių tokių modelių pavyzdžių yra Markovo režimus keičiantis modelis. Šiai dienai šis modelis turi įvairių iteracijų iš kurių Hauptmann, et al. (2014) pritaiko paslėptuosius Markov modelius (angl. *hidden Markov models — HMM*) gana detaliu masteliu. Pasižiūrėti, kaip tas pritaikymas atrodo galima 6 paveiksle, kur sužymėta autorių modelio kryptingumo signalai „S&P 500“ indeksui. Kaip matosi modelis gana stipriai vėluoja, ypač staigaus pakilimo ir nulydžio laikotarpiais.





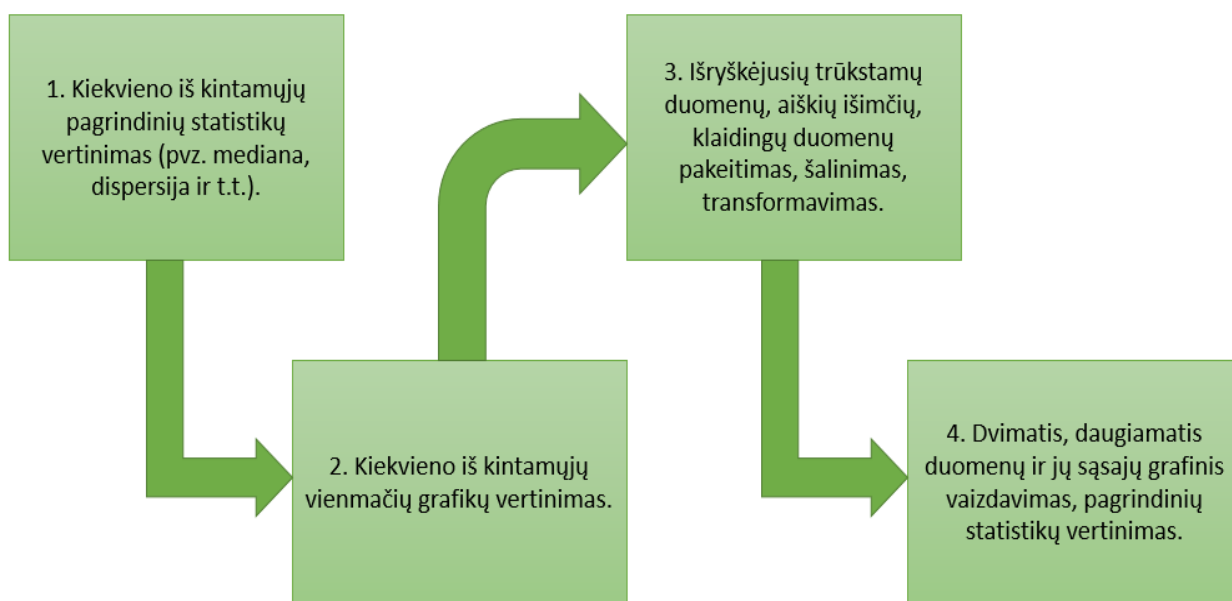
**6 pav. „S&P 500” indekso (juoda linija, dešinė vertikali ašis) ir kintančio režimo modelio vieni iš rezultatų (signalų tikimybės ašis vertikaliai kairėje), kur raudonai pažymėti — modelio signalai prognozuojant labai kintančius neigiamos grąžos periodus, geltonai — labai kintančius teigiamos grąžos periodus ir žaliai — nesmarkiai kintančius laikotarpius. Šaltinis: Hauptmann, et al. (2014).**

Šiame darbe, tyrimas buvo atliekamas naudojantis atviro kodo Pythono programavimo kalba [77]. Tai yra dinamiškai renkama kalba, kuri yra gana populiari mokslinėje bendruomenėje ir siūlo nemažą pasirinkimą įvairių atviro kodo bibliotekų susijusių su matematika, mokslinių tyrimų metodikomis ir panašiai. Aplinka naudota kodo rašymui ir interaktyvumui buvo „Jupyter notebook“ [46]. Pagrindė naudoti paketai jau egzistuojančių funkcijų panaudojimui ir papildomiems funkcionalumams buvo „Pandas“, „SciPy“, „Scikit-learn“, „Matplotlib“ ir „Seaborn“ [74], [84], [83], [68], [85].

## **2.2. Aprašomosios analizės metodai**

Apžvalginė analizė yra metodų kompleksas leidžiantis geriau susipažinti su turimais duomenimis ir jų sąveikavimu. Nors kai kurie autoriai mėgsta per daug nesigilinti į duomenis prieš jų taikymą modeliuose, kita dalis autorių apžvalginės analizės metodus taiko taip detaliai ir plačiai, kad tai tampa pagrindiniu tyrimo akcentu. Kažkokios formos apžvalginę analizę taiko beveik visi sutikti darbai ir daug kur sutinkama, kad mokslinė problematika turi diktuoti apžvalginės analizės pagrindinius tikslus. Tarp tokių tikslų galėtų būti įsivertinti turimus duomenis, pradėti tikrintis hipotezes ir geriau perprasti visų kintamų tarpusavio sąveikos visumą. Tačiau žvelgiant į didesnę kiekį analizių taikomų

finansinėms laiko eilutėms bei rekomendacijų knygoje gali susidaryti įspūdis, kad aprašomoji analizė nėra gerai apibrėžta, nes skirtingi autoriai taiko didžiulę įvairovę metodikų. Pavyzdžiui, kai kurie autoriai preziumuoja, kad duomenys yra visiškai teisingi apžvalginės analizės metu, kai tuo tarpu kiti analizę labiausiai būtent ir nukreipia į neteisingų ar nenaudingų stebinių paiešką ir po to sekantį šalinimą. Remiantis tokiais pavyzdžiais kaip Ling, Naranjo, ir Scheick (2010), Kang (2007), Zhang (2010) bei rekomendacijomis moksliniuose interneto portaluose, šio darbo autoriaus nuomone arčiausiai optimalumo esantys apžvalginės analizės žingsniai išskirti žemiau 7 paveiksle.



**7 pav. Aprašomosios analizės pagrindiniai žingsniai. Šaltinis: sudaryta autoriaus.**

- 1. Kiekvieno iš kintamųjų pagrindinių statistikų vertinimas.** Padeda įsivertinti duomenų pasiskirstymą ir tarpusavio skirtumus, autentiškumą. Rezultate, turėtų būti aišku koks normalizavimo būdas tinkamiausias kintamiesiems ir kiek teisingi duomenys. Pagrindinės metodikos: mediana, dispersija, standartinis nuokrypis, vidurkis.
- 2. Kiekvieno iš kintamųjų vienmačių grafikų vertinimas.** Leidžia įsivertinti akivaizdžias išskirtys ar trūkstamas reikšmes bei duomenų kintamumą laike. Šio žingsnio pabaigoje kiekvienas iš kintamų atskirai turėtų būti pakankamai žinomas, kad suprasti ar reikšmės teisingos ir reprezentyvos. Pagrindinės metodikos: eiliniai linijiniai grafikai, pasikartojančių reikšmių histogramos, įvairaus laikotarpio slenkančiųjų vidurkių lyginimai.

3. **Išryškėjusių trūkstumų duomenų, aiškių išimčių, klaidingų duomenų pakeitimas, šalinimas.** Po pirmų dviejų žingsnių išaiškėję trūkumai turėtų būti adresuojami šiame žingsnyje ar tai būtų trūkstumų reikšmių užpildymas ar akivaizdžių anomalinių stebinių šalinimas ar būdo tam atlikti vėliau parinkimas. Šiame žingsnyje taip pat gali būti atliekamas duomenų transformacijos/normalizavimas, kad jie būtų geriau palyginami tolimesniems žingsniams. Pagrindinės metodikos: interpoliacija, logaritnavimas, duplikatų šalinimas.
4. **Dvimatis, daugiamatis duomenų ir jų sąsajų grafinis vaizdavimas, pagrindinių statistikų vertinimas.** Turint visiškai paruoštus ir švairius duomenis, galima tiesiogiai lyginti kintamus tarpusavyje. Jeigu normalizuoti duomenis neišsaugo palyginamųjų savybių, gali būti įprasta ir šia analizės dalį vykdyti su originaliais, švairiais duomenimis. Dažniausiai grafiniai metodai šioje vietoje būna iškalbingiausi, ypatingai tyrinėjant daugiau nei porą kintamų vienu metu, tačiau pagrindinės statistikos irgi gali būti naudojamos papildomai informacijai išgauti. Rezultate, turėtų būti aišku kurie iš kintamųjų turi/neturi padidintą potencialą stipriai vienas kitą veikti, to ryšio charakteristikos (tiesinis, netiesinis ir t.t.) bei turėtų paaiškėti kurios iš anksto suformuotos hipotezės turi didžiausias galimybes pasitvirtinti. Betyrinėjant gali formotis idėjos ir naujoms hipotezėms. Pagrindinės metodikos: taškiniai (sklaidos) grafikai, stačiakampės diagramos, koreliacijos.

Po šių veiksmų turėtų būti ganėtinai aišku, ko galima tikėtis iš modeliavimo ir kokią rolę analizuoti kintamieji gali vaidinti. Hilpisch (2015) akcentuoja, kad koreliacijos koeficientai gali būti naudojami kaip paruošiamasis veiksmas regresijos lygties formavimui bei pasitikrinimui po to sekančių rezultatų.

### **2.3. Regresijos tyrimams taikomos metodikos ir jautrumo analizės įverčiai**

Įgijus neblogą kontekstą apie finansines eilutes ir atlikus pasiruošiamuosius veiksmus galima pereiti prie labiau komplikuoatų būdų tarpusavio ryšiams nustatinėti ir konkretinti. Akademikai šioje vietoje naudoja labai įvairius instrumentus pradedant elementariomis koreliacijomis ar Grainžerio tarpusavio veikimo testais ir baigiant labai sudėtingais, specifiskai tiriamai problemai modifikuotais regresijos modeliais. Tarp įdomesnių pavyzdžių galima paminėti Verner (2017), kuris akcijų ir obligacijų rinkas tyrinėja pasitelkdamas virpesių banglitą (angl. *wavelet*), kas yra labai specifinis duomenų vizualizavimo būdas.

Jau minėta regresija yra vienas seniausių ir žinomiausių būdų tyrinėti tarpusavio ryšius, kuris ypač mėgstamas finansų srityje. Tai, kad regresinė analizė buvo anksti pamėgta priėjimo forma

finansų srities moksliniuose tyrimuose, reiškia, kad regresijos metodikų ir universalesnių modelių pritaikymas gausus literatūroje, o pats regresinės analizės laukas gana greitai plėtėsi ir šiai dienai yra gana brandus ir netgi kiek mutavęs. Individualias laiko eilučių regresijas savo tyrime taikė ir Kwan (1996). Baker bei Wurgler (2012) pasirenką visai kitokį regresijos pritaikymą, kai akcijų ir obligacijų ryšius nagrinėja per iš anksto suformuotą regresijos lygtį. Panašiu principu autoriai pritaiko tų dienų duomenims ir kitas regresijos lygtis pasiūlytas kitų mokslininkų. Nustatinėdami savo regresijos tikslumą autoriai visur pritaiko gerai žinoma pataisyta  $R^2$  metriką, bei aptarinėja kiekvieno iš regresorių įtaką pagal apskaičiuotus koeficientus regresijos lygtyje. Stebėdami kaip koeficientai skiriasi nuo laikotarpio, stebinių skaičiaus, lygtyje dalyvavusių kintamųjų sudėties, priklausomiems kintamiesiems taikomo lagų skaičiaus autoriai daro prasmingas išvadas apie kiekvieno iš kintamųjų įtaką pasirinktu laiko momentu ar atskirose laiko fragmentuose. Tuo pačiu reikia turėti omeny po tiek tyrimų tapusį jau beveik savaime suprantamą faktą, kad tarpusavy susijusių kintamųjų keliai gali nukrypti trumpuoju laikotarpiu, tačiau ilguoju laikotarpiu turėtų judėti kartu, ką patvirtina ir Norden, Weber (2004) bei didelė dalis kitų mokslininkų

Aprašyti regresijos taikymai sutinka su geriausiomis praktikomis taikant regresiją bei turi jautrumo analizės aspektų. Jautrumo analizei šalia standartinės regresijos koeficientų gali būti taikomi ir koreliacijos koeficientai. Jautrumo analizės kontekste koreliacijos koeficientai yra būdas lyginti ir nustatinėti nepriklausomų kintamųjų įtaką priklausamam kintamui (-iems). Tarp plataus sąrašo paskirčių, kurias galima priskirti jautrumo analizei vienos pagrindinių yra:

- Modelio patikrinimas;
- Modelio rezultatų interpretacija;
- Modelio keitimas, derinimas;
- Modelio supaprastinimas.

Jeigu daugumai iš tų paskirčių pasiekti galima surasti alternatyvų, tai modelių interpretacijai tai būtų padaryti sudėtinga, dėl to šiame darbe jautrumo analizė šoje srityje bus akivaizdžiausia.

Jautrumo metrikų yra labai įvairių, iš kurių vienos paprasčiausių, bet ir efektyviausių yra imties metodai. Šie metodai dažniausiai sutinkami, kadangi jie greiti ir juos galima atlikti su ta pačia imtimi kaip ir taikyta modeliui. Naudojant tiek standartinės regresijos, tiek koreliacijos koeficientų metrikas, skirtumai tarp jų neturėtų būti ženklūs. Savo darbe jautrumo analizės aspektus pritaiko Hofer (1999). Autorius jautrumo analizę pasitelkia norėdamas geriau pažinti, kas kelia silpniau pasirodžiusių modelių neapibrėžtumą. Šiam tikslui autorius pasitelkia abu jau minėtus imties metodus. Baker bei

Wurgler (2012) taip pat naudoja įvairius koreliacijos koeficientus detalesniam nepriklausomų kintamų įtakos rezultatams nagrinėjimui. Tai rodo regresijos panaudojimo universalumą.

Anksčiau minėti, regresijos taikymo principai taikomi ir Norden bei Weber (2004) VAR (vektorių autoregresijos) ir vektorių klaidų taisymo (VECM) modeliams. Ir nors regresijos modelių yra labai įvairių, daug mokslinių tyrimų rodo, kad paprasčiausi regresiniai modeliai, kaip pavyzdžiui standartinė regresija (2-a formulė), dažnai būna labai nežymiai mažiau efektyvūs nei sudėtingiausi modeliai.

$$y = F_{\beta}(x_1, x_2, \dots, x_n) = \beta_0 + \beta_1 \cdot x_1 + \dots + \beta_n \cdot x_n; \quad (2)$$

Kai:

y yra priklausomas kintamas;

F yra funkcija nusakanti nepriklausomų veiksnių ir priklausomo veiksnio ryšį;

$x_1, \dots, x_n$  yra nepriklausomi veiksniai (modelio parametrai);

$\beta_0, \dots, \beta_n$  yra lygties koeficientai;

Manoma, kad taip gali būti dėl to, kad sudėtingi modeliai leidžia juos labai pritaikyti konkrečiam duomenų rinkiniui arba kitaip sakant „persimokyti“. Tačiau testuojant su nauju duomenų rinkiniu tas pritaikymas nebebūna toks tikslus. Tinkamiausias regresijos būdas dažniausiai parenkamas pagal žemiau sekančius kriterijus [4]:

- Nepriklausomų veiksnių skaičius;
- Regresijos linijos forma;
- Priklausomo veiksnio tipas.

Įvertinus šiuos faktorius galima rinktis regresijos modelį ir tada klaidos įvertinimo (angl. *Cost function*) funkciją, kurią minimizavus apskaičiuojami koeficientai ir tuo pačiu regresijos linijos nuolydis. Populiariausias metodas tam yra mažiausių kvadratų metodas, kurį naudoja ir Norden bei Weber (2004). Šio metodo formulė pavaizduota žemiau (formulė nr. 3):

$$J(\beta_0, \beta_1) = \frac{1}{2m} \sum_{i=1}^m (F_{\beta}(x_1, x_2, \dots, x_n)_{(i)} - y^{(i)})^2; \quad (3)$$

Kai (nepaaiškintos reikšmės lieka tokios pačios kaip ir 2-oje formulėje):

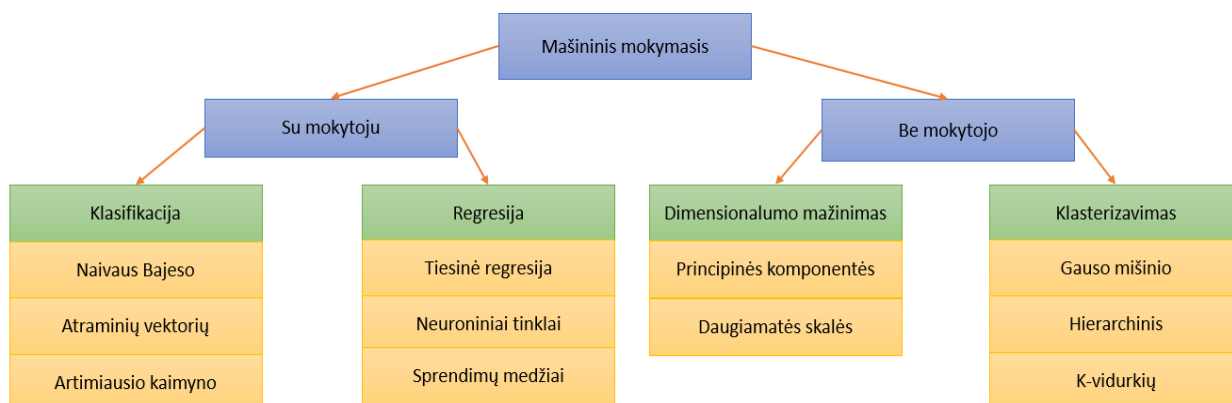
J yra funkcija nusakanti nuostolius (klaidas);

m yra stebinių skaičius;

Tarp kitų tai paskirčiai naudojamų metodų galima pažymėti ir vis labiau populiarėjantį nuolydaus žemėjimo (angl. *gradient descent*) algoritmą.

## 2.4. Mašininio mokymosi metodai

Kaip minėta regresiniai algoritmai labai išsiplėtė ir dalis jų dabar gali būti priskirti vadinamiesiems mašininio mokymosi (angl. *machine learning*) algoritmų mokslo kryptims. „Oxfordo“ žodyne mašininis mokymasis apibrėžiamas kaip „kompiuterio galimybė mokintis iš patirties, pavyzdžiui keisti savo skaičiavimus pagal naujai gautą informaciją“ [73]. Mašininio mokymosi algoritmai skirstomi į dvi pagrindines šakas — su mokytoju (prižiūrimo mokymosi, angl. *supervised*) ir be mokytojo (neprižiūrimo mokymosi angl. *unsupervised*). Bird, Klein, Loper (2009) kalbėdami apie pirmąją algoritmų grupę, klasifikacijos kontekste mini, kad tai grupė, kurioje duomenų imtis paskirta modelio apmokymui turi teisingas etiketes. Kitaip tariant, su pirmąja grupe algoritmų po kiekvienos duomenų eilutes algoritmas gali sulygtinti savo spėjimą su teisingu atsakymu ir taip mokintis. Antroji grupė algoritmų — be mokytojo, teisingų atsakymų neturi ir negali patikrinti savo spėjimų. Verta paminėti, kad grupių galima išskirti dar daugiau kaip pavyzdžiui dalinai su mokytoju (angl. *semi-supervised*) ir su grįžtamuoju ryšiu (angl. *reinforcement*). Dalis pagrindinių mašininio mokymosi algoritmų pritaikymo sričių ir joms priklausančių algoritmų pavaizduota 8-oje schemeje.

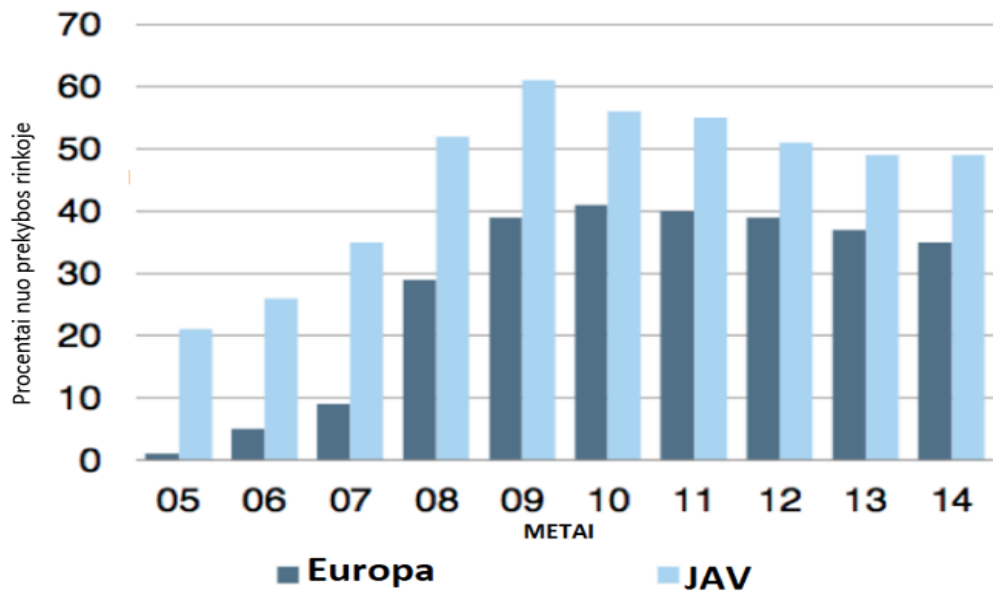


8 pav. Pagrindiniai mašininio mokymosi algoritmai ir jų taikymo sritys. Šaltinis: sudaryta autoriaus pagal „MathWorks“ [67].

Kaip pavaizduota schemeje, dažniausiai abi pagrindinės grupės algoritmų naudojamos skirtingiems tikslams. Pavyzdžiui be mokytojo algoritmai yra populiarūs duomenų dimensionalumo mažinimo ir duomenų klasterizavimo (suskirstymo į homogenines grupes) tipo uždaviniams. Su mokytoju — klasifikacijai ir regresijai. Be to, vaizduojami algoritmai nebūtinai yra pritaikomi tik minimo pobūdžio uždaviniams. Pavyzdžiui, neuroniniai tinklai galėtų būti puikiai pritaikyti ir klasterizavime ar klasifikavime, o sprendimų medžiai be regresijos dažniau naudojami klasifikacijoje. Mašininiai algoritmai gana greitai įgavo pagreitį duomenų analitikų bendruomenėje ir dabar yra plačiai taikomi įvairiose srityse pradedant vartotojų elgesio nustatymu, biologijoje ar telekomunikacijose.

Finansuose mašininiai algoritmai nuo pradžių susilaukė mažiau susidomėjimo, nei kitose pritaikymo srityse. Bontempi, et al. (2013) savo darbe analizavo mašininio mokymosi algoritmų reikšmę laiko eilučių tyryboje ir nustatė, kad tokio pobūdžio metodika per paskutinius 20 metų stipriai populiarėja ir paskutiniu metu jau įsitvirtino šalia dešimtmečiais dominavusių klasikinių laiko eilučių tyrybos metodų kaip ARIMA (autoregresyvus integruotas slenkantis vidurkis). Prie to labai prisidėjo palankios išvados iš tokių tyrimų kaip Lapedes ir Farber (1987) ir kitų, kur mašininio mokymosi algoritmai buvo sėkmingai pritaikyti ir jų neigiami stereotipai sušvelninti ar visai paneigti laiko eilučių atžvilgiu. Kaip jau aptarta, su finansiniais duomenimis dažniausiai pasitaiko regresijos tipo uždaviniai, kur priklausomo kintamo reikšmę bandoma nuspėti nustatant jo ryšį su vienu ar daugiau nepriklausomų kintamųjų. Tam tinkamiausi yra mašininio mokymosi algoritmai su mokytoju.

Šiomis dienomis mašininio mokymosi pritaikymas laiko eilutėse jau mažai kam kelia klausimų ir sėkmingų pavyzdžių yra labai daug. Zankova (2016) pritaiko net keturis algoritmus eksperimentuodama su kas finansuose vadinama —sparčioji prekyba (angl. *High Frequency Trading* — *HFT*). Sparčioji prekyba finansuose yra dažniausiai algoritmais paremta prekyba biržose, kai finansinių instrumentai gali būti įsigijami ir parduodami laikotarpiais matuojamais minutėmis, o kartais net milisekundėmis. Akivaizdu, kad per tokį laikotarpį realios vertės apskaičiavimas nėra pagrindinis tikslas, o yra reaguojama į iš anksto apibrėžtus signalus rinkoje. Būtent tokių signalų „gaudymui“ mašininio mokymosi algoritmai yra plačiai taikomi, o signalai dažniausiai būna susiję su statistiniais arbitražais ir likvidumo suteikimu rinkoje. Algoritminė prekyba užima labai reikšmingą dalį rinkos, nors nuo ekonominės krizės laikotarpio ji pradėjo kiek mažėti (9 pav.).



**9 pav. Algoritminės prekybos dalis nuo rinkos sandorių Europos ir JAV biržose 2005-2014 m. Šaltinis: „Cray“ [20].**

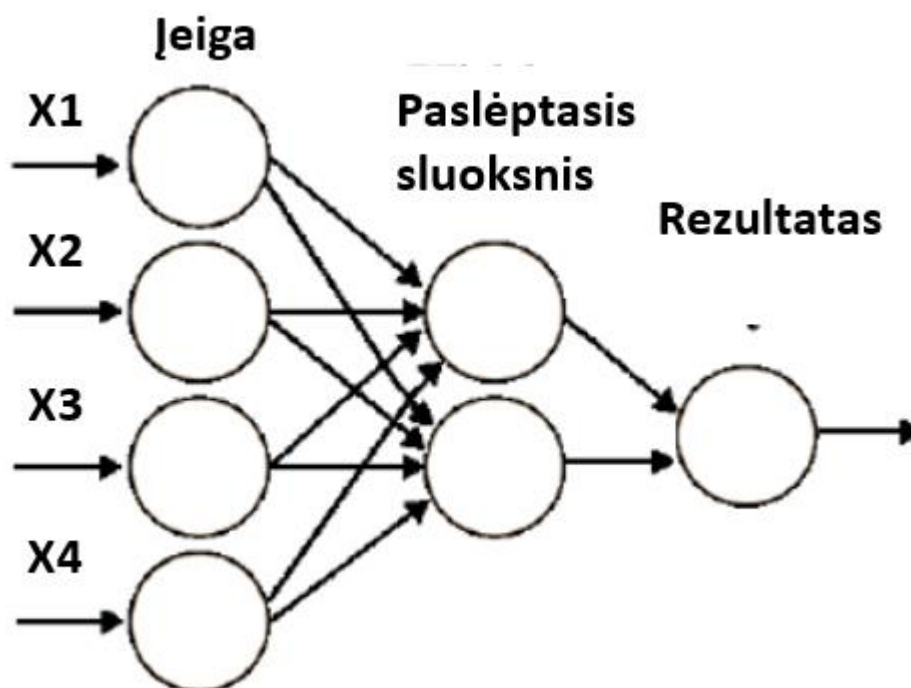
Ekperimentuodama su 4 mašininio mokymosi algoritmais Zankova (2016) pavyksta sėkmingai prognozuoti Norvegijos akcijų biržos 3 įmonių akcijų kainas minute į priekį, o autorė pažymi menką skirtumą tarp pritaikytų algoritmų rezultatų. Tiesa, autorė priduria, kad prognozuojant ilgesnius laikotarpius rezultatai gerokai suprastėja. Su labai skirtingais duomenimis, bet panašiu principu mašininio mokymosi algoritmus pritaiko ir Sheta, Ahmed, Faris (2015). Autoriai bando prognozuoti „S&P 500” indekso savaitines reikšmes ir randa, kad iš pritaikytų algoritmų atraminių vektorių metodas rodo didžiausią potencialą. Įdomu, kad autoriai pritaiko dešimtys ypač įvairių veiksnių, tarp jų — didžiausių pačio indekso kompanijų akcijų kainas, „S&P 500” prekybos apimtis ir reikšmes su lagais, makroekonominis rodiklius ir kitų akcijų indeksų reikšmes aplink pasaulį. Kiti autoriai, Wu ir Xu (2005) sėkmingai pritaiko neuroninius tinklus modeliuodami kompanijų akcijų kainas pagal 14 pačių kompanijų individualių fundamentalių rodiklių (kaip pelnas, realus turtas tenkantys vienai akcijai ir daug kitų).

Kaip rodo minėti ir daug kitų mašininio mokymosi algoritmų pritaikymo pavyzdžių, šie metodai turi jau gana ilgą sėkmingų rezultatų finansų rinkose istoriją prie pačių įvairiausių veiksnių, regionų, laikotarpių ir kitų duomenų charakteristikų. Toliau žymiausi mašininio mokymosi algoritmai bus apžvelgti plačiau.



### 2.4.1. Neuroninių tinklų metodas

Neuroniniai tinklai (angl. *neural networks*) neabejotinai yra vienas populiariausių mašininio mokymosi algoritmų. Tai galima lemti įvairios priežastys, tačiau tarp labiausiai tikėtinų yra šios metodikos sąsajos su gamta, kas leidžia žmonėms gerai įsisavinti šios metodikos veikimą. Tai yra — neuroniniai tinklai, kaip sako jų pavadinimas, bando mimikuoti smegenų neuronų darbą. Tai gerai atsiskleidžia 10 paveiksle.



10 pav. Neuroninių tinklų veikimo principo schema. Šaltinis: sudaryta autoriaus pagal Nascimento, et al. (2012).

Paprasčiausias neuronų tinklas turės tris sluoksnius: įėjimo, paslėptąjį ir išėjimo (rezultato). Pirmasis sluoksnis sudarytas iš naudojamų veiksnių, kurių gali būti vienas arba daug daugiau. Antrajame sluoksnyje — paslėptajame, įėjimo sluoksnyje gautų veiksnių reikšmės yra keičiamos tam tikrais koeficientais ir to pasakoje gaunamas rezultatas trečiame sluoksnyje. Gautą rezultatą sulyginus su tikruoju rezultatu koeficientai yra baudžiami ir derinami per naują remiantis pasirinktu vertinimo kriterijumi. Paslėptųjų sluoksnių gali būti daugiau nei vienas ir kiekvienas iš neuronų tame sluoksnyje turi jungtį su prieš tai buvusiu sluoksniu. Kuo daugiau tokių sluoksnių, tuo sudėtingesnė neuroninių tinklų sistema tampa ir tuo reikšmingesnis tampa pakankamas duomenų ir kompiuterinės galios kiekis.

Yra įvairios funkcijos, kurios naudojamos svoriams priskirtų kiekvieno iš parametru optimizavimui. Tarp populiariausių yra sigmoidinė pateita 4-oje formulėje.

$$H(S) = \frac{1}{1+e^{-S}}, \text{ kai } S = \sum_{i=0}^m x_i \mathbf{w}_{(i)}; \quad (4)$$

Kai:

$H(S)$  yra sigmoidinė funkcija svorių priskirtų veiksmų reikšmėms optimizavimui;

$x_i$  yra nepriklausomi veiksniai (algoritmo įėjimo parametrai);

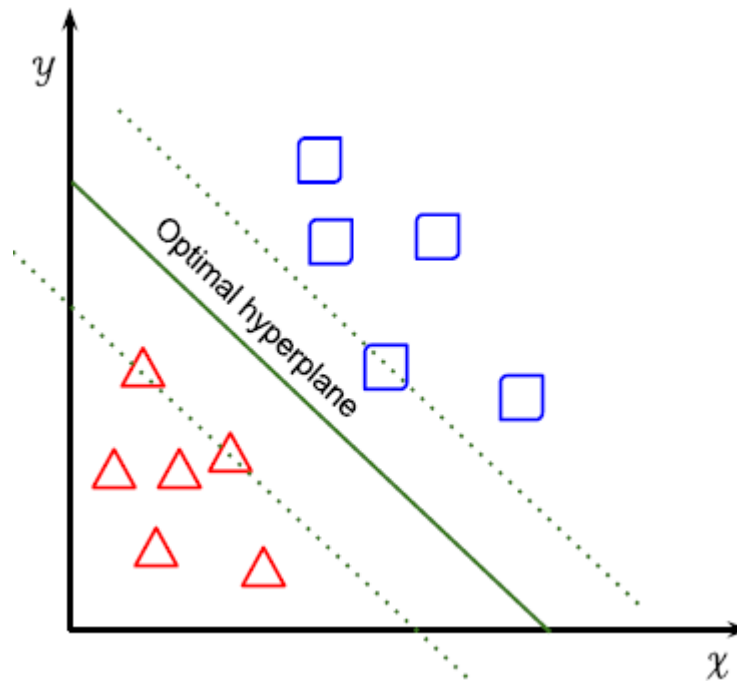
$w_i$  yra svorių koeficientai.

Neuroninius tinklus savo darbuose pritaiko Zankova (2016), Sheta, Ahmed ir Faris (2015) bei Badea (2013).

#### 2.4.2. Atraminių vektorių metodas

Dar vienas dažnai sutinkamas metodas moksliniuose tyrimuose yra atraminių vektorių (angl. *support vector machines* — SVM). SVM savo darbuose pritaiko Sankar (2009), Zankova (2016), Sheta, Ahmed ir Faris (2015).

Šio metodo pagrindinis principas yra, kad jis klasifikavimo atveju ieško hiperplokštės (angl. *hyperplane*). Hiperplokščių gali būti daug, o ta kuri atskiria klases didžiausiu skirtumu yra tinkamiausia. Šio proceso supaprastinta modifikacija pavaizduota 11 pav. Kaip matosi, žalia linija vaizduoja vienintelę liniją, kuri turi maksimalų atstumą su abejomis iš klasių. Atraminiai vektoriai yra vadinami pirmieji taškai iš duomenų rinkinio, kurie turi mažiausią atstumą nuo hiperplokštės. Šie ir kiti vektoriai yra transformuojami iš netiesinės funkcijos į aukštesnę dimensiją, kur jau tiesinė funkcija pritaikoma jų atskiriami. Atstumus tarp hiperplokštės galima optimizuoti skirtingomis branduolio (angl. *kernel*) funkcijomis.



11 pav. Atraminų vektorių mašininio algoritmo optimalios hyperplokštės radimo grafikas.

Šaltinis: Sheta, Ahmed ir Faris (2015).

Jeigu klasifikacijos atveju SVM turi binarinę funkciją, regresijos atveju ta funkcija yra regresinė ir grąžina realias vertes. Atstumų optimizavimo problema regresijos atveju atrodo maždaug taip:

$$\min J(\mathbf{w}, \mathbf{b}, \varepsilon) = \frac{1}{2} \left\| \vec{\mathbf{w}} \right\|_{\mathbf{w}}^2 - C \sum_{i=1}^m (\varepsilon_i), \text{ kai } \varepsilon_i \geq \pm(y_i - (\mathbf{w} \cdot \mathbf{x}_i + \mathbf{b})); \quad (5)$$

Kai:

$J(\mathbf{w}, \mathbf{b}, \varepsilon)$  yra optimizavimo funkcija;

$y_i$  ir  $x_i$  yra atitinkamai priklausomas ir nepriklausomi veiksniai;

$\mathbf{w}$  yra svorio vektorius;

$C$  yra kriterijus baudžiantis svorių vektorius už neatitiktas sąlygas;


$\varepsilon$  yra tikrų reikšmių lygis;

$m$  yra stebinių skaičius;

b yra hyperplokštės riba.

### 2.4.3. Atsitiktinių miškų metodas

Priešpaskutinis algoritmas, kurį detaliau apžvelgsime kaip vėliau naudojamą metodiką yra atsitiktiniai miškai (angl. *random forests*). Jis vienas iš nedaugelio algoritmų, kurie dažniau sutinkami praktikoje negu akademinės bendruomenės darbuose. Atsitiktiniai miškai remiasi sprendimų medžiais, tiksliai vietoj to, kad auginti ir tobulinti vieną medį, atsitiktiniai miškai leidžia auginti jų nors keletą vienu metu ir taip vidurkinti jų rezultatus gaunant naują rezultatą. Šis algoritmas labai mėgstamas su nežinomais duomenimis nes nereikalauja duomenų paruošimo ir turi ansamblio charakteristikų, reiškiančių kad keletos regresorių rezultatai gali būti panaudojami naujam, geresniam rezultatui. 12 paveiksle galima matyti, kaip tą patį pradinių veiksnių rinkinį paleidus per keletą sprendimų medžių vienu metu, jų spėjimai tada yra agreguojami.



12 pav. Atsitiktinių medžių algoritmo veikimo principas. Šaltinis: sudaryta autoriaus.

Regresijos atveju dažniausiai taikoma lygtis nustatyti galutinį atsitiktinio miško algoritmo rezultatą yra vidurkis pateiktas 6-oje formulėje.


$$F(x_1, \dots, x_n) = \frac{1}{T} \sum_{i=1}^T (F_i(x_1, \dots, x_n)); \quad (6)$$

Kai:

$T$  yra naudojamų medžių skaičius.

#### 2.4.4. Artimiausio kaimyno metodas

Metodas paremtas atstumų skaičiavimų tarp skirtingų duomenų taškų. Klasifikavimo atveju, klasės esančios arčiausiai analizuojamo duomenų stebinio nugalėtų ir tas duomuo taip pat būtų priskirtas tai klasei. „Kaimynai“ gali būti skaičiuojami pagal stebinį supančių taškų skaičių arba pagal iš anksto nustatytą atstumą. Šį algoritmą žymiai dažniau galima sutikti klasifikavimo užduotyse, tačiau pasitaiko ir aplikacijų regresijos pritaikymo atvejais.



**13 pav. Artimiausio kaimyno algoritmo veikimo principas. Šaltinis: sudaryta autoriaus.**

Atstumams skaičiuoti ir ieškoti vidurkio taikomi įvairūs metodai, vienas iš jų yra Euklido atstumo formulė:

$$\sqrt{\sum_{i=1}^k (x_i - y_i)^2} ; (7)$$

Kai,

k yra stebinių skaičius;

x yra nepriklausomas kintamas;

y yra priklausomas kintamas.

Artimiausio kaimyno algoritmo atmainas savo darbuose pritaiko Seutin ir Jones (2016), bei Pudaruth (2014).

## 2.5. Mašininio mokymosi metodų taikymas


Išsivalius duomenis, atlikus apžvalginę duomenų analizę bei išsiskyrus tyrinėjimo tikslus turėtų būti daugmaž aišku kokie mašininio mokymosi algoritmai turėtų būti aktualiausi. Atlikus šiuos žingsnius, stebint akademinis darbus ir rekomendacijas, galima išskirti tokį sekantį analizės scenarijų:

1. Kintamųjų atranka ir duomenų suskirstymas į mokymo ir testavimo imtis.
2. Patikrinti visus atsirinktus algoritmus kuo paprastesniais parametrais.
3. Gerinti rezultatus kelių sėkmingiausių ar visų naudotų algoritmų atvejais.

Pirmas žingsnio pirma dalis yra turbūt mažiausiai konsensuso turint dalis iš minimų žingsnių. Nors dalis autorių teigia, kad kai kurie mašininio mokymosi algoritmai yra gana jautrūs kintamųjų skaičiui ir nuo didelio nereikšmingų kintamųjų skaičiaus yra labiau linkę persimokyti, tai yra mažesnė dalis akademinio lauko. Tokiuose darbuose kaip Sheta, Ahmed ir Faris (2015) ar Wu ir Xu (2005), pasirinkti kintamieji yra užduodami mašininio mokymosi metodams be jokių išimčių, nors tų veiksmų buvo net virš keletos dešimčių, o be to ir dalies iš jų stipri koreliacija atrodė labai tikėtina. Pradėti nuo visų veiksmų su mašininio mokymosi algoritmais savo knygoje rekomenduoja ir Bird, Klein, Loper (2009). Tai reiškia, kad nėra būtinybės išmetinėti nepriklausomų veiksmų dėl jų sąryšių su kitais nepriklausomais veiksniais. Kur sutinka visi autoriai, kad šiame etape algoritmams paruošti veiksniai turi turėti aiškiai suprantamą informaciją. Tai yra nestruktūrizuoti duomenys turi būti transformuoti, o struktūrizuoti dažniausiai turi būti normalizuoti. Tokie algoritmai kaip atsitiktiniai miškai yra mažiau jautrūs duomenų dispersijai, tačiau neuroniniai tinklai ir keli kiti dažniausiai tikslesni būna su normalizuotais duomenimis. Kaip buvo paminėta anksčiau, šiame darbe duomenis buvo normalizuoti dar aprašymo etape.

Duomenų suskirstymo sprendimai yra gerokai dažniau pasikartojantys. Jau gana senai buvo žinoma, kad siekiant išvengti persimokymo ir patikrinti rezultatus, tiksliausia turimus duomenis pačioje pradžioje susiskaidyti į mokymosi ir testavimo imtis. Nusistovėjęs standartas yra 80%/20% proporcija, kurią savo darbe pritaiko Wu ir Xu (2005). Tiesa, pastaruoju metu vis dažniau taikomas yra kryžminio tikrinimo (angl. *cross-validation*) metodas. Metodo esmė yra turimus duomenis suskirstyti į  $k$  dalių ir su kiekviena iteracija testuoti vis ant naujos duomenų dalies, likusias dalis paliekant

mokinimui. Tai rekomenduojamas metodas ir Bird, Klein bei Loper (2009) knygoje. Tai kartojama, kol su visom dalimi būna testuota nors po kartą. Tai pavaizduota 14 paveiksle.



**14 pav. Kryžminio tikrinimo metodo veikimo principas. Šaltinis: sudaryta autoriaus.**

Antrame žingsnyje pasirinkti mašininio mokymosi metodai yra išbandomi su tikrais duomenimis. Įprastai, šiame etape nėra per daug vargstama su modelio parametrais, kad sužinoti kiek algoritmai natūraliai tinkami duomenimis ir kurie iš algoritmų potencialiausi. Įprasčiausiai modelių rezultatams vertinti sutinkamos pačios įvairiausios metrikos, Nozari (2013) naudoja pataisytąjį  $R^2$  ir vidutinės kvadratinės šaknies paklaidą (RMSE), vidutinės kvadratinės paklaidos (MSE) metrika yra pagrindinė Badea (2013) ir Zankova (2016) tyrimuose, galiausiai Sheta, Ahmed ir Faris (2015) naudoja vidutinės absoliučios paklaidos rodiklį (MAE). Nors visos šios metrikos yra skirtingai skaičiuojamos, dažniausiai sutinkama, kad naudojant nors porą iš jų rezultatai atspindi tikrovę bei suteikia daugiau konteksto lyginant modelius. RMSE, MAE ir pataisytojo  $R^2$  formulės pateiktos žemiau.

$$\text{Pataisytasis } R^2 = 1 - (1 - R^2) \frac{n-1}{n-p-1}; \quad (8)$$

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|; \quad (9)$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}; \quad (10)$$

Kai:

$R^2$  yra vieneto ir kvadratinių modelio paklaidų sumos, bei nulinio modelio paklaidų santykio skirtumas;

$y_i$  yra priklausomas veiksnys;

$\hat{y}_i$  yra priklausomo veiksnio modelio aproksimacija;

$n$  yra stebinių skaičius;

$p$  yra modelio parametrų skaičius.

MAE ir RMSE yra gana lengvai interpretuojami, nes paklaida yra matuojama y matais, tačiau RMSE labiau baudžia už didesnes klaidas, nes jas pakelia kvadratu (prieš ištraukiant šaknį). Pataisytasis  $R^2$  galimai dar labiau interpretuojamas, nes paaiškina kurią priklausomo kintamo dispersijos dalį paaiškina sudarytas, modelis. Tačiau jei  $R^2$  turi apibrėžimo sritį nuo 0 iki 1, tai pataisytasis  $R^2$  gali būti ir minusinis, kas vis tiek reiškia, jog modelis nėra tikslus.

Trečias žingsnis, potencialių algoritmų derinimas, dažniausiai po duomenų ruošimo atima daugiausiai laiko analitiniame procese. Šiame žingsnyje gali išlįsti mažiau akivaizdžios išskirtys jei tikslumas netikėtai mažas. Išskirtys atsiranda dėl duomenų klaidingumo ar laikinų, tačiau struktūriškai nereikšmingų variacijų. Taikant prielaidą, kad duomenis pilnai išvalyti ir nepalikta klaidų, netenkinantys rezultatai po antro žingsnio gali būti tobulinami keleriopai (pateikta 2 lentelėje).



**2 lentelė. Mašininio mokymo algoritmų rezultatų gerinimo metodai ir jų suskirstymas pagal grupes. Šaltinis: sudaryta autoriaus.**

Metodų grupė	Metodai					
	Duomenų metodai	Stebinių skaičiaus didinimas	Naujų kintamųjų pridurimas	Jau naudojamų kintamųjų agregavimas į naujus kintamus	Išskirčių šalinimas	
Algoritmų metodai	Keisti testavimo imties skirstymo būdą	Standartinių modelio konfigūracijų keitimas	Detalus įvairių diagnostikų vertinimas	Pridurti naujus algoritmus	Taikyti algoritmų ansamblius	

### 3. TYRIMŲ REZULTATAI IR JŲ APTARIMAS

#### 3.1. Tyrimo esmė ir veiksniai

Kaip minėta pirmoje dalyje, darbo esmė bus visapusiškai ištirti galimas sąsajas tarp akcijų rinkos ir įvairių veiksnių, kurie siejasi su obligacijų rinka. Po literatūros apžvalgos šio darbo autorius įvertino, kad šie ryšiai buvo tiriami gana pasikartojančiai, su maža veiksnių įvairove ir su prieštaraujančiais rezultatais. Šis tyrimas turėtų įnešti daugiau įvairovės, sukonkretinti šiuos ryšius bei išnaudoti metodiką dar nematytą šių ryšių tyrinėjime. Skirtingai negu didesnėje dalyje darbų, akcijų rinka bus atstovaujama ne vieno, bet penkių faktorių. Obligacijų pelningumai ir jį lemiantys veiksniai bus atstovaujama viso 11-os veiksnių. Beveik visi tyrime naudojami duomenys, išskyrus „ICE BofAML US High Yield Master II Effective Yield“ ir „ICE BofAML US Corporate Master Effective Yield“, buvo prieinami naudojantis „Bloomberg Professional“ duombaze [12]. Pastarieji minėti veiksniai buvo prieinami per Sant Luiso JAV federalinio banko padalinį [29] [30]. Visi tyrime dalyvaujantys veiksniai yra susiję su JAV akcijų arba obligacijų rinka, tai plačiau komentuojama pirmo skyriaus 5-oje dalyje. Su obligacijomis susijusių veiksnių kompleksas buvo atrenkamas pagal žemiau esančius kriterijus (pirmieji 2 aspektai taikomi kiekvienam iš veiksnių atskirai, sekantys trys — veiksnių daugumai komplekte):

- Galimi dieniniai duomenis.
- Veiksniai atstovauja arba reikšmingai siejasi su esminėmis obligacijų, kaip finansinių instrumentų, savybėmis.
- Veiksniai siejasi tiek su JAV valstybės viešojo sektoriaus obligacijomis, tiek su privataus sektoriaus.
- Veiksniai atstovauja tiek ilgojo, tiek trumpojo laikotarpio obligacijų tendencijas.
- Didesnė dalis veiksnių buvo retai arba visai nesutikti panašiose studijose.

Renkantys akcijų rinką atstovaujančius veiksnius, kriterijai nebuvo identiški, nes buvo daugiau stengiamasi rinktis labiau visuotinai pripažįstamus akcijų indikatorius, galbūt šiek tiek aukojant inovatyvumą. Nors atrinkti priklausomi kintamieji yra matyti tyrimuose atskirai, kad jie visi būtų viename tyrime paraleliai analizuojami nebuvo tekę matyti. Atrinktų priklausomų kintamųjų sąrašas pateiktas lentelėje nr. 3 žemiau. Kiekviena įžvalga apie šiuos faktorius galėtų labai padėti suprasti ir galbūt net prognozuoti akcijų rinkos elgesį.

3 lentelė. Priklausomi kintamieji naudojami tyrime. Šaltinis: sudaryta autoriaus pagal „Bloomberg Professional“ [12].

Veiksnių grupė	Y veiksniai				
	Nr.	1	2	3	4
Trumpinys	SPX	SPX (apyvarta)	VIX	SPW	SPW (apyvarta)
Pilnas angliškas veiksnio pavadinimas	S&P 500 index	S&P 500 index volume	CBOE S&P 500 Volatility index	S&P 500 equal weight index	S&P 500 equal weight index volume
Pilnas lietuviškas veiksnio vertinys	Maždaug 500-ų didžiausių JAV kompanijų pasvertų pagal rinkos kapitalizaciją akcijų indeksas.	"S&P 500" indekso prekybos apyvartos.	"S&P 500" kintamumo indeksas.	Maždaug 500-ų didžiausių JAV kompanijų pasvertų vienodai akcijų indeksas.	"S&P 500" vienodai pasvėto indekso prekybos apyvartos.

„S&P 500” indeksas neabejotinai yra vienas matomiausių veiksnių naudojamų akcijų rinkų atspindėjimui ir jis buvo minimas prie didelės dalies akcijų rinkos tyrimų šaltinių pateiktų ankstesnėse darbo dalyse. Tiesa, beveik visose tyrimuose cituojamas, tik „S&P 500” indeksas, kuriame akcijos pasvertos pagal jų rinkos kapitalizaciją (rinkos verte). Taigi, tokios kompanijos kaip „Amazon“ turi žymiai didesnę svertą indekse, nei kompanijos paskutiniame šimtuose pagal dydį. „S&P 500” skaičiuojamas pagal žemiau esančią formulę:

$$\text{S\&P 500 (SPX)} = \frac{\sum_{i=1}^m P_i \cdot Q_i}{\text{Daliklis}}; \quad (11)$$

Kai:

P yra kaina kiekvienos akcijos atrinktos į indeksą;

Q yra kiekis naudotų akcijų (tenkančių kainai  $P_i$ );

i yra indekse dalyvaujančių kompanijų skaičius.

Daliklis yra neskelbiamas skaičius parinktas indekso sudarinėtojo „Standard & Poor“ sumažinti indekso vertę į paprastesnius skaičius (iš trilijonų JAV dolerių) ir išvengti šokinėjimų naujom akcijoms išeinant, ateinant ar keičiantis.

Taigi, nors SPX indeksas apskaičiuotas pagal 7-ą formulę yra dažniausiai cituojamas mokslinėse publikacijose ar spaudoje, dažnai pametama, tai kad yra kitas „S&P 500“ indeksas skaičiuojamas kita metodika. SPW indeksas skaičiuojamas kiekvienai kompanijai turint tolygų svorį indekse, pagal 8-ą formulę žemiau:

$$\text{S\&P 500 (SPW)} = \sum_{i=1} P_i \cdot Q_i \cdot IWF_i, \text{ kai } IWF_i = \frac{Z}{N \cdot MVA_{i,t}}; \quad (12)$$

Kai:

Z yra neskelbiama konstanta parinkta indekso sudarinėtojo „Standard & Poor“ modifikuoti kiekvieno akcijos vertę indekse;

N yra akcijų skaičius kiekvieno iš indeksų dalyvių;

t yra indekso rebalansavimo diena;

MVA – yra laisvai prekiaujamų akcijų apribota rinkos vertė.

Kaip pastebėta iš apžvalgų 1-oje darbo dalyje šis „S&P 500“ indekso skaičiavimo variantas yra galimai nepakankamai atspindėtas literatūroje, tačiau lygiavertiškiau rodo platesnę akcijų rinkos būklę ir dėl to parodo naują informaciją. To pasakoje, šis rodiklis taip pat buvo įtrauktas. Taip pat, buvo įtrauktos ir šių indeksų prekybos apimtys (sudarytų sandorių vienetų skaičius). Kaip turėtų atskleisti aprašomoji analizė, prekybos apimčių staigūs išaugimai dažnai signalizuoja ypač svarbias ir stipriai kintančias dienas akcijų rinkose, dėl to priduria informacijos apie akcijų rinklų būklę. O paskutinis rodiklis iš priklausomų kintamųjų yra Čikagos opcionų sandorių tarybos (CBOE) „Baimės indeksas“. Šis indeksas vadinamas baimės, kadangi labai grubiai apibendrinant jis atspindi kiek kainuoja nusipirkti opciono sandorių apsidraudžiant dabartinę indekso ar jos dalyvių poziciją. Kuo jo vertė didesnė, tuo tokie sandoriai brangesni. Apsidraudimo kaina įprastai kyla neramiais laikais. Šį rodiklį taip pat sunkoka įvardinti tarp populiariesnių akcijų rinkos atstovų moksliniuose darbuose, tačiau jis sutinkamas tokiuose tyrimuose kaip Grouard, Levy ir Lubochinsky (2003). VIX „Standard & Poor“ kompanija skaičiuoja pagal žemiau pateiktą apibendrintą formulę.

$$\sigma^2 = \frac{2}{T} \sum_i \frac{\Delta K_i}{K_i^2} e^{RT} Q(K_i) - \frac{1}{T} \left[ \frac{F}{K_0} - 1 \right]^2, \text{ kai } \Delta K_i = \frac{K_{i+1} - K_{i-1}}{2}; \text{ (13)}$$

Taip pat:

$\sigma$  yra viena šimtoji VIX ;

T yra laikas iki galiojimo laiko pabaigos;

F yra į ateitį žiūrintis indeksas sudarytas iš indekso sudėtinių kompanijų opcionų kainų;

$K_0$  yra pirma išpirkimo kaina žemiau indekso F vertės;

$K_i$  yra pirma išpirkimo kaina žemiau  $K_0$  (parduodančio opciono atveju) ir aukščiau  $K_0$  (perkančio opciono atveju);

R yra nerizikinga palūkanų norma iki išpirkimo datos;

$Q(K_i)$  yra skirtumo tarp pirkimo ir pardavimo kainų vidurinė vertė.

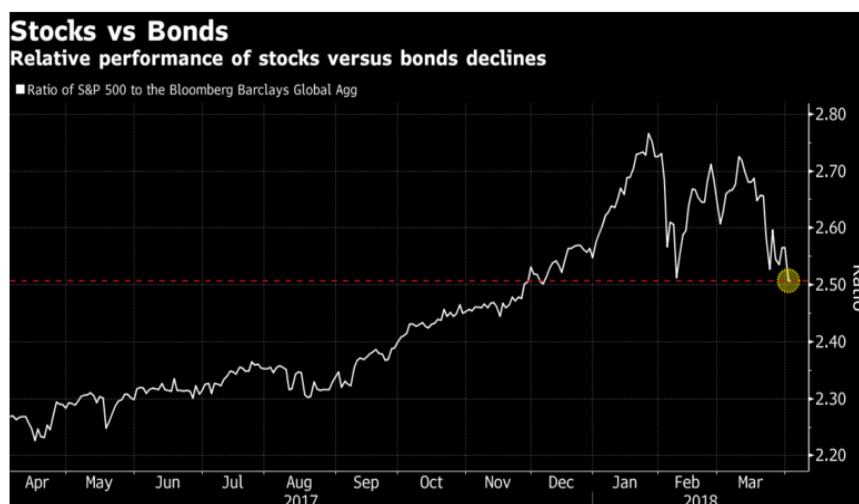
Pereinant prie nepriklausomų kintamų jie pateikti 4-oje lentelėje žemiau.

**4 lentelė. Nepriklausomi kintamieji naudojami tyrime. Šaltinis: sudaryta autoriaus pagal „Bloomberg Profesional“ ir [12], [29], [30].**

Veiksnių grupė	X veiksniai										
Nr.	1	2	3	4	5	6	7	8	9	10	11
Trumpiniai	TYVIX	TNX	MLT1US10	BASPTDSP	USYC2Y10	LF98TRUU	LUACTRUU	LT08TRUU	LUTLTRUU	BAMLH0A0HYM2EY	BAMLC0A0CMEY
Pilnas angliškasis veiksnio pavadinimas	CBOE 10-Year Treasury and Note Volatility Index	CBOE 10-Year Treasury and Note Yield Index	Merrill Lynch 10-year U.S. Treasury Futures Total return	TED (Treasury-EuroDollar rate or 3month LIBOR - 3 month US treasury Yield)	10-Year Treasury Constant Maturity Minus 2-Year Treasury Constant Maturity	Bloomberg Barclays US Corporate high yield total return value unhedged USD	Bloomberg Barclays US corporate total return value unhedged USD	Bloomberg Barclays US Intermediate Treasury total return unhedged USD	Bloomberg Barclays US Long Treasury total return unhedged USD	ICE BofAML US High Yield Master II Effective Yield	ICE BofAML US Corporate Master Effective Yield
Pilnas lietuviškas veiksnio vertinys	10-ies metų JAV išdo obligacijų kintamo indeksas	10-ies metų JAV išdo obligacijų pelningumo indeksas	10-ies metų JAV išdo obligacijų ateities sandorių bendros gražos indeksas	3 mėnesių JAV išdo obligacijų ir 3 mėnesių JAV išdo skolų vertybinio popieriaus skirtumas	JAV išdo pastovaus termino obligacijų 10-ies ir 2 metų trukmės pelningumų skirtumas	JAV privataus sektoriaus didesnio rizikumo obligacijų rinkos bendros gražos vertės indeksas JAV doleriais (neapdraustas nuo valiutos rizikos)	JAV privataus sektoriaus obligacijų rinkos bendros gražos vertės indeksas JAV doleriais (neapdraustas nuo valiutos rizikos)	JAV išdo vidutinės trukmės obligacijų rinkos bendros gražos vertės indeksas JAV doleriais (neapdraustas nuo valiutos rizikos)	JAV išdo ilgų trukmės obligacijų rinkos bendros gražos vertės indeksas JAV doleriais (neapdraustas nuo valiutos rizikos)	Didesnio rizikumo obligacijų pelningumo indeksas	Mažesnio rizikumo obligacijų pelningumo indeksas

X veiksnius sudaro viso 11 kintamųjų. Prededant nuo kairės pirmieji du veiksniai yra CBOE skaičiuojami indeksai 10-ies metų trukmės JAV išdo obligacijoms. Kaip paaikškėjo pirmoje šio darbo dalyje, šis vertybinis popierius yra dažniausiai naudojamas obligacijų rinką tyrimuose, taigi jo svarba plačiai pripažinta. TNX turėtų būti labai artimas įprastam pelningumui, o TYVIX matuoja šios rūšies obligacijų galimą kintamumą panašiai kaip anksčiau aptartas VIX indeksas daro su „S&P 500“ indeksu. TYVIX turėtų gerai atspindėti rinkos veiksmus šios obligacijos atžvilgiu. MLT1US10 yra jau kitos kompanijos, banko „Merrill Lynch“, skaičiuojamas indeksas tačiau vėlgi susijęs su minėto laikotarpio JAV išdo ilgalaikėmis obligacijomis. Šis indeksas skaičiuoja gražą, kurią patyria minėto vertybinio popieriaus nekintanti ateities sandorio pozicija. Tai reiškia, kad šis indeksas geriau negu kiti turėtų atspindėti ateities lūkesčius obligacijos pelningumui. Su 10-ies metų JAV išdo trukmės obligacijomis susijęs ir 5 rodiklis nuo kairės — USYC2Y10. Šis rodiklis jau apima dviejų skirtingos

trukmės, 2-ių ir 5-ių metų, JAV išdo obligacijų pelningumų judėjimus ir yra laikomas vienas ankstyvesnių krizės indikatorių. BASPTDSP lygina didelės dalies pasaulio paskolų normoms naudojamą 3-jų mėnesių LIBOR ir JAV išdo to pačio laikotarpio trumpalaikės obligacijos pelningumą. Apibendrinant galima sakyti, kad šis rodiklis nusako kiek bankams tarpusavyje brangiau kainuoja skolintis negu vienos labiausiai ekonomiškai išsivysčiusios valstybės vyriausybei. Šis rodiklis yra geras likvidumo matas. Toliau sekantys LF98TRUU, LUACTRUU „Bloomberg Barclays“ sudaryti indeksai nusako atitinkamai rizikingesnių ir mažiau rizikingų obligacijų rinkas. Mažiau rizikingos yra laikomos obligacijos, kurios žymiųjų reitingo agentūrų („Fitch“, „Moody“ ar „Standard & Poor“) yra vertinamos atitinkamai bent Ba1/BB+/BB+ reitingais. Platesniam kontekstui susidaryti yra pridėta visų kredito reitingų lentelė 1-ame priede. Į šiuos indeksus įtraukiamos korporacijų obligacijos išleistos JAV doleriais. Ir jeigu paskutiniai veiksniai atspindi dvi grupes korporacijų obligacijų, „Bloomberg Barclays“ LT08TRUU ir LUTLTRUU indeksai atspindi dvi grupes JAV išdo leidžiamų obligacijų. Tiesa, kadangi leidėjas tas pats obligacijos yra skirstomos laikotarpiais. LT08TRUU indeksas atspindi JAV obligacijas, kurių trukmė yra nuo metų iki 10-ies metų (neimtina), o LUTLTRUU atspindi JAV išdo obligacijas 10-ies metų ir ilgesnias. Veiksniai BAMLH0A0HYM2EY ir BAMLC0A0CMEY yra kitos kompanijos „Intercontinental Exchange Bank of America Merrill Lynch“ indeksai sudaryti sekti pelningumus atskirų korporacinių grupių obligacijų. Atskiriant rizikingesnes kompanijas taip pat kaip „Bloomberg Barclays“ kompanijų indeksų atveju, BAMLH0A0HYM2EY seka kompanijas, kurių kredito agentūrų reitingas Ba1/BB+/BB+ arba mažesnis, o BAMLC0A0CMEY atvirkščiai. Kaip rodiklis artimas aptartiems obligacijų rodikliams naudojamas pabrėžti akcijų ir obligacijų rinkų sąryšį galima pastebėti 15-ame paveiksle.

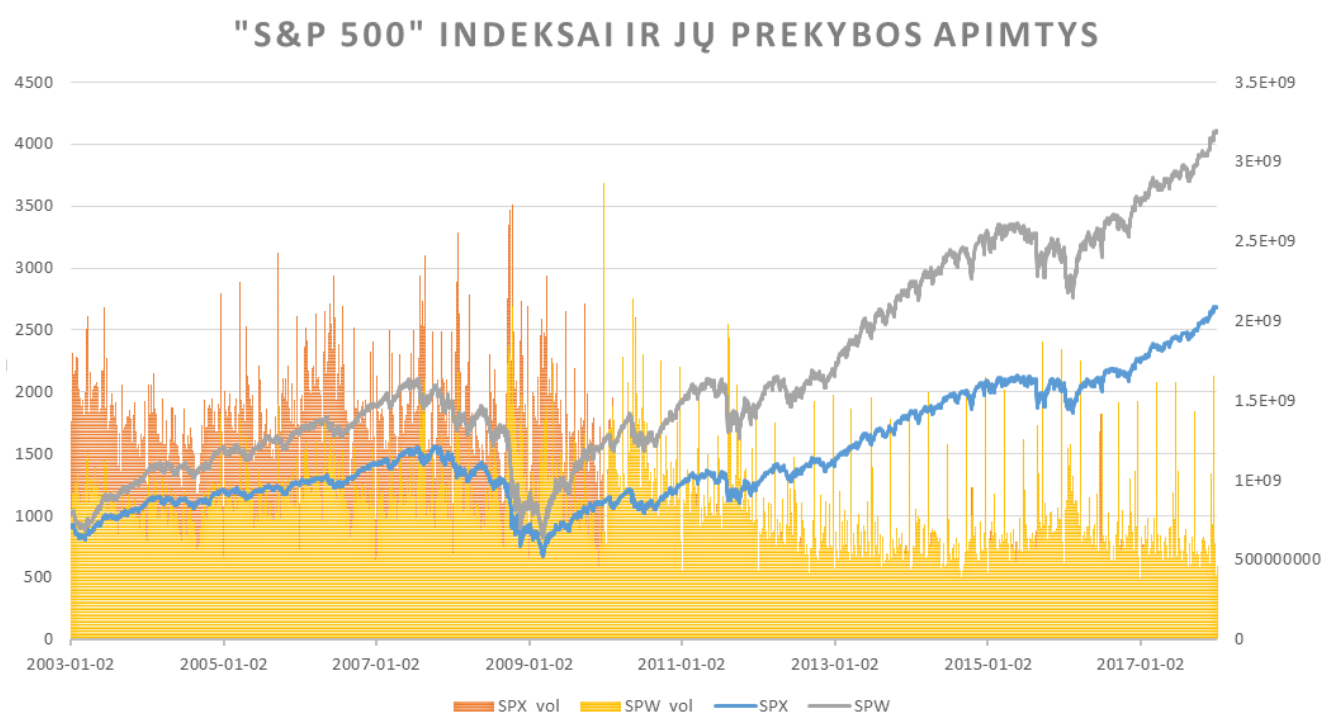


15 pav. „S&P 500“ ir „Bloomberg Barclays“ pasaulio obligacijų indeksų santykis. Šaltinis: „Bloomberg“ [11].

Visi naudojami duomenis buvo surinkti laikotarpiui 2003.01.01 iki 2017.12.31, skaičiuojant tik biržos veikimo dienas. Nors, kai kurie su obligacijomis susiję veiksniai yra prekiaujami visą parą, tačiau šio darbo tikslui, tų veiksnių reikšmės buvo apribotos kartu su kitais veiksniais, tik JAV biržų darbo dienų pabaigos vertėmis. Pagrindinė to priežastis, buvo tai, kad tiriami priklausomi veiksniai — „S&P 500“ lygaus svorio, „S&P 500“ rinkos verte pasverti indeksai ir jų apyvartos bei „Baimės indeksas“ visi yra su akcijomis susiję veiksniai, kurių prekybos vyksta tik JAV darbo dienomis. Galima pažymėti, kad į veiksnius darbe toliau bus pagrinde kreipiamasi trumpiniais nurodytais šioje darbo dalyje.

### 3.2. Duomenų grafinis ir statistinis vertinimas

Kaip pastebėta antroje dalyje, dauguma autorių pradeda savo analizes geriau susipažindami su surinktais duomenimis. Geriausią kontekstą vienu kartu duoda grafikai. Paveiksle žemiau pateikti priklausomi kintamieji — SPX, SPW, bei jų prekybos apimtys. Tai sudaro 4 iš 5-ių priklausomų kintamųjų naudojamų darbe.

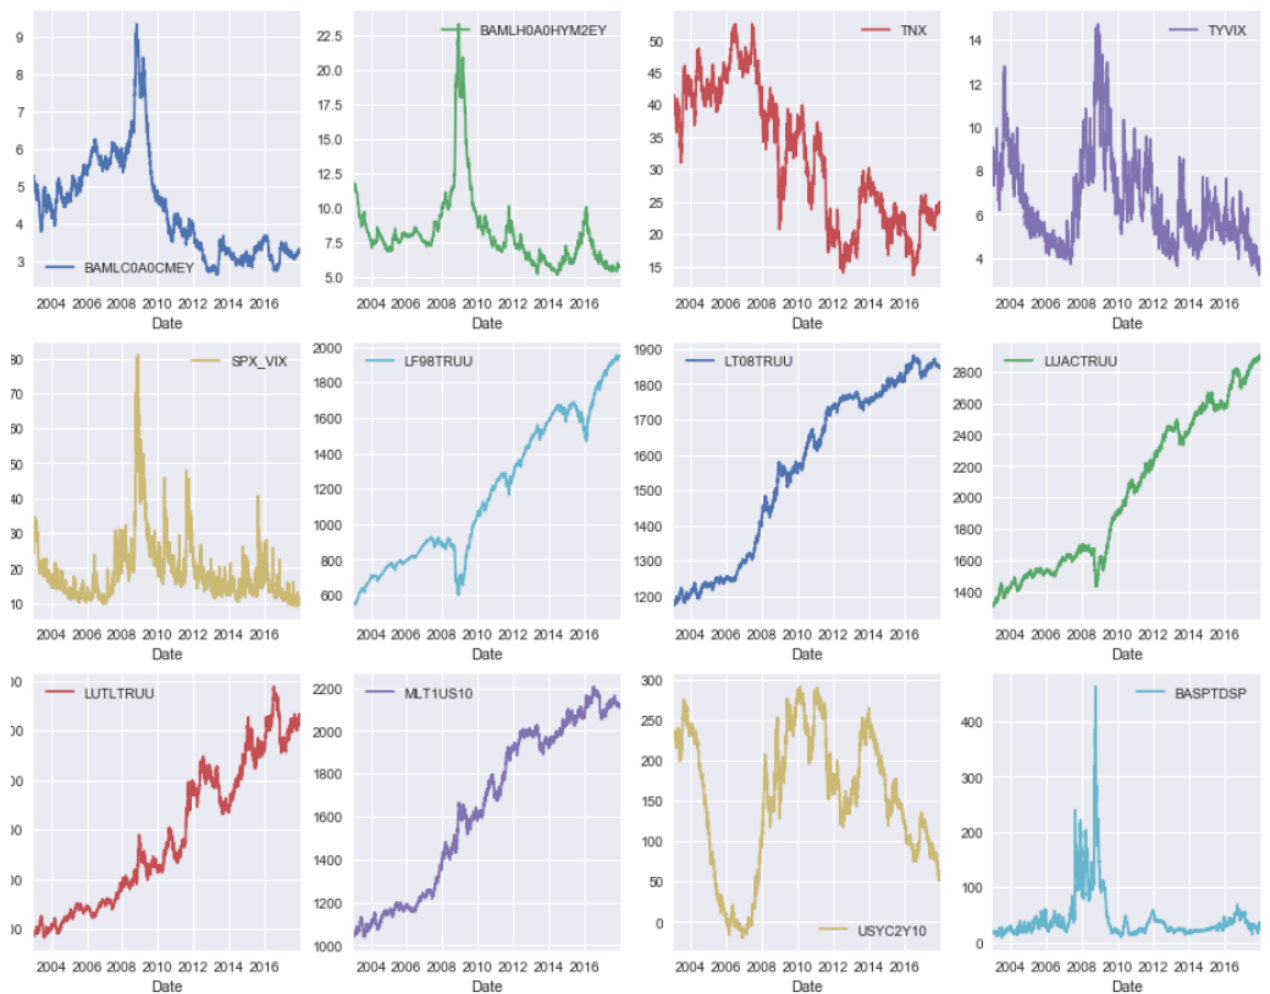


**16 pav. „S&P 500“ indeksai (kairė y ašis) ir jų prekybos apimtys (dešinė y ašis). Šaltinis: sudaryta autoriaus pagal „Bloomberg Professional“ duomenis [12].**



Paveiksle nr. 16 matosi, kad nepaisant skirtingų skaičiavimo metodologijų, SPX ir SPW akivaizdžiai juda tandemu. Net ir smulkesnės variacijos gana akivaizdžiai pereina per abu indeksus vienu metu. Galima pastebėti, kad nors abu indeksai pradėjo panašiose reikšmėse 2003 m., gana greitai atsirado skirtumas, kuris tik didėjo ir išliko iki šių dienų. Vienintelis laikotarpis kai indeksai beveik nesiskyrė buvo ekonominės krizės laikotarpiu, kurios pabaigoje 2009 metų pradžioje indeksai turėjo kone identišką reikšmę. Tai iš dalies paaiškina, kodėl 2003 metais indeksai vėlgi buvo tokioje panašioje būsenoje — nes tai buvo nesenai praėjęs laikas nuo prieš tai buvusio „interneto burbulų“, kuris buvo gerokai nustumęs akcijų kainas. Taigi, nors abu indeksai yra akivaizdžiai stipriai koreliuoti, tačiau SPW juda kiek didesniu masteliu.

Stebint abiejų indeksų prekybos apimtys, galima pastebėti, kad kiek netikėtai abiejų indeksų prekybos apimtys nukritę nuo ekonominės krizės 2007 m.. Tam priežastį ieškoti būtų verta atskirame moksliniame darbe, tačiau tarp labiausiai tikėtinų galėtų būti didelis išvėstinių finansinių instrumentų išpopuliarėjimas kaip biržose prekiaujamų fondų (angl. *Exchange traded funds* — *ETF*). Taip pat, nors SPX buvo akivaizdžiai populiariesnis pirmoje laikotarpio pusėje, antroje laikotarpio dalyje abiejų indeksų prekybos apimtys susilygino. Kaip matosi, prekybos apimčių eilutės turi vis pasikartojančių ir staigių šuolių į viršų, kas rodo labai aktyvią prekybą tomis dienomis. 17-ame paveiksle pereina prie likusių veiksmų grafinės analizės.



**17 pav. Visų nepriklausomų ir priklausomo VIX veiksnio linijiniai grafikai. Šaltinis: sudaryta autoriaus pagal „Bloomberg Professional“ ir Sant Luiso federalinio banko duomenis [12], [29], [30].**

Pradėjus nuo vienintelio priklausomo veiksnio 17 paveiksle, VIX (5-as grafikas 17-ame paveiksle), matosi akivaizdus ekstremumas pasiektas per krizę, kuris nebuvo pakartotas nuo tol. Kaip minėta paprastai kalbant šis rodiklis rodo, kiek investuotojai linkę mokėti už savo investicijų apsidraudimą, taigi logiška, kad per krizę susirūpinimas tuo būtų didžiausias. Kiti aštresni pakylimai, taip pat atrodo besisiejantys su „S&P 500“ indeksų netikėtais nuosmukio laikotarpiais, o mažo kintamumo periodai dažnai sutampa su indeksų stabiliu augimu.

„ICE“ indeksų aukštesnio ir mažesnio rizikingumo obligacijų pelningumai, atitinkamai BAMLH0A0HYM2EY (1-as grafikas 17-ame paveiksle) ir BAMLCOA0CMEY (2-as grafikas 17-ame paveiksle) pasižymi tarpusavyje labai panašiomis judėjimo trajektorijomis. Tai yra, pradeda nuo kiek aukštesnių verčių, tada pasiekia žemiausius taškus ir pradeda palaipsniui didėti, kol pasiekia

absoliučius pikus ekonominės krizės gilumoje. Kaip ir galima tikėtis pakylimas rizikingesnių įmonių pelningumų yra žymiai didesnis ir staigesnis nei mažesnės rizikos įmonių. Jeigu pastarųjų įmonių pelningumas per krizės bangą buvo išaugęs maždaug 50%, tai rizikingesnių įmonių pelningumai šoko daugiau negu 100%. To buvo galima laukti, nes neiškliais laikais investuotojai traukia pinigus iš visur, bet pirmiausia iš rizikingesnių turto vienetų. Dėl to, baisiausiai krizės daliai praėjus, BAMLC0A0CMEY gana greitai grįžta į buvsius laikus ir netgi į žemesnius pelningumus negu prieš kriziniame laikotarpyje, o rizikingesnių įmonių pelningumai ilgesnį laiką išlieka didesni ir toliau patyria gana stiprų kintamumą. Stebint rizikingesnių ir mažiau rizikingų finansinio profilio kompanijų obligacijų rinkos grąžas — atitinkamai LF98TRUU (6 grafikas 17-ame paveiksle) ir LUACTRUU (8 grafikas 17-ame paveiksle), judėjimų skirtumai nuo pelningumų yra ženklūs. Nors abu indeksai prarado vertės per krizės gilumą, nuosmukiai nebuvo labai žymūs. Tiesa, rizikingesnių obligacijų fondas LF98TRUU smuko apie 30%, kai LUACTRUU maždaug tris kartus mažiau. Skirtingai, nei dauguma kitų analizuojamų rodiklių fondai iš karto atsigavo, labai staigiai augo ir analizuojamo laikotarpio pabaigoje pasiekė rekordines reikšmes. Tai turėtų sietis su priežastimis kodėl BAMLC0A0CMEY rodiklis laikosi žemumose taip pat. Investuotojams atgavus pasitikėjimą rinkomis, rizikos tolerancija buvo labai žema todėl jie rinkosi saugiausią turtą — didelių korporacijų ir vyriausybės obligacijas.

Pereinant, prie rodiklių susijusių su JAV vyriausybės trumpalaikėmis ir ilgalaikėmis akcijomis bendros tematikos taip pat sunku apčiuopti. Pavyzdžiui JAV vyriausybės 10-ies metų trukmės obligacijų ateities sandorių indeksas MLT1US10 išgyvena tolygų augimą viso laikotarpio metu. Vyriausybinių obligacijų rinkos indeksai LT08TRUU ir LUTLTRUU per laikotarpį judėjo gana skirtingai. Kol vidutinės trukmės obligacijų indeksas LT08TRUU stabiliai auga, o ypač nuo krizės laikotarpio, LULTRUU augimas buvo kur kas labiau kintantis ir turėjo išties nemenkų laikotarpių su netgi gana ryškiai žemėjančiomis reikšmėmis. Vienas labiausiai išsiskiriančių grafikų yra BASPTDSP, kuris akivaizdžiausiai pažymi krizės tamsiausią etapą didžiule reikšme. Ši reikšmė labai išskirtinė ir iš esmės rodo, kad tarpusavyje bankai skolinosi žymiai, žymiai brangiau nei valstybės trumpalaikių obligacijų pelningumai. Įprastai šis skirtumas būna daug mažesnis, tai vėlgi galima paaiškinti ypač susitraukusiu likvidumu tuo metu rinkoje. Šis rodiklis pats vienmatiškai geriausiai nuspėjo apie gresiančias finansines problemas, nors USYC2Y10 tą irgi darė gana anksti. Galima pastebėti, kad iš karto prieš krizę rodiklis pasiekė gana stiprų ekstremumą kai priartėjo prie nulio. Netrukus šis rodiklis vėl šoktelėjo ir bendrai turbūt yra mažiausiai nuspėjamai judantis rodiklis iš visų. TYVIX ir TNX indeksai turi kur kas tradiciškesnius judėjimus. Pavyzdžiui JAV išdo obligacijų pelningumo indeksas TNX po mažu mažėja nuo krizės gerokai išaugus vyriausybinių popierių paklausai. Kiek stebina, kad

kintamumo indeksas per tą laikotarpį išgyvena gana stiprų kintamumą, nors rinka tuo metu JAV išdo vertybinių popierių (toliau — VP) atrodė subalansuota.

Apibendrinus, kas gali kristi į akis tai iš pažiūros labai skirtingi judėjimai visose grafikuose. Viena iš hipotezių galėjo būti, kad su obligacijų pelningumais susiję veiksniai turės atvirkštinę koreliaciją su obligacijų indeksu vertėmis. Ši hipotezė, nepasitvirtina iš pažiūros visai. Be to, galima spėti, kad visi grafikai bus pasiekę tam tikrus ekstremumus prieš krizę ar jos gilumoje, tačiau tame konsensuso irgi nėra. Nors maždaug pusę grafikų išties turi aiškius pikus krizės gilumoje iš kitu veiksmių grafikų nieko panašaus negalima išskirti.

**5 lentelė. Kintamųjų naudojamų tyrime pagrindinės statistikos. Šaltinis: sudaryta autoriaus pagal „Bloomberg Professional“ ir [12], [29], [30].**

Rodiklis	SPX	SPX_vol	SPX_VIX	SPW	SPW_vol	TYVIX	TNX	MLT1US10
Stebinių skaičius	3 776.00	3 776.00	3 776.00	3 776.00	3 776.00	3 776.00	3 776.00	3 776.00
Vidurkis	1 481.49	951 697 231.54	18.76	2 148.49	733 841 465.92	6.46	31.84	1 643.42
Standartinis nuokrypis	447.97	409 272 368.64	8.84	806.38	236 272 515.98	2.03	10.50	384.99
min reikšmė	676.53	187 691 760.00	9.14	824.01	177 430 160.00	3.21	13.66	1 036.05
0.25 kvartilis	1 154.19	575 765 984.00	13.15	1 560.77	560 825 360.00	4.95	22.40	1 212.63
0.5 kvartilis	1 336.62	902 766 560.00	16.22	1 904.26	706 845 184.00	5.90	31.35	1 688.56
0.75 kvartilis	1 862.92	1 264 596 480.00	21.22	2 917.59	853 701 136.00	7.70	41.41	1 996.35
max reikšmė	2 690.16	2 777 861 120.00	80.86	4 113.40	2 864 659 456.00	14.72	52.48	2 206.57
Rodiklis	BASPTDSP	USYC2Y10	LF98TRUU	LUACTRUU	LT08TRUU	LUTLTRUU	BAMLC0A0CMEY	BAMLH0A0HYM2EY
Stebinių skaičius	3 776.00	3 776.00	3 776.00	3 776.00	3 776.00	3 776.00	3 776.00	3 776.00
Vidurkis	43.08	151.77	1 179.99	2 031.83	1 557.44	2 436.00	4.40	8.20
Standartinis nuokrypis	44.65	84.17	409.65	491.06	240.48	724.59	1.33	2.77
min reikšmė	9.31	-	19.03	537.26	1 308.07	1 171.35	1 412.93	2.64
0.25 kvartilis	22.03	93.08	807.66	1 542.35	1 282.52	1 733.70	3.27	6.55
0.5 kvartilis	28.33	159.01	1 123.19	1 998.56	1 615.90	2 255.18	4.12	7.61
0.75 kvartilis	41.46	226.64	1 578.96	2 489.37	1 767.82	3 084.43	5.38	8.66
max reikšmė	463.61	291.03	1 952.49	2 903.16	1 881.26	3 943.41	9.32	23.26

Kitas iš populiariausių būdų susipažinti su duomenimis yra peržvelgti pagrindines statistikas tokias kaip pateiktas 5-oje lentelėje. SPX galima dar kartą įsitikinti prieš tai darytais pastebėjimais, kad tyrimo laikotarpiu dauguma reikšmių buvo iki 1500 indekso vertės. Tai matosi ir iš to, kad abu pirmieji duomenų kvartiliai yra iki tos reikšmės. Trečio kvartilio ir „max“ reikšmės didelis pokytis dar kartą rodo staigų išaugimą indekso vertėje per paskutinius keletą metų. Gana panašūs rodikliai yra ir su SPW indeksu. Žvelgiant į abiejų indeksų prekybos apyvartos rodmenys įstringa ir reliatyviai labai maži skirtumai tarp abiejų apyvartų minimalių reikšmių ir 3-io kvartilio reikšmių. Štai maksimalios reikšmės labai išsiskiria ir tai rodo, kad apyvartos šoktelėjimai į viršų būna reti, bet labai stiprūs, net kelis kartus vidurkio. Maksimali reikšmė labai išsiskirianti yra ir VIX indekse, tačiau kaip matėme anksčiau grafike prie jos priartėjama dar gerokai rečiau. Iš nepriklausomų kintamų verta pažymėti BASDPTDSP kurio maksimali reikšmė labai stipriai iššoka iš duomenų konteksto, ir viršija vidurkį net 10 kartų. To išskirtinumą liudija ir standartinio nuokrypio su vidurkiu santykis. Nors TYVIX,

BAMLH0A0HYM2EY, BAMLC0A0CMEY taip pat turi maksimalias reikšmes kelis kartus viršijančius vidurkius, skirtumas nėra toks išskirtinis. USYC2Y10 ir TNX atrodė išgyvenantys didelį kintamumą linijiniuose grafikuose, tačiau žvelgiant į pagrindines metrikas duomenis atrodo ganėtinai subalansuotai pasiskirstę. Tai pabrėžia svarbumą į duomenų žvelgimo pro keletą metodų. Kiti kintamieji, kaip obligacijų indeksų gražos ir izdo obligacijų ateities sandorių indeksas MLT1US10 savo pagrindinėmis statistinėmis charakteristikomis patvirtina savybes pastebėtas vizualiai iš linijinių grafikų.

Apibendrinus pastebėjimus iš pirmo susipažinimo su duomenimis, galima pastebėti labai įvairius veiksnius. Sunku rasti nors tris kintamus, kurių judėjimo kryptis, režiai ar dažnis būtų panašūs net ribotą laiką. Nors kai kurie veiksniai turi panašumų, tačiau skirtumai yra pakankamai ženkliūs, kad kiekvienas kintamas atneštų papildomos informacijos ir galėtų padėti daryti papildomas išvadas apie akcijų ar obligacijų rinkas. Taip pat nepasitvirtino keletą hipotezių, kurios galėjo formuotis apie duomenų ryšius. Tarp jų nustebino mažėjančios akcijų indeksų prekybos apimtys ir netolygūs tiesiniai neigiami ryšiai tarp obligacijų pelningumų ir rinkos indeksų.

Kitas svarbus dalykas pasižiūrėti yra veiksmų skirstiniai. Kaip aptarta, Shah (2013) ir Hilpisch (2015) darbuose, finansiniai duomenys dažnai būna sunkūs tuo, kad labai retai kada jie būna pasiskirstę pagal normalųjį (Gauso) skirstinį, tačiau dauguma modeliavimo metodų savo prielaiduose turi būtent tokį skirstinį. Nors kai kurie mašininio mokymosi algoritmai yra mažiau griežti tuo atžvilgiu, pravartu atsižvelgti į tai ir dėl platesnio duomenų konteksto.

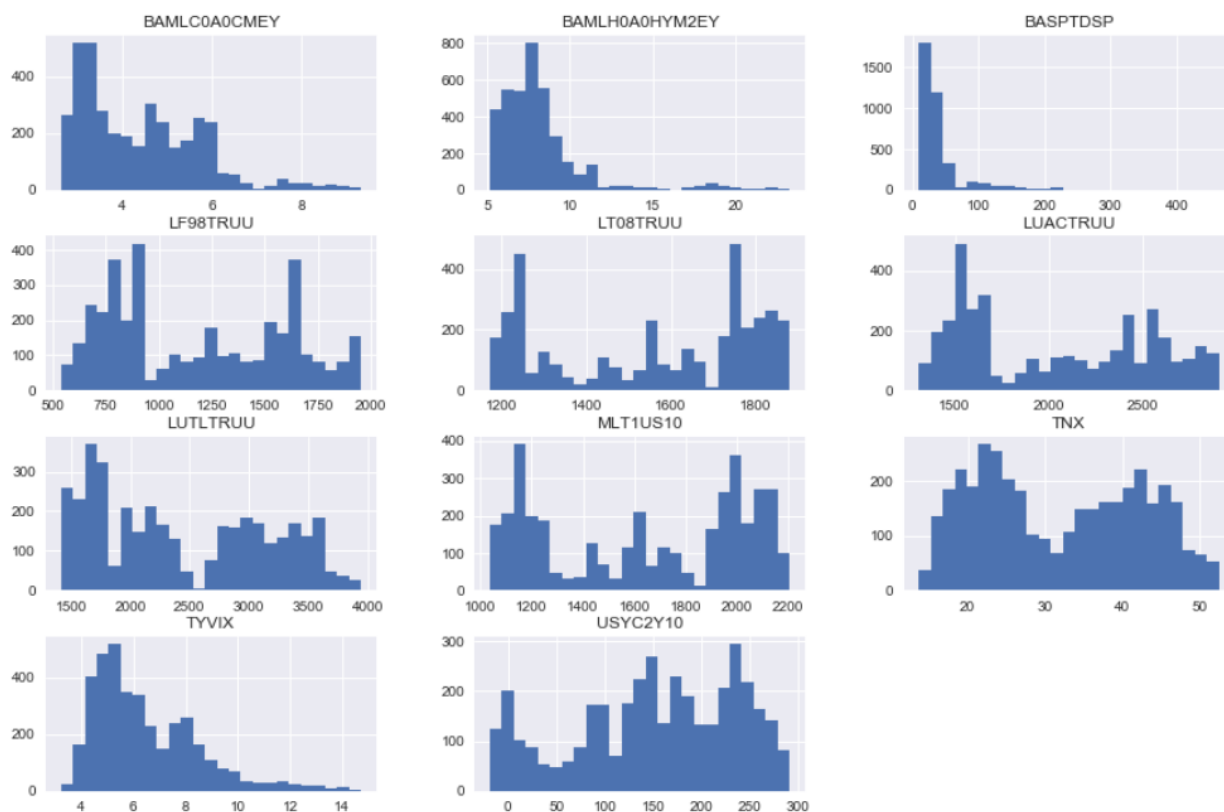
Priklausomų kintamųjų pasiskirstymą galima pamatyti 18 paveiksle, kur vienintelis SPW\_vol kintamas primena, normalųjį skirstinį. Įdomu ir šio kintamo skirtumas nuo labai panašaus SPX\_vol, kurio reikšmės gerokai labiau pasklidusios, o didžiausias klasteris reikšmių yra prie mažiausių verčių. Tai turi būti pasakoje labai suvienodėjusių SPX pardavimo apyvartų paskutinius penkis metus kaip pastebėta iš ankstesnių grafikų. Prekybos apimčių skirtumai gana žymūs nors indeksų SPX ir SPW reikšmių pasiskirstymas ko ne identiškas. SPX\_VIX reikšmės gausiausias pasikartojimus turi gana koncentruotuose reikšmių režiuose, tačiau šiaip reikšmės egzistuoja labai plačia amplitude, nors didžiausių reikšmių dažnis ypač mažas. Šiuose grafikuose taip pat pasimato, kad didžiausios reikšmės indeksų SPX ir SPW kartojosi rečiausiai, netgi mažiau negu pirmo kvartilio reikšmės, tačiau jos arčiausiai dabartinio laikotarpio. Tai rodo, kad šiuo metu akcijų rinkos yra kiek beprecedentiniame

laikotarpyje.



**18 pav. Priklausomų veiksnių reikšmių dažnio histogramos. Šaltinis: sudaryta autoriaus pagal „Bloomberg Professional“ [12].**

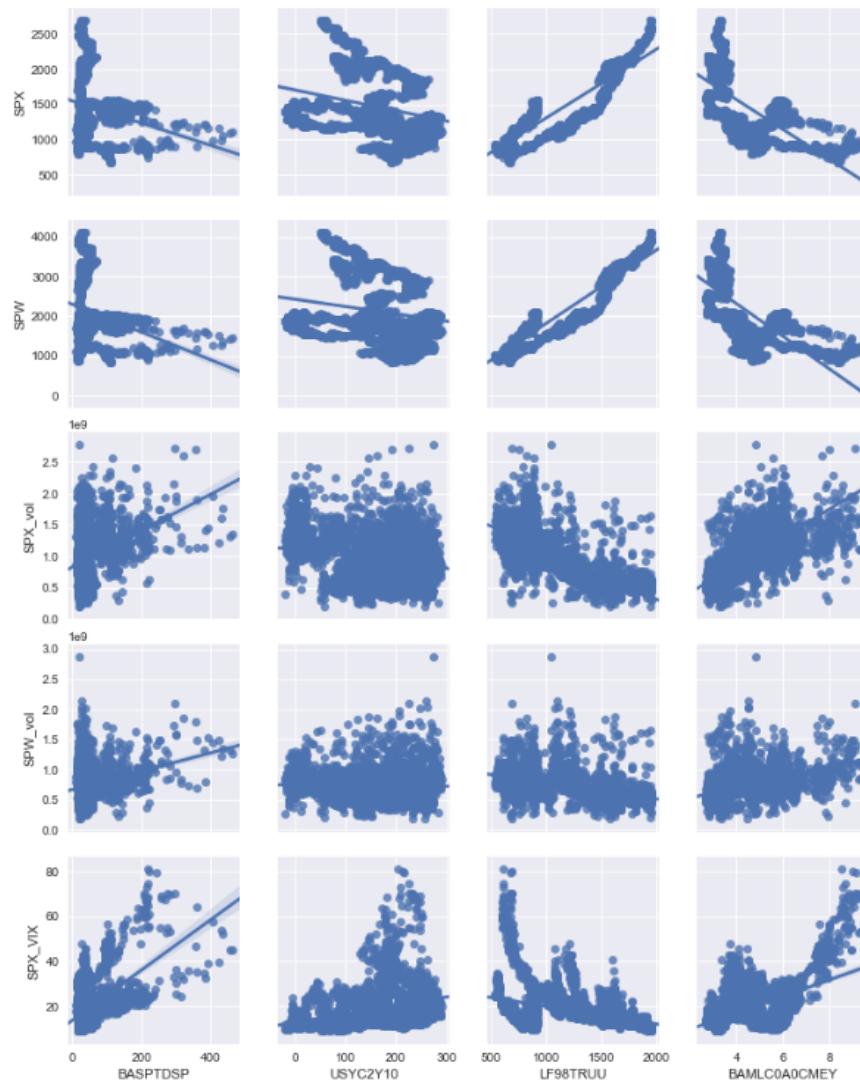
Žvelgiant į 18-ą paveikslą, kur pavaizduoti nepriklausomi kintamieji galima pastebėti, kad visų kintamų reikšmės pasiskirstę labai netolygiai kaip rodė linijiniai grafikai. Nė vienas iš kintamų neprimena Gauso skirstinio, o reikšmės pasiskirstę labai plačiai. Vieninteliai du netikėtai panašūs skirstiniai pasirodo esantys BAMLC0A0CMEY ir TYVIX. Tai kiek stebina, tačiau pažvelgus giliau abu šie veiksniai gana iš anksto signalizuoja mažiau rizikingų vertybinių popierių paklausą privačiame ir valstybiniame sektoriuje. Obligacijų fondų indeksai LF98TRUU, LUACTRUU, LT08TRUU, LUTLTRUU kartu su JAV išdo ateities sandorių indeksu MLT1US10 taip pat demonstruoja dalinai artimą pasiskirstymą. Ši grupė atrodo turinti panašių duomenų charakteristikų. Viena įdomiausių dažnių histogramų yra BASPTDSP, kuri dar kartą patvirtina kaip stipriai atitolę buvo šio veiksnio reikšmės per krizę nuo įprastai gana siaurai judančių verčių.



**19 pav. Nepriklausomų veiksnių reikšmių dažnio histogramos. Šaltinis: sudaryta autoriaus pagal „Bloomberg Proffesional“ ir Sant Luiso federalinio banko duomenis [12], [29], [30].**

### **3.3. Duomenų tarpusavio ryšių vertinimas grafiškai**

Anksčiau išvalgos buvo daugiau sukoncentruotas į vienmačius kintamųjų judėjimus, tačiau aprašomosios analizės metodai dažnai naudojami ir tarpusavio kintamų ryšių nustatinėjimui. Žemiau sklaidos diagramoje pateikta priklausomų kintamųjų sąryšiai su keletą įdomiausių obligacijų rinkos veiksnių. Grafikas su visais kintamais pateiktas 2-ame priede.




**20 pav. Akcijų rinkos ir su obligacijomis susijusių dalies veiksnų sklaidos diagramos. Šaltinis: sudaryta autoriaus pagal „Bloomberg Professional“ ir Sant Luiso federalinio banko duomenis [12], [29], [30].**

Paveiksle demonstruojami ryšiai gana iškalbingi ir patvirtina anksčiau pasirodžiusius ryšius. Pavyzdžiui matosi, kaip BASPTDSP reikšmės yra susikoncentravusios kairėje grafiko pusėje, tačiau didesnės reikšmės yra lydimos signalų apie streso ištiktą akcijų rinką — VIX augančias reikšmes, augančias prekybos apimtis ir žemėjančias akcijų indeksų reikšmes. USYC2Y10 kintamas rodo, kad tikrai ne visi kintamieji turi tiesinius ryšius su akcijomis. Tačiau rizikingesnes obligacijas atstovaujantis indeksas LF98TRUU turi ko ne tobulą tiesinį ryšį akcijų rinkos indeksais SPX ir SPW. Tiesa, su prekybos apimtimis ir VIX indeksu panašių teiginių nebūtų galima sakyti. Iš to galima sakyti, kad augant obligacijų rinkai, auga ir akcijų rinka, tačiau kitos akcijų metrikos to taip aiškiai nerodo. BAMLC0A0CMEY rodo, kad ir aukštesnės kokybės obligacijų rodikliai turi visai stiprų tiesinį ryšį su



akcijų indeksais, tiesa ryšis neigiamas. Kitaip sakant pingant obligacijoms (didėjant pelningumams) akcijų rinkos irgi traukiasi. Iš paskutinių pastebėjimų galima sakyti, kad korporacijų obligacijų tendencijos ir akcijos juda gana lygiagrečiai, tačiau vėlgi prekybos apimtys nesekioja akcijų indeksu taip tiesiškai. VIX rodo tokių savybių, tačiau neišbaigta, nes nors LF98TRUU atveju labai aiškios krypties negalima išskirti, BAMLC0A0CMEY atveju aukščiausios pelningumų reikšmės sutampa su aukščiausiomis VIX reikšmėmis įrodant ne patį stipriausią tiesinį ryšį. Tai vėl sutaptų su prieš tyrimą kelta hipotezė, kad kuo pigesnės obligacijos, tuo daugiau streso išgyvenama bendrai rinkoje ir tuo tai labiau atsispindi akcijų „baimės indekse“.



**21 pav. Akcijų rinkos veiksmų naudojamų tyrime tarpusavio sklaidos diagramos. Šaltinis: sudaryta autoriaus pagal „Bloomberg Professional“ [12], [29], [30].**

Smulkiau apžvelgus dalies priklausomų ir nepriklausomų kintamų ryšius, nemažai išlindo ir peripetijų dėl pačių priklausomų kintamųjų ryšių kurie pavaizduoti 21-ame paveiksle aukščiau. Kaip

jau ganėtinai aišku iš visų kitų tyrinėjimų, iš karto matosi labai stiprūs tiesiniai ryšiai tarp abiejų indeksų, SPW ir SPX, bei jų prekybos apimčių SPW\_vol ir SPX\_vol. Aiškaus trendo apyvartos nedemonstruoja nei su pačiais indeksais nei su VIX. Savo ruožtu VIX indeksas neturi tokio stipraus ryšio su “S&P 500” indeksais, bet matosi aiškėjanti tendencija aukščiausioms VIX reikšmėms rodytis indeksų verčių smukimo laikotarpiais.

Aprašomosios analizės metodai iš tiesų parodė, gana vientisą vaizdą ir darytos įžvalgos kartojosi per visus taikytus metodus. Tiesa, analizė paneigė nemažą dalį hipotezių, kurias buvo galima kelti apie duomenis, tačiau tolimesni metodų pritaikymai pateikė galimas priežastis staigmenoms. Galima pridurti, kad trūkstatų ar akivaizdžiai neteisingų duomenų nebuvo rasta. Tai patikrinantys veiksmai kartu su kitos aprašomosios analizės vykdymu matosi 15-ame priede su pateiktu kodu ir kitais veiksmais.

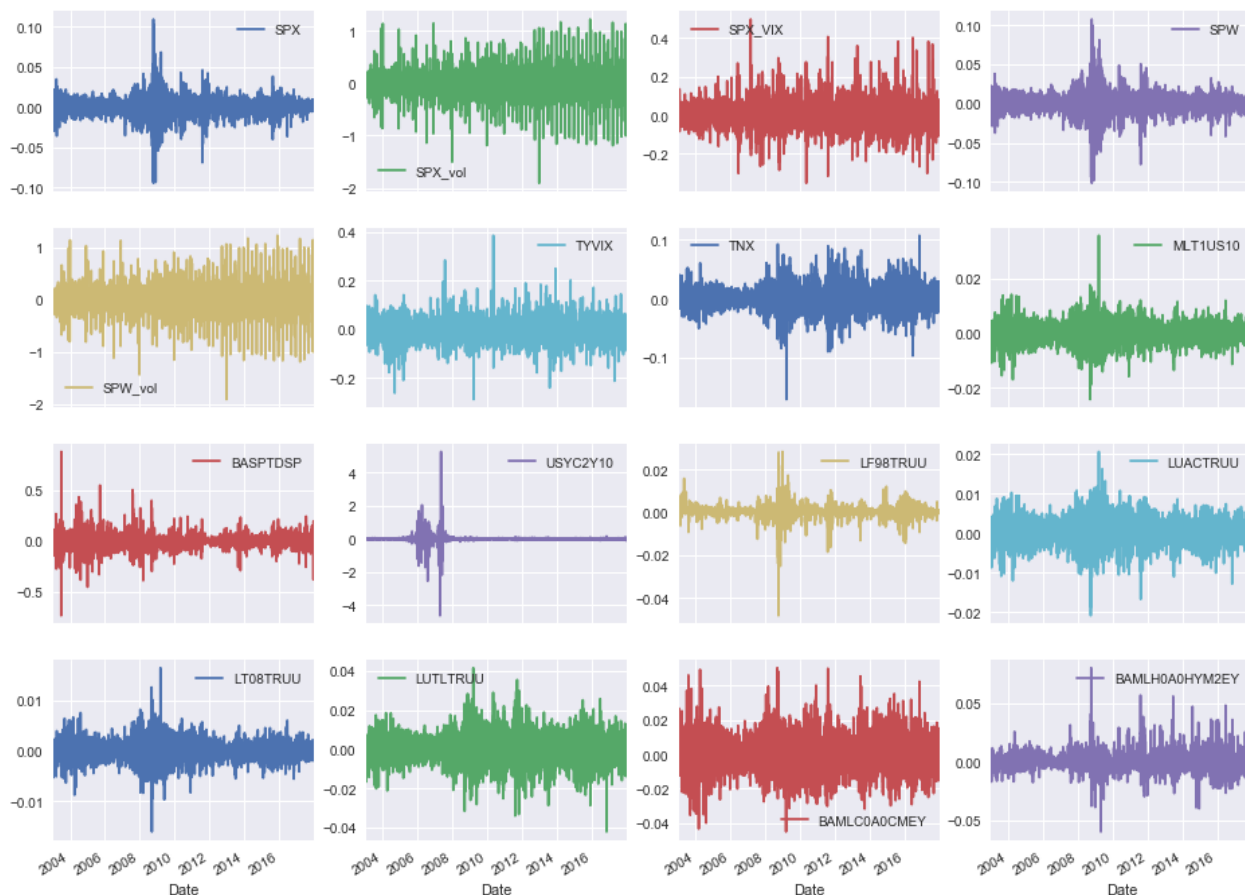
### 3.4. Mašininio mokymosi algoritmų taikymas tyrime

Iš aprašomosios analizės paaiškėjo nemažas sąrašas dalykų. Dalis iš jų tiesiog leido geriau pažinti duomenis, tiriamą situaciją ir kintamųjų tarpusavio ryšius, kas sudaro geresnį kontekstą apie duomenis. Kitą informaciją bus galima pritaikyti aiškinantis ryšius giliau. Šiame darbe to bus siekiama taikant mašininio mokymosi algoritmus. Sekančios išvados mašininio mokymosi algoritmų pritaikymo kontekste formuojasi dėka apžvalginės analizės:

- **Reikia duomenis normalizuoti.** Dauguma duomenų turi labai plačią duomenų sklaidos amplitudę ir gali išbalansuoti tokius algoritmus kaip neuroniniai tinklai.
- **Rezultatai daliai iš priklausomų kintamųjų gali būti labai panašūs.** Iš priklausomų kintamų indeksai SPX ir SPW bei jų prekybos apimtys SPX\_vol ir SPW\_vol turi daug homogeninių savybių. Panašu, kad dalis nepriklausomų kintamųjų taip pat gali turėti stiprius ryšius tarpusavyje.
- **Greičiausiai nebūtų tikslūs modeliai, kurių prielaiduose yra tiesiniai ryšiai.** Mažai su obligacijomis susijusių veiksnių turi stiprius tiesinius ryšius su nors dalimi priklausomų kintamųjų ir joks veiksnys neturi jų su visais.
- **Ne visi priklausomi kintami bus vienodai svarbūs rezultatuose.** LF98TRUU rodė potencialą būtų įtakingiausias indeksams SPX ir SPW, kol TYVIX atrodė artimiausias VIX indeksui. TYVIX atrodė turintis nemažą potencialą ir SPX bei SPW vertinimui.

Abiejų indeksų apyvartos atrodė kaip labai sudėtingai modeliuojamos ir obligacijų veiksmų įtaką jau dabar atrodo labai abejotina.

Remiantis šiomis įžvalgomis duomenis buvo standartizuoti. Tai buvo atlikta taikant 1-ą formulę apžvelgtą antroje darbo dalyje. Išgavus logaritmuotas gražas, duomenys atrodė kaip pavaizduoti 22 paveiksle.




**22 pav. Logaritmuotų dieninių pokyčių veiksmių dalyvavusių tyrime grafikai 2003-2017 m.**

**Šaltinis: sudaryta autoriaus.**

Atlikti veiksmai leido pasiekti rezultatą ir standartizuoti kiekvieną iš kintamų į gana siauras ribas. Vienintelis USYC2Y10 turi labai plačią amplitudę, tačiau tokia reikšmė tikrai turėtų būti panaikinta ieškant išskirčių prieš pritaikant algoritmus. Šiuose grafikuose labiau nei ankstesniuose pasimato ekstremalios reikšmės aplink krizės laikotarpį 2007-2009 m., o kai kurie iš kintamųjų patyria labai išskirtinius pokyčius kelias dešimtis kartų viršijant įprastas reikšmes. Taip pat, šiuose grafikuose aiškiai išsiskiria kintamieji kurie patyria žymiai didesnę kintamumą už kitus, tarp jų reikėtų išskirti priklausomus kintamus — SPX\_vol, SPW\_vol, kurie vos ne pastoviai patyria iš esmės didžiulius

pokyčius. Obligacijų indeksai LF98TRUU, LUACTRUU ir LT08TRUU yra tarp patyriančių mažiausius pokyčius, kuriems logaritnavimas turėjo mažiausiai įtakos. Didesnės dalies kitų kintamų skaitinių reikšmių tiesioginė interpretacija čia nėra labai tiksli dėl logaritmatavimo, tačiau buvo išgautas Gauso skirstinys iš visų kintamųjų. To pavyzdys su vienu iš labiausiai kompleksišku kintamų matosi 23-ame paveiksle žemiau. Skirtumus tarp logaritmuotų pokyčių reikšmių ir paprastų pokyčių galima pamatyti lyginant 22 pav. ir 3-ią priedą.



**23 pav. BAMLH0A0HYM2EY logaritmuota dieninių pokyčių reikšmių pasiskirstymo diagrama. Šaltinis: sudaryta autoriaus.**

Tyrimė bus sekama Sheta, Ahmed ir Faris (2015), Wu ir Xu (2005) bei Bird, Klein ir Loper (2009) pavyzdžiais, kurie nenagrinėjo priklausomų veiksnių tarpusavio ryšių ir netaikė veiksnių atrankos prieš atiduodant juos mašininio mokymosi algoritmams. Darbo tikslas yra nustatyti geriausią įmanomą modelį ir iš to detaliau spręsti apie ryšius tarp šių dviejų turto klasių atstovaujamų atrinktais veiksniais, o tam aktualūs visi atrinkti obligacijų veiksniai. Kaip rodo daug apžvelgtų tyrimų ir faktų minėtų pirmose dviejuose šio darbo dalyse, pakankamą tikslumą ir patikimumą prognozuoti turintis modelis iš pasirinktų veiksnių būtų svarbu ir gal net kiek netikėta. Taip teigiama, nes akcijas veikia tiek daug veiksnių, kad pasirinkti veiksniai gali nepriartėti prie reikšmingos dalies reikalingos variacijos. Rinkos rezultatai rodo, kad net prognozių tikslumas nestipriai viršijantis šanso tikimybę gali būti labai naudingas, nes pritaikius teisingus kapitalo valdymo principus ir prekiaujant didžiuliais svoriais su tuo galima pasiekti reikšmingo pelningumo.

Be to, Bird, Klein ir Loper (2009) sako, kad tinkamai klasifikavimui paruošti mašininio mokymosi modelį gali užtekti ir 100 stebinių, kas turbūt nebūtų pakankamas kiekis duomenų regresijai, tačiau šiame tyrime naudojamas 3776 stebinys turėtų būti tikrai daugiau nei pakankamas.

Rezultatai buvo vertinami trimis metrikomis apžvelgtomis 2.5 šio darbo dalyje — pataisytoju  $R^2$ , MAE ir RMSE. Šios metrikos buvo pritaikytos, kai apmokyti algoritmai darydavo prognozes apie kiekvienos iteracijos testavimo imtį. Sulyginus tikrąsias reikšmes su prognozuotomis buvo gautos minėtos metrikos. Kaip atrodė iteracijos ir suskirstymas į apmokymo bei testavimo imtis pateikta 3.5 skyriuje. Vertingiausi rezultatai — dažniausiai naudojami lyginimui ir sprendimų priėmimui buvo paskutinės iteracijos testavimo imties. Visi keturi mašininio mokymosi algoritmai taikyti analizėje buvo detaliau apžvelgti 2.4. dalyje. Pasikartojant šie algoritmai yra: neuroniniai tinklai, atraminiai vektoriai (SVR), atsitiktiniai miškai ir artimiausio kaimyno. Nors buvo eksperimentuojama su įvairiais algoritmų parametrais, ne už ilgo pasirodė, kad geriausi parametrai kartojasi įvairiai suformuotiems duomenims, dėl to algoritmų parametrai mažai kito analizės eigoje. Visur buvo taikytos šių algoritmų regresijos, o tikslus programos kodas naudotas parametrizuoti algoritmus ir skaičiuoti rezultatas pateiktas 15-ame priede, kartu su kitais veiksmais.

### **3.5. Metodų taikytų išskirčių šalinimui ir suskirstymui į apmokymo bei testavimo imtis apžvalga**

Taigi, turint standartizuotus duomenis, sekantis žingsnis apibrėžtas programoje šio darbo 2.5. dalyje yra pasiskirstyti juos į treniravimo ir testavimo imtis. Vienas patikimiausių būdų tai daryti — tradicinis kryžminis validavimas, nėra visai tinkamas šioje analizėje dėl keletos priežasčių:


- Dauguma kryžminio validavimo pritaikymų duomenis laiko nepriklausomais ir skirsto atstiktinai į grupes (angl. *folds*) taip praradant laiko eilučių sekos savybes.
- Suskaidant finansines laiko eilutes į labai daug dalių (kryžminiame validavime dažnai sutinkama 10 dalių), į laikotarpį papuolę duomenis gali būti labai šališki, vienapusiški, kas sunkintų modelio treniravimą, nes su kiekviena testavimo imtimi būtų labai daug naujos informacijos.
- Net paskirsčius duomenis iš eilės į pamatuotą kiekį dalių, svarbu, kad apmokius su viena dalimi, modeliai būtų testuojami su sekančio laikotarpio duomenų dalimi, o ne atsitiktinai parinkta, bet kuria iš kitų grupių.

Dėl to, šiame tyrime buvo pritaikyta kryžminio validavimo metodo variacija siūloma programinėje įrangoje naudotoje tyrimo metu. Metodas vadinamas „TimeSeriesSplit“ leidžia duomenis suskaidyti į kiek norima dalių, tačiau pritaikomos visos savybės reikalingos laiko eilutėms:

- Duomenis skaidomi iš eilės.
- Modeliai testuojami su duomenų grupe, kuri eina iškart po imties naudotos modelio mokyme. Išsaugomos laiko eilučių sekos savybės.
- Dalys prieš tai naudotos testavime ir treniravime sujungiamos į vieną naują treniravimo imtį, o sekanti dalis naudojama testavimui. Taip išsaugoma prieš tai naudota informacija mokiniuisi, tik prie jos priduriama dalis naujos informacijos, kuri leidžia modeliui nuosekliai pažindintis su laiko eilutėmis.

Šis metodas taip pat, užtikrina kad prognozių testavimas vyksta su vienodo dydžio imtimis, taigi rezultatai būtų palyginami. Ką tik pristatytas mašininio mokymosi algoritmų treniravimo metodas pavaizduotas 24 paveiksle žemiau.

### Treniravimui Testavimui



**24 pav. Mašininio mokymosi algoritmų mokymo ir vertinimo metodas naudotas tyrime. Šaltinis: sudaryta autoriaus.**

Siekiant, kad viena imtis atspindėtų kiek įmanoma daugiau bendrų duomenų savybių taikytas 2-ų arba 3-ių grupių suskirstymas. 3-ių grupių suskirstymas dažniau buvo naudojamas taikant algoritmus

naujose situacijose, kad šiek tiek detaliau pamatyti algoritmo pritaikymo sėkmę, o 2 grupių susiskirstymas buvo naudojamas patikrinti rezultatus.

Atvejais kai buvo siekiama panaikinti išimtis tam buvo taikomas specializuotas algoritmas paremtas atraminių vektorių principu, kuris buvo apžvelgtas 2.4.2. dalyje. Šis metodas vadinasi „OneClassSVM“. Buvo eksperimentuojama ir su tradiciniu būdu nustatyti išimtis — pašalinus visas reikšmes, kurios buvo didesnės/mažesnės už reikšmes gautas pridėjus/atėmus dvi standartines deviacijas prie vidurkio. Visgi minėtas automatizuotas algoritmas atnešė geresnius rezultatus.

### 3.6. Mašininio mokymosi algoritmų analizės rezultatai

Mašininio mokymosi algoritmai iš pradžių buvo pritaikyti visam duomenų rinkiniui. Prieš taikymą buvo pašalintos išimtis. Jų buvo rasta 224, kas vis tiek paliko labai nemažą skaičių stebinių — 3531. Pradžioje apie modelio galimą sėkmingumą buvo stengiamasi išsiaiškinti iš koreliacijos koeficientų. Pilna lentelė pateikta 4 priede, o skirtumai pašalinus išskirtys gali būti pastebimi lyginant 4-ą priedą su 5-u priedu.

**6 lent. Pradinio duomenų rinkinio priklausomų ir nepriklausomų kintamų koreliacijos lentelė . Šaltinis: sudaryta autoriaus.**

	SPX	SPX_vol	SPX_VIX	SPW	SPW_vol
SPX	1	-0.089086	-0.734354	0.984464	-0.0899616
SPX_vol	-0.089086	1	0.150034	-0.0771637	0.96748
SPX_VIX	-0.734354	0.150034	1	-0.714228	0.151753
SPW	0.984464	-0.0771637	-0.714228	1	-0.0796531
SPW_vol	-0.0899616	0.96748	0.151753	-0.0796531	1
TYVIX	-0.155485	0.0712329	0.305934	-0.147321	0.0726813
TNX	0.362037	-0.0846665	-0.287621	0.363981	-0.0838685
MLT1US10	-0.0921657	0.0132817	0.0873207	-0.0913252	0.0115992
BASPTDSP	-0.00546519	-0.00662821	0.00337641	-0.0047922	-0.00212337
USYC2Y10	0.0242447	0.0193688	-0.0204523	0.0292656	0.00905165
LF98TRUU	0.147951	-0.0473163	-0.149582	0.15907	-0.0521962
LUACTRUU	-0.0238903	-0.0102776	0.0379858	-0.021767	-0.0111268
LT08TRUU	-0.0873888	-0.00161634	0.0695712	-0.0878214	-0.00154091
LUTLTRUU	-0.0886126	0.0080958	0.0908107	-0.0861271	0.00733333
BAMLC0A0CMEY	0.0401131	0.0194273	-0.0429037	0.0385178	0.017496
BAMLH0A0HYM2EY	-0.168186	0.0805478	0.201154	-0.172077	0.0834962

Kaip matosi, atliktas normalizavimas kiek pakeitė tarpusavio kintamų ryšius ir jie atrodo silpnesni negu buvo galima spręsti iš aprašomosios analizės. Panašu, kad TYVIX ir TNX kintami turi geriausią šansą būti įtakingi akcijų indeksų modeliams, o indeksų apyvartos išlieka neturinčios jokių stipresnių ryšių su nei su vienu iš priklausomų kintamųjų. 7-oje lentelėje pavaizduota pritaikytų algoritmų rezultatai (pavaizduota tik paskutinės treniravimo-testavimo imties rezultatai). Šiuo atveju testuojant buvo pritaikytas 3 grupių suskirstymas. Analizuojant buvo vedama ir atsižvelgiama į MAE metriką, tačiau ji netilpo į lentelę suformatuota žemiau. Paskutiniai rezultatai buvo gauti algoritmus mokinant su 2649 stebiniais, o testuojant ant 882.

**7 lentelė. Pradinių duomenų paskutinės testavimo imties pritaikytos mašininio mokymosi algoritmams tikslumo rezultatai . Šaltinis: sudaryta autoriaus.**

<i>Priklausomas kintamas</i>	SPX		SPX_vol		SPX_VIX		SPW		SPW_vol	
	<i>Pataisytasis R2</i>	<i>RMSE</i>	<i>Pataisytasis R2</i>	<i>RMSE</i>	<i>Pataisytasis R2</i>	<i>RMSE</i>	<i>Pataisytasis R2</i>	<i>RMSE</i>	<i>Pataisytasis R2</i>	<i>RMSE</i>
<i>Neuroniniai tinklai</i>	0.1371	0.0070	0.0230	0.1571	0.2630	0.0645	0.1492	0.0073	0.0323	0.1565
<i>Atsitiktiniai miškai</i>	0.0724	0.0072	-0.0026	0.1592	0.2124	0.0667	0.0455	0.0077	-0.0057	0.1595
<i>Artimiausio kaimyno</i>	-0.0400	0.0076	-0.1634	0.1715	0.1636	0.0687	-0.0888	0.0082	-0.1905	0.1736
<i>SVR</i>	-0.2026	0.0082	-0.0014	0.1591	-0.0107	0.0755	-0.0302	0.0080	-0.0008	0.1591

Kaip matosi 7-oje lentelėje šis eksperimentas neatnešė gerų rezultatų. Vienintelis VIX kintamas turi nors kiek pranašesnę modelį, kurio tikslumas irgi yra toli nuo tinkamo prognozavimui. RMSE viršijanti 6 procentus reiškia, kad spėjimai nelabai tikslūs ir beveik siekia standartinį nuokrypį (žr. 8 lent.). Nors VIX turint tokias kintamumo savybes, netgi prognozė su 6% paklaida galėtų turėti prasmės, tiesa mažas pataisytas  $R^2$  rodo, kad ši paklaida galbūt nėra labai tiksli. Taip pat, nors kiek tikslesnius modelius neuroniniams tinklams pavyko sukonstruoti abiejų indeksų SPX ir SPW atveju, tačiau vėlgi tikslumas labai toli nuo didesnio potencialo. Remiantis tiek RMSE, tiek pataisytojo  $R^2$  metrikomis neuroniniai tinklai buvo tiksliausi, o atsitiktiniai miškai buvo tolimoje antroje vietoje. Kaip matosi, modeliams sekėsi taip sunkiai, kad dauguma artimiausio kaimyno ir SVM metodų modelių turėjo netgi minusinį pataisytąjį  $R^2$ , kas reiškia ypatingai netikslūs duomenis, kurių tikslumas gali būti prilyginamas nuliui. Taip pat, pasimato tendencija, kad kintamiesiems turint nors kiek stipresnį ryšį tai pasirodo per visus algoritmus, kurių modelių tikslumai sustiprėja. Vienintelis SVM regresijos algoritmas nerodo jokios modeliavimo galimybės nė vieno iš akcijų rinkos kintamų atžvilgiu. Verta pažymėti, kad SPX\_vol ir SPW\_vol patvirtina prielaidą kilusią po aprašomosios analizės, kad jie bus labai sunkiai modeliuojami.



**8 lentelė. Pradinio duomenų rinkinio, pritaikyto mašininio mokymosi algoritams, priklausomų kintamų pagrindinės statistikos. Šaltinis: sudaryta autoriaus.**

	SPX	SPX_vol	SPX_VIX	SPW	SPW_vol
<i>Stebinių sk.</i>	3755	3755	3755	3755	3755
<i>Vidurkis</i>	0.0003	-0.0009	-0.0002	0.0004	-0.0007
<i>Standartinis nuokrypis</i>	0.0116	0.2375	0.0686	0.0128	0.2383
<i>Min reikšmė</i>	-0.0947	-1.9090	-0.3506	-0.1014	-1.9090
<i>25%</i>	-0.0040	-0.1045	-0.0381	-0.0046	-0.1055
<i>50%</i>	0.0007	-0.0048	-0.0050	0.0008	-0.0036
<i>75%</i>	0.0053	0.1071	0.0321	0.0061	0.1089
<i>Max reikšmė</i>	0.1096	1.2270	0.4960	0.1073	1.2270

Iš pastarųjų rezultatų tapo aišku, kad pasirinkti obligacijų kintamieji neturi labai stipraus einamo ryšio su akcijų rinka ir puikų modelį visam laikotarpiui vargu ar pavyks pasiekti. Labai gerą modelį, bet kuriuo atveju sunku pasiekti, nes regresija bando nustatyti tikslias reikšmes, o tai sudėtinga padaryti, net turint didesnę dalį visų įtakingų kintamųjų, tarp kurių pasirinkti obligaciniai veiksniai nebūtinai papuola. Be to, nugrimzdo viltys pasiekti modelį, kuris galėtų prognozuoti tiksliai į ateitį su dienos ar didesniais lagais nepriklausomiems kintamiesiems. To patvirtinimą galima matyti 9-oje lentelėje vos su vienos dienos lagu, jokiame nepriklausomam kintamam neviršijant 0.15 koreliacijos koeficiento į neigiamą ar teigiamą pusę. Tai dar papildomai buvo patvirtinta koreliacinėmis lentelėmis su 3,5, 10, 20 dienų lagais priklausomiems kintamiesiems, kurios pilnos pateiktos atitinkamai 6-10 prieduose.

**9 lent. Duomenų rinkinio priklausomų ir nepriklausomų kintamų (su vienos dienos lagu) koreliacijos lentelė . Šaltinis: sudaryta autoriaus.**

	SPX	SPX_vol	SPX_VIX	SPW	SPW_vol
SPX	1	-0.088846	-0.733281	0.985161	-0.0848249
SPX_vol	-0.088846	1	0.128024	-0.0760509	0.983169
SPX_VIX	-0.733281	0.128024	1	-0.714256	0.128623
SPW	0.985161	-0.0760509	-0.714256	1	-0.0732728
SPW_vol	-0.0848249	0.983169	0.128623	-0.0732728	1
TYVIX	0.00793018	0.0235906	-0.00949679	0.00719184	0.0242342
TNX	-0.0338224	-0.00361814	0.0327106	-0.0313133	-0.00364354
MLT1US10	-0.000787377	-0.00257684	-0.0080341	-0.00801048	-0.0088284
BASPTDSP	-0.0208922	-0.00720512	0.0109474	-0.0221958	-0.00667409
USYC2Y10	0.00838921	0.00473171	-0.0119186	0.00976907	0.00211994
LF98TRUU	0.0994496	0.0123879	-0.0586815	0.105674	0.0166205
LUACTRUU	0.0129774	-0.0155899	-0.0160814	0.0128629	-0.018803
LT08TRUU	-0.0141861	0.0127943	0.00926398	-0.0207494	0.00308935
LUTLTRUU	-0.00379708	-0.0235514	-0.000865764	-0.00811149	-0.027511
BAMLC0A0CMEY	-0.0200747	0.0006858	0.0143019	-0.0204904	0.00343568
BAMLH0A0HYMZEY	-0.0883182	-0.0326545	0.0486817	-0.0962925	-0.035312

Iš minėtų įžvalgų aiškėja, kad su pasirinktais obligacijų veiksniais vargiai pavyks tiksliai prognozuoti akcijų veiksmų reikšmes, tačiau yra šansas, kad reikšmes kiek generalizavus galima būtų nusakyti tendenciją, kuria linkme judėtų pasirinkti akcijų rinkos veiksniai. Tam siekti buvo pasirinkta vidurkinti paskutinių 20-ies dienų reikšmes. Tai vaizduoja 14 formulė:

$$\overline{X}_n = \frac{x_{n-19} + \dots + x_n}{20}; \quad (14)$$

Kai:

$\overline{X}_n$  yra n-tojo stebinio reikšmė — to stebinio ir prieš tai sekusių 19-os reikšmių vidurkis.

Toks laikotarpis pasirodė tinkamas, nes tai atitinka pilną mėnesį prekybos veiklos (turint omeny, kad į analizuojamą laikotarpį įtrauktos tik darbo dienos). Slenkančio lango vidurkinimo metodą kintamiesiems savo darbe pritaiko ir tokie autoriai kaip Baker bei Wurgler (2012). Pradėta buvo vidurkinant visas x veiksmų reikšmes. Tam neatnešus rezultatų tas pats buvo atlikta su visų 5-ių y veiksmų reikšmėmis. Abu bandymai pateikti atitinkamai 11-ame ir 12-ame prieduose. Verta paminėti, kad taikant vidurkius nebuvo papildomai išskiriamos išskirtys. Taip buvo elgiamasi, nes vidurkinant reikšmes tai jau pritaiko grubų išskirčių švelninimo mechanizmą. Sekantis bandymas buvo vidurkinant paskutinių 20-ies dienų reikšmes tiek X, tiek Y veiksmų. Šiuo atveju koreliacijos koeficientai pateikti 10-oje lentelėje buvo daug žadantys. Pilna koreliacijos lentelė matoma 13-ame priede.

**10 lent. Suvidurkintų paskutinių dvidešimties stebinių reikšmių duomenų rinkinio priklausomų ir nepriklausomų kintamų koreliacijos lentelė. Šaltinis: sudaryta autoriaus.**

	SPX	SPX_vol	SPX_VIX	SPW	SPW_vol
SPX	1	-0.229302	-0.729054	0.978869	-0.227357
SPX_vol	-0.229302	1	0.326997	-0.209235	0.975048
SPX_VIX	-0.729054	0.326997	1	-0.69268	0.32478
SPW	0.978869	-0.209235	-0.69268	1	-0.206122
SPW_vol	-0.227357	0.975048	0.32478	-0.206122	1
TYVIX	-0.298591	0.132838	0.438095	-0.261761	0.144936
TNX	0.270819	-0.100812	-0.247701	0.262666	-0.0836456
MLT1US10	-0.216822	0.086134	0.18269	-0.224336	0.0577749
BASPTDSP	-0.15887	0.0605126	0.226155	-0.150498	0.0710632
USYC2Y10	-0.0177074	0.0301803	0.0208377	-0.0100967	0.00723373
LF98TRUU	0.692463	-0.145342	-0.514952	0.731413	-0.147593
LUACTRUU	0.336156	-0.0645042	-0.234987	0.344189	-0.0892867
LT08TRUU	-0.26928	0.104754	0.232743	-0.276143	0.0800891
LUTLTRUU	-0.219333	0.077569	0.211035	-0.224896	0.0580441
BAMLC0AOCMEY	-0.283942	0.0259933	0.191144	-0.295317	0.0470886
BAMLH0A0HYM2EY	-0.690336	0.154594	0.575282	-0.710158	0.155786

Vidurkinant abi lygties puses išties buvo galima išvysti žymiai pastiprėjusius koreliacijos koeficientus. Dauguma priklausomų kintamų su akcijų indeksais įgijo ryšius viršijančius 0.2 koeficientą, o LF98TRUU ir BAMLH0A0HYM2EY koreliacijos koeficientas su SPW ir SPX pakylėjo iki maždaug 0.7. VIX indeksas taip pat įgijo stipresnius ryšius su tais pačiais kintamais, kurių koeficientas viršijo 0.5. Nežymiai sustiprėjo ir kai kurie ryšiai su indeksų apyvartomis. Tačiau, nepaisant žadančių koreliacijos koeficientų, mašininio mokymosi rezultatai nebuvo kaip tikėtasi.


**11 lentelė. Suvidurkintų paskutinių dvidešimties stebinių reikšmių duomenų rinkinio paskutinės testavimo imties pritaikytos mašininio mokymosi algoritmams tikslumo rezultatai. Šaltinis: sudaryta autoriaus.**

<i>Priklausomas kintamas</i>	SPX		SPX_vol		SPX_VIX		SPW		SPW_vol	
	<i>Tikslumo rodiklis/ Algoritmas</i>	Pataisy-tasis R2	RMSE	Pataisy-tasis R2	RMSE	Pataisy-tasis R2	RMSE	Pataisy-tasis R2	RMSE	Pataisy-tasis R2
<i>Neuroniniai tinklai</i>	0.1118	0.0013	0.0379	0.0155	0.3889	0.0086	0.2212	0.0013	0.0395	0.0155
<i>Atsitiktiniai miškai</i>	0.1709	0.0013	-0.0172	0.0159	0.2863	0.0093	0.1980	0.0014	-0.0295	0.0160
<i>Artimiasio kaimyno</i>	-0.0744	0.0014	-0.16477	0.0170	0.1990	0.0099	-0.1540	0.0016	-0.1663	0.0171
SVR	-6.2427	0.0037	-0.0689	0.0163	-0.7707	0.0147	-6.2297	0.0041	-0.1651	0.0170

Paskutinėje tikrinimo iteracijoje duomenis buvo mokinami su 2491 stebiniais, o testuojami su 1245-iais. Buvo pritaikytas 2 dalių testavimas. Matome, kad nors modelių rezultatai tikslesni už rezultatus kai duomenis buvo ne vidurkinti, tačiau tikslumas vis tiek nėra pakankamas patikimam modeliavimui į ateitį. Iš koreliacijų koeficientų tikrai buvo galima tikėtis geriau. Kaip ir anksčiau indeksų SPX ir SPW prekybos apimčių modeliai visai netikslūs su visais algoritmais. Pagal RMSE kriterijų vidutinė neuroninių tinklų ir atsitiktinių miškų modelių prognozės indeksų SPW ir SPX reikšmės skiriasi mažiau negu procentu, kas būtų labai neblogas indikatorius turint omeny akcijų rinkų didelius kintamumus. Netgi VIX indeksas, kuris pasižymi dar didesniu kintamumu anot modelio prognozuojamas su vidutiniškai mažiau negu procento paklaida nuo tikrosios reikšmės. Prekybos apyvartų atveju, RMSE dažniausiai laikosi apie pora procentų paklaida, kas nėra mažai, nors šių rodiklių kintamumai irgi didžiuliai. SPX indekso atveju geriau už neuroninius tinklus pasirodo ir atsitiktinių miškų algoritmas. Kaip ir anksčiau SVM algoritmas pasirodo bevertis.

Ką tik aptarti rezultatai ypatingai stebino, nes rezultatai labai suprastėjo po antrojo-paskutinio tikrinimo. Pirmojo tikrinimo metu, kai buvo mokinamasi su pirmaisiais 1246 stebiniais, o testuojama su sekančiais 1245-iais rezultatai buvo beveik dvigubai geresni. Tai sukėlė minčių, kad galbūt pasirinkti obligacijų veiksniai turi pakankamai įtakingus ryšius su akcijų rinkomis, tačiau tie ryšiai nėra

pakankamai atkaklūs laiko kontekste arba stipriai keičiasi. Tai paaiškintų kodėl modeliai vienu laikotarpiu yra tikslesni nei kitu ir skirtumai tokie drastiški. Tokiu atveju kintamų ryšiai turėtų kisti drastiškai taip pat. Tam įsitikinti buvo atlikta paskutinių 20-ies dienų „slenkanti“ koreliacija, kai imama centrinė lango reikšmė. Paveiksle nr. 25 pateikta dalis korelacijų su kintamais, pilni koreliaciniai grafikai pateikti 14-ame priede.



**25 pav. Priklausomo kintamo SPX ir keturių nepriklausomų kintamų dvidešimtys dienų slenkančios korelacijos grafikai. Šaltinis: sudaryta autoriaus.**

Kaip vaizdingai perteikia grafikai kintamųjų ryšiai iš tiesų yra labai nepastovūs su šiuo atveju pasirinktu SPX indeksu. Poros metų laikotarpyje koreliacija su vienu kintamu gali siekti nuo -0.5 iki

0.75 kaip matosi USYC2Y10 kintamo atveju. Šalia to gali prisidėti situacijos, kai iš vienos būsenos kintamieji pereina į visai kitas. Pavyzdžiui BAMLC0A0CMEY kintamas didžiąją dalį laikotarpio juda nuo 0.4 iki -0.4 režiuose, tačiau nuo maždaug 2013 m. vidurio pradeda labai stipriai ir dar nepastoviau svyruoti nuo -0.6 iki 0.8 režiuose. Tai reiškia, kad net modeliams apdirbus aplink nuolatinius svyravimus kintamųjų ryšiuose, nustatyti ryšiai gali kardinaliai keistis tolimesniuose laikotarpiuose ir modelio prognozių tikslumas stipriai nusilpti.

Atsivežlgiant į kintamųjų savybes, bei pastebėtų koreliacijų tęstinumus, buvo pastebėta, kad didesnė dalis ryšių išgyvena gana stiprius pokyčius nuo maždaug 2014 m. Dėl to tam pačiam duomenų rinkiniui, kuriame buvo suvidurkintos 20 dienų reikšmės, buvo sudaryti modeliai būtent 2003-2014 m. laikotarpiui, pabaigiant balandžio 14 dienos vidurkiu. Rezultatai pateikti 12-oje lentelėje.

**12 lentelė. Suvidurkintų paskutinių dvidešimties stebinių reikšmių duomenų rinkinio paskutinės testavimo imties pritaikytos mašininio mokymosi algoritmams tikslumo rezultatai 2003-2014-04-14 laikotarpiui (pirmiesiems 2800 stebinių). Šaltinis: sudaryta autoriaus.**

<i>Priklausomas kintamas</i>	SPX		SPX_vol		SPX_VIX		SPW		SPW_vol	
	<i>Tikslumo rodiklis/ Algoritmas</i>	Pataisy-tasis R2	RMSE	Pataisy-tasis R2	RMSE	Pataisy-tasis R2	RMSE	Pataisy-tasis R2	RMSE	Pataisy-tasis R2
<i>Neuroniniai tinklai</i>	0.6494	0.0011	0.0125	0.0157	0.4667	0.0072	0.6440	0.0013	-0.0098	0.0158
<i>Atsitiktiniai miškai</i>	0.5414	0.0013	-0.0443	0.0161	0.4324	0.0075	0.5706	0.0014	-0.0576	0.0162
<i>Artimiausio kaimyno</i>	0.2601	0.0016	0.0035	0.0157	0.5241	0.0068	0.2295	0.0018	-0.0140	0.0159
<i>SVR</i>	-3.6949	0.0040	-0.0028	0.0158	-1.0073	0.0141	-3.5132	0.0045	-0.0713	0.0163

Išskirčių šiuo atveju vėlgi nebuvo ieškota dėl vidurkinimo, o pateikti rezultatai gauti mokinantis iš 1867 stebinių, o testuojant ant 933. Atlikti veiksmai pasiteisino, neuroniniai tinklai sukonstravo gana tikslų modelį, tiek SPW, tiek SPX indeksams, kurio pataisytasis  $R^2$  yra beveik 0.65, o RMSE yra tik kiek daugiau nei viena dešimtoji procento. Tai iš tiesų modelis, kuris atrodo gana patikimas ir daug žadantis. Paremiant neuroninio tinklų rezultatus galima išvysti ir gana neblogų atsitiktinių miškų rezultatų, kurių RMSE taip pat labai maža, o pataisytasis  $R^2$  viršija šansą. Kiek netikėtai šiuo atveju, prastokai pasirodo artimiausio kaimyno algoritmas, kuris anksčiau ne daug atsilikdavo nuo kitų algoritmų. Šis algoritmas tiesa, geriausiai prisitaiko VIX kintamajam ir taip pat sukonstruoja gana tikslų modelį, kurio pataisytasis  $R^2$  viršija 0.5, o RMSE mažiau negu procentas. Atsitiktiniai miškai ir neuroniniai tinklai VIX atžvilgiu mažai atsilieka. Kitos išvados kartojasi iš ankstesnių rezultatų — SPX\_vol ir SPW\_vol niekaip nerandama tinkamesnio modelio, o SVM principu paremta regresija SVR nepriduria jokios vertės nei vieno iš priklausomų kintamų atžvilgiu.

### 3.7. Nepriklausomų kintamųjų įtakingumo palyginimas ir rezultatų interpretacija

Kadangi, naudoti netiesiniai modeliai iš sudarytų modelių negalima pasiimti daug naudingos informacijos apie tai, kurie kintamieji buvo naudingiausi sudarinėjant modelius. Neuroniniu tinklų atveju koeficientai yra, tačiau jie neturi tiesioginės reikšmės kaip pavyzdžiui tiesinės regresijos atveju. Visgi vienas naudotas algoritmas, atsitiktinių miškų regresorius, leidžia pasižiūrėti, kuriuos iš nepriklausomų kintamųjų jis rado naudingiausiais. Šie koeficientai pateikiami 13 lent. modelio SPX ir VIX kintamųjų atžvilgiu. Dėl SPX ir SPW stulbinančių panašumų, išryškėjusių daug kartų analizėje, manoma, kad visos išvados žemiau apie SPX taikomos ir SPW. Rezultatai, per daug nestebina, nes pagrindinė sutampa su tendencijomis užduotomis koreliacijos koeficientais, tiesa reikia turėti omenyje, kad VIX atveju atsitiktinių miškų algoritmas buvo gerokai silpnesnis. Iš koreliacijos koeficientų atrodė, kad BAMLH0A0HYM2EY ir LF98TRUU turės didžiausią įtaką modeliams. Tada, pagrindinė papildomos naudingos informacijos atrodė pridedantys TYVIX ir TNX kintamieji. Turint omenyje, kad koreliacijų sėkmingumas ir mašininio mokymosi algoritmų sėkmingumas koreliuoja, tai tikrai atrodo svarbu. Štai atsitiktiniai miškai SPX kintamo atžvilgiu labiausiai naudojo LF98TRUU beveik pusei modelio naudojamos informacijos išgauti SPX atveju, tačiau BAMLH0A0HYM2EY buvo daugiau nei dvigubai naudingesnis už LF98TRUU VIX atveju. Tęsiant su SPX, kitas svaresnis kintamas buvo MLT1US10, o toliau kintamųjų procentai ženkliai krenta. „Baimės indekso“ atveju, kintamųjų įtaka buvo labiau pasiskirsčius po antro pagal įtakingumą — TYVIX veiksnio. TNX, LUACTRUU kartu su anksčiau minėtų LF98TRUU visi skiriasi vos per pora procentinių punktų. Netoli atsilieka ir USYC2Y10, kuris yra vienintelis kintamas, kurio įtaka tokia sugretinama abiejų pasirinktų akcijų rinkos veiksmu atžvilgiu. Galima spėti, kad ypač SPX atveju, kitų kintamųjų su stipriais koreliacijos koeficientais, modelis taip nepaisė, nes daug informacijos buvo pasikartojančios su prieš tai sekusiais kintamais.

**13 lentelė. Atsitiktinių miškų svarbumo koeficientai priskirti kiekvienam iš naudotų nepriklausomų kintamųjų SPX ir VIX kintamųjų atžvilgiu. Šaltinis: sudaryta autoriaus.**

Priklausomas kintamas	Atsitiktinių miškų svarbumo koeficientas		Priklausomas kintamas	Atsitiktinių miškų svarbumo koeficientas	
	SPX	SPX_VIX		SPX	SPX_VIX
<b>LF98TRUU</b>	<b>46.52%</b>	<b>11.26%</b>	<b>LUACTRUU</b>	<b>3.31%</b>	<b>8.03%</b>
<b>MLT1US10</b>	<b>16.72%</b>	<b>3%</b>	<b>BAMLC0A0CMEY</b>	<b>3.20%</b>	<b>3.84%</b>

Priklausomas kintamas	Atsitiktinių miškų svarbumo koeficientas		Priklausomas kintamas	Atsitiktinių miškų svarbumo koeficientas	
	SPX	SPX_VIX		SPX	SPX_VIX
<b>USYC2Y10</b>	<b>7.74%</b>	<b>7.22%</b>	<b>LUTLTRUU</b>	<b>2.71%</b>	<b>3.64%</b>
<b>LT08TRUU</b>	<b>6.75%</b>	<b>3.86%</b>	<b>BAMLH0A0HYM2EY</b>	<b>2.32%</b>	<b>25.11%</b>
<b>TNX</b>	<b>4.47%</b>	<b>9.54%</b>	<b>BASPTDSP</b>	<b>1.82%</b>	<b>5.29%</b>
<b>TYVIX</b>	<b>4.44%</b>	<b>19.21%</b>	<b>SUMA</b>	<b>100.00%</b>	<b>100%</b>

Apibendrinus, abiejų akcijų veiksniai yra labiausiai įtakojami rizikingesnių įmonių obligacijų indekso ir pelningumų. VIX atveju įtakingesni pastarieji, o SPX atveju — pirmieji. Tai galima pagrįsti, tuo kad VIX indeksas yra labai staigus ir kintantis rodiklis, kuris greičiau reaguoja paskui obligacijų pelningumus, kurie taip pat yra greitesni lyginant su LF98TRUU indeksu. Taip pat, SPX labiau reaguoja į JAV išdo 10-ies metų trukmės obligacijų ateities sandorių indeksą, o VIX į to pačio vertybinio popieriaus kintamumo indeksą. Tai buvo visai tikėtina, žvelgiant į grafikus, kur ateities sandorių indeksas turėjo žymiai artimesnį judėjimą SPX kylančiai trajektorijai, o kintamumo indeksas buvo artimas akcijų kintamumui VIX pavidale. Tai rodo, kad obligacijų ateities paklausa susijusi su akcijų dabartine situacija, tačiau ruošimasis tiek akcijų, tiek obligacijų portfelio pokyčiams vyksta vienu metu. TNX įtaka VIX rodo, kad bendrai vyriausybiniai obligacijų rodmenys VIX turi gerokai didesnę įtaka nei SPX.

Visai tai reikia įvertinti prieš tai paaiškėjusių aplinkybių kontekste, kad akcijų rinkos ryšiai su pasirinktais obligacijų pelningumais ir susijusiais veiksniais yra labai nestabilūs. Nors norėtusi, kad modeliai veiktų tiksliai ir vientisai, tačiau praktikoje tai retai pasiekama be modelio kalibravimo. Tai yra periodiško parametrų ir kintamųjų peržiūra, kurios metu galimai peržiūrima modelio parametrai ir kintamieji. Tai ypač aktualu padaugėjus ženklų, kad modelio tikslumas ar prielaidos jam pasikeitė. Šio darbo autorius mano, kad modelis sukonstruotas 3.6. dalyje, kuris gali paaiškinti 65% akcijų rinkos judėjimo 2800 dienų iš eilės turi potencialo, su tinkama priežiūra ir disciplina, būti panaudotas gana tiksliai akcijų rinkų tendencijų nusakymui. Kadangi, JAV rinkos įtaka aplink pasaulį gerai iliustruota, tokie ryšiai turėtų potencialo kartotis daugelyje kitų nors kiek JAV rinką menančių šalių pasaulyje.

## IŠVADOS

Tyrimo pabaigoje atrodo, kad padėta nors iš dalies užpildyti vakuumus išvelgtus literatūros apžvalgoje. Tyrimo metu pritaikyti su obligacijomis susiję veiksniai pasirodė inovatyvūs ir išsiskiriantys kitų dažniau sutinkamų makroekonominių veiksnių kontekste. Taip pat, platesnis pasirinkimas veiksnių atstovaujančių akcijų rinką leido šią rinką įvertinti visapusiškiau.

Bandant nuodugniau tirti abiejų rinkų veiksnių sąryšius, šalia labiau tradicinių metodų kaip įvairaus pobūdžio grafikų, statistikų ir koreliacijos koeficientų buvo naudota mašininio mokymosi algoritmai. Naudoti keturi iš geriausių netiesinių regresinių algoritmų: neuroniniai tinklai, atsitiktiniai miškai, artimiausio kaimyno ir atraminių vektorių. Šių algoritmų naudojimo metu buvo pritaikyta palyginamuose tyrimuose pritaikytos metodikos ir keletas rečiau sutiktų, siekiant sekti ir prisidėti prie geriausių praktikų formavimosi šioje srityje, kurios dar atrodo ankstyvame etape.

Pasiekus darbo tikslą, apibendrinus galima pastebėti, kad nuosekliai su įvairiai transformuotais duomenimis ir laikotarpiais geriausiai pasirodė neuroninių tinklų algoritmas. Matuojant tiek pataisytojo  $R^2$ , tiek RMSE ar MAE klaidomis šio algoritmo modeliai būdavo tiksliausi ir tai sutiko su Zankova (2016) atradimais. Antras algoritmas pagal efektyvumą buvo atsitiktiniai miškai, nors atotrūkis tarp jo ir artimiausio kaimyno buvo gana mažas. Prasčiausiai pasirodė, SVM algoritmo regresorius, kuris prie įvairių tiriamų situacijų neatnešė jokios naudos ir dažniausiai nepaaiškino net mažos dalies kintamųjų. Tai prieštarauja Sheta, Ahmed, Faris (2015) rezultatams, kuriuose lyginant keletą algoritmų SVM modelis buvo tinkamiausias.

Rezultatai parodė, kad pasirinkti obligacijų veiksniai neįtakoja pasirinktų akcijų veiksnių to pačio laiko momentu taip stipriai, kad vien iš jų sudaryti tikslų ir vientisą regresinį modelį visam pasirinktam laikotarpiui. Rezultatai tik prastėjo pritaikant 1,3,5,10 ar 20 dienų lagus obligacijų veiksniams. Tačiau, tikslumas buvo ženkliai pagerintas kai vietoj konkrečios kiekvienos dienos pokyčio, regresoriai buvo pritaikyti paskutinių dvidešimties prekybos dienų suvidurkintoms reikšmėms. Tokiu atveju, obligacijų veiksniai buvo naudojami nustatyti daugiau akcijų rinkos tendencijas nei tiksliai reikšmes. Pagal šį šabloną, pavyko sudaryti modelius akcijų indeksams su keletą algoritmų, kurių tikslumai gerokai viršijo šansą gana ilgame laikotarpyje viršijančiame dešimtmetį. O paklaidos RMSE metrikomis buvo mažesnės nei kelios procentinės dalys. Tai rezultatai rodantys potencialą ir su kalibravimu modelis turėtų perspektyvos ir praktikoje.



Tai, kad rezultatai buvo išgauti per įvairius ciklo etapus ir efektyviausioje kapitalo rinkoje pasaulyje JAV — teikia potencialo, kad rezultatai yra mažiau jautrūs laikotarpiui ir regionui. Šalia to, darbo metu išryškėjo tolimesni rezultatai:

1. Rinkos verte sveriamo ir lygių svorių „S&P 500” indeksai, kaip ir jų apyvartos yra labai susiję.
2. Akcijų indeksų prekybos apimtys neatrodo veikiamos fundamentalių faktorių ir dėl to visiškai neturėjo ryšio su obligacijų veiksniais.
3. Rizikingų kompanijų obligacijų rinkos ir pelningumų indeksai pasirodė turintys stipriausią ryšį su akcijų veiksniais. To buvo galima tikėtis, nes rizikingos obligacijos yra arčiausiai akcijų rizikos profilio.
4. Iš vyriausybių obligacijų veiksmų, JAV 10-ies metų ateities sandorių indeksas buvo įtakingiausias akcijų SPX ir SPW indeksams, o to paties vertybinio popieriaus kintamumo indeksas buvo įtakingiausias VIX indeksui.
5. JAV išdo 10-ies metų trukmės obligacijų pelningumas neišsiskyrė kaip labiau reikšmingas faktorius už kitus pasirinktus obligacijų veiksmus ir dėl to nepateisino savo reputacijos kaip vienas reikšmingiausių obligacijų veiksmų, nuolatos sutinkamų literatūroje.
6. Akcijų indeksai turi stiprų teigiamą tiesinį ryšį su korporacijų obligacijų rinkos indeksais ir stiprų neigiamą tiesinį ryšį su korporacijų obligacijų pelningumais. Dauguma vyriausybės obligacijų veiksmų rodė nežymiai tiesinį arba visai netiesinį ryšį su akcijų indeksais.
7. Koreliacijos koeficientai yra patikimas indikatorius kokio tikslumo gali gautis mašininio mokymosi algoritmų modeliai.
8. Pasirinktų obligacijų ir akcijų veiksmų ryšiai labai nestabilūs laike, dėl to mašininio mokymosi algoritmų modeliai turėtų būti nuolatos testuojami ir koreguojami, kad tinkamai atspindėtų paskutinius ryšius.

Tyrimas užčiuopė obligacijų ir akcijų rinkos bei mašininio mokymosi algoritmų potencialą, patvirtino dalį anksčiau tirtų hipotezių ir ištyrė visai naujas. Tačiau erdvės tolimesniems tyrimams išlieka. Pritaikius klasifikavimo principą vietoj regresijos kintamiesiems, būtų galimai stipriai išauginti mašininio mokymosi algoritmų pasirinkimą ir sėkmingumą, kaip ir režimo keitimo modeliai galėtų padėti kovoti su obligacijų ir akcijų ryšių kintamumo nenuspėjamumu laike.

## ŠALTINIAI

1. Alatiqi, S., & Fazel, S. (2008). Can Money Supply Predict Stock Prices? *Journal For Economic Educators*, 8(2), 54–59.
2. Alesii, G. (2006). Fundamentals Efficiency of the Italian Stock Market: Some Long Run Evidence. *International Journal of Business and Economics*, 5(3), 245–264.
3. Aliahmadi, A., Jafari-eskandari, M., Mozafari, A., & Nozari, H. (2013). *Neural Networks and Regression Methods for Predicting Crude Oil Exports*. 5(2), 40–59.
4. Analytics Vidhya (2015). *7 Types of Regression Techniques you should know!*. [žiūrėta 2018-04-21]. Prieiga per internetą: <https://www.analyticsvidhya.com/blog/2015/08/comprehensive-guide-regression/>
5. Antti Ilmanen (2003). Expected Returns on Stocks and Bonds. *The Journal of Fixed Income* Fall 2003, 13 (2) 55-66; DOI:
6. Arnott, Robert D., Cornell, Bradford, Kalesnik, Vitali. *Presidential Politics and Stock Returns* (April 28, 2017).
7. Badea, L. M. (2013). *Supporting management decisions by using artificial neural networks for exchange rate prediction*. 12(4), 578–594.
8. Balke, N. S., & Wohar, M. E. (2001). *Explaining Stock Price Movements: Is There a Case for Fundamentals?* *Economic & Financial Review*, 22.
9. Binswanger, M. (2004). How do stock prices respond to fundamental shocks? *Finance Research Letters*, 1(2), 90–99.
10. Bird, S. Klein, E., Loper E. (2009). *Natural Language Processing with Python*. Sebastopol: O'Reily media.
11. Bloomberg (2018). *Paulsen Says 'Proceed With Caution' Across Many Asset Classes*. [žiūrėta 2018-05-04]. Prieiga per internetą: <https://www.bloomberg.com/news/articles/2018-04-03/paulsen-says-proceed-with-caution-across-many-asset-classes>
12. Bloomberg. (2018). Bloomberg Professional. [žiūrėta 2018-04-09]. Prieiga per prenumeratą.
13. Bontempi G., Ben Taieb S., Le Borgne YA. (2013) Machine Learning Strategies for Time Series Forecasting. In: Aufaure MA., Zimányi E. (eds) *Business Intelligence*. eBISS 2012. Lecture Notes in Business Information Processing, vol 138. Springer, Berlin, Heidelberg
14. Campbell, J. Y., & Taksler, G. B. (2003). *Equity Volatility and Corporate Bond Yields*, 58(6), 2321–2349.
15. Chambers, J. C., Mullick S. K., Smith, D.D. (1971). How to Choose the Right Forecasting Technique. *Harvard Business Review*.
16. Chris Downing, Shane Underwood and Yuhang Xing (2009). *The Relative Informational Efficiency of Stocks and Bonds: An Intraday Analysis*. Published: 01 October 2009
17. Chris Kirby (1997). Measuring the Predictable Variation in Stock and Bond Returns. *The Review of Financial Studies*, Volume 10, Issue 3, 1 July 1997, Pages 579–630.
18. CNBC (2017). *Social Capital's Palihapitiya says bitcoin is going to \$1 million in the next 20 years* [žiūrėta 2018-03-19]. Prieiga per internetą: <https://www.cnbc.com/2017/12/12/social-capitals-palihapitiya-says-bitcoin-is-going-to-1-million-in-the-next-20-years.html>
19. Colacito, R., Ghysels, E., & Meng, J. (2015). Skewness in Expected Macro Fundamentals and the Predictability of Equity Returns: Evidence and Theory. *SSRN Electronic Journal*.
20. Cray (2016). *Trading Smarter: Advanced Technology for Algorithmic Trading*. [žiūrėta 2018-05-02]. Prieiga per internetą: <https://www.cray.com/blog/leveraging-advanced-technology-algorithmic-trading-trading-smarter-part-1/>
21. D'Arcy, P., & Poole, E. (2010). Interpreting Market Responses to Economic Data. *Reserve Bank of Australia, Bulletin September Quarter 2010*, 35–42.

22. Degenhardt, T., Benjamin, R. A. (2017). The “Sell in May” effect: A review and new empirical evidence. *The North American Journal of Economics and Finance*. 43. 10.1016/j.najef.2017.09.003.
23. Douglas D. Evanoff, Kaufman, G. G., & Anastasios G. Malliaris. (2012). *Asset price bubbles: What are the causes, consequences, and public policy options?*
24. Durré, A. and Giot, P. (2007), An International Analysis of Earnings, Stock Prices and Bond Yields. *Journal of Business Finance & Accounting*, 34: 613-641. doi:10.1111/j.1468-5957.2007.02010.x
25. Ewing, B. T., & Thompson, M. A. (2007). Dynamic cyclical comovements of oil prices with industrial production, consumer prices, unemployment, and stock prices. *Energy Policy*, 35(11), 5535-5540.
26. F., A., Elsir, S., & Faris, H. (2015). A Comparison between Regression, Artificial Neural Networks and Support Vector Machines for Predicting Stock Market Index. *International Journal of Advanced Research in Artificial Intelligence*, 4(7), 55–63.
27. F., A., Elsir, S., & Faris, H. (2015). A Comparison between Regression, Artificial Neural Networks and Support Vector Machines for Predicting Stock Market Index. *International Journal of Advanced Research in Artificial Intelligence*, 4(7), 55–63.
28. Fama, E. F. (1965). Random Walks in Stock Market Prices. *Financial Analysts Journal*, 21(5), 55–59.
29. Federal reserve bank of St. Louis. (2018). *ICE BofAML US Corporate Master Effective Yield* . [žiūrēta 2018-03-08]. Prieiga per internetą: <https://fred.stlouisfed.org/series/BAMLC0A0CMEY>
30. Federal reserve bank of St. Louis. (2018). *ICE BofAML US High Yield Master II Effective Yield*. [žiūrēta 2018-03-08]. Prieiga per internetą: <https://fred.stlouisfed.org/series/BAMLH0A0HYM2EY>
31. Ferson, W., Sarkissian, S., & Simin, T. (2003). Is Stock Return Predictability Spurious? *Journal of Investment Management*, 1(3), 1–10.
32. Financial Times (2018). *Head of BIS calls for clampdown on bitcoin*. [žiūrēta 2018-03-19]. Prieiga per internetą: <https://www.ft.com/content/78bf5612-0b1a-11e8-839d-41ca06376bf2>
33. Ghysels, E., Moreno, A., Nijman, T., Pasquariello, P., Koijen, R., Schotman, P., Wouters, R. (2009). *The determinants of stock and bond return comovements*.
34. Gogineni, S. (2008). *The Stock Market Reaction to Oil Price Changes*. SSRN
35. Good Reads (2018). *John Kenneth Galbraith Quotes*. [žiūrēta 2018-03-04]. Prieiga per internetą: <https://www.goodreads.com/quotes/476607-there-are-two-kinds-of-forecasters-those-who-don-t-know>
36. Google trends. (2018). *Google trends comparison* [žiūrēta 2018-04-11]. Prieiga per internetą: <https://trends.google.com/trends/explore?date=2004-01-01%202018-01-01&q=stocks,bonds,commodities,derivatives,etf>
37. Grouard, M.H., Lévy, S., & Lubochinsky, C. (2003). Stock market volatility : from empirical data to their interpretation. *Market and Financial Stability Research Division*, (June), 57–74.
38. Hauptmann, J.; Hoppenkamps, A.; Min, A.; Ramsauer, F.; Zagst, R Forecasting market turbulences using regime-switching models. *Financial Markets and Portfolio Management* (2014) 28: 1
39. Heaton, J., & Lucas, D. (2000). *Stock Prices and Fundamentals*. *NBER Macroeconomics Annual* (Vol. 14).
40. Hilesch, Yves (2015). *Python for Finance*. Sebastapol: O'Reily media.
41. Hofer, E. (1999). Sensitivity analysis in the context of uncertainty analysis for computationally intensive models. *Computer Physics Communications L*, 7, 21–34.

42. Hördahl, P., & Packer, F. (2007). *Understanding asset prices: an overview*. Basel.
43. Hosseini, S. M., Ahmad, Z., & Lai, Y. W. (2011). The Role of Macroeconomic Variables on Stock Market Index in China and India. *International Journal of Economics and Finance*, 3(6), 233.
44. Hui-Ju Tsai (2014). The informational efficiency of bonds and stocks: The role of institutional sized bond trades. *International Review of Economics & Finance*, Volume 31, 2014, Pages 34-45, ISSN 1059-0560.
45. Jordà, Ò., Knoll, K., Kuvshinov, D., Schularick, M., & Taylor, A. (2017). *The Rate of Return on Everything, 1870–2015*.
46. Jupyter notebook (2018). *Interactive computing*. [žiūrėta 2018-02-03]. Prieiga per internetą: <http://jupyter.org/>
47. Kahneman, Daniel (2011). *Thinking, Fast and Slow*. GB: Penguin Books.
48. Kam C. Chan, Hung-Fung, Gaiyan Zhang, (2009). On the Relationship Between Asian Credit Default Swap and Equity Markets. *Journal of Asia Business Studies*, Vol. 4 Issue: 1, pp.3-12
49. Kang, L. (2007). *Modeling the Dependence Structure between Bonds and Stocks: A Multidimensional Copula Approach*.
50. Koller, T., Goedhart, M., & Wessels, D. (2005). *Valuation: Measuring and managing the value of companies*. *Long Range Planning* (Fourth, Vol. 25). Hoboken: John Wiley & Sons, Inc.
51. Kwan, Simon H. (1996). Firm-Specific Information and the Correlation between Individual Stocks and Bonds, *Journal of Financial Economics*, January 1996, Volume 40, Number 1, Page 63-80.
52. Lakonishok, J., Shleifer, A., & Vishny, R. W. (1992). The impact of institutional stock prices. *Journal of Financial Economics*, 32, 23–43.
53. Lapedes, A., Farber, R. (1987). *Nonlinear signal processing using neural networks: prediction and system modelling*. Technical Report LA-UR-87-2662, Los Alamos National Laboratory, Los Alamos, NM (1987)
54. Lee J., Saktiandi, S., Liew Y.S. (2006). *Understanding asset prices: determinants and policy implications*. BIS Autumn Economists' Meeting, 30-31 October, Base
55. Li, Lingfeng (2002). Macroeconomic Factors and the Correlation of Stock and Bond Returns (November 2002). Yale ICF Working Paper No. 02-46; AFA 2004 San Diego Meetings.
56. Ling, D. C., Naranjo, A., & Scheick, B. (2010). Investor Sentiment and Asset Pricing in Public and Private Markets. *SSRN ELibrary*.
57. Lipsy, P. Y., & Takinami, H. (2013). The politics of financial crisis response in Japan and the United States. *Japanese Journal of Political Science*.
58. Liu, X., Swift, S., Tucker, A., Cheng, G., & Loizou, G. (1999). *Modelling multivariate time series*.
59. Locarno, A., Massa, M. (2005). *Monetary policy uncertainty and the stock market*, CEPR Discussion Paper, no 4828.
60. Chen, L., Da, Z., Zhao, X. (2013). What Drives Stock Price Movements?. *The Review of Financial Studies*, Volume 26, Issue 4, 1 April 2013, Pages 841–876. Spausdinta: 23 February 2013
61. LR Finansų ministerija (2018). ). *Kredito reitingų reikšmės*. [žiūrėta 2018-05-06]. Prieiga per internetą: <https://finmin.lrv.lt/lt/veiklos-sritys/valstybes-skolos-valdymas/kredito-reitingai/kredito-reitingu-reiksmes>
62. Magnus Andersson, Elizaveta Krylova & Sami Vähämaa (2007) Why does the correlation between stock and bond returns vary over time?, *Applied Financial Economics*, 18:2, 139-151, DOI: 10.1080/09603100601057854
63. Malcolm Baker, Jeffrey Wurgler (2012). Comovement and Predictability Relationships Between Bonds and the Cross-section of Stocks. *The Review of Asset Pricing Studies*, Volume 2, Issue 1, 1 June 2012, Pages 57–87.

64. Malkiel, B. G. (2007). *A Random Walk Down Wall Street*. W. W. Norton & Co Ltd.
65. Malkiel, B. G. (2010). Bubbles in Asset Prices. *CEPS Working Paper*, (200).
66. Mark J. Flannery Aris A. Protopapadakis (2002). Macroeconomic Factors Do Influence Aggregate Stock Returns. *The Review of Financial Studies*, Volume 15, Issue 3, 1 April 2002, Pages 751–782.
67. Mathworks (2018). *Machine Learning in MATLAB*. [žiūrėta 2018-04-05]. Prieiga per internetą: <https://se.mathworks.com/help/stats/machine-learning-in-matlab.html>
68. Matplotlib (2018). *Python 2D plotting library*. [žiūrėta 2018-02-03]. Prieiga per internetą: <https://matplotlib.org/>
69. Mukhopadhyay, D. & Sarkar, N. (2003). *Stock return and macroeconomic fundamentals in model- specification framework: Evidence from Indian stock market*. Indian Statistical Institute, Economic Research Unit, ERU 2003-05 Discussion Paper, January 2003, 1-28.
70. Nascimento, Tiago & Boccardo, Davidson & Prado, Charles & Machado, Raphael & Carmo, Luiz. (2012). Program Matching through Code Analysis and Artificial Neural Networks. *International Journal of Software Engineering and Knowledge Engineering*. 22. 225-241.
71. Nicholas Sapankevych, Ravi Sankar. Time series prediction using support vector machines: a survey. *Computational Intelligence Magazine*, IEEE, 4(2):24{38, 2009.
72. Norden, L., & Weber, M. (2004). *The comovement of credit default swap, bond and stock markets: an empirical analysis*.
73. Oxford dictionary (2015). *Machine learning*. [žiūrėta 2018-05-08]. Prieiga per internetą: [https://en.oxforddictionaries.com/definition/machine\\_learning](https://en.oxforddictionaries.com/definition/machine_learning)
74. Pandas (2018). *Python Data Analysis Library*. [žiūrėta 2018-02-03]. Prieiga per internetą: <https://www.python.org/>
75. Park, J., & Ratti, R. A. (2008). Oil price shocks and stock markets in the U.S. and 13 European countries. *Energy Economics*, 30(5), 2587-2608.
76. Perry, G., & Herrera, S. (2001). *Tropical Bubbles*.
77. Python (2018). *Python*. [žiūrėta 2018-02-03]. Prieiga per internetą: <https://www.python.org/>
78. Pudaruth, S. (2014). Predicting the Price of Used Cars using Machine Learning Techniques. *International Journal of Information & Computation Technology*, 4(7), 753–764. Retrieved from <http://www>.
79. Ritchie Ng (2018). *Support Vector Machines (SVMs)*. [žiūrėta 2018-04-27]. Prieiga per internetą: <http://www.ritchieng.com/machine-learning-svms-support-vector-machines/>
80. s, J., & Glabadanidis, P. (2003). Risk Premia and the Dynamic Covariance between Stock and Bond Returns. *Journal of Financial and Quantitative Analysis*, 38(2), 295-316. doi:10.2307/4126752
81. Sadorsky, P. (2008). Assessing the impact of oil prices on firms of different sizes: Its tough being in the middle. *Energy Policy*, 36(10), 3854-3861.
82. Santa-Clara, P., & Valkanov, R. (2003). The Presidential Puzzle: Political Cycles and the Stock Market. *Journal of Finance*, 58(5), 1841–1872.
83. Scikit-learn (2018). *Machine Learning in Python*. [žiūrėta 2018-02-03]. Prieiga per internetą: <http://scikit-learn.org/stable/>
84. Scipy (2018). *Python-based ecosystem of open-source software for mathematics, science, and engineering*. [žiūrėta 2018-02-03]. Prieiga per internetą: <https://www.scipy.org/>
85. Seaborn (2018). *Statistical data visualization*. [žiūrėta 2018-02-03]. Prieiga per internetą: <https://seaborn.pydata.org/>
86. Seutin, A., & Jones, I. (2016). *Using Machine Learning to Predict Housing Prices Given Multivariate Input*, 1–10.
87. Shah, N. (2013). *Statistical Dynamical Models of Multivariate Financial Time Series*.



88. Siegel, Jeremy J (2003). "What Is An Asset Price Bubble? An Operational Definition." *European Financial Management* 9.1 (2003): 11-24.
89. Tetlock, P. E. (2005). *Expert Political Judgment: How Good Is It? How Can We Know? In Thinking: Psychological Perspectives on Reasoning, Judgment and Decision Making*. Princeton University Press (JAV).
90. Tetlock, P., & Gardner, D. (2015). *Superforecasting: The Art and Science of Prediction*. Penguin Random House.
91. The analysis factor (2018). *7 Practical Guidelines for Accurate Statistical Model Building*. [žiūrėta 2018-04-17]. Prieiga per internetą: <https://www.theanalysisfactor.com/7-guidelines-model-building/>
92. The minitab blog (2015). *How to Choose the Best Regression Model*. [žiūrėta 2018-04-22]. Prieiga per internetą: <http://blog.minitab.com/blog/adventures-in-statistics-2/how-to-choose-the-best-regression-model>
93. The World bank. (2018). *GDP per capita growth (annual %)*. [žiūrėta 2018-04-29]. Prieiga per internetą: <https://data.worldbank.org/indicator/NY.GDP.PCAP.KD.ZG?end=2016&start=1961&type=shaded&view=map&year=2009>
94. The World bank. (2018). *Market capitalization of listed domestic companies (current US\$)*. [žiūrėta 2018-05-03]. Prieiga per internetą: <https://data.worldbank.org/indicator/CM.MKT.LCAP.CD>
95. Value Walk (2016). *Global Real Estate Value Hits \$217 Trillion In 2015, 2.7 Times World GDP*. [žiūrėta 2018-02-22]. Prieiga per internetą: <https://www.valuewalk.com/2016/01/global-real-estate-value/>
96. Verner, R. (2017). Bond yields and stock returns comparison using wavelet semblance analysis. *Investment Management and Financial Innovations*.
97. Veronesi, P., & Pastor, L. (2017). Political Cycles and Stock Returns. NBER Working Paper Series.
98. Wahlbeck, K., & Awolin, M. (2009). *The Impact of Economic Crises on the Risk of Depression and Suicide : A Literature Review*.
99. Werner, Richard A. (2003). *Princes of the Yen*. New York: M.E. Sharpe, Inc.
100. Wongbangpo, P., & Sharma, S. C. (2002). Stock market and macroeconomic fundamental dynamic interactions: ASEAN-5 countries. *Journal of Asian Economics*, 13, 27-51.
101. Wu, W., & Xu, J. (2005). Fundamental analysis of stock price by artificial neural networks model based on rough set theory. *World Journal of Modeling and Simulation*, 2(1), 36-44.
102. Zankova, E. (2016). *High frequency financial time series prediction : machine learning approach*. (May), 126.
103. Zhang, X. F. (2010). *The Effect of High-Frequency Trading on Stock Volatility and Price Discovery*, (203), 1-53.

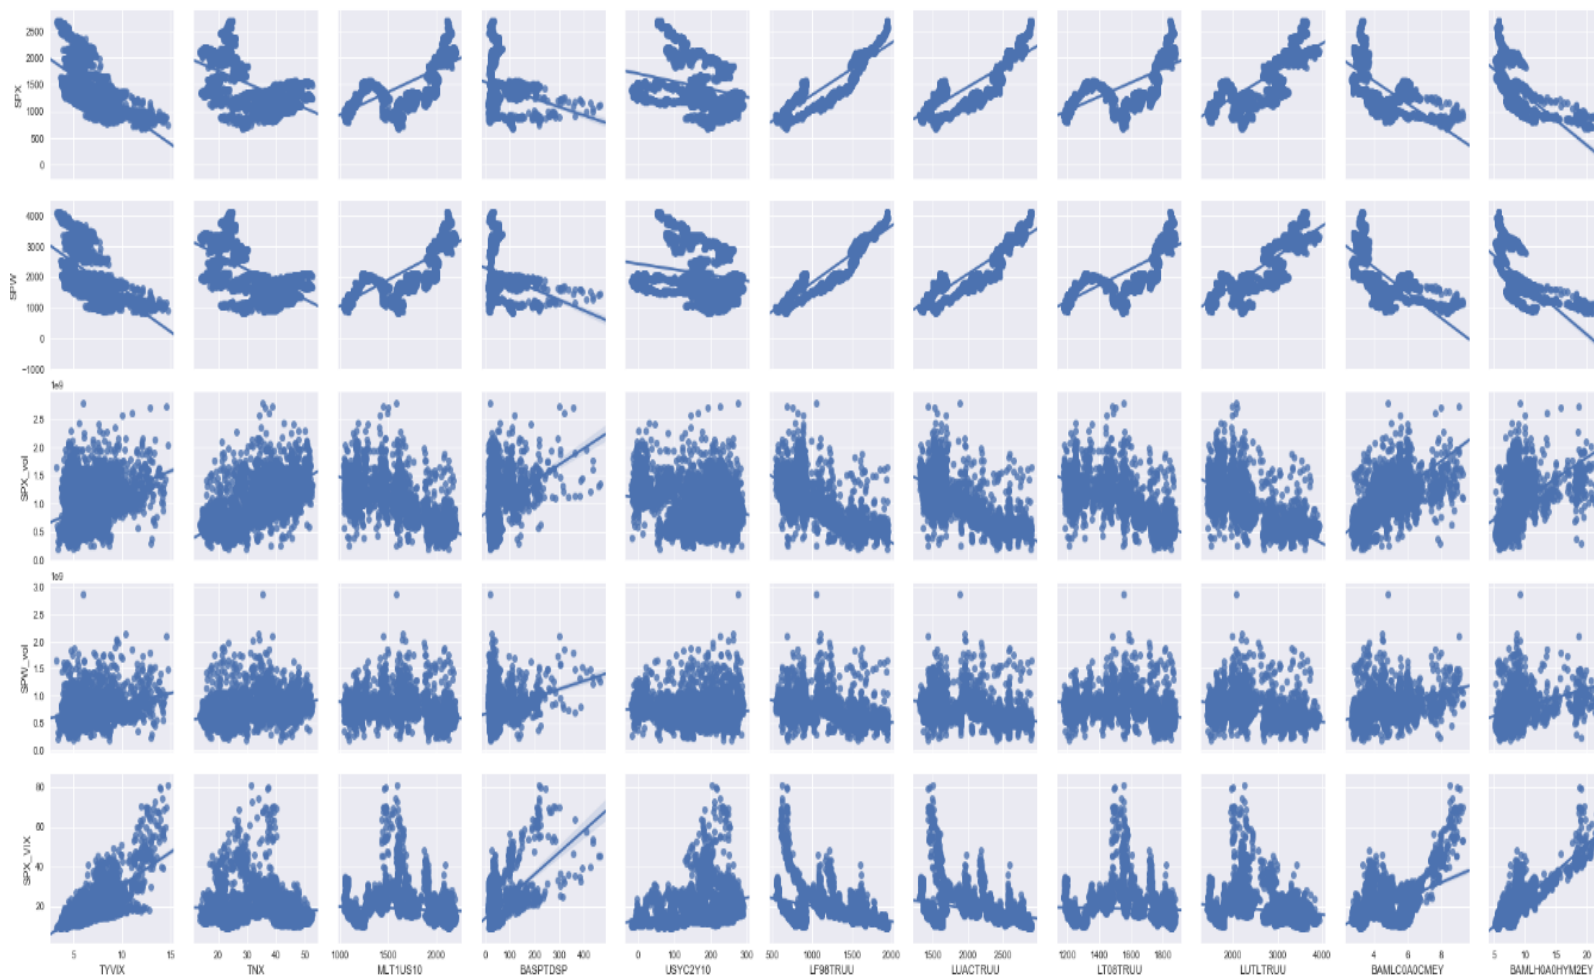
# PRIEDAI

## 1 PRIEDAS. Pagrindinių kredito vertinimo agentūrų ilgalaikio skolinimosi reitingų lentelė.

### Ilgalaikio skolinimosi reitingai

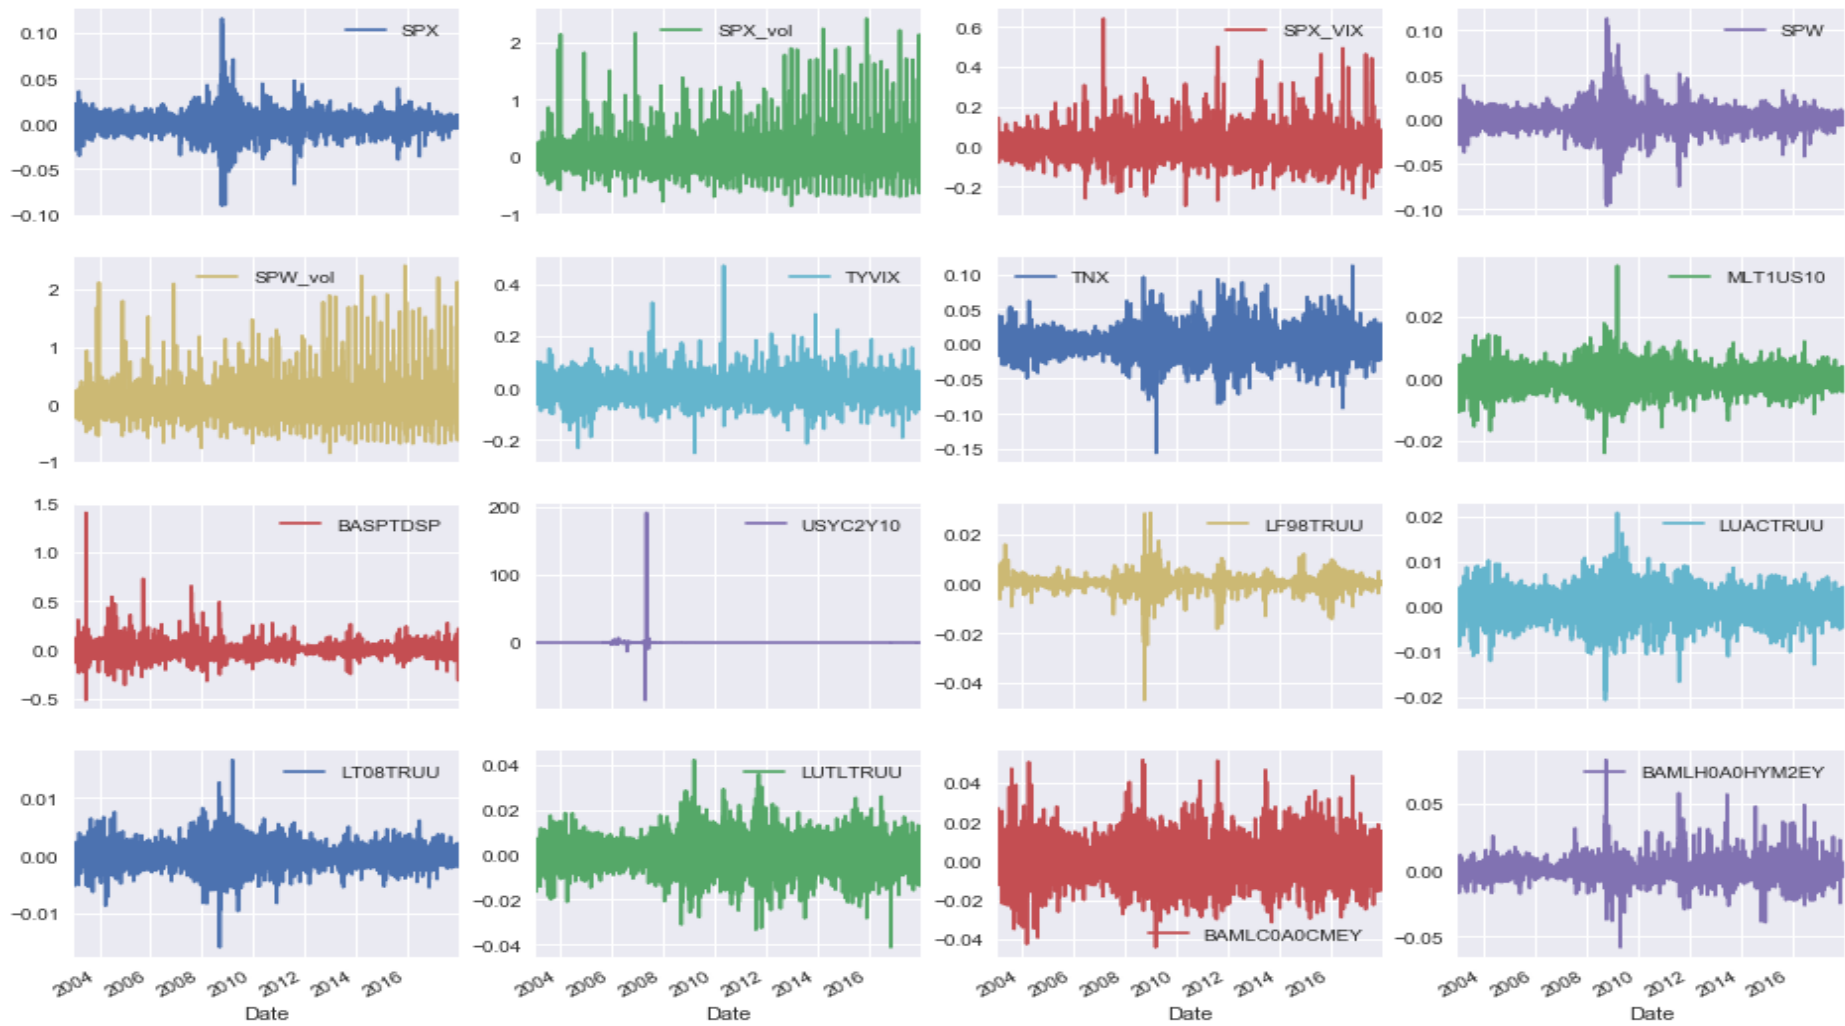
Moody's	S&P	Fitch Ratings	Apibūdinimas
Aaa	AAA	AAA	Aukščiausias saugumo lygis
Aa1	AA+	AA+	Aukštas saugumo lygis
Aa2	AA	AA	Aukštas saugumo lygis
Aa3	AA-	AA-	Aukštas saugumo lygis
A1	A+	A+	Aukštesnis investicinis reitingas
A2	A	A	Aukštesnis investicinis reitingas
A3	A-	A-	Aukštesnis investicinis reitingas
Baa1	BBB+	BBB+	Žemesnis investicinis reitingas
Baa2	BBB	BBB	Žemesnis investicinis reitingas
Baa3	BBB-	BBB-	Žemesnis investicinis reitingas
Ba1	BB+	BB+	Neinvesticinis (spekuliacinis) reitingas
Ba2	BB	BB	Neinvesticinis (spekuliacinis) reitingas
Ba3	BB-	BB-	Neinvesticinis (spekuliacinis) reitingas
B1	B+	B+	Labai spekuliacinis reitingas
B2	B	B	Labai spekuliacinis reitingas
B3	B-	B-	Labai spekuliacinis reitingas
Caa1	CCC+	CCC+	Bloga būklė
Caa2	CCC	CCC	Bloga būklė
Caa3	CCC-	CCC-	Bloga būklė
Ca	CC	CC	Ypač spekuliacinis reitingas
C	C	C	Galimas įsipareigojimų nevykdymas
-	D	D	Įsipareigojimų nevykdymas
WR	-	-	Nutrauktas reitingavimas
NR	NR	-	Nereitinguojamas

## 2 PRIEDAS. Tyrinėjamų priklausomų ir nepriklausomų veiksnių sklaidos diagrama.





### 3 PRIEDAS. Nelogaritmuotų priklausomų ir nepriklausomų veiksnių pokyčių grafikai.



#### 4 PRIEDAS. Pilna logaritmuotų veiksnių pokyčių koreliacinė lentelė.

	SPX	SPX_vol	SPX_VIX	SPW	SPW_vol	TYVIX	TNX	MLT1US10	BASPTDSP	USYC2Y10	LF98TRUU	LUACTRUU	LT08TRUU	LUTLTRUU	BAMLC0A0CMEY	BAMLH0A0HYM2EY
SPX	1	-0.0888373	-0.733257	0.98516	-0.084817	-0.173028	0.366776	-0.072701	-0.00360289	0.0152535	0.157657	-0.00038614	-0.0703617	-0.0764835	0.0288807	-0.178299
SPX_vol	-0.0888373	1	0.128061	-0.0760334	0.983169	0.0229595	-0.0904569	0.0273743	0.0163193	-0.00457618	-0.031379	0.0192127	0.0161859	0.0321236	-0.00943346	0.0499564
SPX_VIX	-0.733257	0.128061	1	-0.714222	0.128657	0.318034	-0.302857	0.0854795	0.00287945	-0.0275214	-0.155894	0.0293579	0.0711811	0.0931226	-0.0426996	0.206317
SPW	0.98516	-0.0760334	-0.714222	1	-0.0732568	-0.164179	0.369111	-0.0732795	-0.0042007	0.0177431	0.168213	0.000148546	-0.0719927	-0.0752031	0.0285226	-0.181129
SPW_vol	-0.084817	0.983169	0.128657	-0.0732568	1	0.0236737	-0.0889045	0.0282587	0.0195074	-0.013761	-0.0334851	0.0208195	0.0184183	0.0324681	-0.0117079	0.0511692
TYVIX	-0.173028	0.0229595	0.318034	-0.164179	0.0236737	1	0.108912	-0.0517638	-0.00480212	0.0144719	-0.0775467	-0.0749944	-0.0495815	-0.0448648	0.0907126	0.145427
TNX	0.366776	-0.0904569	-0.302857	0.369111	-0.0889045	0.108912	1	-0.282973	-0.0189026	0.0826883	0.0492827	-0.266374	-0.273079	-0.337618	0.321187	-0.042076
MLT1US10	-0.072701	0.0273743	0.0854795	-0.0732795	0.0282587	-0.0517638	-0.282973	1	0.162949	-0.0285764	-0.0690916	0.87631	0.837906	0.882615	-0.874705	0.0642349
BASPTDSP	-0.00360289	0.0163193	0.00287945	-0.0042007	0.0195074	-0.00480212	-0.0189026	0.162949	1	0.000650779	-0.0633058	0.111317	0.093622	0.118826	-0.133231	0.0481303
USYC2Y10	0.0152535	-0.00457618	-0.0275214	0.0177431	-0.013761	0.0144719	0.0826883	-0.0285764	0.000650779	1	-0.00880177	-0.0328174	-0.0366977	-0.0379096	0.0364738	0.00560208
LF98TRUU	0.157657	-0.031379	-0.155894	0.168213	-0.0334851	-0.0775467	0.0492827	-0.0690916	-0.0633058	-0.00880177	1	0.186898	-0.106493	-0.11565	-0.174605	-0.851631
LUACTRUU	-0.00038614	0.0192127	0.0293579	0.000148546	0.0208195	-0.0749944	-0.266374	0.87631	0.111317	-0.0328174	0.186898	1	0.728913	0.884069	-0.923388	-0.16175
LT08TRUU	-0.0703617	0.0161859	0.0711811	-0.0719927	0.0184183	-0.0495815	-0.273079	0.837906	0.093622	-0.0366977	-0.106493	0.728913	1	0.751719	-0.738296	0.0882031
LUTLTRUU	-0.0764835	0.0321236	0.0931226	-0.0752031	0.0324681	-0.0448648	-0.337618	0.882615	0.118826	-0.0379096	-0.11565	0.884069	0.751719	1	-0.830195	0.111941
BAMLC0A0CMEY	0.0288807	-0.00943346	-0.0426996	0.0285226	-0.0117079	0.0907126	0.321187	-0.874705	-0.133231	0.0364738	-0.174605	-0.923388	-0.738296	-0.830195	1	0.182213
BAMLH0A0HYM2EY	-0.178299	0.0499564	0.206317	-0.181129	0.0511692	0.145427	-0.042076	0.0642349	0.0481303	0.00560208	-0.851631	-0.16175	0.0882031	0.111941	0.182213	1

## 5 PRIEDAS. Pilna logaritmuotų veiksnių pokyčių su pašalintomis išskirtimis koreliacinė lentelė.

	SPX	SPX_vol	SPX_VIX	SPW	SPW_vol	TYVIX	TNX	MLT1US10	BASPTDSP	USYC2Y10	LF98TRUU	LUACTRUU	LT08TRUU	LUTLTRUU	BAMLC0A0CMEY	BAMLH0A0HYM2EY
SPX	1	-0.089086	-0.734354	0.984464	-0.0899616	-0.155485	0.362037	-0.0921657	-0.00546519	0.0242447	0.147951	-0.0238903	-0.0873888	-0.0886126	0.0401131	-0.168186
SPX_vol	-0.089086	1	0.150034	-0.0771637	0.96748	0.0712329	-0.0846665	0.0132817	-0.00662821	0.0193688	-0.0473163	-0.0102776	-0.00161634	0.0080958	0.0194273	0.0805478
SPX_VIX	-0.734354	0.150034	1	-0.714228	0.151753	0.305934	-0.287621	0.0873207	0.00337641	-0.0204523	-0.149582	0.0379858	0.0695712	0.0908107	-0.0429037	0.201154
SPW	0.984464	-0.0771637	-0.714228	1	-0.0796531	-0.147321	0.363981	-0.0913252	-0.0047922	0.0292656	0.15907	-0.021767	-0.0878214	-0.0861271	0.0385178	-0.172077
SPW_vol	-0.0899616	0.96748	0.151753	-0.0796531	1	0.0726813	-0.0838685	0.0115992	-0.00212337	0.00905165	-0.0521962	-0.0111268	-0.00154091	0.00733333	0.017496	0.0834962
TYVIX	-0.155485	0.0712329	0.305934	-0.147321	0.0726813	1	0.1182	-0.0472921	-0.00602765	0.0564298	-0.073851	-0.0646424	-0.0459543	-0.0391154	0.0844293	0.14132
TNX	0.362037	-0.0846665	-0.287621	0.363981	-0.0838685	0.1182	1	-0.271991	-0.0282217	0.185457	0.0440359	-0.259798	-0.265255	-0.323105	0.314322	-0.0339204
MLT1US10	-0.0921657	0.0132817	0.0873207	-0.0913252	0.0115992	-0.0472921	-0.271991	1	0.181253	-0.0332199	-0.0704403	0.876649	0.837373	0.885771	-0.876181	0.0635199
BASPTDSP	-0.00546519	-0.00662821	0.00337641	-0.0047922	-0.00212337	-0.00602765	-0.0282217	0.181253	1	-0.00980125	-0.0619124	0.124621	0.109897	0.132051	-0.14986	0.045235
USYC2Y10	0.0242447	0.0193688	-0.0204523	0.0292656	0.00905165	0.0564298	0.185457	-0.0332199	-0.00980125	1	0.00435622	-0.0395935	-0.0571504	-0.0600066	0.0421154	-0.00280279
LF98TRUU	0.147951	-0.0473163	-0.149582	0.15907	-0.0521962	-0.073851	0.0440359	-0.0704403	-0.0619124	0.00435622	1	0.180421	-0.113539	-0.11581	-0.173391	-0.852001
LUACTRUU	-0.0238903	-0.0102776	0.0379858	-0.021767	-0.0111268	-0.0646424	-0.259798	0.876649	0.124621	-0.0395935	0.180421	1	0.728089	0.886811	-0.927381	-0.156492
LT08TRUU	-0.0873888	-0.00161634	0.0695712	-0.0878214	-0.00154091	-0.0459543	-0.265255	0.837373	0.109897	-0.0571504	-0.113539	0.728089	1	0.755785	-0.739097	0.0912959
LUTLTRUU	-0.0886126	0.0080958	0.0908107	-0.0861271	0.00733333	-0.0391154	-0.323105	0.885771	0.132051	-0.0600066	-0.11581	0.886811	0.755785	1	-0.834549	0.111267
BAMLC0A0CMEY	0.0401131	0.0194273	-0.0429037	0.0385178	0.017496	0.0844293	0.314322	-0.876181	-0.14986	0.0421154	-0.173391	-0.927381	-0.739097	-0.834549	1	0.183369
BAMLH0A0HYM2EY	-0.168186	0.0805478	0.201154	-0.172077	0.0834962	0.14132	-0.0339204	0.0635199	0.045235	-0.00280279	-0.852001	-0.156492	0.0912959	0.111267	0.183369	1

## 6 PRIEDAS. Pilna logaritmuotų veiksnių pokyčių su 1 dienos lagu nepriklausomiems veiksniams koreliacinė lentelė.

	SPX	SPX_vol	SPX_VIX	SPW	SPW_vol	TYVIX	TNX	MLT1US10	BASPTDSP	USYC2Y10	LF98TRUU	LUACTRUU	LT08TRUU	LUTLTRUU	BAMLC0A0CMEY	BAMLH0A0HYM2EY
SPX	1	-0.088846	-0.733281	0.985161	-0.0848249	0.00793018	-0.0338224	-0.000787377	-0.0208922	0.00838921	0.0994496	0.0129774	-0.0141861	-0.00379708	-0.0200747	-0.0883182
SPX_vol	-0.088846	1	0.128024	-0.0760509	0.983169	0.0235906	-0.00361814	-0.00257684	-0.00720512	0.00473171	0.0123879	-0.0155899	0.0127943	-0.0235514	0.0006858	-0.0326545
SPX_VIX	-0.733281	0.128024	1	-0.714256	0.128623	-0.00949679	0.0327106	-0.0080341	0.0109474	-0.0119186	-0.0586815	-0.0160814	0.00926398	-0.000865764	0.0143019	0.0486817
SPW	0.985161	-0.0760509	-0.714256	1	-0.0732728	0.00719184	-0.0313133	-0.00801048	-0.0221958	0.00976907	0.105674	0.0128629	-0.0207494	-0.00811149	-0.0204904	-0.0962925
SPW_vol	-0.0848249	0.983169	0.128623	-0.0732728	1	0.0242342	-0.00364354	-0.0088284	-0.00667409	0.00211994	0.0166205	-0.018803	0.00308935	-0.027511	0.00343568	-0.035312
TYVIX	0.00793018	0.0235906	-0.00949679	0.00719184	0.0242342	1	0.108945	-0.0517858	-0.00478388	0.0144724	-0.0775488	-0.0750163	-0.0496075	-0.0448837	0.0907286	0.145426
TNX	-0.0338224	-0.00361814	0.0327106	-0.0313133	-0.00364354	0.108945	1	-0.282933	-0.0189545	0.0826905	0.0492894	-0.266334	-0.27303	-0.337587	0.321163	-0.0420743
MLT1US10	-0.000787377	-0.00257684	-0.0080341	-0.00801048	-0.0088284	-0.0517858	-0.282933	1	0.162992	-0.0285763	-0.0690965	0.876305	0.837899	0.882611	-0.874703	0.0642338
BASPTDSP	-0.0208922	-0.00720512	0.0109474	-0.0221958	-0.00667409	-0.00478388	-0.0189545	0.162992	1	0.000650126	-0.0633038	0.111357	0.0936696	0.118862	-0.133261	0.0481333
USYC2Y10	0.00838921	0.00473171	-0.0119186	0.00976907	0.00211994	0.0144724	0.0826905	-0.0285763	0.000650126	1	-0.00880171	-0.0328173	-0.0366979	-0.0379096	0.0364736	0.00560212
LF98TRUU	0.0994496	0.0123879	-0.0586815	0.105674	0.0166205	-0.0775488	0.0492894	-0.0690965	-0.0633038	-0.00880171	1	0.186898	-0.1065	-0.115654	-0.174605	-0.851631
LUACTRUU	0.0129774	-0.0155899	-0.0160814	0.0128629	-0.018803	-0.0750163	-0.266334	0.876305	0.111357	-0.0328173	0.186898	1	0.728901	0.884065	-0.923387	-0.161755
LT08TRUU	-0.0141861	0.0127943	0.00926398	-0.0207494	0.00308935	-0.0496075	-0.27303	0.837899	0.0936696	-0.0366979	-0.1065	0.728901	1	0.75171	-0.73829	0.0882028
LUTLTRUU	-0.00379708	-0.0235514	-0.000865764	-0.00811149	-0.027511	-0.0448837	-0.337587	0.882611	0.118862	-0.0379096	-0.115654	0.884065	0.75171	1	-0.830191	0.11194
BAMLC0A0CMEY	-0.0200747	0.0006858	0.0143019	-0.0204904	0.00343568	0.0907286	0.321163	-0.874703	-0.133261	0.0364736	-0.174605	-0.923387	-0.73829	-0.830191	1	0.182217
BAMLH0A0HYM2EY	-0.0883182	-0.0326545	0.0486817	-0.0962925	-0.035312	0.145426	-0.0420743	0.0642338	0.0481333	0.00560212	-0.851631	-0.161755	0.0882028	0.11194	0.182217	1

## 7 PRIEDAS. Pilna logaritmuotų veiksnių pokyčių su 3 dienų lagu nepriklausomiems veiksniams koreliacinė lentelė.

	SPX	SPX_vol	SPX_VIX	SPW	SPW_vol	TYVIX	TNX	MLT1US10	BASPTDSP	USYC2Y10	LF98TRUU	LUACTRUU	LT08TRUU	LUTLTRUU	BAMLC0A0CMEY	BAMLH0A0HYM2EY
SPX	1	-0.0893047	-0.73372	0.985154	-0.085331	0.00702282	-0.00749331	-0.0884963	-0.00440568	-0.00261871	0.148076	-0.0447872	-0.0831233	-0.120098	0.0304291	-0.130131
SPX_vol	-0.0893047	1	0.12799	-0.0764757	0.98321	0.00554098	0.0157393	0.00586903	-0.0403046	0.00247216	-0.0377241	0.00679191	0.0192767	0.00993644	-0.0035172	0.0324794
SPX_VIX	-0.73372	0.12799	1	-0.714612	0.128604	-0.00982384	0.0372749	0.0833898	0.0335444	0.00491599	-0.0956185	0.0509536	0.0855285	0.0970814	-0.0412639	0.0939143
SPW	0.985154	-0.0764757	-0.714612	1	-0.0737253	0.0149572	-0.00518093	-0.0871566	-0.00583657	-0.00271672	0.161376	-0.0397398	-0.0821466	-0.122418	0.0269857	-0.137744
SPW_vol	-0.085331	0.98321	0.128604	-0.0737253	1	0.00252479	0.0151101	0.00321422	-0.042363	0.00173568	-0.0357792	0.000668555	0.0141051	0.0053183	0.000600006	0.0300319
TYVIX	0.00702282	0.00554098	-0.00982384	0.0149572	0.00252479	1	0.108698	-0.0515955	-0.00488064	0.0143551	-0.0775543	-0.0747318	-0.0494244	-0.0445355	0.0904676	0.145341
TNX	-0.00749331	0.0157393	0.0372749	-0.00518093	0.0151101	0.108698	1	-0.282765	-0.0189362	0.082555	0.0493058	-0.268053	-0.272868	-0.337292	0.320821	-0.0422373
MLT1US10	-0.0884963	0.00586903	0.0833898	-0.0871566	0.00321422	-0.0515955	-0.282765	1	0.163233	-0.0284745	-0.0691067	0.876306	0.837872	0.882652	-0.874693	0.0643436
BASPTDSP	-0.00440568	-0.0403046	0.0335444	-0.00583657	-0.042363	-0.00488064	-0.0189362	0.163233	1	0.000778643	-0.0634356	0.111335	0.0938377	0.118767	-0.133325	0.0485142
USYC2Y10	-0.00261871	0.00247216	0.00491599	-0.00271672	0.00173568	0.0143551	0.082555	-0.0284745	0.000778643	1	-0.00879594	-0.0326463	-0.0366023	-0.0377055	0.0363181	0.00551995
LF98TRUU	0.148076	-0.0377241	-0.0956185	0.161376	-0.0357792	-0.0775543	0.0493058	-0.0691067	-0.0634356	-0.00879594	1	0.186928	-0.106512	-0.115708	-0.174628	-0.851667
LUACTRUU	-0.0447872	0.00679191	0.0509536	-0.0397398	0.000668555	-0.0747318	-0.268053	0.876306	0.111335	-0.0326463	0.186928	1	0.728864	0.884012	-0.923357	-0.161609
LT08TRUU	-0.0831233	0.0192767	0.0855285	-0.0821466	0.0141051	-0.0494244	-0.272868	0.837872	0.0938377	-0.0366023	-0.106512	0.728864	1	0.751707	-0.738249	0.0883086
LUTLTRUU	-0.120098	0.00993644	0.0970814	-0.122418	0.0053183	-0.0445355	-0.337292	0.882652	0.118767	-0.0377055	-0.115708	0.884012	0.751707	1	-0.830124	0.112219
BAMLC0A0CMEY	0.0304291	-0.0035172	-0.0412639	0.0269857	0.000600006	0.0904676	0.320821	-0.874693	-0.133325	0.0363181	-0.174628	-0.923357	-0.738249	-0.830124	1	0.18209
BAMLH0A0HYM2EY	-0.130131	0.0324794	0.0939143	-0.137744	0.0300319	0.145341	-0.0422373	0.0643436	0.0485142	0.00551995	-0.851667	-0.161609	0.0883086	0.112219	0.18209	1



## 8 PRIEDAS. Pilna logaritmuotų veiksnių pokyčių su 5 dienų lagu nepriklausomiems veiksniams koreliacinė lentelė.

	SPX	SPX_vol	SPX_VIX	SPW	SPW_vol	TYVIX	TNX	MLT1US10	BASPTDSP	USYC2Y10	LF98TRUU	LUACTRUU	LT08TRUU	LUTLTRUU	BAMLC0A0CMEY	BAMLH0A0HYM2EY
SPX	1	-0.0896423	-0.733791	0.985147	-0.0854145	0.0652597	-0.0393887	-0.0203893	-0.0124759	-0.0242234	0.213922	0.0262028	-0.0305051	-0.0292983	-0.0273933	-0.127893
SPX_vol	-0.0896423	1	0.128088	-0.0767587	0.98324	-0.0478681	0.0139818	-0.0175016	-0.0164356	0.000742194	0.013859	-0.00257899	-0.019893	-0.000467148	-0.00558468	-0.0210376
SPX_VIX	-0.733791	0.128088	1	-0.714626	0.128619	-0.0345982	0.0233259	0.01582	0.0131072	0.0294358	-0.0689294	0.00262716	0.00994849	0.0153638	-0.00387167	0.0327731
SPW	0.985147	-0.0767587	-0.714626	1	-0.0737868	0.0599021	-0.0404274	-0.0280289	-0.0142174	-0.0251426	0.229286	0.0258752	-0.0383479	-0.0322252	-0.0251017	-0.136649
SPW_vol	-0.0854145	0.98324	0.128619	-0.0737868	1	-0.0514606	0.0153991	-0.0096985	-0.0108335	0.0061938	0.0084059	0.00481531	-0.00920352	0.00629478	-0.0076905	-0.0196294
TYVIX	0.0652597	-0.0478681	-0.0345982	0.0599021	-0.0514606	1	0.108659	-0.0515465	-0.00558358	0.0143591	-0.0775352	-0.0746597	-0.0493713	-0.0444477	0.0903777	0.145349
TNX	-0.0393887	0.0139818	0.0233259	-0.0404274	0.0153991	0.108659	1	-0.28274	-0.0195518	0.0825466	0.0493194	-0.266013	-0.272848	-0.337252	0.320884	-0.0422364
MLT1US10	-0.0203893	-0.0175016	0.01582	-0.0280289	-0.0096985	-0.0515465	-0.28274	1	0.164423	-0.0284674	-0.0691211	0.876305	0.837869	0.882659	-0.874694	0.0643435
BASPTDSP	-0.0124759	-0.0164356	0.0131072	-0.0142174	-0.0108335	-0.00558358	-0.0195518	0.164423	1	0.000614331	-0.0635105	0.112657	0.0946502	0.120311	-0.134784	0.0487421
USYC2Y10	-0.0242234	0.000742194	0.0294358	-0.0251426	0.0061938	0.0143591	0.0825466	-0.0284674	0.000614331	1	-0.00879447	-0.0326329	-0.0366001	-0.0376688	0.0363086	0.00552146
LF98TRUU	0.213922	0.013859	-0.0689294	0.229286	0.0084059	-0.0775352	0.0493194	-0.0691211	-0.0635105	-0.00879447	1	0.186916	-0.108526	-0.115741	-0.174614	-0.851689
LUACTRUU	0.0262028	-0.00257899	0.00262716	0.0258752	0.00481531	-0.0746597	-0.266013	0.876305	0.112657	-0.0326329	0.186916	1	0.72886	0.884001	-0.923352	-0.161619
LT08TRUU	-0.0305051	-0.019893	0.00994849	-0.0383479	-0.00920352	-0.0493713	-0.272848	0.837869	0.0946502	-0.0366001	-0.108526	0.72886	1	0.751712	-0.738245	0.0883098
LUTLTRUU	-0.0292983	-0.000467148	0.0153638	-0.0322252	0.00629478	-0.0444477	-0.337252	0.882659	0.120311	-0.0376688	-0.115741	0.884001	0.751712	1	-0.830108	0.112223
BAMLC0A0CMEY	-0.0273933	-0.00558468	-0.00387167	-0.0251017	-0.0076905	0.0903777	0.320884	-0.874694	-0.134784	0.0363086	-0.174614	-0.923352	-0.738245	-0.830108	1	0.182102
BAMLH0A0HYM2EY	-0.127893	-0.0210376	0.0327731	-0.136649	-0.0196294	0.145349	-0.0422364	0.0643435	0.0487421	0.00552146	-0.851689	-0.161619	0.0883098	0.112223	0.182102	1

## 9 PRIEDAS. Pilna logaritmuotų veiksnių pokyčių su 10 dienų lagu nepriklausomiems veiksniams koreliacinė lentelė.

	SPX	SPX_vol	SPX_VIX	SPW	SPW_vol	TYVIX	TNX	MLT1US10	BASPTDSP	USYC2Y10	LF98TRUU	LUACTRUU	LT08TRUU	LUTLTRUU	BAMLC0A0CMEY	BAMLH0A0HYM2EY
SPX	1	-0.0895432	-0.733844	0.985166	-0.085314	-0.0566961	0.00393549	-0.00391128	0.00799324	-0.0113299	0.0315955	0.00841469	-0.00351063	-0.00119784	-0.00454536	-0.0239667
SPX_vol	-0.0895432	1	0.128094	-0.076703	0.983258	-0.0170242	-0.0153851	-0.0122819	-0.0231478	0.000963857	0.00818915	-0.013572	0.00291557	-0.0127172	0.0160022	-0.00318699
SPX_VIX	-0.733844	0.128094	1	-0.714623	0.128588	0.0733483	-0.0129881	0.0109447	-0.00884097	0.00723536	-0.00617762	-0.000719637	0.0126343	0.0092307	6.11554e-05	0.0029967
SPW	0.985166	-0.076703	-0.714623	1	-0.0737156	-0.0609639	0.00150777	-0.00766292	0.00467149	-0.0116773	0.0391682	0.00743655	-0.00560944	-0.00253613	-0.0056473	-0.028594
SPW_vol	-0.085314	0.983258	0.128588	-0.0737156	1	-0.0146871	-0.00984685	-0.00552309	-0.0240288	-0.00206466	0.0159251	-0.00101851	0.00814968	-0.00687755	0.00908641	-0.00731569
TYVIX	-0.0566961	-0.0170242	0.0733483	-0.0609639	-0.0146871	1	0.108337	-0.0513653	-0.00557036	0.0140608	-0.0775895	-0.0741178	-0.0493351	-0.04351	0.0899472	0.145515
TNX	0.00393549	-0.0153851	-0.0129881	0.00150777	-0.00984685	0.108337	1	-0.282264	-0.0193094	0.0822845	0.0494791	-0.265327	-0.272466	-0.338461	0.320281	-0.0425208
MLT1US10	-0.00391128	-0.0122819	0.0109447	-0.00766292	-0.00552309	-0.0513653	-0.282264	1	0.164463	-0.0282754	-0.0692587	0.876313	0.837803	0.882898	-0.874672	0.0645689
BASPTDSP	0.00799324	-0.0231478	-0.00884097	0.00467149	-0.0240288	-0.00557036	-0.0193094	0.164463	1	0.000816778	-0.0635709	0.112338	0.0947037	0.119846	-0.134535	0.0489425
USYC2Y10	-0.0113299	0.000963857	0.00723536	-0.0116773	-0.00206466	0.0140608	0.0822845	-0.0282754	0.000816778	1	-0.00876309	-0.0322884	-0.0364693	-0.0372008	0.036003	0.00543804
LF98TRUU	0.0315955	0.00818915	-0.00617762	0.0391682	0.0159251	-0.0775895	0.0494791	-0.0692587	-0.0635709	-0.00876309	1	0.186884	-0.106658	-0.116042	-0.174561	-0.851893
LUACTRUU	0.00841469	-0.013572	-0.000719637	0.00743655	-0.00101851	-0.0741178	-0.265327	0.876313	0.112338	-0.0322884	0.186884	1	0.72885	0.883917	-0.923285	-0.161456
LT08TRUU	-0.00351063	0.00291557	0.0126343	-0.00560944	0.00814968	-0.0493351	-0.272466	0.837803	0.0947037	-0.0364693	-0.106658	0.72885	1	0.751947	-0.738203	0.0885126
LUTLTRUU	-0.00119784	-0.0127172	0.0092307	-0.00253613	-0.00687755	-0.04351	-0.338461	0.882898	0.119846	-0.0372008	-0.116042	0.883917	0.751947	1	-0.829993	0.112701
BAMLC0A0CMEY	-0.00454536	0.0160022	6.11554e-05	-0.0056473	0.00908641	0.0899472	0.320281	-0.874672	-0.134535	0.036003	-0.174561	-0.923285	-0.738203	-0.829993	1	0.181956
BAMLH0A0HYM2EY	-0.0239667	-0.00318699	0.0029967	-0.028594	-0.00731569	0.145515	-0.0425208	0.0645689	0.0489425	0.00543804	-0.851893	-0.161456	0.0885126	0.112701	0.181956	1

**10 PRIEDAS. Pilna logaritmuotų veiksnių pokyčių su 20 dienų lagu nepriklausomiems veiksniams koreliacinė lentelė.**

	SPX	SPX_vol	SPX_VIX	SPW	SPW_vol	TYVIX	TNX	MLT1US10	BASPTDSP	USYC2Y10	LF98TRUU	LUACTRUU	LT08TRUU	LUTLTRUU	BAMLC0A0CMEY	BAMLH0A0HYM2EY
SPX	1	-0.0905412	-0.733617	0.98514	-0.0861328	-0.0141031	-0.0169486	-0.00493855	0.0173043	-0.00614308	-0.00304807	-0.0152617	-0.000572715	-0.00247749	0.00323577	0.00673133
SPX_vol	-0.0905412	1	0.128726	-0.0775768	0.983294	0.0158998	-0.0248902	0.0274123	0.00270738	-0.00981448	-0.0119753	0.0284598	0.0195308	0.0236008	-0.0267703	0.0115532
SPX_VIX	-0.733617	0.128726	1	-0.714151	0.129004	0.0181493	0.0249007	0.00525212	-0.00805981	-0.00521267	-0.0108202	0.0094011	-0.0038214	-0.00202545	0.00535176	0.0068673
SPW	0.98514	-0.0775768	-0.714151	1	-0.0743883	-0.0156958	-0.0191705	0.00300352	0.0133823	-0.00627248	-0.0039167	-0.00547831	0.00902705	0.00592581	-0.00488882	0.00923753
SPW_vol	-0.0861328	0.983294	0.129004	-0.0743883	1	0.012992	-0.0212501	0.0219345	-0.00101937	-0.00308448	-0.00866759	0.0251126	0.0156352	0.0203873	-0.0251343	0.00858396
TYVIX	-0.0141031	0.0158998	0.0181493	-0.0156958	0.012992	1	0.108069	-0.0509916	-0.00409904	0.0141795	-0.0778108	-0.0738594	-0.0488887	-0.0433546	0.0894109	0.146042
TNX	-0.0169486	-0.0248902	0.0249007	-0.0191705	-0.0212501	0.108069	1	-0.281654	-0.0187747	0.0821147	0.0494083	-0.264501	-0.271926	-0.335565	0.319437	-0.0425455
MLT1US10	-0.00493855	0.0274123	0.00525212	0.00300352	0.0219345	-0.0509916	-0.281654	1	0.16416	-0.0281645	-0.0692042	0.876306	0.837714	0.883064	-0.874634	0.0645531
BASPTDSP	0.0173043	0.00270738	-0.00805981	0.0133823	-0.00101937	-0.00409904	-0.0187747	0.16416	1	0.000729047	-0.0633014	0.11205	0.0941737	0.11967	-0.133878	0.0484889
USYC2Y10	-0.00614308	-0.00981448	-0.00521267	-0.00627248	-0.00308448	0.0141795	0.0821147	-0.0281645	0.000729047	1	-0.00876297	-0.0320452	-0.0364245	-0.0368688	0.0358317	0.00534375
LF98TRUU	-0.00304807	-0.0119753	-0.0108202	-0.0039167	-0.00866759	-0.0778108	0.0494083	-0.0692042	-0.0633014	-0.00876297	1	0.187082	-0.1066	-0.116069	-0.174846	-0.851734
LUACTRUU	-0.0152617	0.0284598	0.0094011	-0.00547831	0.0251126	-0.0738594	-0.264501	0.876306	0.11205	-0.0320452	0.187082	1	0.728807	0.883805	-0.923264	-0.161492
LT08TRUU	-0.000572715	0.0195308	-0.0038214	0.00902705	0.0156352	-0.0488887	-0.271926	0.837714	0.0941737	-0.0364245	-0.1066	0.728807	1	0.752099	-0.738063	0.0884359
LUTLTRUU	-0.00247749	0.0236008	-0.00202545	0.00592581	0.0203873	-0.0433546	-0.335565	0.883064	0.11967	-0.0368688	-0.116069	0.883805	0.752099	1	-0.829893	0.112972
BAMLC0A0CMEY	0.00323577	-0.0267703	0.00535176	-0.00488882	-0.0251343	0.0894109	0.319437	-0.874634	-0.133878	0.0358317	-0.174846	-0.923264	-0.738063	-0.829893	1	0.182214
BAMLH0A0HYM2EY	0.00673133	0.0115532	0.0068673	0.00923753	0.00858396	0.146042	-0.0425455	0.0645531	0.0484889	0.00534375	-0.851734	-0.161492	0.0884359	0.112972	0.182214	1



**11 PRIEDAS. Pilna logaritmuotų, nesuvidurkintų priklausomų ir suvidurkintų nepriklausomų veiksnių pokyčių koreliacinė lentelė.**

	SPX	SPX_vol	SPX_VIX	SPW	SPW_vol	TYVIX	TNX	MLT1US10	BASPTDSP	USYC2Y10	LF98TRUU	LUACTRUU	LT08TRUU	LUTLTRUU	BAMLC0A0CMEY	BAMLH0A0HYM2EY
SPX	1	-0.0903944	-0.733516	0.985125	-0.0859427	-0.0566898	0.0512914	-0.0270017	-0.0403284	0.00583167	0.110691	0.0418579	-0.0410546	-0.0428564	-0.026078	-0.109983
SPX_vol	-0.0903944	1	0.128714	-0.0774829	0.983292	-0.00791846	-0.0115133	0.00883678	-0.00360986	0.00528082	0.000714489	0.00571165	0.00796356	0.00494951	-0.00629436	8.09706e-05
SPX_VIX	-0.733516	0.128714	1	-0.714112	0.128988	0.0549079	-0.0324992	0.0239639	0.0329065	-0.00913617	-0.0495543	-0.0130515	0.030501	0.0328688	0.00200598	0.0518912
SPW	0.985125	-0.0774829	-0.714112	1	-0.074265	-0.057769	0.0473189	-0.0269671	-0.047083	0.0041314	0.128586	0.053224	-0.042732	-0.0424343	-0.0350184	-0.122724
SPW_vol	-0.0859427	0.983292	0.128988	-0.074265	1	-0.00846142	-0.0121621	0.00805127	-0.00139385	0.00145074	0.000303046	0.00358133	0.00895551	0.00389948	-0.00435358	0.000220713
TYVIX	-0.0566898	-0.00791846	0.0549079	-0.057769	-0.00846142	1	0.154846	-0.148921	0.140024	0.0939238	-0.322226	-0.327455	-0.0912968	-0.135771	0.340453	0.379915
TNX	0.0512914	-0.0115133	-0.0324992	0.0473189	-0.0121621	0.154846	1	-0.777731	-0.0790415	0.135658	0.0825983	-0.480223	-0.755511	-0.832583	0.484526	-0.0765897
MLT1US10	-0.0270017	0.00883678	0.0239639	-0.0269671	0.00805127	-0.148921	-0.777731	1	0.0941787	-0.111681	-0.124498	0.599487	0.963051	0.887087	-0.611484	0.0827856
BASPTDSP	-0.0403284	-0.00360986	0.0329065	-0.047083	-0.00139385	0.140024	-0.0790415	0.0941787	1	0.00817514	-0.229856	-0.225872	0.130037	0.100254	0.193467	0.234063
USYC2Y10	0.00583167	0.00528082	-0.00913617	0.0041314	0.00145074	0.0939238	0.135658	-0.111681	0.00817514	1	-0.022171	-0.114349	-0.0934054	-0.145754	0.0982914	0.0262774
LF98TRUU	0.110691	0.000714489	-0.0495543	0.128586	0.000303046	-0.322226	0.0825983	-0.124498	-0.229856	-0.022171	1	0.577065	-0.190638	-0.172164	-0.539014	-0.932258
LUACTRUU	0.0418579	0.00571165	-0.0130515	0.053224	0.00358133	-0.327455	-0.480223	0.599487	-0.225872	-0.114349	0.577065	1	0.510263	0.570733	-0.937892	-0.573902
LT08TRUU	-0.0410546	0.00796356	0.030501	-0.042732	0.00895551	-0.0912968	-0.755511	0.963051	0.130037	-0.0934054	-0.190638	0.510263	1	0.834569	-0.559743	0.144001
LUTLTRUU	-0.0428564	0.00494951	0.0328688	-0.0424343	0.00389948	-0.135771	-0.832583	0.887087	0.100254	-0.145754	-0.172164	0.570733	0.834569	1	-0.531005	0.150898
BAMLC0A0CMEY	-0.026078	-0.00629436	0.00200598	-0.0350184	-0.00435358	0.340453	0.484526	-0.611484	0.193467	0.0982914	-0.539014	-0.937892	-0.559743	-0.531005	1	0.581708
BAMLH0A0HYM2EY	-0.109983	8.09706e-05	0.0518912	-0.122724	0.000220713	0.379915	-0.0765897	0.0827856	0.234063	0.0262774	-0.932258	-0.573902	0.144001	0.150898	0.581708	1

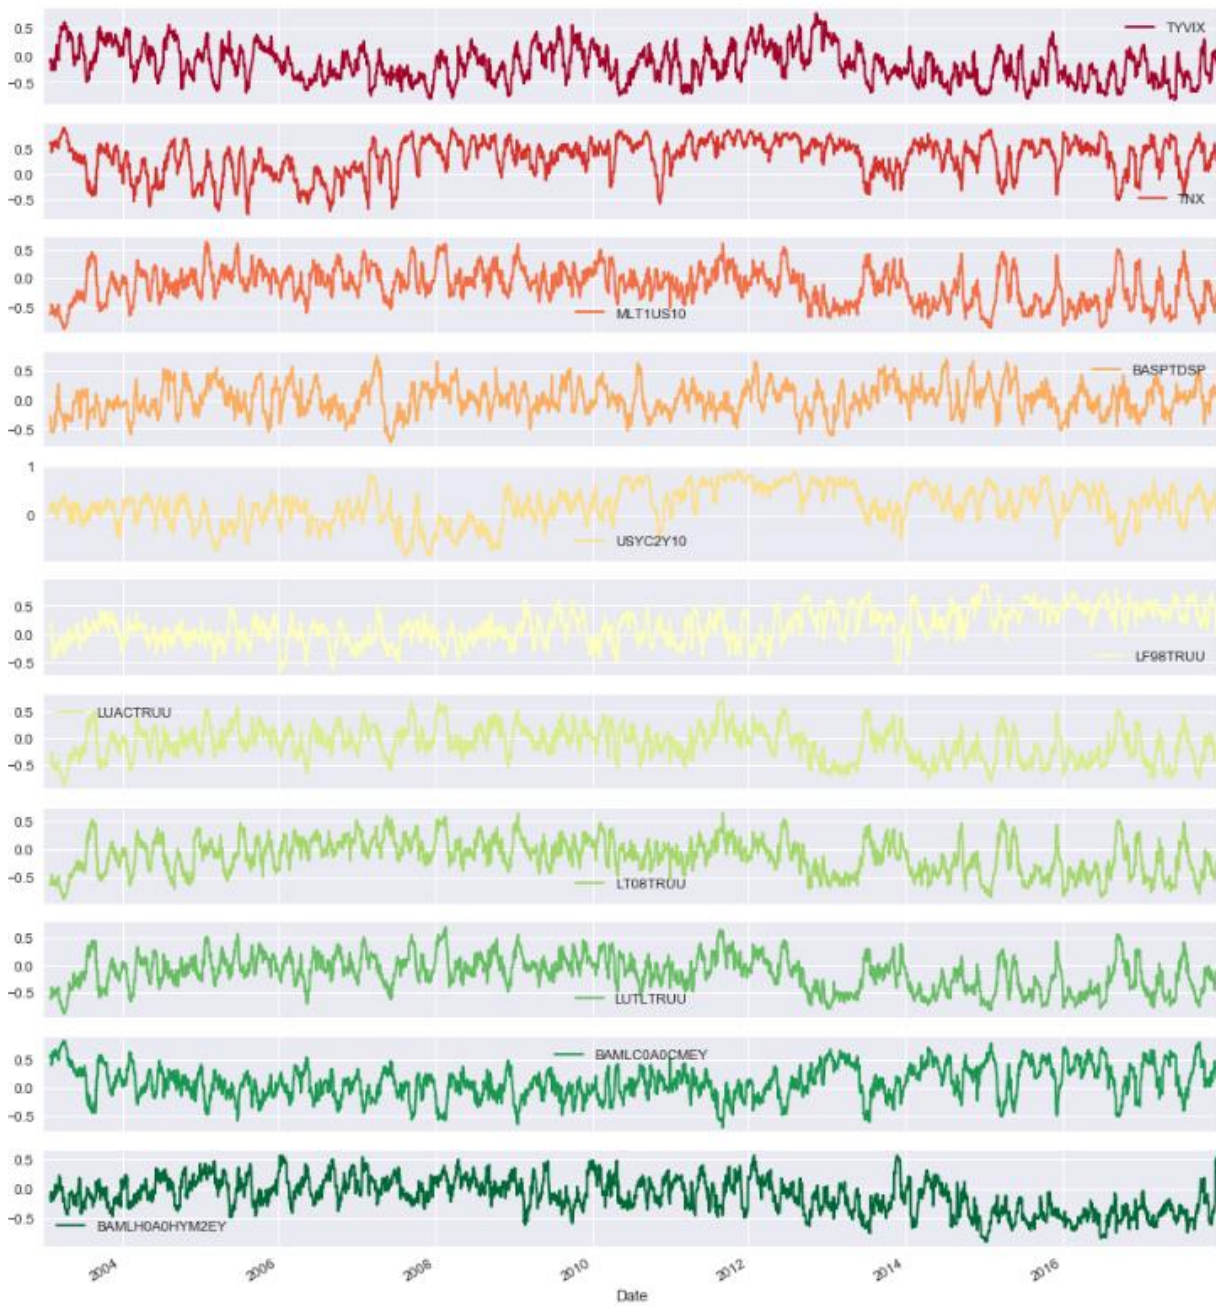
**12 PRIEDAS. Pilna logaritmuotų, suvidurkintų priklausomų ir nesuvidurkintų nepriklausomų veiksnių pokyčių koreliacinė lentelė.**

	SPX	SPX_vol	SPX_VIX	SPW	SPW_vol	TYVIX	TNX	MLT1U\$10	BASPTDSP	USYC2Y10	LF98TRUU	LUACTRUU	LT08TRUU	LUTLTRUU	BAMLC0A0CMEY	BAMLH0A0HYM2EY
SPX	1	-0.229302	-0.729054	0.978889	-0.227357	-0.0529565	0.0910512	-0.0399442	0.0029261	-0.00298509	0.179335	0.0658983	-0.0425505	-0.0178942	-0.0650119	-0.151046
SPX_vol	-0.229302	1	0.326997	-0.209235	0.975048	0.0251985	-0.0380668	0.0289191	0.0118169	-0.00671332	-0.104114	-0.010235	0.0235825	0.0402757	0.0153655	0.11018
SPX_VIX	-0.729054	0.326997	1	-0.69268	0.32478	0.104272	-0.0846369	0.0242706	0.0232832	0.00336131	-0.195339	-0.0684925	0.0332721	0.0187191	0.0673889	0.18898
SPW	0.978889	-0.209235	-0.69268	1	-0.208122	-0.0469363	0.0913727	-0.0444104	0.00376989	0.00103497	0.192627	0.0609034	-0.0458742	-0.02307	-0.0631749	-0.158288
SPW_vol	-0.227357	0.975048	0.32478	-0.208122	1	0.0268764	-0.0385296	0.0261604	0.0131564	-0.0090857	-0.107741	-0.0120859	0.0223775	0.0394433	0.0150776	0.112286
TYVIX	-0.0529565	0.0251985	0.104272	-0.0469363	0.0268764	1	0.107748	-0.0499028	-0.0040613	0.0144933	-0.0764351	-0.0733184	-0.0479552	-0.0435425	0.0889023	0.144176
TNX	0.0910512	-0.0380668	-0.0846369	0.0913727	-0.0385296	0.107748	1	-0.280814	-0.0178848	0.0827197	0.0496076	-0.264455	-0.271091	-0.33607	0.319359	-0.0424386
MLT1U\$10	-0.0399442	0.0289191	0.0242706	-0.0444104	0.0261604	-0.0499028	-0.280814	1	0.162172	-0.0285544	-0.0696559	0.876023	0.837309	0.882378	-0.874357	0.0648127
BASPTDSP	0.0029261	0.0118169	0.0232832	0.00376989	0.0131564	-0.0040613	-0.0178848	0.162172	1	0.000755964	-0.0638646	0.110105	0.0927913	0.117844	-0.132327	0.0495244
USYC2Y10	-0.00298509	-0.00671332	0.00336131	0.00103497	-0.0090857	0.0144933	0.0827197	-0.0285544	0.000755964	1	-0.00886843	-0.0328054	-0.0367074	-0.0378988	0.0365029	0.00563875
LF98TRUU	0.179335	-0.104114	-0.195339	0.192627	-0.107741	-0.0764351	0.0496076	-0.0696559	-0.0638646	-0.00886843	1	0.186759	-0.107144	-0.116242	-0.174481	-0.852435
LUACTRUU	0.0658983	-0.010235	-0.0684925	0.0609034	-0.0120859	-0.0733184	-0.264455	0.876023	0.110105	-0.0328054	0.186759	1	0.728114	0.883912	-0.92328	-0.161398
LT08TRUU	-0.0425505	0.0235825	0.0332721	-0.0458742	0.0223775	-0.0479552	-0.271091	0.837309	0.0927913	-0.0367074	-0.107144	0.728114	1	0.751039	-0.737403	0.0888224
LUTLTRUU	-0.0178942	0.0402757	0.0187191	-0.02307	0.0394433	-0.0435425	-0.33607	0.882378	0.117844	-0.0378988	-0.116242	0.883912	0.751039	1	-0.829882	0.112537
BAMLC0A0CMEY	-0.0650119	0.0153655	0.0673889	-0.0631749	0.0150776	0.0889023	0.319359	-0.874357	-0.132327	0.0365029	-0.174481	-0.92328	-0.737403	-0.829882	1	0.181909
BAMLH0A0HYM2EY	-0.151046	0.11018	0.18898	-0.158288	0.112286	0.144176	-0.0424386	0.0648127	0.0495244	0.00563875	-0.852435	-0.161398	0.0888224	0.112537	0.181909	1

### 13 PRIEDAS. Pilna logaritmuotų, suvidurkintų abiejų grupių veiksnių pokyčių koreliacinė lentelė.

	SPX	SPX_vol	SPX_VIX	SPW	SPW_vol	TYVIX	TNX	MLT1US10	BASPTDSP	USYC2Y10	LF98TRUU	LUACTRUU	LT08TRUU	LUTLTRUU	BAMLC0A0CMEY	BAMLH0A0HYM2EY
SPX	1	-0.229302	-0.729054	0.978869	-0.227357	-0.298591	0.270819	-0.218822	-0.15887	-0.0177074	0.692463	0.336156	-0.26928	-0.219333	-0.283942	-0.690336
SPX_vol	-0.229302	1	0.326997	-0.209235	0.975048	0.132838	-0.100812	0.086134	0.0605126	0.0301803	-0.145342	-0.0645042	0.104754	0.077569	0.0259933	0.154594
SPX_VIX	-0.729054	0.326997	1	-0.69268	0.32478	0.438095	-0.247701	0.18269	0.226155	0.0208377	-0.514952	-0.234987	0.232743	0.211035	0.191144	0.575282
SPW	0.978869	-0.209235	-0.69268	1	-0.208122	-0.261761	0.262666	-0.224336	-0.150498	-0.0100967	0.731413	0.344189	-0.276143	-0.224896	-0.295317	-0.710158
SPW_vol	-0.227357	0.975048	0.32478	-0.208122	1	0.144936	-0.0836456	0.0577749	0.0710632	0.00723373	-0.147593	-0.0892867	0.0800891	0.0580441	0.0470886	0.155786
TYVIX	-0.298591	0.132838	0.438095	-0.261761	0.144936	1	0.154846	-0.148921	0.140024	0.0939238	-0.32226	-0.327455	-0.0912966	-0.135771	0.340453	0.379915
TNX	0.270819	-0.100812	-0.247701	0.262666	-0.0836456	0.154846	1	-0.777731	-0.0790415	0.135658	0.0825983	-0.480223	-0.755511	-0.832563	0.484526	-0.0765897
MLT1US10	-0.218822	0.086134	0.18269	-0.224336	0.0577749	-0.148921	-0.777731	1	0.0941787	-0.111661	-0.124498	0.599487	0.963051	0.887087	-0.611484	0.0827856
BASPTDSP	-0.15887	0.0605126	0.226155	-0.150498	0.0710632	0.140024	-0.0790415	0.0941787	1	0.00617514	-0.229856	-0.225872	0.130037	0.100254	0.193467	0.234063
USYC2Y10	-0.0177074	0.0301803	0.0208377	-0.0100967	0.00723373	0.0939238	0.135658	-0.111661	0.00617514	1	-0.022171	-0.114349	-0.0934054	-0.145754	0.0982914	0.0282774
LF98TRUU	0.692463	-0.145342	-0.514952	0.731413	-0.147593	-0.32226	0.0825983	-0.124498	-0.229856	-0.022171	1	0.577065	-0.190638	-0.172184	-0.539014	-0.932258
LUACTRUU	0.336156	-0.0645042	-0.234987	0.344189	-0.0892867	-0.327455	-0.480223	0.599487	-0.225872	-0.114349	0.577065	1	0.510263	0.570733	-0.937892	-0.573902
LT08TRUU	-0.26928	0.104754	0.232743	-0.276143	0.0800891	-0.0912966	-0.755511	0.963051	0.130037	-0.0934054	-0.190638	0.510263	1	0.834569	-0.559743	0.144001
LUTLTRUU	-0.219333	0.077569	0.211035	-0.224896	0.0580441	-0.135771	-0.832563	0.887087	0.100254	-0.145754	-0.172184	0.570733	0.834569	1	-0.531005	0.150696
BAMLC0A0CMEY	-0.283942	0.0259933	0.191144	-0.295317	0.0470886	0.340453	0.484526	-0.611484	0.193467	0.0982914	-0.539014	-0.937892	-0.559743	-0.531005	1	0.581708
BAMLH0A0HYM2EY	-0.690336	0.154594	0.575282	-0.710158	0.155786	0.379915	-0.0765897	0.0827856	0.234063	0.0282774	-0.932258	-0.573902	0.144001	0.150696	0.581708	1

# 14 PRIEDAS. Kintamo SPX ir visų nepriklausomų kintamų 20 dienų slenkančios koreliacijos grafikai.





## 15 PRIEDAS. Programos kodas naudotas darbe.

```
import csv
import numpy
import pandas
import matplotlib
# sudo apt-get install python-matplotlib
import seaborn
import sklearn
import statsmodels.api as statsm
%matplotlib inline

data=pandas.read_csv('data/dataset_daily.csv', sep=';', header='infer', nrows=
3776)
data.head()
data.tail()
data.info()
data.isnull().sum() #to see if any values have no existing values
data.ndim #Number of axes / array dimensions
data.columns

def very_corr(x): #highliting strong correlation
    if x>=0.75:
        color = 'green'
    else:
        if x<=-0.75:
            color = 'orange'
        else:
            color = 'black'
    return 'color: %s' % color

cor_tablep=data.corr(method='pearson')
cor_tablep.style.applymap(very_corr)
data[["SPX_vol" , "SPW_vol", "SPX" , "SPW", 'SPX_VIX']].hist(layout=(6,3), bins
=25, figsize=(15,15))
data[['BAMLC0A0CMEY' , 'BAMLH0A0HYM2EY' , 'TNX' , 'TYVIX' , 'LF98TRUU' , 'LT08TRUU'
, 'LUACTRUU' , 'LUTLTRUU' , 'MLT1US10' ,
'USYC2Y10' , 'BASPTDSP']].hist(layout=(6,3), bins=25, figsize=(15,15))

viz1=data[["SPX_vol" , "SPW_vol"]]
viz2=data[["SPX" , "SPW"]]
viz3=data[['BAMLC0A0CMEY' , 'BAMLH0A0HYM2EY' , 'TNX' , 'TYVIX' , 'SPX_VIX']]
viz4=data[['LF98TRUU' ,
'LT08TRUU' ,
'LUACTRUU' ,
'LUTLTRUU']]
viz5=data[[
'MLT1US10' ,
'USYC2Y10' , 'BASPTDSP']]

viz11=data[["SPX_vol" , "SPW_vol", "SPX" , "SPW"]]

viz11.insert(2, 'Date', data['Date'].values)
viz11.plot(x='Date', grid=True, figsize=(15,8), secondary_y=["SPX" , "SPW"])

viz22=data[['BAMLC0A0CMEY' , 'BAMLH0A0HYM2EY' , 'TNX' , 'TYVIX' , 'LF98TRUU' , 'LT0
8TRUU' , 'LUACTRUU' , 'LUTLTRUU' , 'MLT1US10' ,
```

```

'USYC2Y10', 'BASPTDSP']]
date_index=pandas.to_datetime(data['Date'],format='%Y/%m/%d')
viz22.insert(2, 'Date', date_index)
viz22.plot(subplots=True, layout=(3, 4), x='Date', figsize=(16, 12), sharex=False)

seaborn.distplot(data['SPX'])

seaborn.jointplot(x="SPX", y="SPX_vol", data=data)

seaborn.lmplot(x="LF98TRUU", y="SPW", data=data)

seaborn.heatmap(data==0,yticklabels=False,cbar=False, cmap='viridis')
date_index=pandas.to_datetime(data['Date'],format='%Y/%m/%d')

time_df = data.set_index(date_index)
time_df.axes[0]
time_df=time_df.drop(labels="Date", axis=1)

return_data=(time_df/time_df.shift(1))-1
return_data=return_data.dropna()
return_data

nolog_return=numpy.log(time_df/ time_df.shift(1))
nolog_return=nolog_return.dropna()

nolog_return
seaborn.distplot(nolog_return['BAMLH0A0HYM2EY'])

def fish_corr(x): #highliting almost any correlation
    if x>=0.10:
        color = 'green'
    else:
        if x<=-0.10:
            color = 'orange'
        else:
            color = 'black'
    return 'color: %s' % color
cor_nolog_return=return_data.corr(method="pearson")
cor_nolog_return.style.applymap(fish_corr)

nolog_return.plot(subplots=True, layout=(4, 4), figsize=(16, 12), sharex=True)
return_data.plot(subplots=True, layout=(4, 4), figsize=(16, 12), sharex=True)

cor_nolog_return=nolog_return.corr(method="pearson")
cor_nolog_return.style.applymap(fish_corr)

from sklearn.neural_network import MLPRegressor
from sklearn.ensemble import RandomForestRegressor
ann=MLPRegressor(
    activation='relu', #{'identity', 'logis
tic', 'tanh', 'relu'}
    solver='lbfgs', # 'lbfgs', 'sgd', 'adam
'}
    learning_rate='adaptive',
    max_iter=10000, tol=0.0,
    learning_rate_init=0.01,
    alpha= 0.0001 #0.01
    #beta_1=0.9, beta_2=0.999, epsilon=1e-08,

```

```

        ,hidden_layer_sizes=50)
ann2=MLPRegressor(
    activation='relu',
    solver='adam',
    learning_rate='adaptive',
    max_iter=10000, tol=0.0,
    learning_rate_init=0.01,
    alpha= 0.0001 #0.01
    #beta_1=0.9, beta_2=0.999, epsilon=1e-08,
    ,hidden_layer_sizes=50)

from sklearn.neighbors import KNeighborsRegressor
knn=KNeighborsRegressor(n_neighbors=5, weights='distance', algorithm='auto')

random_fr=RandomForestRegressor(max_features='auto', min_samples_split=2,n_estimators=10000, min_samples_leaf=1, criterion='mse',
                                min_weight_fraction_leaf=0,
                                max_depth=None)

from sklearn.svm import SVR
svmr=SVR(kernel='poly', tol=0.001, C=1000, epsilon=0.1) #coef0=0.0 # 'poly', '
rbf', 'sigmoid'

from sklearn.model_selection import TimeSeriesSplit
tsplits = TimeSeriesSplit(n_splits=2)
tsplitd = TimeSeriesSplit(n_splits=3)

from sklearn.svm import OneClassSVM

from sklearn import metrics

no_out=nolog_return
outliers_fraction = 0.01
nu_estimate = 0.95 * outliers_fraction + 0.05
out = OneClassSVM(nu=nu_estimate, kernel='rbf', gamma=0.1)
out.fit(no_out)
result = out.predict(no_out)
out_data = no_out[result==1]
nu_out=len(no_out)-len(out_data)
len(out_data)

cor_nolog_return=out_data.corr(method="pearson")
cor_nolog_return.style.applymap(fish_corr)

def evaluate(x, y): #model results evaluation
    ea=sklearn.metrics.r2_score(y, x)
    eb=sklearn.metrics.mean_absolute_error(y, x)
    ec=numpy.sqrt(sklearn.metrics.mean_squared_error(y, x))
    print("R2 adjusted:",ea, "MAE:",eb, "RMSE:",ec)

for i in range(0,5,1):
    Y=out_data[out_data.columns[i]]
    X=out_data[out_data.columns[5:]]
    print(" %s " %(out_data.columns[i] ))
    for train_index, test_index in tsplitd.split(X):
        print("TRAIN:", len(train_index), "TEST:", len(test_index))
        y_train, y_test = Y[train_index], Y[test_index]
        X_train, X_test = X.iloc[train_index], X.iloc[test_index]
        ann2.fit(X_train, y_train)
        aresults=ann2.predict(X_test)

```

```

random_fr.fit(X_train, y_train)
rresults=random_fr.predict(X_test)
knn.fit(X_train, y_train)
bresults=knn.predict(X_test)
svmr.fit(X_train, y_train)
sresults=svmr.predict(X_test)
evaluate(areults, y_test)
evaluate(rresults, y_test)
evaluate(bresults, y_test)
evaluate(sresults, y_test)

irdar=pandas.rolling_mean(nolog_return[nolog_return.columns[0:5]], 20)
irdar=irdar.dropna()
atsarga=nolog_return[nolog_return.columns[0:5]]
irdar2=pandas.rolling_mean(nolog_return[nolog_return.columns[5:]], 20)
irdar2=irdar2.dropna()
atsarga2=nolog_return[nolog_return.columns[5:]]
galas=pandas.concat([irdar,irdar2],axis=1)
galas=galas.dropna()
galas2=pandas.concat([atsarga,irdar2],axis=1)
galas3=pandas.concat([irdar,atsarga2],axis=1)
galas2=galas2.dropna()
galas3=galas3.dropna()
galas

cor_nolog_return=galas.corr(method="pearson")
cor_nolog_return.style.aplymap(fish_corr)

#resetting algoritms and starting over with new dataset
from sklearn.neural_network import MLPRegressor
from sklearn.ensemble import RandomForestRegressor
ann=MLPRegressor(
    activation='relu', #{'identity', 'logis
tic', 'tanh', 'relu'}
    solver='lbfgs', # 'lbfgs', 'sgd', 'adam
'}

    learning_rate='adaptive',
    max_iter=10000, tol=0.0,
    learning_rate_init=0.01,
    alpha= 0.0001 #0.01
    #beta_1=0.9, beta_2=0.999, epsilon=1e-08,
    ,hidden_layer_sizes=50)
ann2=MLPRegressor(
    activation='relu',
    solver='adam',
    learning_rate='adaptive',
    max_iter=10000, tol=0.0,
    learning_rate_init=0.01,
    alpha= 0.0001 #0.01
    #beta_1=0.9, beta_2=0.999, epsilon=1e-08,
    ,hidden_layer_sizes=50)
from sklearn.neighbors import KNeighborsRegressor
knn=KNeighborsRegressor(n_neighbors=5, weights='distance', algorithm='auto')

random_fr=RandomForestRegressor(max_features='auto', min_samples_split=2,n_est
imators=10000, min_samples_leaf=1, criterion='mse',
    min_weight_fraction_leaf=0,
    max_depth=None)
from sklearn.svm import SVR

```



```

svmr=SVR(kernel='poly', tol=0.001, C=1000, epsilon=0.1) #coef0=0.0 # 'poly', '
rbf', 'sigmoid'

portion=galas
for i in range(0,5,1):
    Y=portion[portion.columns[i]]
    X=portion[portion.columns[5:]]
    print(" %s " %(portion.columns[i] ))
    for train_index, test_index in tsplits.split(X):
        print("TRAIN:", len(train_index), "TEST:", len(test_index))
        y_train, y_test = Y[train_index], Y[test_index]
        X_train, X_test = X.iloc[train_index], X.iloc[test_index]
        ann2.fit(X_train, y_train)
        aresults=ann2.predict(X_test)
        random_fr.fit(X_train, y_train)
        rresults=random_fr.predict(X_test)
        knn.fit(X_train, y_train)
        bresults=knn.predict(X_test)
        svmr.fit(X_train, y_train)
        sresults=svmr.predict(X_test)
        evaluate(aresults, y_test)
        evaluate(rresults, y_test)
        evaluate(bresults, y_test)
        evaluate(sresults, y_test)

#resetting algoritms and starting over with new dataset
from sklearn.neural_network import MLPRegressor
from sklearn.ensemble import RandomForestRegressor
ann=MLPRegressor(
    activation='relu', #{'identity', 'logis
tic', 'tanh', 'relu'}
    solver='lbfgs', # 'lbfgs', 'sgd', 'adam
'}
    learning_rate='adaptive',
    max_iter=10000, tol=0.0,
    learning_rate_init=0.01,
    alpha= 0.0001 #0.01
    #beta_1=0.9, beta_2=0.999, epsilon=1e-08,
    ,hidden_layer_sizes=50)
ann2=MLPRegressor(
    activation='relu',
    solver='adam',
    learning_rate='adaptive',
    max_iter=10000, tol=0.0,
    learning_rate_init=0.01,
    alpha= 0.0001 #0.01
    #beta_1=0.9, beta_2=0.999, epsilon=1e-08,
    ,hidden_layer_sizes=50)
from sklearn.neighbors import KNeighborsRegressor
knn=KNeighborsRegressor(n_neighbors=5, weights='distance', algorithm='auto')

random_fr=RandomForestRegressor(max_features='auto', min_samples_split=2,n_est
imators=10000, min_samples_leaf=1, criterion='mse',
    min_weight_fraction_leaf=0,
    max_depth=None)

from sklearn.svm import SVR
svmr=SVR(kernel='poly', tol=0.001, C=1000, epsilon=0.1) #coef0=0.0 # 'poly', '
rbf', 'sigmoid'

```

```

portion=galas2
for i in range(0,5,1):
    Y=portion[portion.columns[i]]
    X=portion[portion.columns[5:]]
    print(" %s " %(portion.columns[i] ))
    for train_index, test_index in tsplits.split(X):
        print("TRAIN:", len(train_index), "TEST:", len(test_index))
        y_train, y_test = Y[train_index], Y[test_index]
        X_train, X_test = X.iloc[train_index], X.iloc[test_index]
        ann2.fit(X_train, y_train)
        aresults=ann2.predict(X_test)
        random_fr.fit(X_train, y_train)
        rresults=random_fr.predict(X_test)
        knn.fit(X_train, y_train)
        bresults=knn.predict(X_test)
        svmr.fit(X_train, y_train)
        sresults=svmr.predict(X_test)
        evaluate(aresults, y_test)
        evaluate(rresults, y_test)
        evaluate(bresults, y_test)
        evaluate(sresults, y_test)

#resetting algoritms and starting over with new dataset
learn.neural_network import MLPRegressor
from sklearn.ensemble import RandomForestRegressor
ann=MLPRegressor(
    activation='relu', #{'identity', 'logis
tic', 'tanh', 'relu'
    solver='lbfgs', # 'lbfgs', 'sgd', 'adam
'}
    learning_rate='adaptive',
    max_iter=10000, tol=0.0,
    learning_rate_init=0.01,
    alpha= 0.0001 #0.01
    #beta_1=0.9, beta_2=0.999, epsilon=1e-08,
    ,hidden_layer_sizes=50)
ann2=MLPRegressor(
    activation='relu',
    solver='adam',
    learning_rate='adaptive',
    max_iter=10000, tol=0.0,
    learning_rate_init=0.01,
    alpha= 0.0001 #0.01
    #beta_1=0.9, beta_2=0.999, epsilon=1e-08,
    ,hidden_layer_sizes=50)
from sklearn.neighbors import KNeighborsRegressor
knn=KNeighborsRegressor(n_neighbors=5, weights='distance', algorithm='auto')

random_fr=RandomForestRegressor(max_features='auto', min_samples_split=2,n_est
imators=10000, min_samples_leaf=1, criterion='mse',
    min_weight_fraction_leaf=0,
    max_depth=None)

from sklearn.svm import SVR
svmr=SVR(kernel='poly', tol=0.001, C=1000, epsilon=0.1) #coef0=0.0 # 'poly', '
rbf', 'sigmoid'

```

```

portion=galas3
for i in range(0,5,1):
    Y=portion[portion.columns[i]]
    X=portion[portion.columns[5:]]
    print(" %s " %(portion.columns[i] ))
    for train_index, test_index in tsplits.split(X):
        print("TRAIN:", len(train_index), "TEST:", len(test_index))
        y_train, y_test = Y[train_index], Y[test_index]
        X_train, X_test = X.iloc[train_index], X.iloc[test_index]
        ann2.fit(X_train, y_train)
        aresults=ann2.predict(X_test)
        random_fr.fit(X_train, y_train)
        rresults=random_fr.predict(X_test)
        knn.fit(X_train, y_train)
        bresults=knn.predict(X_test)
        svmr.fit(X_train, y_train)
        sresults=svmr.predict(X_test)
        evaluate(aresults, y_test)
        evaluate(rresults, y_test)
        evaluate(bresults, y_test)
        evaluate(sresults, y_test)

cor_plot=pandas.rolling_corr(nolog_return[nolog_return.columns[0]],nolog_return[nolog_return.columns[5:]], window=20)
cor_plot.plot(grid=True, figsize=(15,18), legend='Reverse', colormap='RdYlGn', subplots=True ) #

cor_plot=pandas.rolling_corr(nolog_return[nolog_return.columns[0]],nolog_return[['TNX', 'USYC2Y10', 'LF98TRUU', 'BAMLC0A0CMEY']], window=20)
cor_plot.plot(grid=True, figsize=(15,18), legend='Reverse', colormap='RdYlGn', subplots=True ) #

#resetting algoritms and starting over with new dataset
from sklearn.neural_network import MLPRegressor
from sklearn.ensemble import RandomForestRegressor
ann=MLPRegressor(
    activation='relu', #{'identity', 'logistic', 'tanh', 'relu'}
    solver='lbfgs', #\lbfgs', 'sgd', 'adam'
    learning_rate='adaptive',
    max_iter=10000, tol=0.0,
    learning_rate_init=0.01,
    alpha= 0.0001 #0.01
    #beta_1=0.9, beta_2=0.999, epsilon=1e-08,
    ,hidden_layer_sizes=50)
ann2=MLPRegressor(
    activation='relu',
    solver='adam',
    learning_rate='adaptive',
    max_iter=10000, tol=0.0,
    learning_rate_init=0.01,
    alpha= 0.0001 #0.01
    #beta_1=0.9, beta_2=0.999, epsilon=1e-08,
    ,hidden_layer_sizes=50)
from sklearn.neighbors import KNeighborsRegressor

```

```

knn=KNeighborsRegressor(n_neighbors=5, weights='distance', algorithm='auto')

random_fr=RandomForestRegressor(max_features='auto', min_samples_split=2,n_estimators=10000, min_samples_leaf=1, criterion='mse',
                                min_weight_fraction_leaf=0,
                                max_depth=None)

from sklearn.svm import SVR
svmr=SVR(kernel='poly', tol=0.001, C=1000, epsilon=0.1) #coef0=0.0 # 'poly', 'rbf', 'sigmoid'

portion=galas[:2800]
for i in range(0,5,1):
    Y=portion[portion.columns[i]]
    X=portion[portion.columns[5:]]
    print(" %s " %(portion.columns[i] ))
    for train_index, test_index in tsplits.split(X):
        print("TRAIN:", len(train_index), "TEST:", len(test_index))
        y_train, y_test = Y[train_index], Y[test_index]
        X_train, X_test = X.iloc[train_index], X.iloc[test_index]
        ann2.fit(X_train, y_train)
        aresults=ann2.predict(X_test)
        random_fr.fit(X_train, y_train)
        rresults=random_fr.predict(X_test)
        knn.fit(X_train, y_train)
        bresults=knn.predict(X_test)
        svmr.fit(X_train, y_train)
        sresults=svmr.predict(X_test)
        evaluate(arresults, y_test)
        evaluate(rresults, y_test)
        evaluate(bresults, y_test)
        evaluate(sresults, y_test)
random_fr.feature_importances_

nolog_return_1lag=nolog_return[data.columns[6:]].shift(1)
nolog_return_1lag=pandas.concat([nolog_return[['SPX', 'SPX_vol', 'SPX_VIX', 'SPW', 'SPW_vol']], nolog_return_1lag],axis=1)
nolog_return_1lag=nolog_return_1lag.dropna()
nolog_return_3lag=nolog_return[data.columns[6:]].shift(3)
nolog_return_3lag=pandas.concat([nolog_return[['SPX', 'SPX_vol', 'SPX_VIX', 'SPW', 'SPW_vol']], nolog_return_3lag],axis=1)
nolog_return_3lag=nolog_return_3lag.dropna()
nolog_return_5lag=nolog_return[data.columns[6:]].shift(5)
nolog_return_5lag=pandas.concat([nolog_return[['SPX', 'SPX_vol', 'SPX_VIX', 'SPW', 'SPW_vol']], nolog_return_5lag],axis=1)
nolog_return_5lag=nolog_return_5lag.dropna()
nolog_return_10lag=nolog_return[data.columns[6:]].shift(10)
nolog_return_10lag=pandas.concat([nolog_return[['SPX', 'SPX_vol', 'SPX_VIX', 'SPW', 'SPW_vol']], nolog_return_10lag],axis=1)
nolog_return_10lag=nolog_return_10lag.dropna()
nolog_return_20lag=nolog_return[data.columns[6:]].shift(20)
nolog_return_20lag=pandas.concat([nolog_return[['SPX', 'SPX_vol', 'SPX_VIX', 'SPW', 'SPW_vol']], nolog_return_20lag],axis=1)
nolog_return_20lag=nolog_return_20lag.dropna()

```

```

cor_nolog_return=nolog_return_1lag.corr(method="pearson")
cor_nolog_return.style.applymap(fish_corr)

cor_nolog_return=nolog_return_3lag.corr(method="pearson")
cor_nolog_return.style.applymap(fish_corr)

cor_nolog_return=nolog_return_5lag.corr(method="pearson")
cor_nolog_return.style.applymap(fish_corr)

cor_nolog_return=nolog_return_10lag.corr(method="pearson")
cor_nolog_return.style.applymap(fish_corr)

cor_nolog_return=nolog_return_20lag.corr(method="pearson")
cor_nolog_return.style.applymap(fish_corr)

seaborn.pairplot(data, y_vars=['SPX', 'SPX_vol', 'SPX_VIX', 'SPW', 'SPW_vol'],
x_vars=['SPX', 'SPX_vol', 'SPX_VIX', 'SPW', 'SPW_vol'], size=2, aspect=1)

seaborn.pairplot(data, kind="reg", y_vars=["SPX" , "SPW", "SPX_vol" , "SPW_vol"
, "SPX_VIX" ], x_vars=[
    'TYVIX', 'TNX',
    'MLT1US10', 'BASPTDSP', 'USYC2Y10', 'LF98TRUU',
    'LUACTRUU', 'LT08TRUU', 'LUTLTRUU', 'BAMLCOA0CMEY', 'BAMLHOA0HYM2EY'])
#, size=5, aspect=.8

```