



Vilniaus universitetas
Matematikos ir informatikos
institutas
LIETUVA



INFORMATIKOS INŽINERIJA (07 T)

**DAUGIAKRITERINIS FINANSŲ RINKŲ
EFEKTYVUMO DINAMIKOS
MODELIAVIMAS**

Marius Liutvinavičius

2017 m. spalis

Mokslinė ataskaita MII-DS-07T-17-05

VU Matematikos ir informatikos institutas, Akademijos g. 4, Vilnius LT-08663

www.mii.lt

Santrauka

Finansų rinkų nestabilumas ir krizinių situacijų gausa paskatino naujų idėjų paiešką ir intensyvius mokslinius tyrimus finansų sistemų analizės srityje.

Naujausi moksliniai tyrimai įrodo, kad rinkos funkcionavimas nėra racionalus. Jas veikia ne tik ekonominiai, geopolitiniai, socialiniai veiksniai, bet ir investuotojų lūkesčiai, baimės, intuicija, taip pat manipuliavimas žinių srautais bei apskritai informacijos ribotumas. Visi šie veiksniai yra skirtini, tačiau veikia tiek finansų rinkų judėjimą, tiek realios ekonomikos procesus, todėl turi būti įvertinant prognozuojant galimas krizes.

Vykdomas tyrimas planuojama gauti naujų mokslui ir praktikai svarbių rezultatų integravant intelektinės didelių duomenų analizės, daugiakriterinio modeliavimo bei informacijos efektyvumo vertinimo metodus, sukurti naujus kiekybinio vertinimo rodiklius bei intelektinius modelius, skirtus anomalinių situacijų prognozavimui bei investavimo rizikos vertinimui.

Tyrimus galima priskirti „computational economics“ mokslo sričiai, apjungiančiai ekonomiką ir kompiuterių mokslą. Finansų rinkos suvokiamos kaip dinaminės tarpusavyje sąveikaujančių agentų sistemos, kurių modeliavimas ir prognozavimas remiasi kompiuterinėmis technologijomis.

Gauti rezultatai gali būti naudingi ilgalaikio investavimo sprendimus priimantiems investicinių bendrovių, bankų ir pensijų fondų investavimo profesionalams, bei eiliniams investuotojams.

Reikšminiai žodžiai: finansų rinkos, anomalijų prognozavimas, didieji duomenys

Turinys

IVADAS	5
1. SISTEMŲ MODELIAVIMO METODAI.....	9
1.1 Sistemų modeliavimo metodologijos.....	9
1.1.2 Metamodeliavimas	9
1.1.3 Procesų erva ir elementarus valdymo ciklas	10
1.2. Modeliavimo metodai	13
1.2.1. Sprendimo priėmimo modeliavimas	13
1.2.2. Valdomos sistemos procesų imitacinis modeliavimas.....	15
1.2.2.1. Imitacinis procesų modeliavimas.....	15
1.2.2.2. Sistemų dinamika (priežastinių kilpų ir srautų-talpų diagramos)	17
1.2.2.3. Objektinis sistemų modeliavimas (UML diagramos)	20
1.2.3 Tikslų ir rizikos modeliavimas.....	20
2. DUOMENŲ ANALIZĖS METODAI	23
2.1. Daugiamatių duomenų projekcijos metodai.....	23
2.1.1 Principinių komponenčių analizės metoda.....	23
2.1.2. Daugiamatės skalės	26
2.2. Neuroninių tinklų taikymas duomenų analizei	28
2.2.1. Duomenų vizualizavimas ir analizė naudojant SOM.....	28
2.2.1.1. Vizualizavimas naudojant Viscovery Somine	28
2.2.1.2. Vizualizavimas naudojant Matlab.....	31
2.2.1.3. SOM ir Sammon metodų junginys	32
2.2.2. Perceptroninis neuroninis tinklas	33
2.3. Klasterizavimo metodai	36
2.4 Daugiapakopė duomenų analizė ir vizualizavimas	38
3. PROGRAMINĖS ĮRANGOS ANALIZĖ.....	44
3.1 Modeliavimo ir imitavimo programinė įranga	44
3.2. Didelių duomenų analizei skirtos programinės įrangos analizė	48
4. INVESTAVIMO RIZIKĄ LEMIANČIŲ VEIKSNIŲ TYRIMAI.....	54
4.1. Veiksnių, įtakojančių kaupimo fonduose efektyvumą, tyrimas	54
4.2. Daugiakriterinis ilgalaikių taupymo priemonių pasirinkimo modelis	64
4.3. Dinaminis investavimo procesų imitavimas ir investavimo strategijų tyrimas	71
4.4. Finansų rinkų prognozavimas remiantis investuotojų nuotaikų indikatoriumi.	82

4.4.1 Finansų krizių prognozavimo metodų apžvalga	84
4.4.2 Finansiniai ir nuotaikų indikatoriai anomalijų prognozavimui.....	87
4.4.3 Nuotaikų indikatoriaus taikymo metodologija.....	91
4.4.4 Anomalijų prognozavimo ir nuotaikų indikatoriumi paremtų investavimo strategijų tyrimo rezultatai	95
LITERATŪRA	104

IVADAS

Finansų rinkų nestabilumas ir krizinių situacijų gausa paskatino naujų idėjų paiešką ir intensyvius mokslinius tyrimus finansų sistemų analizės srityje. Tarptautinės finansų organizacijos ir mokslo atstovai atkreipė ypatingą dėmesį į pastarojo meto finansinio sektoriaus nesaugumą, klasikinių ekonomikos teorijų ribotumą, pabrėžę finansinės informacijos analizės ir prognozavimo mechanizmų tobulinimo svarbą.

Nusistovėjusios ekominės teorijos, pabrėžiančios rinkų efektyvumą neatitinka šių dienų realijų. Naujausi moksliniai tyrimai įrodo, kad rinkos funkcionavimas nėra racionalus. Jas veikia ne tik ekominiai, geopolitiniai, socialiniai veiksniai, bet ir investuotojų lūkesčiai, baimės, intuicija, taip pat manipuliavimas žinių srautais bei apskritai informacijos ribotumas.

Visi šie veiksniai yra skirtini, tačiau veikia tiek finansų rinkų judėjimą, tiek realios ekonomikos procesus, todėl turi būti įvertinant prognozuojant galimas krizes.

Vykdomas tyrimas planuojama gauti naujų mokslui ir praktikai svarbių rezultatų. Integravant intelektinės didelių duomenų analizės, daugiakriterinio modeliavimo bei informacijos efektyvumo vertinimo metodus, sukurti naujus kiekybinio vertinimo rodiklius bei intelektinius modelius, skirtus anomalinių situacijų prognozavimui bei investavimo rizikos vertinimui.

Gauti rezultatai gali būti naudingi ilgalaikio investavimo sprendimus priimantiems investicinių bendrovių, bankų ir pensijų fondų investavimo profesionalams, bei eiliniams investuotojams.

Tikslos ir uždaviniai

Darbo tikslos – Integravant intelektinės didelių duomenų analizės ir daugiakriterinio modeliavimo metodus sukurti naujus kiekybinio vertinimo rodiklius bei intelektinius modelius, skirtus anomalinių situacijų prognozavimui bei investavimo rizikos vertinimui.

Siekiant šio tikslui bus sprendžiami tokie **uždaviniai**:

- Ištirti išskirtinių finansinių situacijų eksperimentinių tyrimų metodologiją, išanalizuoti dinaminių sistemų modeliavimo metodus naudojamus finansų rinkų mechanizmams tirti bei atlikti modelių pritaikymą kompiuteriniams situacijų simuliavimui.

- Ištirti investavimo riziką lemiančių *racionalių* bei *iracionalių* veiksnių poveikį profesionalaus ir *neprofesionalaus* investavimo atvejais. Atliliki skirtinę tipų faktorių integravimo į daugiakriterines sprendimų paramos sistemas tyrimus.
- Išanalizuoti investicinio sprendimo priėmimo procesą *investicinės aplinkos rizikos* įvertinimo bei *investuotojo lūkesčių ir rizikos tolerancijos nustatymo* aspektais bei pasiūlyti originalius rodiklius ir metodus rinkų efektyvumui bei investavimo rizikai vertinti.
- Įvertinti rinkos naujenų, įvairiose media ar socialiniuose tinkluose skelbiamos informacijos įtaką finansų rinkų stabilumui ir integruoti atitinkamą poveikį į rinkų efektyvumo identifikavimo modelius. Pritaikyti didelių duomenų analizės metodus situacijų modeliavimui ir finansinių krizių prognozavimui.

Tokiu būdu galima objektyviau įvertinti finansų rinkų stabilumą, ilgalaikio prognozavimo ir investavimo patikimumą, iš anksto numatyti anomalinių situacijų atsiradimą, modeliuoti poveikio priemonių įtaką ir sumažinti investavimo riziką.

Metodai ir priemonės

Modeliavimas: UML 2.0; Causal loop, Stock and Flow diagrams

Įrankiai procesų simuliavimui: Powersim Studio 8, Vensim, Altreva

Techniniai ir neuroninių tinklų skaičiavimai: Matlab, Statistica

Didelių duomenų apdorojimas: Rapid Miner

Sistemos prototipo realizavimas: R, R-Studio, R-Shiny

Aktualumas ir originalumas

Finansų rinkos elgesys yra dinaminis procesas, kuriame didesnio stabilumo periodus keičia nervingi momentai, kurių metu ženkliai sumažėja rinkos efektyvumas ir padidėja krizinių situacijų tikimybė. Todėl finansų rinkų efektyvumo kitimo stebėjimas - labai svarbus uždavinys, reikalaujantis integruotų techninės ir fundamentaliosios analizės įrankių, naujų kiekybinio vertinimo rodiklių bei efektyvių vertinimo metodų. Tai salygoja intelektinių modelių kūrimo poreikį, metodų integravimo, modifikavimo, specializavimo finansinėms rinkoms būtinumą.

Investavimo sprendimai daromi įvertinant daug faktų, bet dažnai nesuvokiama, kad iš tikro sprendimo rezultatą įtakoja daug papildomų veiksnių, kuriuos būtina suprasti ir įvertinti (naujenų srautai, politiniai interesai, socialiniai pokyčiai, investuotojų lūkesčiai). Rinkų burbulai formuoja dėl šio neteisingo ir nekokybisko

informacijos kieko. Mūsų tikslas yra nustatyti koks yra optimalus informacijos kiekis ir turinys, kuriuo remiantis racionaliai būtų galima nustatyti teisingą kainą. **Būtina sukurti tokius rinkų prognozavimo modelius, kuriais būtų galima patikrinti įtarimus, jog formuojasi kainų burbulas, ir nustatyti kurie veiksniai jį lemia.**

Priešingai techninei analizei, kuria aktyvų kaina prognozuojama pagrinde remiantis tik jos kitimu praeityje, mes stengsimės išsiaiškinti visus veiksnius, turinčius įtakos kainų pokyčiams, bei tų veiksnių įtaką vienas kitam. Paneigiamo nuostatą, kad rinkos kaina yra teisinga. Priešingai, darome prielaidą, kad rinkos kaina gali būti neteisinga dėl gaunamos klaidingos informacijos (viena iš 2008 m. krizės priežasčių – suteikti aukštį investiciniai reitingai bevertėms obligacijoms), emocijomis grįstų sprendimų ar perdėtų lūkesčių, neteisingo objektyvių rodiklių interpretavimo bei apskritai svarbios informacijos naturėjimo.

Sukurti nauji rizikos vertinimo metodai leis identifikuoti kritinius parametrus, sukuriančius nestabilias situacijas ir trukdančius šių sistemų optimaliam darbui.

2013 metų Nobelio ekonomikos premija paskirta R. Shiller [118] (kartu su E. Fama [34] ir L.P Hansen [20]), tyrusiam finansinių aktyvų kainų kitimą ir pabréžusiam rinkų iracionalumą. Pastaroji finansų krizė leido kitaip pažvelgti į ekonominius procesus, paneigtį klasikinį požiūrį į savaimė susireguliuojančias ir racionalias rinkas. Tai atveria kelius naujiems tyrimams, o informacinių technologijų pažanga įgalina šiuos tyrimus. Norint modeliuoti ir integrnuoti tarpusavyje skirtingus veiksnius, būtina apdoroti su jais susijusius didelius duomenų kiekius (ekonominiai rodikliai, naujienu srautai...). Būtina tyrinėti ir tokius naujus, bet svarbius, duomenų šaltinius kaip naujienu srautai socialiniuose tinkluose.

Mūsų moksliniame projekte numatoma sukurti metodą, apjungiantį intelektinių duomenų analizės metodą, daugiakriterinio modeliavimo ir informacijos efektyvumo rodiklių privalumus vertinant finansų rinkų efektyvumą, identifikuojant anomalines situacijas ir prognozuojant artėjančias krizes.

Tyrimus galima priskirti „computational economics“ mokslo sričiai, apjungiančiai ekonomiką ir kompiuterių mokslą. Finansų rinkos suvokiamos kaip dinaminės tarpusavyje sąveikaujančią agentų sistemas, kurių modeliavimas ir prognozavimas remiasi kompiuterinėmis technologijomis.

Šioje srityje tyrimai vykdomi jau daugiau nei dešimtmetį (S.E. Page (2008) [66][97], K.L. Judd (2006) [26][27], Alvin E. Roth (2002), M.J. Miranda ir P.L. Fackler (2002)), tačiau šiuo metu jgauna naujų formų.

Didžiausio tyrėjų dėmesio dabar sulaukia neuroninių tinklų, dirbtinių agentų, sąveikos taisyklių ir kitų intekstinių metodų taikymai finansų rinkų analizei ir prognozavimui (Yao J.T., Tan C.L. (2001), Barunik J., Kristoufek L. (2010), Kumar M., Thenmozhi M. (2004), Rocco W.A. (2009). Š.Raudys (2008), A.Račkauskas (2007)).

Be R. Shilerio turto vertinimo klausimus tyrinėjo ir E. Fama [34] bei L. Hansen [20]. Elgesio ekonomikos („behaviour economics“) tyrimuose pasižymėjo G. Caginalp, V. Smith, D. Porter [18], D. Balenovich. Vienas iš mėginimų įvertinti akcijų kainos reakciją į informacijos srautus buvo R. Thaler pasiūlytas modelis.

Darbo su dideliais finansiniais duomenimis svarbą pabrėžia ir ypatybes analizuoją TechAmerica Foundation's Federal Big Data Commission (2012) [132], IBM (2013) [59], Forrester (2011) Kovalerchuk and Vitaev (2005) [74], Bughin (2010), Luna, (2010). Kuriami nauji ir pritaikomi esami metodai didelių duomenų apdorojimui siekiant tiksliau prognozuoti akcijų kainų pokyčius, bankrotus ar sukčiavimo atvejus. Reikalingi metodai, leidžiantys efektyviau nustatyti priežastinius ryšius tarp įvairių viensnių.

Iki šiol skelbtose publikacijose Lietuvos finansų rinkos efektyvumo vertinimas ar anomalinių situacijų identifikavimas dažniausiai apsiribojo tik bendraisiais klausimais ir jų taikymu konkrečių bankų veikloje vertinant kreditų riziką, patikimumą ar planuojamą pelningumą (M. Kudinska (2003), V. Sakalauskas (2006, 2011), V. Valvonis (2007), R. Leipus (2006), L. Simanauskas (2006), Danilenko S S. (2009)).

Mes visų pirma stengsimės sumodeliuoti sudėtingus ekonominius procesus, įvairių faktorių įtaką galutiniam rezultatui ir jų tarpusavio priklausomybę. Sumodeliuoti procesai bus simuliujami, siekiant eksperimentų būdu išanalizuoti įvairius galimus scenarijus. Kadangi didelė dalis pradinės informacijos (media srautas, finansiniai rodikliai) atitinka dideliems duomenims („big data“) būdingus parametrus, ši informacija bus apdorojama specialiai tokiemis duomenims pritaikytais metodais ir programine įranga.

Sukurtas naujas rodiklis turėtų leisti tiksliau įvertinti ne tik momentinį rinkos efektyvumą, bet ir nustatyti efektyvumo dinamiką laike. Siūlomas finansinių rinkų analizės metodas suteiktų galimybę gauti naujų charakteristikų anomalinių situacijų identifikavimui.

1. SISTEMŲ MODELIAVIMO METODAI

1.1 Sistemų modeliavimo metodologijos

Skaičiuojamosios ekonomikos („computational economics“) mokslo sritis apjungia ekonomiką ir kompiuterių mokslą. Finansų rinkos suvokiamos kaip dinaminės tarpusavyje sąveikaujančių agentų sistemos, kurių modeliavimas ir prognozavimas remiasi kompiuterinėmis technologijomis.

Visų pirma stengiamasi sumodeliuoti sudėtingus ekonominius procesus, įvairių faktorių įtaką galutiniam rezultatui ir jų tarpusavio priklausomybę. Sumodeliuoti procesai simuliujami, siekiant eksperimentų būdu išanalizuoti įvairius galimus scenarijus. Sprendimų paramos sistemos analizuodamos valdomos sistemos būsenų parametrus bei išorės veiksnius priima atitinkamus sprendimus.

Apjungiant intelektinių duomenų analizės metodų, daugiakriterinio modeliavimo ir informacijos efektyvumo rodiklių privalumus galima efektyviau vertinti finansų rinkų efektyvumą, identifikuoti anomalines situacijas ir prognozuojant artėjančias krizes. Tačiau visų pirma reikalingi metodai, kurie leistų paprasčiau modeliuoti sudėtingus ekonominius procesus bei finansų sistemos mechanizmus ir į modeliavimo procesą integrnuotų skirtingo tipo veiksnius, turinčius įtakos finansų rinkoms. I vieną visumą reikia sujungti valdomos sistemos procesų imitacinių modeliavimą, sprendimo priėmimo proceso modeliavimą bei tikslų ir rizikos modeliavimą.

Šio skyriaus objektas – sistemų dinamikos ir sprendimo priėmimo modeliavimo metodikos. **Analizės tikslas:** išanalizuoti dinaminį sistemų ir jas valdančių sprendimo paramos sistemų modeliavimo metodus

Tikslui pasiekti iškelti uždaviniai:

- Aprašyti modeliavimo metodologijas
- Ištirti sprendimo priėmimo sistemų modeliavimą
- Išanalizuoti procesų imitacinių modeliavimą
- Pateikti tikslų modeliavimo metodus
- Visus metodus vertinti finansų rinkų sferos kontekste

Toliau apžvelgiamas metamodeliavimas, ontologijos bei elementaraus valdymo ciklo atvaizdavimas procesų erdvėje

1.1.2 Metamodeliavimas

Metamodelis – modeliavimo kalbos modelis, kuriame apibrėžtos esminės kalbos savybės. Metamodelis turi būti tikslus išreikštinių darinių (angl. artifact) ir

taisyklių apibrėžimas, kuris reikalingas semantinių arba dalykinės srities modelių kūrimui [92][23]. Metamodelį sudaro:

- Koncepcijos, kurias pats metamodelis palaiko.
- Tekstinė sintaksė
- Grafinė sintaksė
- Metamodelio semantika

Kurdami realaus pasaulio modelius inžinieriai dažniausiai bražo schemas arba aprašinėja realų pasaulį tam tikrais simboliais. Galima sakyti jie bendrauja tam tikra kalba. Tų kalbą yra labai daug - kiekvienai dalykinei sričiai, kiekvienai specialybei ar problemai gali būti po atskirą modeliavimo kalbą.

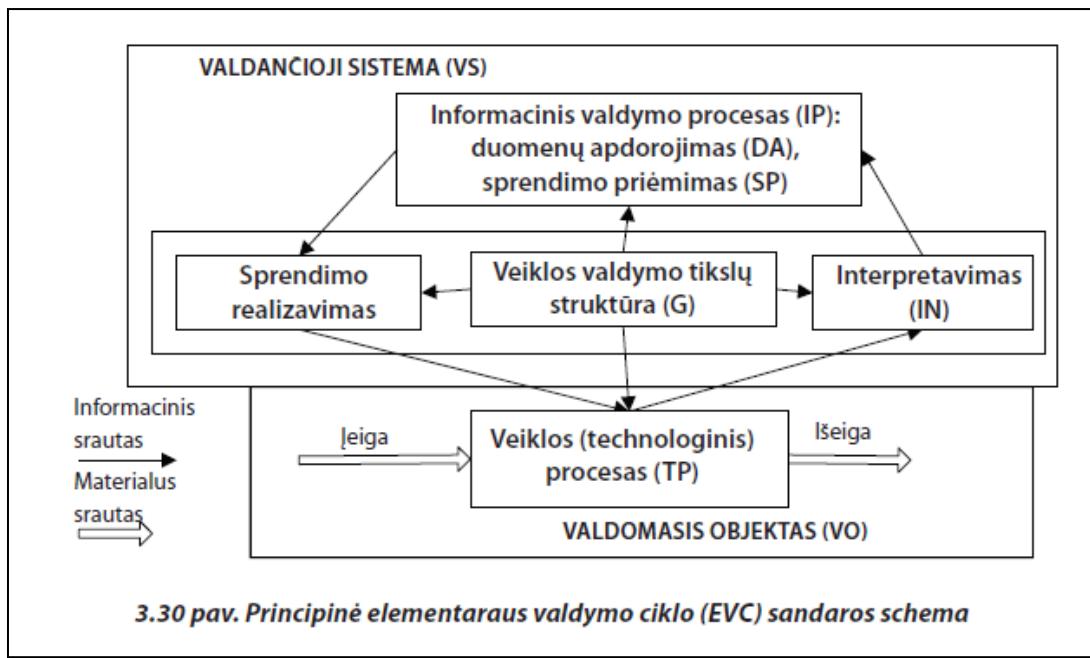
Vienas iš aktyviausių šiuo metu modeliaių paremtos inžinerijos naudojamų metodų yra OMG pasiūlyta modelių architektūra. Šis būdas remiasi kalbos panaudojimu rašant metamodelius, vadinamus metaobjektų įranga () arba MOF. Tipiniai metamodeliai pasiūlyti OMG yra UML, SysML, SPEM arba CWM. ISO taip pat pasiūlė standartinį metamodelį ISO/IEC 24744 [92][23].

1.1.3 Procesų erdvė ir elementarus valdymo ciklas

IS inžinerijos ir veiklos modeliavimo sričių raidos analizė leidžia tvirtinti, kad IS inžinerijos poreikiai skatina integruotis įvairias mokslo sritis ir technologijas [110]:

- IS inžineriją,
- veiklos modeliavimą ir veiklos reinžineriją,
- sprendimų priėmimo procesų kompiuterizavimą,
- žinių atvaizdavimo metodus.

Šiame darbe orientuojamasi ne į organizacijų veiklos ir jų procesų modeliavimą, bet analizuojamos galimybės modeliuoti tokias dinamines sritis kaip finansų rinkos. Pagrindinis tikslas yra į vieną visumą sujungti valdomos sistemos (domeno) procesų imitacinių modeliavimą, sprendimo priėmimo proceso modeliavimą bei tikslų ir rizikos modeliavimą.

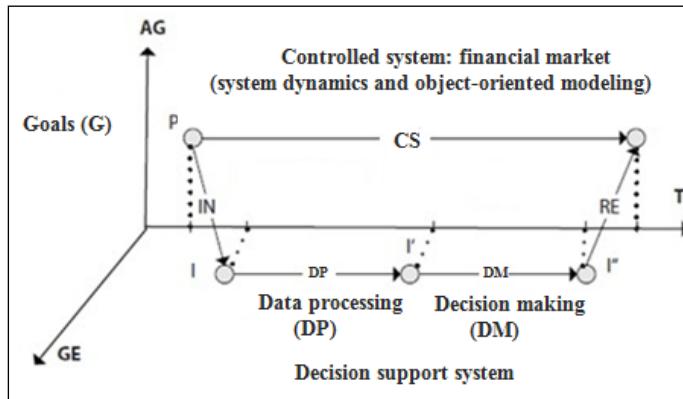


Šaltinis: S. Gudas. Informacijos sistemų inžinerijos teorijos pagrindai (2012) [110]

1 pav. Elementaraus valdymo ciklo schema

1 pav. pateikiama elementaraus valdymo ciklo schema, kuri parodo kaip valdančioji sistema remdamasi tikslų modeliu interpretuoja valdomos sistemos parametrus bei realizuoja ją valdančius sprendimus.

Visų trijų tipų modeliai (valdomos sistemos, sprendimo priėmimo proceso, tikslų) gali būti atvaizduoti vienoje tyrimų erdvėje (2 pav.).



Šaltinis: sukurta autoriaus remiantis S. Gudas. Informacijos sistemų inžinerijos teorijos pagrindai (2012) [110]

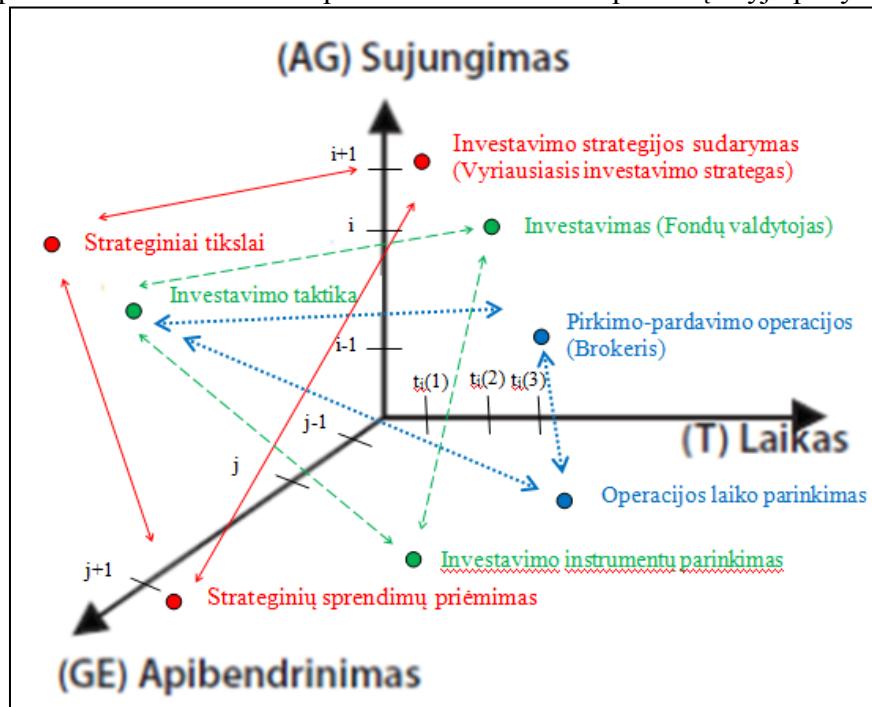
2 pav. Skirtingų tipų modeliai vienoje procesų erdvėje

2 paveiksle pavaizduotas elementarus valdymo ciklas gali būti labai sėkmingai pritaikytas dinaminėms finansų rinkų sistemoms ir jų valdymui modeliuoti. Plokštumoje (AG, T) atvaizduojama pati sistema (jos modelis). Plokštumoje (GE, T) atvaizduojami jos valdymą aprašantys duomenų apdorojimo ir sprendimo priėmimo

modeliai. Plokštumoje (AG, GE) modeliuojami tikslai ir galimi rizikos faktoriai. Toliau atskirai aptariami šie 3 rūšių modeliai.

Žemiau esančiame paveiksle pateikiamas pavyzdys, kaip sprendimų priėmimo proceso modeliai, tikslų modeliai bei pačios valdomos sistemos dinamikos modeliai atvaizduojami ir sujungiami procesų erdvėje. Valdomos sistemos elementai ir juos veikiantys faktoriai tam tikrais laiko momentais tą igyja vis naujas reikšmes, kurias sprendimo paramos sistema analizuoją. Atsižvelgiant į iškeltus tikslus ir rizikos valdymo taisykles priimami valdymo sprendimai.

Toliau pateikiamas investavimo proceso detalizavimo procesų ašyje pavyzdys.

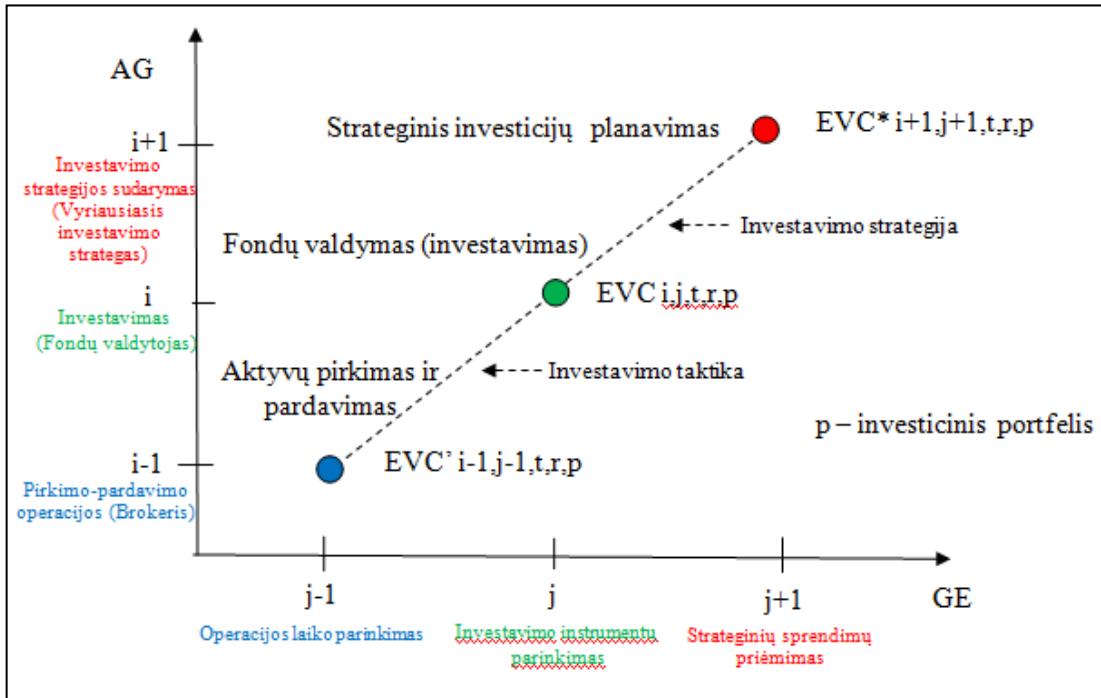


3 pav. EVC komponentai procesų erdvėje

Vyriausiasis investavimo strėgas remdamasis strateginiais tikslais laiko momentu $t_i(1)$ parengia investavimo strategiją $(i+1, j+1)$, kuri bus aktuali visam laiko periodui t_i . Tikslų hierarchija detalizuojama parengiant taktinius tikslus. Jais vadovaujantis fondų valdytojas laiko momentu $t_i(2)$ parenka konkrečius investavimo produktus (akcijas, obligacijas), į kuriuos bus investuojama laiko periodu t_i (i,j). Brokeris atlieka akcijų ir obligacijų pirkimą remdamasis investavimo taktika ir parinkdamas tam tinkamiausią laiką $(i-1,j-1)$. Valdomas objektas – investicinis portfelis.

7 paveiksle visa tai pavaizduota kaip 3 atskirų EVC koordinavimas vienoje plokštumoje. EVC* atitinka strateginį planavimą. EVC žymi fondų valdymo

(investavimo) procesus, EVC' atitinka žemiausio lygio brokerio vykdomų pirkimo-pardavimo operacijų valdymą. Tai atitinka A3.1 koordinavimo tipą [110].



4 pav. Veiklos koordinavimo tipas A3.1

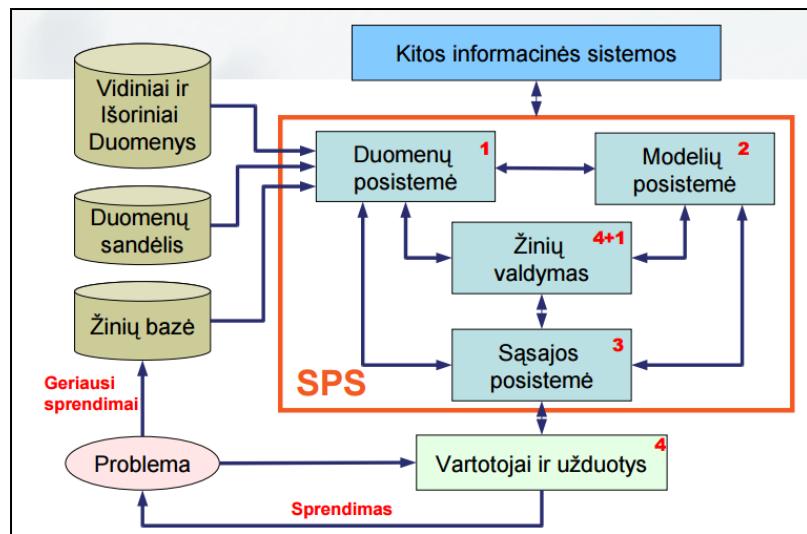
1.2. Modeliavimo metodai

1.2.1. Sprendimo priėmimo modeliavimas

Sprendimo priėmimas (angl. Decision Making – DM) – tai procesas, kurio metu iš kelių galimų racionalių alternatyvų parenkama viena – geriausia. Sprendimų priėmimo fazės [129]:

1. Žvalgybos (įžvalgos, angl. intelligence) fazė. Aplinkos analizė ieškant susidariusių aplinkybių, dėl kurių reikia priimti sprendimus.
2. Projektavimo (analizės, angl. design) fazė. Galimų veiksmų (alternatyvų) sugalvojimas, išvystymas, analizė ir įvertinimas. Problemos supratimas, galimų sprendimų generavimas, sprendimų įgyvendinimo galimumo tikrinimas
3. Pasirinkimo (spr. priėmimo, angl. choice) fazė. Iš visų galimų pasirenkama viena alternatyva. Tas pasirinkimas įgyvendinamas.
4. Įvertinimo fazė. Praeityje padarytų pasirinkimų įvertinimas.

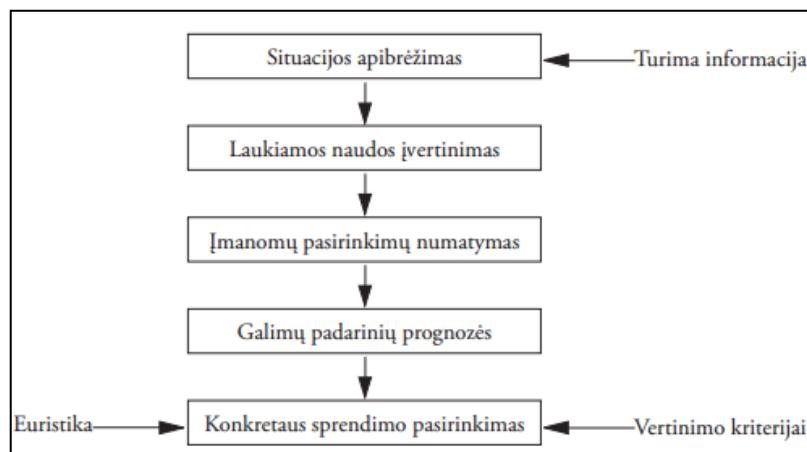
Modeliavimas yra sprendimų paramos sistemų pagrindas. Sprendimų paramos sistemas – tai IS kurios apjungia modelius ir duomenis ir padeda spręsti pusiau struktūruotas problemas (5 pav.). Modelių posistemė apima valdomos sistemas, sprendimo priėmimo proceso bei tikslų modelius.



Šaltinis: http://www.oksl.ktu.lt/studijos/T120B120/slides/iit2010/08_Intel.pdf

5 pav. Sprendimų paramos sistemos architektūra

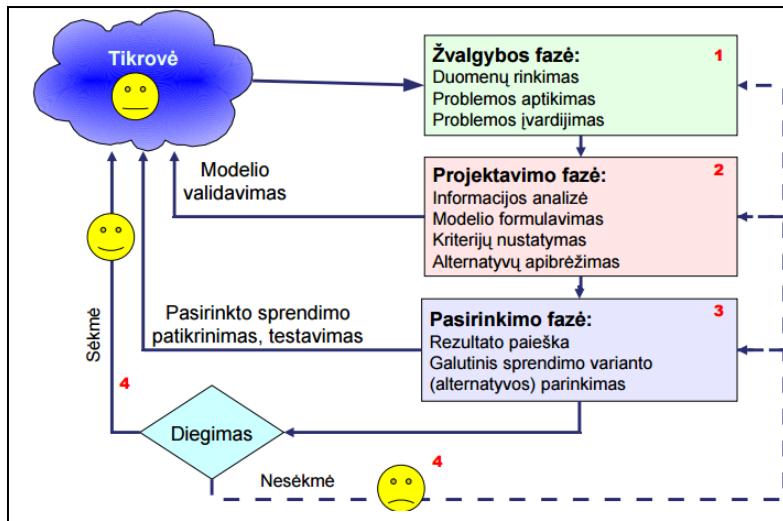
6 pav. pateikiami sprendimo priėmimo proceso etapai. Visus juos turi realizuoti intelektuali sprendmo paramos sistema.



Šaltinis: L. Šarkutė. Sprendimų priėmimo samprata ir tyrimų tradicijos. Sociologija. Mintis ir veiksmas. 2009 [80]

6 pav. Sprendimo priėmimo proceso etapai

7 paveiksle pateiktas detalizuotas sprendimo priėmimo/modeliavimo procesas. Modeliavimo aspektu yra svarbiausia antroji (projektavimo) fazė, kurios metu atliekama informacijos analizė, modelio formulavimas, kriterijų nustatymas, alternatyvų apibrėžimas.



Šaltinis: http://www.oksl.ktu.lt/studijos/T120B120/slides/iit2010/08_Intel.pdf
 pagal E.Turban, J. Aronson. etc. Decision support and business intelligence systems 2007.
 [29]

7 pav. Detaliuotas sprendimo priėmimo/modeliavimo modelis

Daugiakriterinio sprendimų priėmimo metodų pavyzdžiai: porinių palyginimų, Pareto, neraiškiųjų skaičių (Fuzzy). Porinių palyginimų ir neraiškiųjų skaičių metodai tinkamai taikomi tik jei yra baigtiniai leistinai sričiai, t.y. gali būti taikomi tik jei yra baigtiniai alternatyvų skaičius.

Porinių palyginimų metodo atveju ekspertas palygina kiekvieną alternatyvą su kiekvieną ir nusprendžia, kuri iš dviejų alternatyvų yra nuomonė geresnė (galimos ir sprendimas, kad alternatyvos ekvivalenčios). Pareto sprendimų priėmimo metodas grindžiamas vieno kriterijaus – svertinės kriterijų sumos formavimu. Neraiškiųjų skaičių metodas eksperto pažiūriu sudėtingiausias, nes ekspertui tenka nurodyti ne tik vidutinius įverčius, bet ir jų minimalias bei maksimalias reikšmes. [1]

1.2.2. Valdomos sistemos procesų imitacinis modeliavimas

Modelis – tai abstrakti konstrukcija, kuria mėginama atkartoti kai kurias realios sistemas savybes. Tuomet, kai modeliavimas su realiomis sistemomis yra arba labai brangus, arba pernelyg sudėtingas, i pagalbą galima pasitelkti kompiuterinį modeliavimą, dar vadinamą tiesiog imitaciniu modeliavimu [68].

1.2.2.1. Imitacinis procesų modeliavimas

Imitacinis modeliavimas apima skaičiavimo ir matematikos metodus modeliuojant, imituojant ir analizuojant įvairių sistemų funkcionavimą. Tikslas yra įžvalga, geresnis sistemas ar jos dalies pažinimas, jos funkcionavimo supratimas bei

reagavimas į pokyčius, priimant sprendimus ir aptinkant galimas tiriamos sistemos silpnas vietas, įvairių vidinių ir išorinių veiksnių poveikio mąstą [68].

Imitacino modeliavimo etapai [68]:

1. Apibrėžti tiriamos sistemos ar jos dalies analizės **tikslus** ir **uždavinius**.
2. Sudaryti **koncepcionalų modelį** atsižvelgiant į tiriamai sistemai iškeltus tikslus.
3. Konvertuoti konceptualų modelį į **loginį (specifikacijų) modelį**.
4. Igyvendinti specifikacijos modelį kompiuteryje, taip sukuriant **imitacinių (skaičiuojamajų) modelių**.
5. **Verifikuoti** - realizuotas skaičiuojamas modelis turi atitikti sudarytas specifikacijas.
6. **Validuoti** – patikrinti ar realizuotas imitacinis modelis atitinka tiriamą realią sistemą.

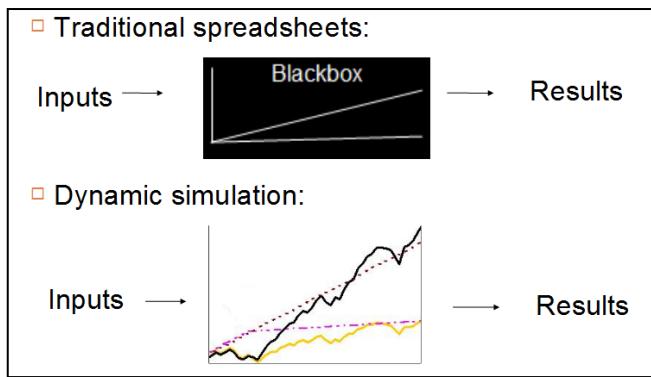
Dinaminį sistemų imitacinis modeliavimas artimas žiniomis grindžiamai IS inžinerijai. Žiniomis grindžiamoje kompiuterizuotoje IS inžinerijoje informacijos sistema kuriama naudojant ir veiklos žinių bazėje saugomas dalykinės srities žinias (veiklos modelį).

Vidinio modeliavimo atveju analitikas naudoja apriori žinias - žino objektyvizuotą (mokslinę) informaciją, mokslo sukauptas žinias apie realybės srities dėsningumus [51] (11 pav.).

Šiuo atveju analitikui (stebėtojui) modeliuojamos sistemos ar modeliuojamos sistemos dalis yra „balta dėžė“, kurios esminius elementus ir jų tarpusavio sąveikas apibrėžia nagrinėjamos realybės srities dėsningumas [51].

Vidinio modeliavimo atveju analitikas identifikuja priežastinius veiklos procesų ryšius, t.y. įvardina būtiną ir pakankamas veiklos elementų (materialių, informacinių procesų ir struktūrinių informacijos vienetų) dedamąsias ir jų sąveikas (ieško elementų, kurie atitinka analitiko žinias apie nagrinėjamos realybės srities dėsningumą) [50].

Išorinio modeliavimo atveju gauname tik „juodąją dėžę“, kurios pagalba galime matyti tik jėjimo kintamuosius ir rezultatus. Tuo tarpu vidinis modeliavimas leidžia į sistemą pažvelgti iš vidaus: galima analizuoti kaip gaunami šie rezultatai, kaip keičiasi sistemos elementų būsenos, kokią įtaką sistemos elementai daro galutiniam rezultatui ir vienas kitam.



Šaltinis: sudaryta autoriaus

8 pav. Vidinio ir išorinio modeliavimo skirtumai

8 pav. pateikti vidinio ir išorinio modeliavimo atveju gaunamų rezultatų skirtumai. Pvz., simuliujant investavimo į fondus procesą, matome ne tik galutinę investicijų vertę, bet ir jos kitimą per visą investavimo laikotarpį bei kaip kintą ją įtakojantys veiksnių.

1.2.2.2. Sistemų dinamika (priežastinių kilpų ir srautų-talpų diagramos)

Šiame skyriuje toliau detaliai analizuojami sistemų dinamikos modeliavimo metodai. Jame pateikiami Sauliaus Norvaišo ir Vaidoto Sruogio Sistemų dinamikos kurso medžiagos pagrindiniai aspektai (visą medžiagą galima rasti <http://www.culture.lt/science/SD/>). Taip pat remiamasi tinklapyje http://studento.vikis.lt/wiki/index.php/Sistem%C5%BD_dinamika esančia informacija.

Sistemų dinamikos sąvoka

Viena iš daugelio mokslo sričių, gvildenančių kitimo uždavinius, yra **sistemų dinamika (SD)**. Ji remiasi daugelio kitų mokslų - tiek matematikos ir gamtos, tiek ir socialinių - pasiekimais.

Sistemų dinamika – tai metodologija, skirta realių sistemų aprašymui ir analizei. Tai taikomasis mokslas, kurio paskirtis yra suprasti sistemų elgseną. Žodis “dinaminis” numano nuolatinį kitimą, o viena iš pagrindinių dinaminių sistemų ypatybių ir yra nuolatinis keitimasis. Forrester (1961) metodologiškai pagrįsta sistemų dinamika yra matematinio modeliavimo kryptis, kurioje akcentuojama taikomųjų modelių sudarymo pusė. Tai reiškia, kad rezultatas turi būti sistemos modelis, maksimaliai atitinkantis realią (dažnai sudėtingą) sistemą.

Toks sistemų aprašymas panaudojant minimalias matematikos žinias bei kompiuterius leidžia imituoti (kitaip sakant - mègdžioti) realaus pasaulio sistemų elgseną, duoda galimybę eksperimentuoti nesikišant į pačią realią sistemą, jos

nepakeičiant ir nepažeidžiant natūralios jos būsenos. Dar daugiau - eksperimentuodami galime ne tik geriau suprasti, kaip ir kodėl sistemoje vyksta vienokie ar kitokie procesai, bet ir atrasti būdus tiems procesams valdyti bet patobulinti [113].

Ši metodologija naudoja imitavimo modelius tam, kad nustatytu ryšį tarp sistemos struktūros ir jos elgsenos kitimo laike. Tai yra galinga priemonė norint suprasti sudėtingas problemas: užuot stengiantis mintyse susieti kelis veiksnius, galima naudoti informacines technologijas formalizuojant ir apjungiant pakankamai daug idėjų, prielaidų ir imituoti jų raidą laike [121].

Priežastys ir pasekmės

Sistemų dinamika leidžia analizuojant kokį nors reiškinį nuosekliai atrasti ir išskirti pagrindinius priežastinius- pasekminių sąryšius, esančius tarp viso reiškinio sudedamujų dalių. Priežastinio mąstymo organizavimas turi savo metodiką, etapus, tikslus ir t.t [113].

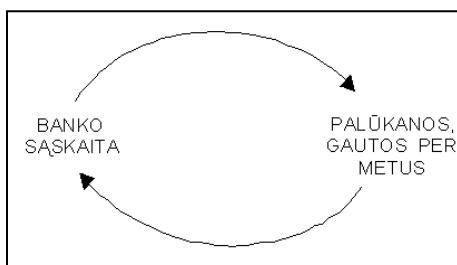
Grafinis priežastinių ryšių vaizdavimas

Dinaminis reiškinys yra kurio nors kintamo dydžio pasikeitimas, įtakotas kitų reiškinių. Norint supaprastinti bei aiškiau pavaizduoti kintančius reiškinius (dinamiškas sistemos), yra naudojamos **grafinės diagramos**. Jos padeda matyti bendrą reiškinių sąryšių “paveikslą”, arba struktūrą. Be to šios diagramos palengvina reiškinių analizę ir supratimą [113].

Priežastinės linijos (kilpos) diagramos

Dažnai vieno reiškinio pasekmė yra priežastis, sukelianti kitą pasekmę. Tokią uždarą priežastinių ryšių grandinę vadiname grįžtamuoju ryšiu, arba kilpa. Kilpos nebūtinai turi būti sudarytos tik iš dviejų kintamujų. Iš tiesų kilpa gali turėti kiek norima daug kintamujų. Svarbu tai, kad jos padėtų geriau suprasti reiškinio esmę, bet nesukeltų painiavos [113].

Pavyzdys, kuriame atsiranda **priežastinė kilpa**, yra pinigų sumos kitimas banko sąskaitoje dėl mokamų palūkanų:



Šaltinis: <http://www.culture.lt/science/SD/sd.htm>

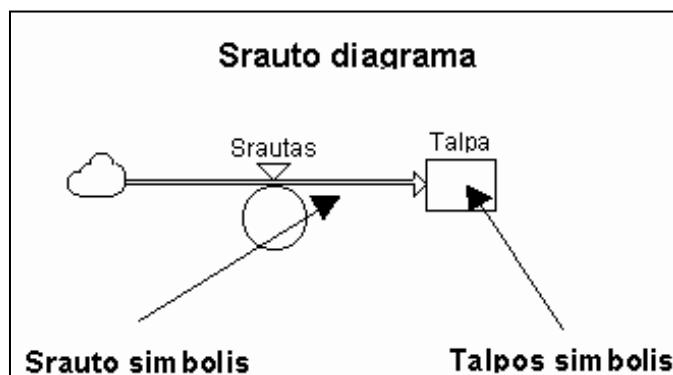
9 pav. Priežastinė kilpa

Struktūros ir elgsenos modeliavimas

Modeliai naudojami, norint aprašyti sistemos sandarą arba, kitaip sakant, struktūrą bei jos elgseną. **Dinaminiai modeliai** yra funkcinių modelių grupė, kurie gali atspindėti sistemos pokyčius arba vystymasi laikui bėgant. Kilpa, arba grįztamasis ryšys, yra pagrindinė tokio modelių savoka [113].

Sistemos struktūra: talpos ir srautai

Norint sudaryti sistemos modelį, naudojami “statybiniai blokai”, kurie vadinasi talpomis ir srautais. Talpa yra sistemos elementas, kuris išlieka pastovus iki tol, kol jo nepakeičia jeinantis ar išeinantis srautas. Srautas aprašo medžiagos arba informacijos judėjimą tarp talpų. Srautai ir talpos yra tarpusavyje sujungiami tam tikru būdu ir sudaro modeliuojamos sistemos struktūrą. Galima laikyti, kad kiekviena sistema turi struktūrą, kuri nusako sistemos elgseną laike [113].



Šaltinis: <http://www.culture.lt/science/SD/sd.htm>

10 pav. Srauto-talpos diagramma

Sistemos elgsenos imitavimas

Norint modelį “atgaivinti” ir pažiūrėti, kaip jis elgiasi, juo reikia atliki imitavimą. Modelio sudarymo tikslas yra struktūros sukūrimas, t.y. toks srautų ir talpų sujungimas, kuris leidžia atkartoti realios sistemos, kurią modeliuojame, elgseną. Taigi modelis imituoja realią sistemą, jos elgseną. Sudarkius tokį modelį galima su juo (o ne su realia sistema) atliki įvairius eksperimentus ir sužinoti, kaip reali sistema funkcionuoja [113].

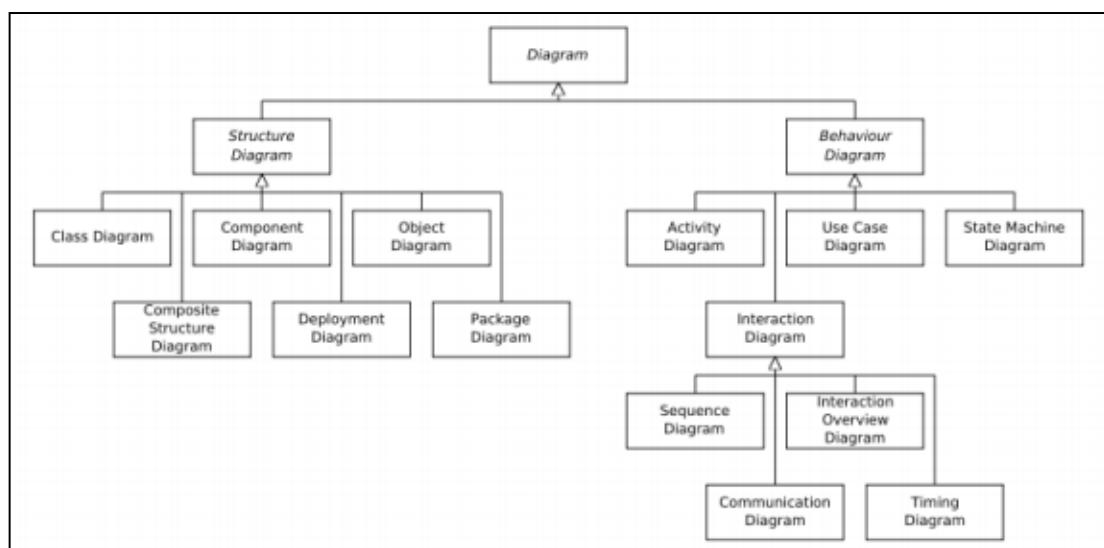
Kad kompiuteris galėtų suprasti sudarytą modelį, visų pirma reikia pasinaudojant imitavimo įrankio priemonėmis nubraižyti modelio talpų ir srautų diagramą. Po to apibrėžiamas kiekvienas diagramos kintamasis arba priskiriant jam konkrečią reikšmę, arba aprašant jį matematine formulę. Toks apibrėžimas kompiuteriui nurodo, kokia yra kintamojo pradinė reikšmė (jei tai yra talpos

kintamasis), arba koks talpos pasikeitimo dydis per laiko vienetą (pavyzdžiui, kiek litrų vandens pratekės pro čiaupą per vieną minutę) [113].

Sistemų modeliavimui ir jų elsenos imitavimui skirta programinė įranga yra apžvelgiama 4 skyriuje.

1.2.2.3. Objektinis sistemų modeliavimas (UML diagramos)

UML projektuotojams pateikia aibę notacijų ir semantiką informacinių sistemų statiniams, dinaminiams ir elgesio aspektams modeliuoti. Pavyzdžiui UML palaiko penkias notacijas sistemos dinamikai modeliuoti. Dvi iš jų yra veiklos ir būsenų diagramos. Naudojant veiklos diagramą galima modeliuoti darbų sekas, kurios pakeičia sudėtinių veiklos objektų, tokį kaip draudimo ieškiniai, banko sąskaitos, statusą. Naudojant būsenų diagramą galima pavaizduoti kaip darbai sudėtiname darbų sekų modelyje keičia atskirų atvejų, draudimo ieškiniai ar bankų sąskaitų, būseną. Šios kelių dimensijų panaudojimo perspektyvos leidžia apibūdinti sistemą iš skirtingų požiūrių ir padeda atvaizduoti šiuolaikinių sistemų sudėtingas savybes (11 pav.) [60].



Šaltinis: <http://jucmnav.softwareengineering.ca/ucm/pub/UCM/VirLibAbidMScThesis/AbidThesis-Final.pdf>

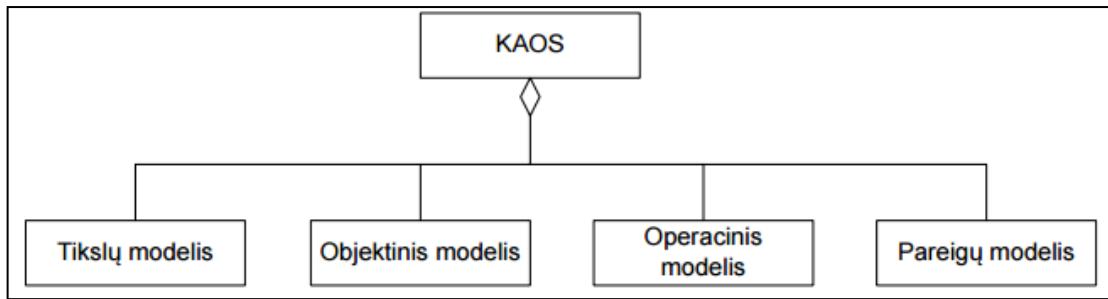
11 pav. UML diagramos

1.2.3 Tikslų ir rizikos modeliavimas

Tikslų modeliavimui gali būti panaudojamos UML, KAOS bei GRL metodikos.

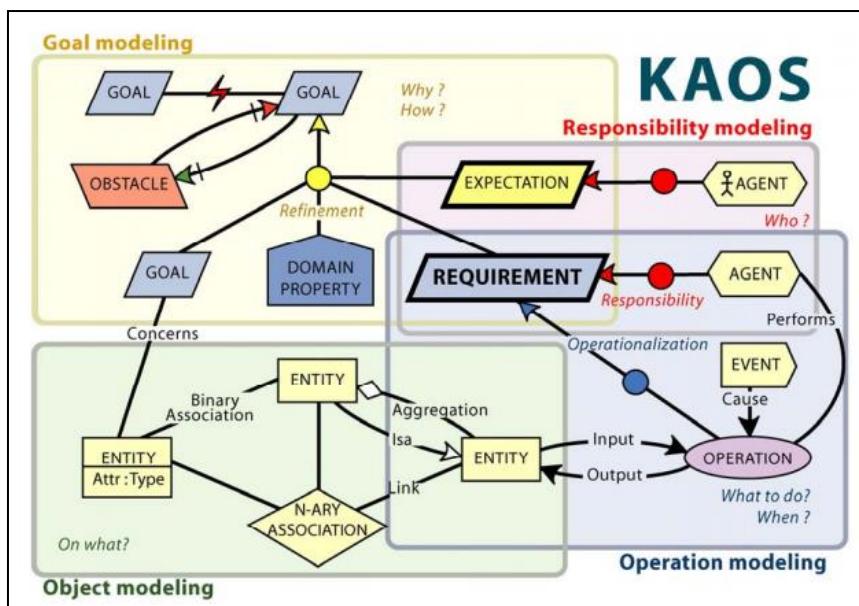
KAOS objektinis modelis

Kaos metodika apima 4 tipų modelius: tikslų, objektinių, operacinių, pareigų (18 pav.):



12 pav. KAOS modelių schema

13 pav. pateiktas KAOS meta-modelis bei vaizdavimo notacija.



Šaltinis: <http://www.objectiver.com/fileadmin/download/documents/KaosTutorial.pdf> [107]

13 pav. KAOS meta-modelis

GRL metodika

URN yra pirmas tarptautinis standartas skirtas verslo tikslų, verslo scenarijų ir ryšių tarp jų atvaizdavimui grafiniu būdu [109]. Jis apima:

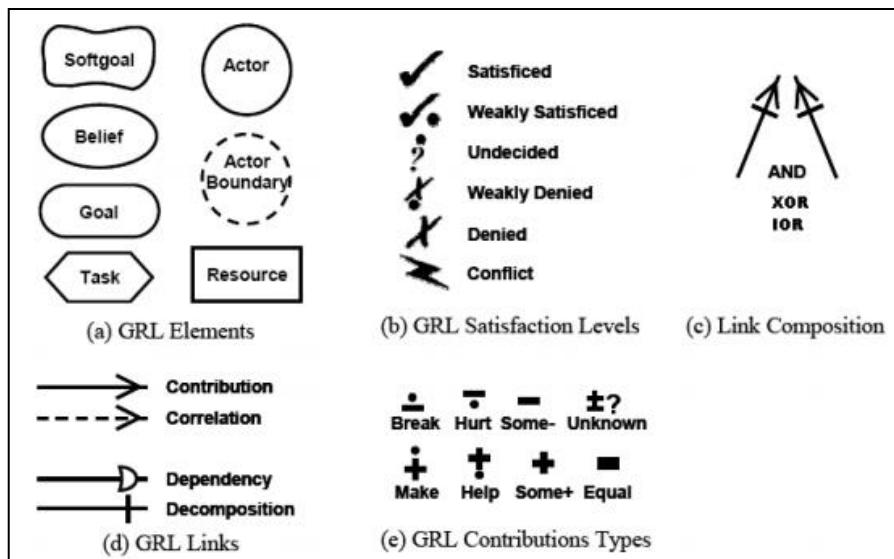
- GRL (angl. Goal-oriented Requirement Language -GRL) yra grafinė(vizuali) notacija skirta modeliuoti skirtingų suinteresuotų šalių verslo tikslams, nefunkciniams reikalavimams. Ji parodo konfliktuojančių reikalavimų poveikį bei galimus alternatyviusprendimus, kurie gali būti naudojami verslo tikslams pasiekti.
- UCM (angl. Use Case Maps) yra grafinė (vizuali) notacija skirta sistemos komponentų veiklos scenarijų analizei. Analizuojama sistemos komponentų

struktūra siekiant išsiaiškinti, kaip komponentų struktūros pokyčiai paveiktu nefunkcinius reikalavimus bei realizuojamus verslo scenarijus.

GRL skirsto savo modeliavimo elementus į 3 pagrindines grupes [95]:

- Tikslų elementas (angl. „intentional elements“) - skirtas modeliuoti susijusių šalių (angl. „stakeholders“) tikslus ir interesus. Yra penki šio elemento tipai: Softgoal, Goal, Task, Resource ir Belief..
- Aktorius (angl. „actor“) – susijusi šalis (angl. „stakeholders“)
- Ryšys (angl. „link“) - skirtas sujungti tikslus ir susijusias šalis (angl. „stakeholders“) bei atskleisti jų tarpusavio priklausomybes [95].

14 pav. pateikiama GRL tikslų modelio notacija.



Šaltinis: <http://jucmnav.softwareengineering.ca/ucm/pub/UCM/VirLibAbidMScThesis/AbidThesis-Final.pdf>

14 pav. GRL notacija

GRL gali būti sėkmingai integruota į UML sukuriant specialų UML profilį, skirtą tikslų modeliavimui (22 pav.). Tokiu būdu tikslų diagramos ir jų elementai gali būti susieti su kitomis UML diagramomis. Profilio kūrimui panaudojami tokie konstruktai, kaip „stereotype“, „tagged value“, „constraints“ [95].

Negalima teigti, kad UML neleidžia modeliuoti tikslų ar veiklos taisyklių. Yra daug būdų pavaizduoti veiklos taisykles UML kalboje. Problema yra ta, kad UML nespecifikuja veiklos taisyklių ar tikslų kaip atskiro elemento modelių kūrimo bloke – unikalios modeliavimo elemento klasės. GRL integravimas su UML šią problemą išsprendžia.

2. DUOMENŲ ANALIZĖS METODAI

Šio skyriaus tikslas yra aprašyti metodus, tinkamus finansinių duomenų analizei.

2.1. Daugamačių duomenų projekcijos metodai

Šių metodų tikslas yra transformuoti daugamačius duomenis į mažesnio skaičiaus matmenę erdvę, išlaikant pradinių duomenų struktūrą. Duomenis transformavus į dvimatę erdvę ir juos vizualizavus galima geriau suprasti duomenų pasiskirstymą.

Tiriamas objektas – biržoje kotiruojamų įmonių akcijos. Analizuojami tokie įmonių finansiniai rodikliai: akcijos kainos pokytis, ilgo laikotarpio augimo tendencijos, P/E ir P/B rodikliai, pajamos, vidinių ir institucinių investuotojų dalis, ekspertų rekomendacija.

Metodų bandymams naudojami du duomenų rinkiniai. Pirmame yra 8 kriterijai ir 111 įmonių. Šiame duomenų rinkinyje nėra aiškaus įmonių pasiskirstymo į grupes. Antrajame rinkinyje yra 6 kriterijai ir 61 įmonė. Ši duomenų rinkinį sudaro trijų grupių įmonės (turinčios gerus, vidutinius ir prastus rodiklius). 15 pav. pateiktas antro duomenų rinkinio fragmentas.

Price Change 4 Weeks	Average Recmd.	Long Term Growth Rate Mean	P/E	Qtrly Price To Book	TTM Return On Avg. Equity	Ivertinimas
20,00	1,38	21,50	7,00	2,18	30,05	1
15,00	1,48	21,50	5,00	2,27	30,05	1
20,00	1,58	25,50	5,00	2,36	35,05	1
20,00	1,68	28,50	8,00	2,45	25,00	1
...
2,00	1,51	14,50	10,96	1,96	23,61	0
3,00	1,32	12,50	10,96	1,02	10,61	0
...
-3,83	2,34	2,00	24,68	3,44	14,87	2
-2,33	2,21	4,00	24,75	3,44	14,57	2
-0,83	2,40	5,00	22,75	2,93	14,27	2

15 pav. Analizuojami duomenys

2.1.1 Principinių komponenčių analizės metodas

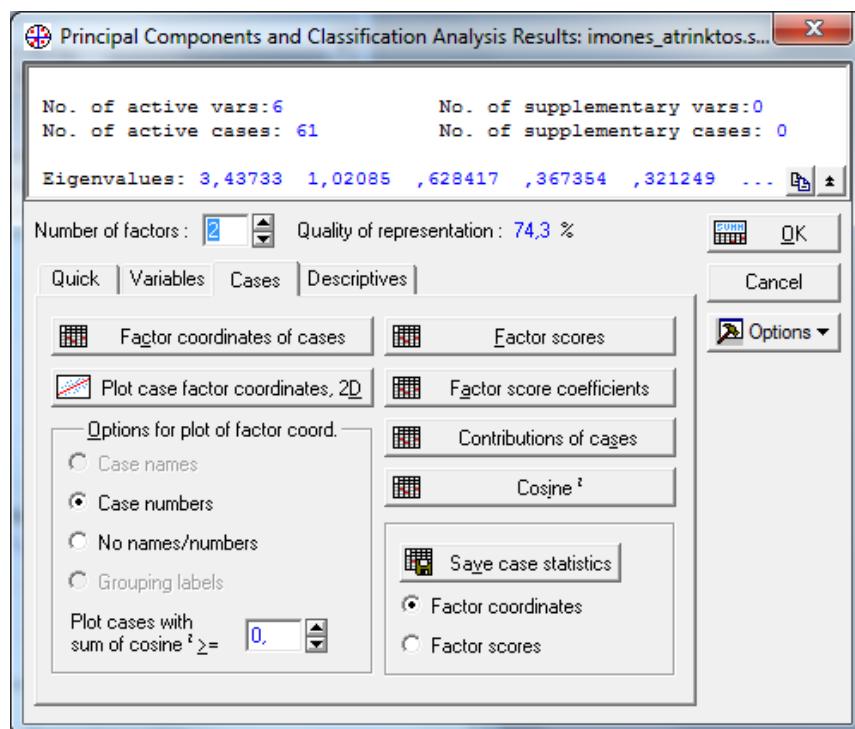
Principinių komponenčių analizės metodas (PKA) leidžia sumažinti duomenų matmenų skaičių atliekant tiesinę transformaciją. Jos metu atsisakoma dalies po transformacijos gautų naujų komponenčių, kurių dispersijos yra mažiausios [40]. Analizei naudojama Statistica v.7 programa.

Visų pirmą metodą buvo išbandytas su pirmu duomenų rinkiniu. Tačiau šiuo atveju pirmosios dvi komponentės reprezentuoja tik 50 % visos dispersijos (16 pav.). Norint pasiekti daugiau nei 80% duomenų atvaizdavimo tikslumą tektų naudoti pirmas 5 komponentes.

Value number	Eigenvalues of correlation matrix, and related statistic Active variables only			
	Eigenvalue	% Total variance	Cumulative Eigenvalue	Cumulative %
1	2,195888	27,44860	2,195888	27,4486
2	1,483903	18,54879	3,679791	45,9974
3	1,265943	15,82429	4,945735	61,8217
4	0,989125	12,36406	5,934860	74,1857
5	0,850996	10,63745	6,785856	84,8232
6	0,660337	8,25421	7,446193	93,0774
7	0,473330	5,91662	7,919522	98,9940
8	0,080478	1,00597	8,000000	100,0000

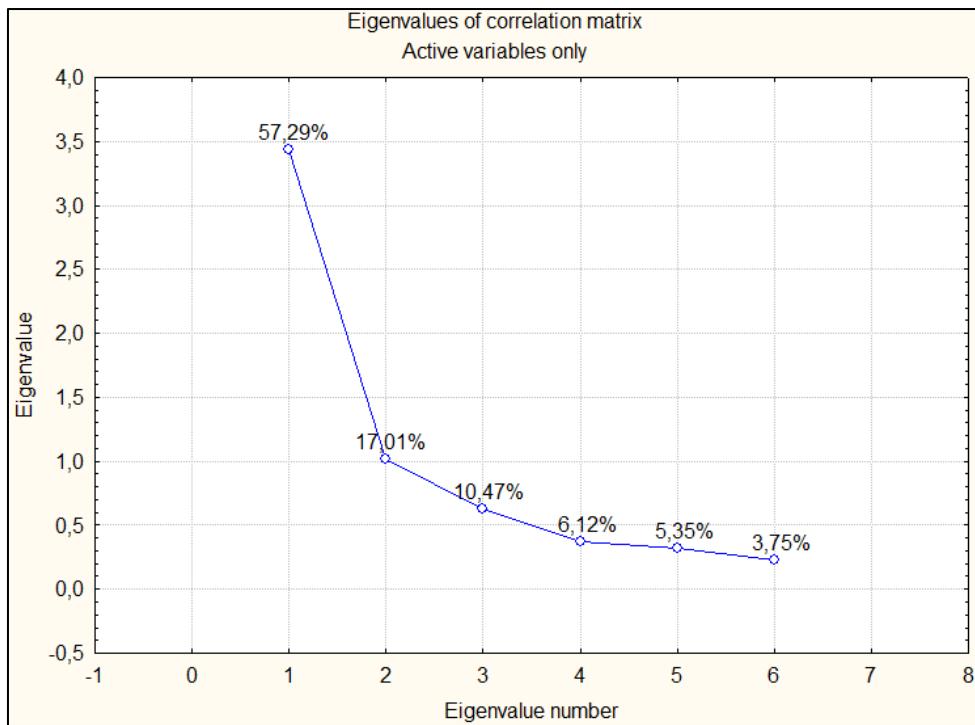
16 pav. Tirkinių vektorių sukauptos reikšmės

Tą patį metodą pritaikius antrajam duomenų rinkiniui buvo gauti žymiai geresni rezultatai. Šiuo atveju dvi pagrindinės komponentės reprezentuoja 74,3% visos dispersijos (17 pav.).



17 pav. PKA analizė su Statistica

18 pav. pateiktos pagrindinių komponenčių (tirkinių vektorių) reikšmės ir jų reprezentuojama dispersijos dalis.



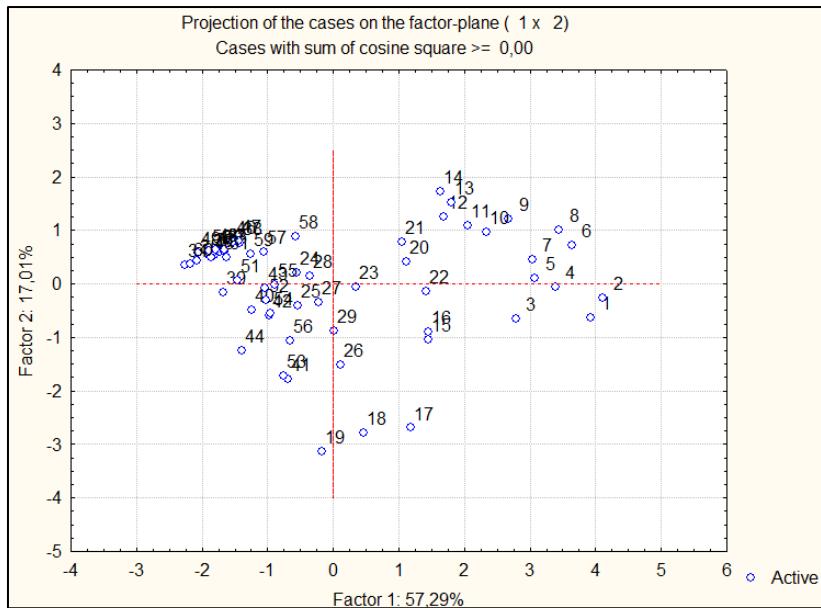
18 pav. Tirkinių vektorių reikšmės

19 pav. galime matyti, kad šiuo atveju užtenka naudoti 3 komponentes, kad būtų išlaikytas 85% atvaizdavimo tikslumas.

Value number	Eigenvalues of correlation matrix, and related statistic Active variables only			
	Eigenvalue	% Total variance	Cumulative Eigenvalue	Cumulative %
1	3,437334	57,28889	3,437334	57,2889
2	1,020853	17,01422	4,458187	74,3031
3	0,628417	10,47361	5,086604	84,7767
4	0,367354	6,12257	5,453958	90,8993
5	0,321249	5,35415	5,775207	96,2534
6	0,224793	3,74655	6,000000	100,0000

19 pav. Tirkinių vektorių sukauptos reikšmės

20 pav. visi duomenys atvaizduoti dvimatėje erdvėje. Galime matyti, jog gerus rodiklius turinčios įmonės (pažymėtos mažesniais skaičiais) atskiria nuo turinčių blogesnius rodiklius (pažymėtos skaičiais nuo 26 iki 61).



20 pav. Duomenys dvimatėje erdvėje

21 pav. pavaizduotos tikrinių vektorių reikšmės.

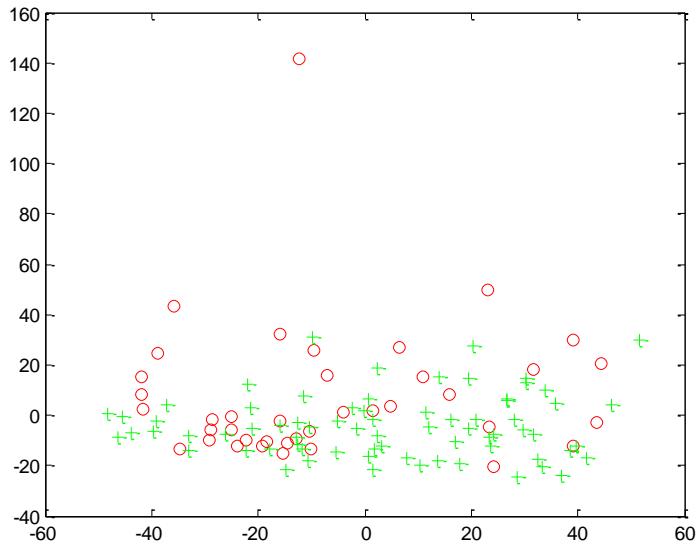
Variable	Eigenvectors of correlation matrix (imones_atrinktos.sta) Active variables only					
	Factor 1	Factor 2	Factor 3	Factor 4	Factor 5	Factor 6
Price Change 4 Weeks	0,448426	0,100517	-0,540947	0,043141	-0,170120	0,682191
Average Recmd.	-0,390864	0,338496	-0,665033	-0,175042	-0,327131	-0,390798
Long Term grth Rate Mean	0,454531	0,167458	-0,280755	0,495043	0,482170	-0,457144
P/E	-0,460105	-0,071115	-0,272122	-0,177917	0,766677	0,299579
Qtrly Price To Book	-0,263016	0,789843	0,295606	0,384492	0,004915	0,267823
TTM Return On Avg. Equity	0,398330	0,467296	0,157644	-0,736847	0,209138	-0,106934

21 pav. Tirkinių vektorių reikšmės

2.1.2. Daugiamatės skalės

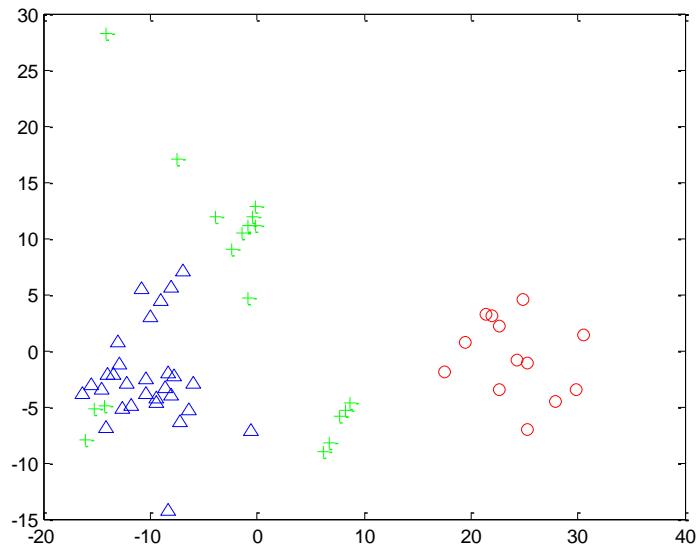
Tai netiesinės projekcijos metodai, kuriais ieškoma daugiamatių duomenų projekcijų mažesnio skaičiaus matmenų erdvėje, siekiant išlaikyti panašumus arba skirtingumus. Gautuose vaizduose panašūs objektai išdėstomi arčiau vieni kitų, o skirtini – toliau vieni nuo kitų [40]. Šio metodo pritaikymui naudojama Matlab programinė įrangą. Skirtingumo matas – Euklido atstumai.

22 pav. pateikti pirmo duomenų rinkinio duomenys, atvaizduoti dvimatėje erdvėje. Raudonais apskritimais pažymėtos įmonės, ekspertiškai įvertintos kaip tinkamesnės investavimui, tačiau grafike tokio aiškaus pasiskirstymo nesimato.



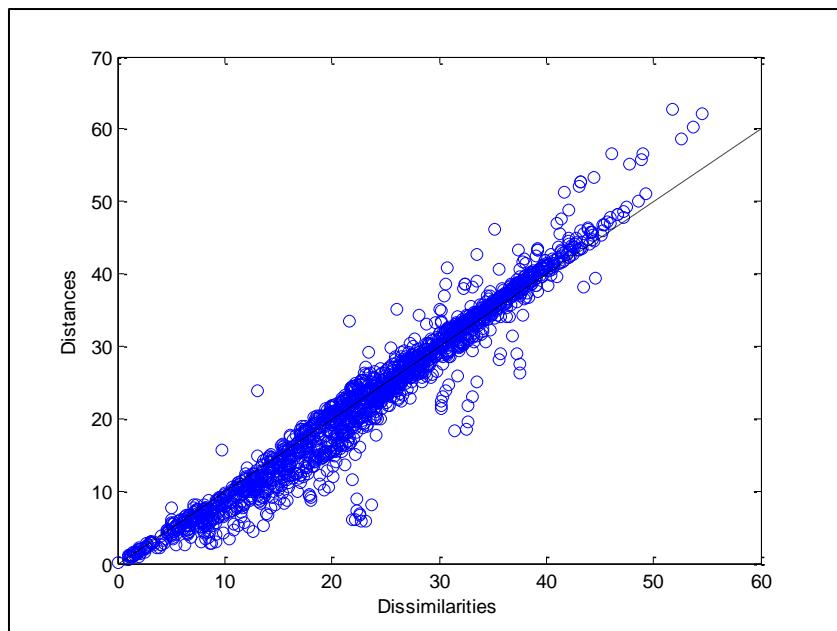
22 pav. Duomenys apdoroti MDS metodu

Tą patį metodą pritaikius antrajam duomenų rinkiniui galime matyti aiškiai atsiskyrusį geresnius rodiklius turinčių įmonių klasterį (raudoni apskritimai) (23 pav.). Blogesnės įmonės (trikampiai) irgi sudaro atskirą grupę grafike, o vidutinės (kryžiukai) išsibarstė labiau.



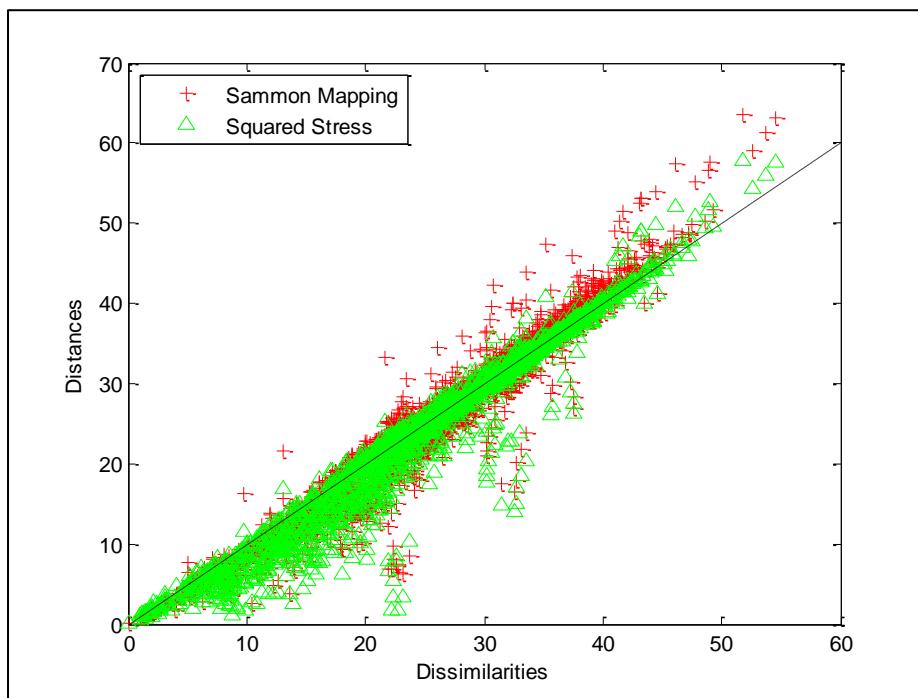
23 pav. MDS metodu atskirti klasteriai

24 pav. pavaizduota diagrama atskleidžia kaip tiksliai pradiniai duomenys buvo atvaizduoti dvimatėje erdvėje. Tikslumas yra geras, nes dauguma taškų (žymi pradinių ir dvimačių vektorių atstumus) yra išsidėstę ant tiesės.



24 pav. Pradinių vektorių ir dvimačių vektorių atstumai

Papildomai buvo pritaikyti Sammon ir Squared Stress projekcijos iškraipymo minimizavimo metodai (25 pav.). Galime pastebėti, jog esant didesniems atstumams tarp pradinių vektorių jie tiksliau atvaizduojami dvimatėje erdvėje naudojant Squared Stress metodą.



25 pav. Sammon mapping ir Squared Stress metodų palyginimas

2.2. Neuroninių tinklų taikymas duomenų analizei

2.2.1. Duomenų vizualizavimas ir analizė naudojant SOM

2.2.1.1. Vizualizavimas naudojant Viscovery Somine

Darbo tikslas yra išbandyti SOMine programinę įrangą klasterizujant biržoje kotiruojamus vertybinius popierius ir surasti labiausiai investavimui tinkamas akcijas. Analizei naudojama Viscovery Somine programinė įranga.

Analizuojami 111 kompanijų duomenys, klasterizavimui naudojami tokie kriterijai: akcijos kainos pokytis, ilgo laikotarpio augimo tendencijos, P/E ir P/B rodikliai, pajamos, vidinių ir institucinių investuotojų dalis, ekspertų rekomendacija. 26 pav. pateiktas duomenų fragmentas.

	Price% Change 4 Weeks	Average Recmd.	Long Term Grth Rate Mean	P/E	Qtyly Price To Book	TTM Return On Avg. Equity	Insider Ownership Percent	Institutional Percent Held
1	29,56	1,71	21,5	19,76	1,91	11,99	35,63	58,18
2	19,85	1,25	14,33	15,98	1,65	11,16	29,54	67,81
3	6,27	1,82	16,83	15,43	3,89	30,05	25,04	90,02
4	11,71	2	14,33	12,17	1,5	13,79	28,1	61,69
5	6,51	2,06	21,25	18,69	2,86	17,89	27,86	74,4
6	1,06	2	14,1	12,9	1,65	14,02	31,26	17,88
7	1,56	1	17	10,89	1,33	15,63	26,46	16,31
8	25,06	2	12,4	10,84	2,18	22,88	26,94	51,71
9	6,21	1,71	21	12,49	2,35	22,4	40,82	95
10	7,08	2,25	15,67	10,13	1,57	17,81	62,93	57,58

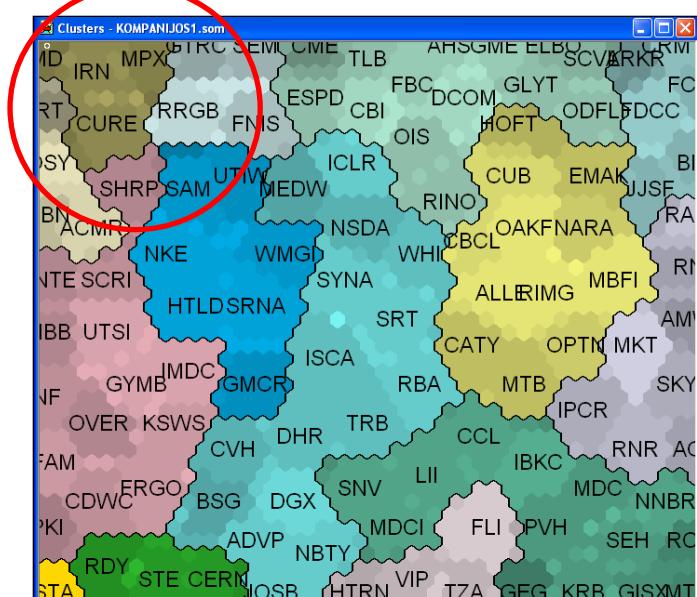
26 pav. Analizuojami duomenys

Visų pirma atliekamas kompanijų klasterizavimas. Kitame etape reikia nustatyti, kurio klasterio įmonių akcijos yra tinkamiausios investavimui. 27 pav. parodyti vieno iš klasterių parametrai.

Values - KOMPANIJOS1					
Range:	Cluster	X: 3	Y: 1	Nodes: 63	C 10
Component	Mean	Std. deviation	Minimum	Maximum	Sum
Price% Change 4 Weeks	6,96	6,32	1,38	19,57	34,25
Average Recmd.	1,148	0,182	1,000	1,665	4,330
Long Term Grth Rate Mean	28,17	5,15	20,00	35,50	115,50
P/E	13,19	2,70	8,97	20,93	48,08
Qtyly Price To Book	2,581	0,659	1,790	3,450	10,510
Qtyly LT Debt To Tot. Equity	0,0058	0,0291	0,0000	0,2047	0,0000
TTM Return On Avg. Equity	28,2	12,8	14,5	48,9	125,0
Insider Ownership Percent	46,89	8,82	32,31	72,85	178,11
Institutional Percent Held	41,50	14,29	14,89	64,18	137,83
Frequency	0,06349	0,2438	0	1	4
Quantization error	0,0000000...	0,000000000...	0,000000000...	0,000000000...	0,000000000...
L1 Matrix	0,422	0,393	0,000	1,327	26,559
Curvature	0,655	0,221	0,128	1,121	41,272

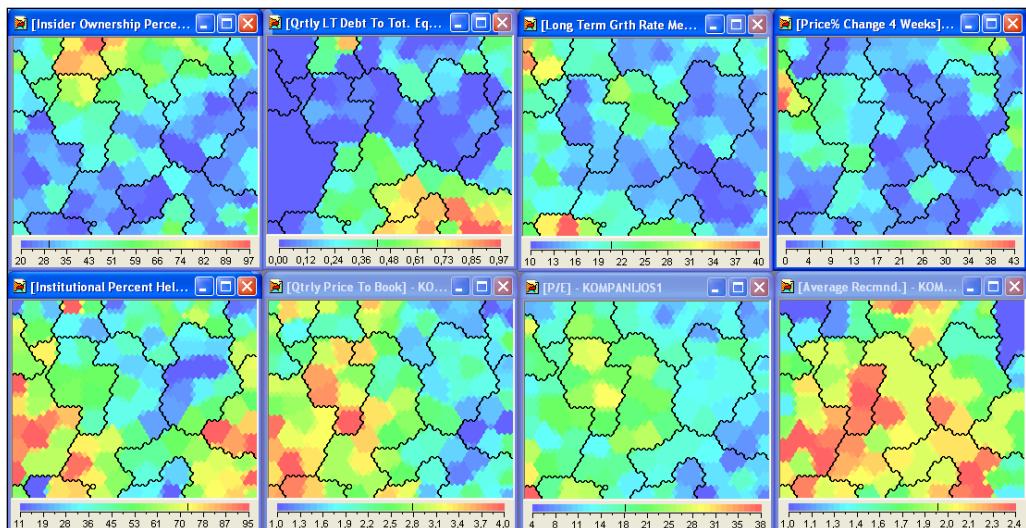
27 pav. Parametrai

Siekant išskirti geriausią klasterį buvo pasirinktas sudėtinis kriterijus: mažesnis P/E, geresnė analitikų rekomendacija, ilgo laikotarpio augimo perspektyva, didesnis ROE. Kompanijos suskirstytos į 14 klasterių ir iš jų išskirtas geriausias. (28 pav.).



28 pav. Išskirtas geriausias klasteris

Tikslas yra surasti įmonių, kurių kaina nėra išpūsta, kurios turi stabilias pajamas ir geras ateities perspektyvas. Geriausiai šiuos kriterijus atitiko pažymėtas klasteris. 29 paveiksle pavaizduota atskirų komponentų įtaką geriausiam klasteriui.

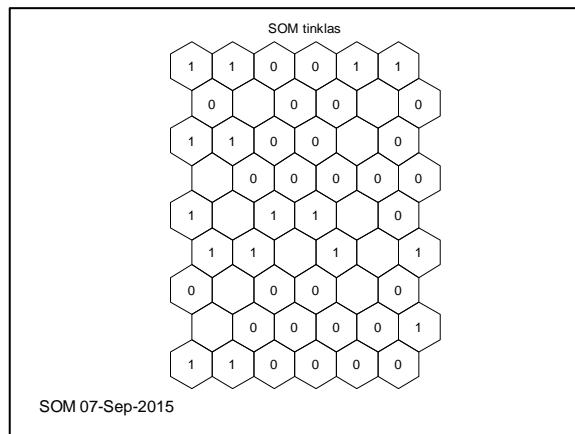


29 pav. Komponentų įtaka

Analizuojant pasirinktą klasterį pagal atskirus komponentus, matyti kad labiausiai iš visų klasterių jis išsiskiria pagal teigiamą analitikų rekomendaciją. Taip pat matyti ilgo laikotarpio augimo potencialias yra didesnis nei kitų, o P/E rodiklis taip pat žemesnis už didelę dalį kitų įmonių. Kiti rodikliai pasirinkto klasterio yra taip pat geri, tačiau taip smarkiai neišsiskiria iš bendro konteksto.

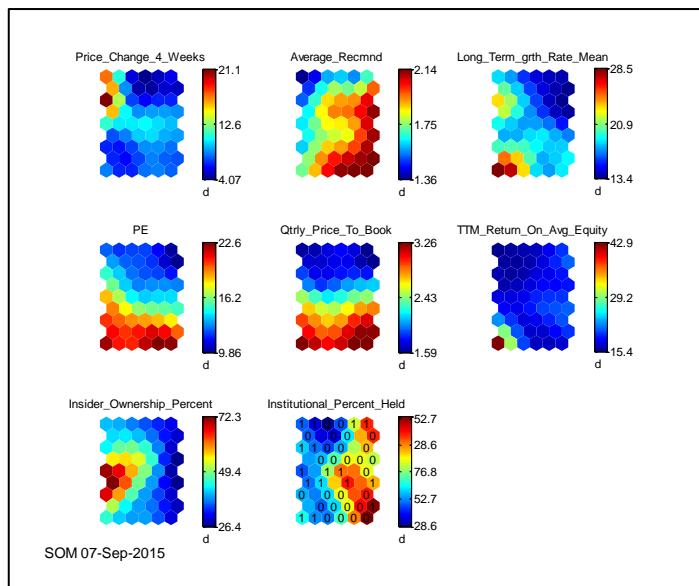
2.2.1.2. Vizualizavimas naudojant Matlab

Tiems patiemis duomenims sukurtas SOM tinklas naudojant Matlab programinę įrangą ir SomToolbox biblioteką. „1” pažymėtos ekspertiškai teigiamai įvertintos kompanijos, „0” – įvertintos neigiamai. Tačiau SOM žemėlapyje tokio pasiskirstymo nesimato (30 pav.).



30 pav. SOM tinklas

31 pav. galime matyti atskirų komponenčių įtaką skirtiniams SOM vektoriams.

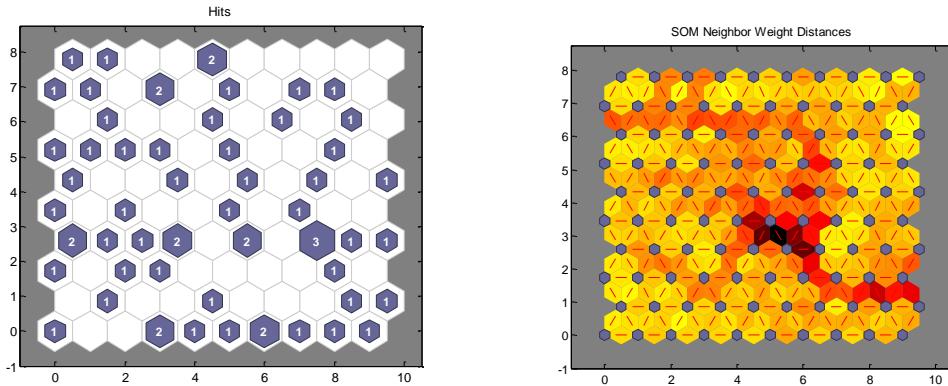


31 pav. Komponenčių įtaka

Ankstesniame pavyzdyme SOM tinklas buvo konstruojamas naudojant komandinę eilutę. Matlab SomToolbox leidžia SOM tinklus kurti naudojant ir grafinę sąsają turintį įrankį.

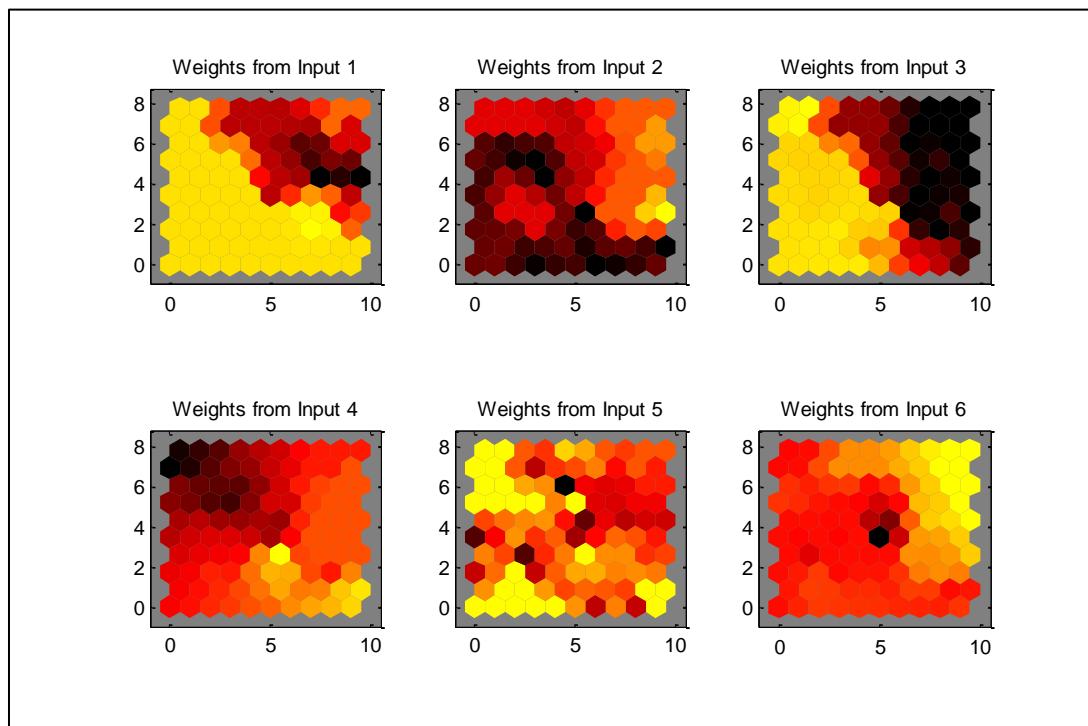
Šiuo atveju išbandytas antrasisis duomenų rinkinys, kuriame įmonės pasidalinusios aiškiau (32 pav.). Tamsesnės raudonos linijos žymi didesnius atstumus

tarp vektorių. Viršutiniame dešiniajame kampe galime ižvelgti atskyrusį geriau įvertintų įmonių klasterį.



32 pav. SOM žemėlapis (10X10) ir atstumai tarp vektorių

33 pav. pavaizduota atskirų komponenčių įtaką žemėlapio elementams.

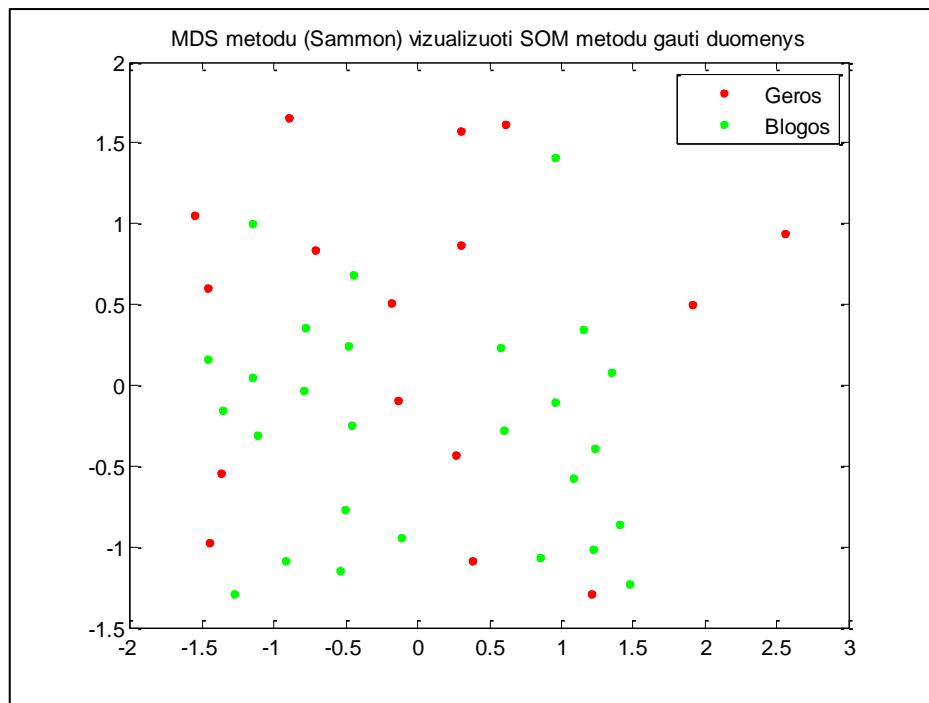


33 pav. Komponenčių įtaka.

2.2.1.3. SOM ir Sammon metodų junginys

Taikant SOM metodą gaunami n -mačiai vektoriai nugalėtojai. Jie išdėstomi lentelėje, tačiau iš jos nėra aišku, kaip arti yra kaimyniniuose langeliuose esantys vektoriai. Gauti n -mačiai vektoriai nugalėtojai gali būti atvaizduojami plokštumoje panaudojant Sammono algoritmą [34].

45 pav. pavaizduota 3.1.2 skyriuje gauto SOM tinklo projekcija dvimatėje erdvėje panaudojus Sammon metodą.



34 pav. SOM tinklo vektoriai atvaizduoti 2D erdvėje (Sammon metodas)

2.2.2. Perceptroninis neuroninis tinklas

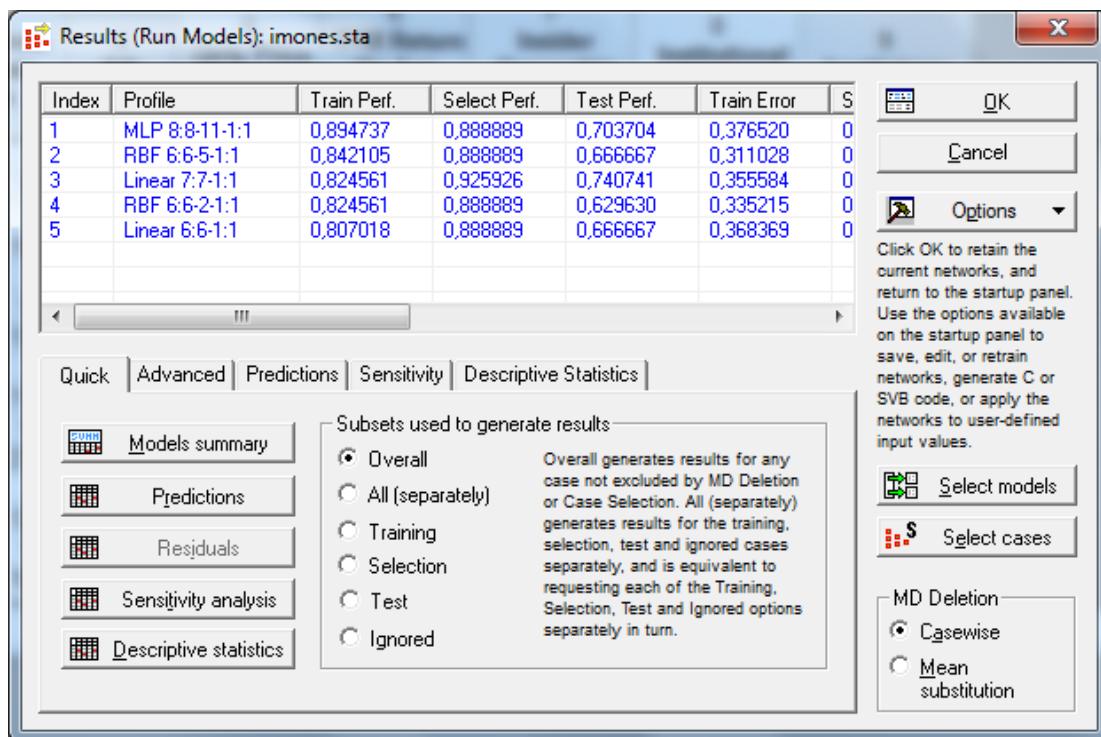
Šio darbo tikslas yra pritaikyti neuroninį tikimybinį tinklą atrenkant investavimui tinkamas kompanijas. Yra 8 įėjimo kintamieji ir 2 išėjimo kintamieji („gera“ ir „bloga“). Iš viso analizuojami 111 įmonių duomenys, 35 pav. pateiktas duomenų fragmentas.

	Price% Change 4 Weeks	Average Recmnd.	Long Term Grth Rate Mean	P/E	Qtyly Price To Book	TTM Return On Avg. Equity	Insider Ownership Percent	Institutional Percent Held	Ivertinimas
1	29,56	1,71	21,5	19,76	1,91	11,99	35,63	58,18	g
2	19,85	1,25	14,33	15,98	1,65	11,16	29,54	67,81	g
3	6,27	1,82	16,83	15,43	3,89	30,05	25,04	90,02	g
4	11,71	2	14,33	12,17	1,5	13,79	28,1	61,69	b
5	6,51	2,06	21,25	18,69	2,86	17,89	27,86	74,4	g
6	1,06	2	14,1	12,9	1,65	14,02	31,26	17,88	b
7	1,56	1	17	10,89	1,33	15,63	26,46	16,31	b
8	25,06	2	12,4	10,84	2,18	22,88	26,94	51,71	b
9	6,21	1,71	21	12,49	2,35	22,4	40,82	95	g
10	7,08	2,25	15,67	10,13	1,57	17,81	62,93	57,58	b
11	25,91	1	20	7,43	1,08	15,78	40,27	15,18	g
12	1,99	1	14,5	13,97	2,57	21,1	29,8	59,52	g

35 pav. Analizuojamų duomenų fragmentas

Analizei naudojamas *Statistica* programos *Neural network* modulis.

Apskaičiuojame tinklus:



36 pav. Tinklų apskaičiavimas (5 geriausi iš 10)

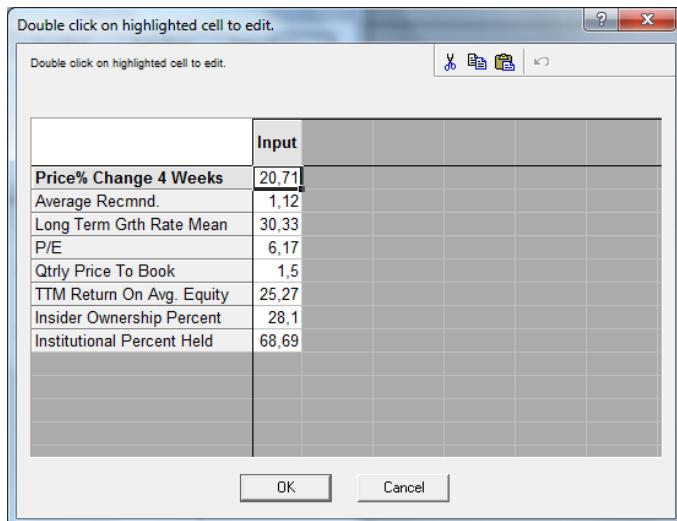
Peržiūrime apskaičiuotų tinklų rodiklių jautrumą:

	Sensitivity Analysis - 1-5 (imones.sta)							
	Price% Change 4 Weeks	Average Recmnd.	Long Term Growth Rate Mean	P/E	Qtrly Price To Book	TTM Return On Avg. Equity	Insider Ownership Percent	Institutional Percent Held
Ratio.1	1.065969	1,553202	1,111379	1,068337	1,074929	1,130693	1,036949	1,342179
Rank.1	7,000000	1,000000	4,000000	6,000000	5,000000	3,000000	8,000000	2,000000
Ratio.2		1,274420	1,016607	1,002985		1,011174	1,017949	1,117808
Rank.2		1,000000	4,000000	6,000000		5,000000	3,000000	2,000000
Ratio.3	0,999456	1,166838	1,032519	1,017132	1,119929	0,946058	1,001570	
Rank.3	6,000000	1,000000	3,000000	4,000000	2,000000	7,000000	5,000000	
Ratio.4		1,222429	1,027193	0,965229		1,039317	0,987670	1,112722
Rank.4		1,000000	4,000000	6,000000		3,000000	5,000000	2,000000
Ratio.5		1,195925	1,037348	1,014011	1,105515	0,957143	1,002214	
Rank.5		1,000000	3,000000	4,000000	2,000000	6,000000	5,000000	

37 pav. Rodiklių jautrumas

5 geriausiai apskaičiuoti/apmokyti tinklai skiriasi ne tik tipais (MLP, RBF, Linear), bet ir įtrauktais kintamaisiais ir jų svoriais, kurie turi įtakos galutiniui įvertinimui – „gera“ ar „bloga“ įmonė.

Tikriname tinklą: (Advanced->User defined case):

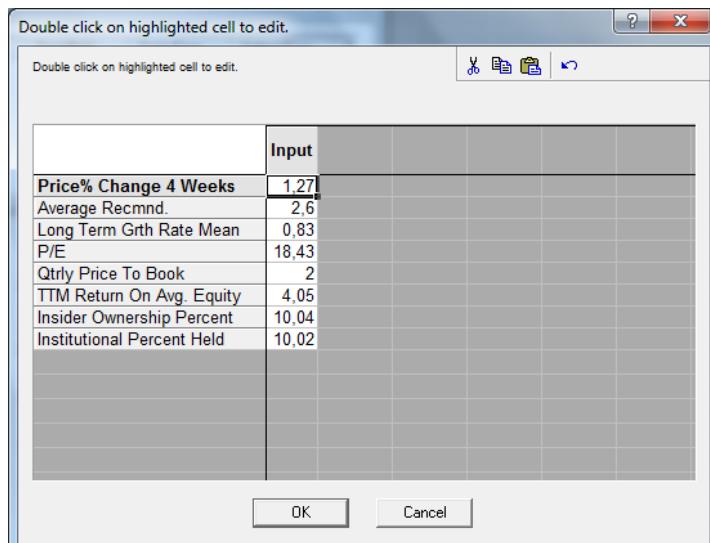


38 pav. „Geros“ įmonės vertinimas

User Defined Case Prediction, (1-5) (imones.sta)					
	Ivertinimas.1	Ivertinimas.2	Ivertinimas.3	Ivertinimas.4	Ivertinimas.5
1	q	g	g	g	g

39 pav. „Geros“ įmonės atpažinimo rezultatai

Visi 5 atrinkti tinklai teisingai atpažino „geros“ įmonės kontrolinių duomenų rinkinių, tinklai apsimokė ir tinkamai įvertina anksčiau nematytus duomenis.



40 pav. „Blogos“ įmonės vertinimas

User Defined Case Prediction, (1-5) (imones.sta)					
	Ivertinimas.1	Ivertinimas.2	Ivertinimas.3	Ivertinimas.4	Ivertinimas.5
1	b	b	b	b	b

41 pav. „Blogos“ įmonės atpažinimo rezultatai

Visi 5 atrinkti tinklai teisingai atpažino „blogos“ įmonės kontrolinių duomenų rinkinių, tinklai apsimokė ir tinkamai įvertina anksčiau nematytus duomenis.

2.3. Klasterizavimo metodai

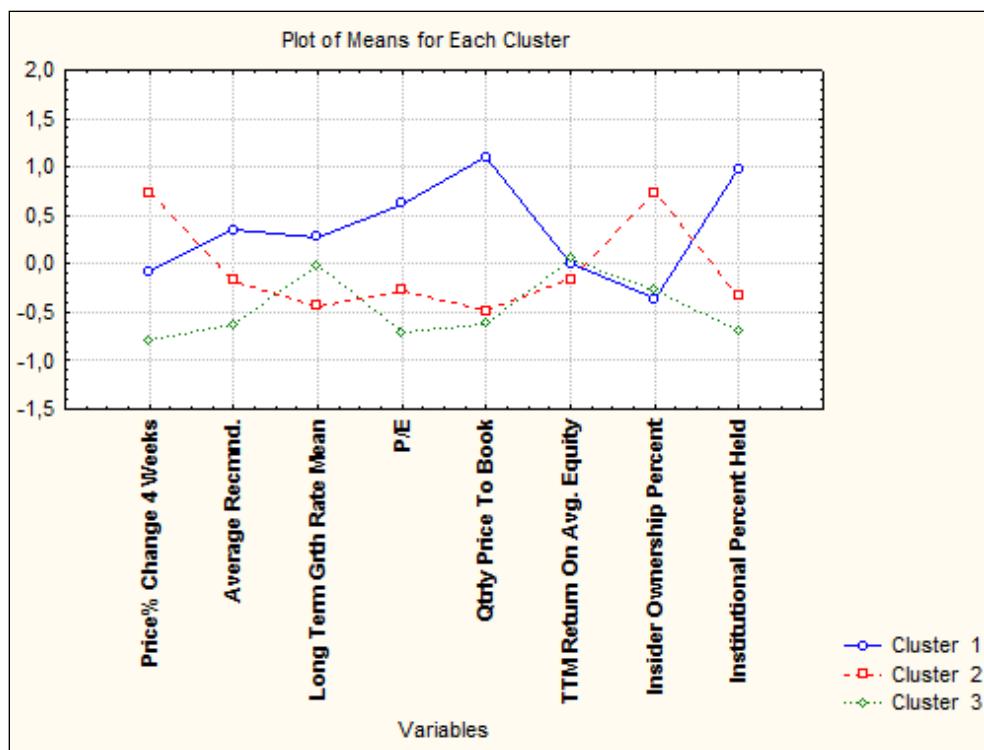
Dažnai kyla klausimas kaip suklasifikuoti duomenis į bent daugmaž susijusias grupes. Šiuo atveju klasterizuojamos 50 įmonių. Naudojami 8 požymiai: akcijos kainos pokytis, ilgo laikotarpio augimo tendencijos, P/E ir P/B rodikliai, pajamos, vidinių ir institucinių investuotojų dalis, ekspertų rekomendacija. Analizei naudojami normalizuoti duomenys. Naudojama Statistica programinė įranga.

Yra keletas klasifikavimo metodų (angl. cluster analysis):

- Apjungimo (medžio struktūra) - Joining (Tree Clustering)
- Dvipusio apjungimo (blokinė struktūra) - Two-way Joining (Block Clustering)
- K-vidurkio struktūra - K-means Clustering.

Šiuo atveju naudojamas K-vidurkio struktūros (angl. K-means clustering) metodas. Pasirinkus šį klasterizavimo metodą, reikia nuspresti į kelias grupes norime suskirstyti vertybinius popierius pagal požymių panašumą. Visų pirma skaidome į 3 klasterius.

42 pav. matyti, kokios yra kiekvieno klasterio vidutinės rodiklių reikšmės.



42 pav. Trijų sudarytų klasterių rodiklių įtaka

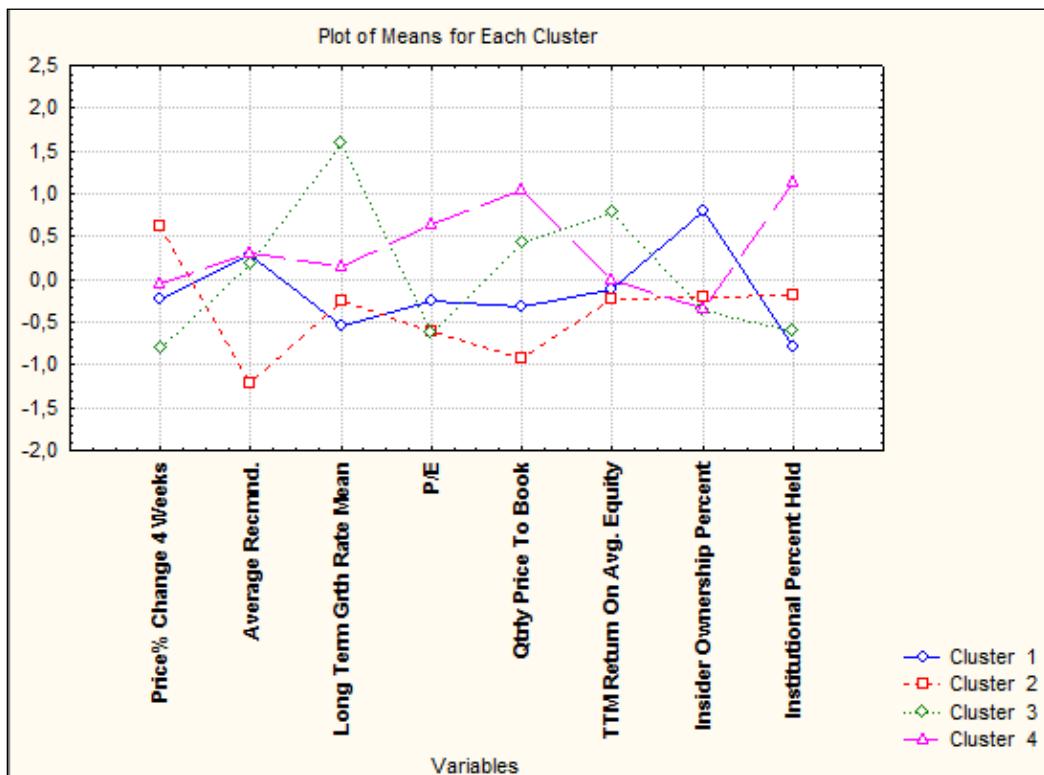
Išryškėja gan didelis skirtumas tarp pirmo ir likusių dviejų klasterių.

Case No.	Members of Cluster Number 1 and Distances from Respective Cluster contains 30 cases		Case No.	Members of Cluster Number 2 and Distances from Respective Cluster contains 14 cases		Case No.	Members of Cluster Number 3 and Distances from Respective Cluster contains 14 cases	
	Distance	Case No.		Distance	Case No.		Distance	Case No.
C_1	0,932874	C_1	0,568690	C_6	0,713596	C_7	0,757944	C_12
C_2	0,839045	C_2	0,516311	C_14	0,516311	C_18	0,647294	C_20
C_4	0,691968	C_4	0,482182	C_24	0,481727	C_28	0,481727	C_29
C_8	0,820870	C_8	0,486089	C_31	0,963004	C_33	0,810647	C_36
C_10	0,693598	C_10	0,726495	C_35	0,874160	C_39	0,726495	C_43
C_11	1,202383	C_11	1,149227	C_38	0,874160	C_44	0,874160	C_48
C_15	1,034229	C_15	0,874160	C_40	0,874160	C_41	0,874160	C_49
C_19	0,520047	C_19	0,874160	C_25	0,874160	C_26	0,874160	C_50
C_25	0,480563	C_25	0,874160	C_27	0,874160	C_28	0,874160	C_29
C_26	1,259632	C_26	0,874160	C_31	0,874160	C_33	0,874160	C_36
C_31	0,382230	C_31	0,874160	C_35	0,874160	C_39	0,874160	C_43
C_33	0,585310	C_33	0,874160	C_38	0,874160	C_44	0,874160	C_48
C_34	0,567559	C_34	0,874160	C_40	0,874160	C_41	0,874160	C_49
C_35	0,707288	C_35	0,874160	C_42	0,874160	C_43	0,874160	C_50
C_38	0,874971	C_38	0,874160	C_44	0,874160	C_45	0,874160	C_49
C_40	0,683280	C_40	0,874160	C_48	0,874160	C_49	0,874160	C_50
C_41	0,594714	C_41	0,874160	C_49	0,874160	C_50	0,874160	C_50
C_42	0,874160	C_42	0,874160	C_43	0,874160	C_44	0,874160	C_49
C_44	1,149227	C_44	0,874160	C_48	0,874160	C_49	0,874160	C_50
C_48	0,874160	C_48	0,874160	C_49	0,874160	C_50	0,874160	C_50

43 pav. Įmonių priskyrimas tam tikram klasteriu

I pirmą ir antrą klasterius pateko panašus skaičius įmonių, į trečią šiek tiek mažiau. Siekiant geriau suklasifikuoti įmones, išbandomas 4 klasterių variantas.

Skaidymas į 4 klasterius:



44 pav. 4 sudarytų klasterių rodiklių įtaka

Šiuo atveju nėra tokio didelio atotrūkio tarp klasterių, tačiau nėra ir vienodų (linijos nepersidengia) (44 pav.).

Mažiausiai įmonių pateko į trečią klasterį. Jis išskiria dideliu ilgo laikotarpio augimo tempu, aukštų pajamingumo rodikliu, žemu P/E rodikliu, tačiau turi mažą

akcijos kainos prieaugi per pastarąsias 4 savaites. Šias įmonių akcijas vertėtų detaliau ižvertinti kaip galimas investicijas.

2.4 Daugiapakopė duomenų analizė ir vizualizavimas

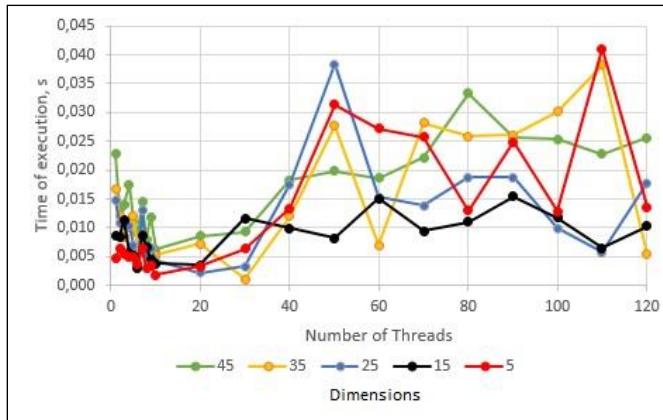
This research focuses on big financial data visualization that is based on dimensionality reduction methods. We use data set that contains financial ratios of stocks traded on NASDAQ stock exchange. Our goal is to find the most effective ways to analyze and visualize such type data. In the second section, we present a brief overview of the most popular dimensionality reduction and visualization methods. In the third section we present how to adjust the algorithms of these methods for parallel computing. We use MPI technology in computer cluster to perform dimensionality reduction. [103][57][93] In the last section we present the classification and visualization results which where get while using Random projection and Multidimensional scaling methods. The current data set is relatively small, but the results give suggestions what techniques to choose for future works with big online data streams.

Research results

In this section we present the results of applying Random projection and Multidimensional scaling methods for our financial market data set. [28][2]

The data set contains information about 1400 companies that are traded on NASDAQ stock exchange. Every company is described by 54 different parameters. All these parameters are grouped into 6 categories: overview, valuation, financial, performance, technical and ownership. All data is from finviz.com website.

In the Overview group there are such parameters as sector, industry, market capitalization, price, volume. In Valuation group we have P/E, PEG, P/B, EPS and sales parameters. Financial parameters group contains ROA, ROE, ROI, earnings, debt and margins parameters. Performance indicators present price changes during different periods of time, volatility and recommendation values.



45 pav. The execution times of Random projection algorithm

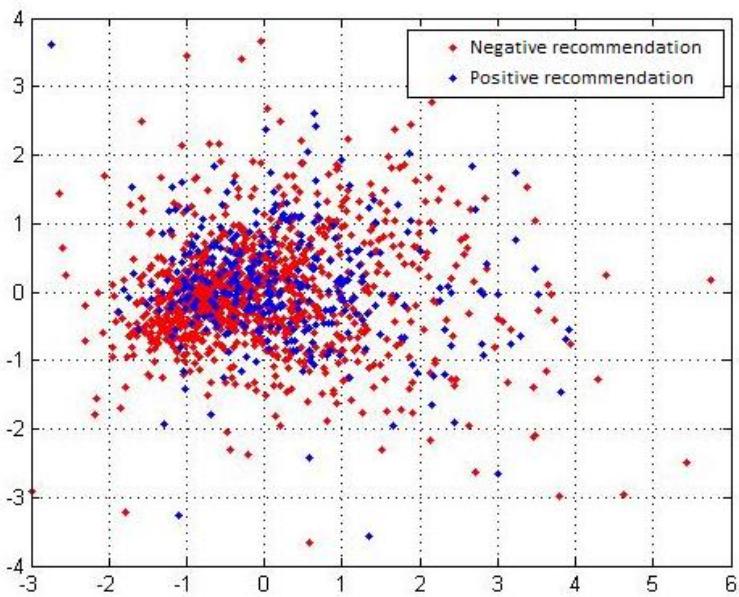
Technical indicators are ATR, Beta, Simple moving averages of different periods of time, RSI, the lowest and highest prices at which a stock has traded in the previous 52 weeks. And the last group contains parameters of stock ownership.

Usually our goal is to visualize data and uncover hidden information. This means that for example in this case we have to reduce the dimensions from 54 to 2 or 3. It's complicated to quickly perform such tasks with single machine. So in the first step we executed Random projection algorithm in the cluster having 120 nodes to reduce the dimensions from initial 54 to smaller amount: 25, 15, 10 and 5 (got several new data sets). When the most suitable number of threads were chosen it took less than 0,04 seconds to complete each task (Figure 4). It should be noted that using more threads not always leads to better performance. As this data set was relative small, 10 to 30 threads was optimal choice to execute the algorithm in the fastest way. In comparison with serial code, MPI code worked from 10 to 20 times faster.

In the second step we applied Multidimensional scaling method (with Sammon) to visualize the reduced data set containing 5 variables. We investigated two stock classification cases: based on analysts' recommendation and based on multicriteria indicator.

	Overview											
	No.	Ticker	Company	Sector	Industry	Country	Market Cap	Price	Change	Volume		
Valuation												
P/E	Fwd P/E	PEG	P/S	P/B	P/C	P/FCF	EPS this Y	EPS next Y	EPS past 5Y	EPS next 5Y	Sales past 5Y	
Financial												
Dividend	ROA	ROE	ROI	Curr R	Quick R	LTDebt/Eq	Debt/Eq	Gross M	Oper M	Profit M	Earnings	
Performance												
Perf Week	Perf Month	Perf Quart	Perf Half	Perf Year	Perf YTD	Volatility W	Volatility M	Recom	Rel Volume			
Technical												
Beta	ATR	SMA20	SMA50	SMA200	52W High	52W Low	RSI	from Open	Gap			
Ownership												
Outstanding	Float	Insider Own	Insider Trans	Inst Own	Inst Trans	Float Short	Short Ratio					

46 pav. Parameters of analysed companies



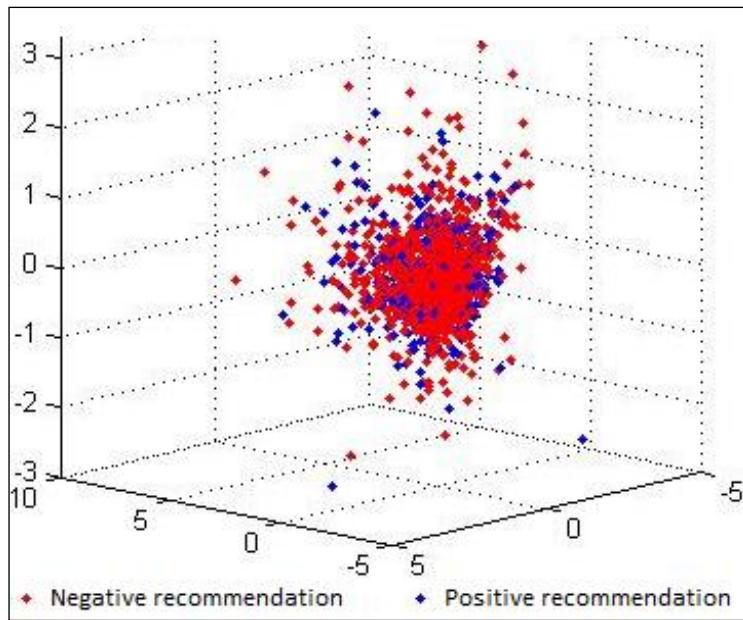
47. Data visualization using Multidimensional scaling

Stock classification based on analysts' recommendation

One of our initial 54 factors was the recommendation of financial analysts. This variable ranges from 1 (strong recommendation to buy stock) to 5 (strong recommendation to sell stock). We raised hypothesis that “good” companies (having recommendation ratio from 1 to 2) should be separated from the rest companies after dimensionality reduction and visualization processes.

However, figure 6 shows that the combination of Random projection and Multidimensional scaling methods couldn’t separate these two classes. They just overlapped each other. We tried to use 3D plot, but it was uninformative too (Fig. 7).

The first thought could be that the methods are not efficient enough. But it also could be that in reality the potentiality of “good” and “bad” companies (as determined by analysts) don’t differ so much. This would explain why using just the opinion of financial advisors often leads to unstable returns or even losses. It also suggests that opinions might be more based on intuition than various stock ratios.



48. Data visualization using Multidimensional scaling (3D plot)
Multicriteria indicator for stock classification

	P/E	EPS this Year %	ROE	SMA50 %	RSI
„Good stocks“	< 20	> 5	> 5	> 0	> 50
„Bad stocks“	> 20	< 5	< 5	< 0	< 50

Stock classification based on multicriteria indicator

In the second case we constructed multicriteria indicator for separating stocks that are worth investing (“good”), neutral stocks and “bad” stocks.

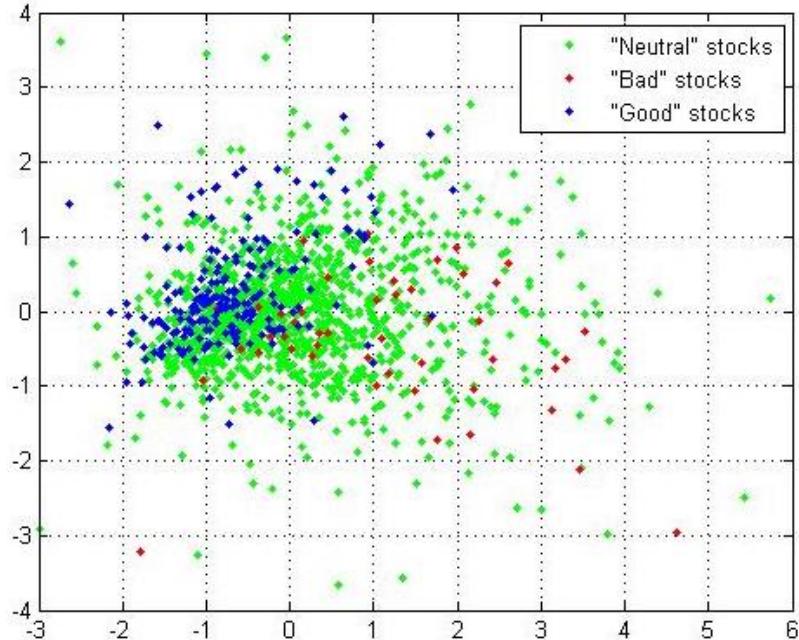
In our assumption “good” stocks meet all following criteria: P/E < 20, EPS this year > 5, ROE > 5, 50-period SMA > 0, RSI > 50. Table 1 shows the ratios by which “good” and “bad” classes of stocks are constructed. “Neutral” stocks are those which don’t fall within any of previously defined two classes.

We used the same Multidimensional scaling method to visualize the reduced data set, so the arrangement of data points is the same as presented in figure 6. But in this case we found that the three different classes of stocks were separated quite well.

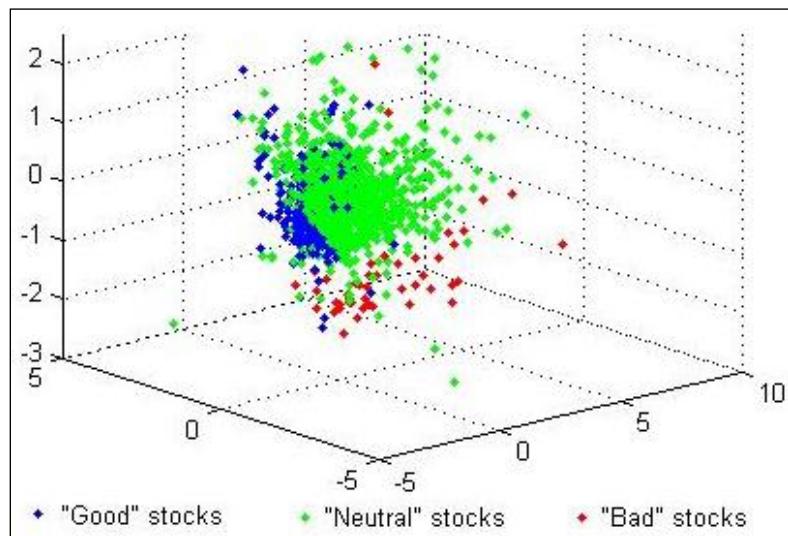
Figure 8 shows that “good” companies were presented in the left side of the plot. The “bad” and “neutral” companies overlapped, but “bad” companies separated from “good” companies.

This leads to suggestion, that dimensionality reduction and visualization methods can effectively classify data and find the most promising stocks. However, in order to explain the differences between classes we need to use several different ratios.

We used the combination of Multidimensional scaling and Random projection methods because the latter one is very fast. However it might be not so accurate. So we tried to apply MDS method for full initial data set and it actually led to better results. 3D plot in figure 9 shows that “bad” stocks were separated from “neutral” stocks.



49. Visualizing three classes of stocks



50. Visualizing initial data set using MDS

Conclusions

Various data mining methods are used for examining large financial data sets to uncover hidden and useful information. This research focused on financial data visualization that is based on dimensionality reduction methods. We used data set that contained financial ratios of stocks traded on NASDAQ stock exchange. A brief

overview of the most popular data dimensionality reduction and visualization methods was presented in this paper. We also showed how to adjust the algorithm of Random projection method for parallel computing. The MPI technology was applied in computer cluster to perform dimensionality reduction. The performance results revealed the advantages of parallel computing. Our goal was to visualize data and uncover hidden information. In order to do this we had to reduce the dimensions to 2 or 3. In the first step we executed Random projection algorithm in the cluster to reduce the dimensions from initial 54 to smaller amount. In the second step we applied Multidimensional scaling method to visualize the reduced data set.

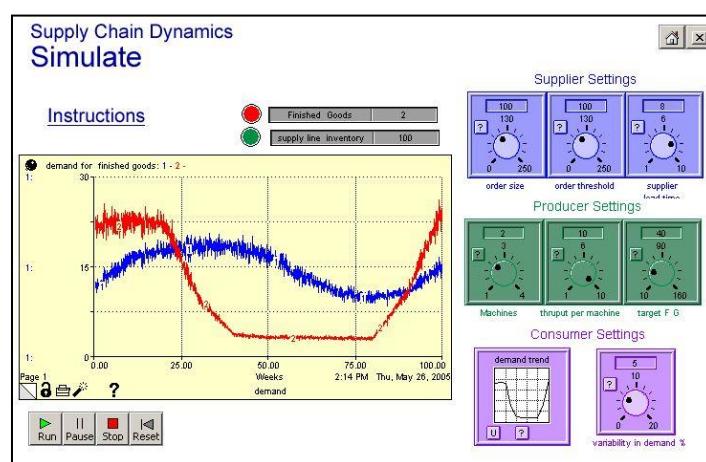
One of the data set ratios was the recommendation of financial analysts. We raised hypothesis that companies having recommendation to buy them should be separated from the rest of companies. But the results showed that the combination of Random projection and Multidimensional scaling methods couldn't do this. This might have happened because in reality the potentiality of "good" and "bad" companies (as they are determined by analysts' recommendations) doesn't differ so much. However, in the second case of stock classification based on multicriteria indicator "good" and "bad" stocks were separated quite well. This leads to suggestion, that dimensionality reduction and visualization methods can effectively classify data and find the most promising stocks. But in order to explain the differences between classes we need to use several different ratios. It should be also noted, that MDS method alone was more accurate than combination of two methods.

3. PROGRAMINĖS ĮRANGOS ANALIZĖ

3.1 Sistemų modeliavimo ir procesų imitavimo programinė įranga

Šiame skyriue apžvelgiami populiausiai sistemų dinamikos modeliavimo įrankiai.

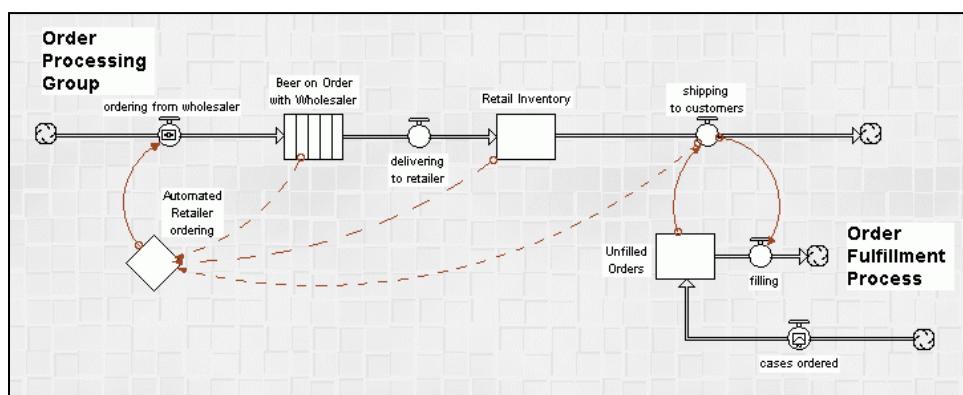
iThink® ir STELLA yra du pavadinimai tos pačios modelių kūrimo platformos, siūlomos kompanijos Isee systems. Stella Professional yra paprastai valdomas, interaktyvus įrankis, kuris leidžia kurti sistemų modelius bei atlikti simuliacijas su jais (59 pav.). Modeliai gali būti kuriami tokioms sritims kaip sveikatos apsauga, energetika, ekosistemos, verslo sistemos, transportas.



Šaltinis: <http://www.iseesystems.com/softwares/Business/IthinkSoftware.aspx>

50. pav. STELLA modelių simuliavimo aplinka

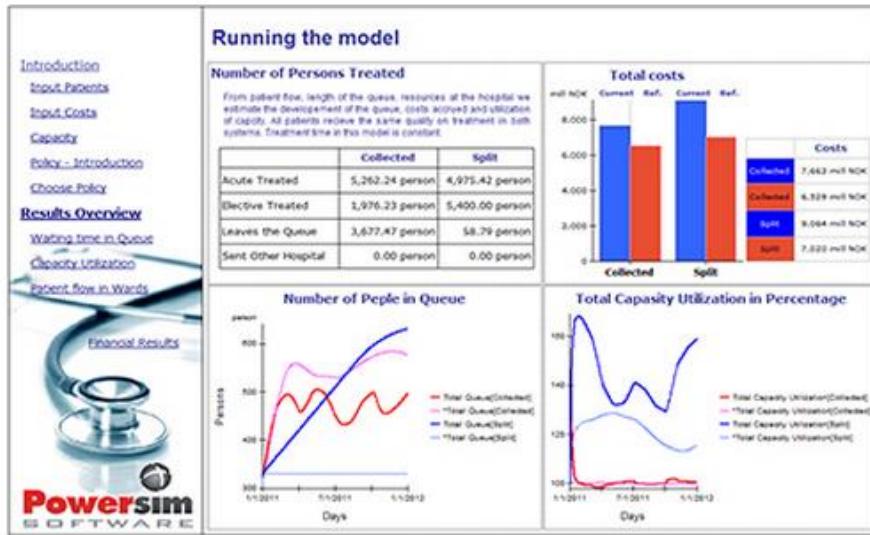
Modeliavimui naudojamos priežastinių kilpų bei srautų ir talpų diagramos (51 pav.). Programinė įranga leidžia daryti įžvalgas, geriau suprasti sistemų veikimo principus, analizuoti įvairių scenarijų rezultatus. Siūloma komercinė bei mokomoji programos versija.



Šaltinis: <http://www.iseesystems.com/softwares/Business/IthinkSoftware.aspx>

51 pav. STELLA modeliavimo aplinka

Kitas galingas modeliavimo ir simuliavimo įrankis yra **Powersim Studio**. Jis taip pat remiasi priežastinių kilpų bei srautų ir talpų diagramomis. Programa skirta MS Windows operacinei sistemai.



Šaltinis: <http://www.powersim.com/>

52 pav. Ligoninės veiklos modeliavimas Powersim aplinkoje

Yra komercinė, mokomoji bei nemokama Studio express versija. Taip pat yra galimybė kurti nepriklausomus modelių paketus, kurie gali būti simuliuojami ir kompiuteriuose, kuriuose nėra įdiegta Powersim Studio.

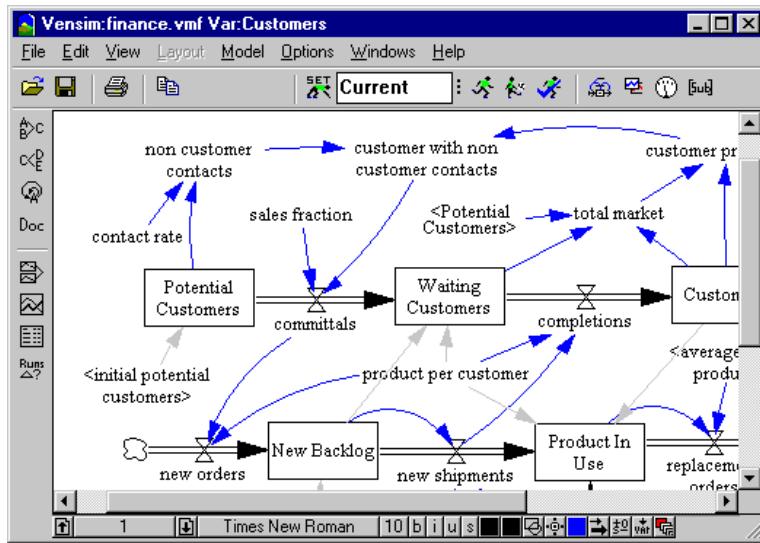


Šaltinis: <http://www.powersim.com/>

53 pav. Telekomunikacijų bendrovės tinklų plėtimo proceso modeliavimas

Yra komercinė, mokomoji bei nemokama Studio express versija. Taip pat yra galimybė kurti nepriklausomus modelių paketus, kurie gali būti simuliuojami ir kompiuteriuose, kuriuose nėra įdiegta Powersim Studio.

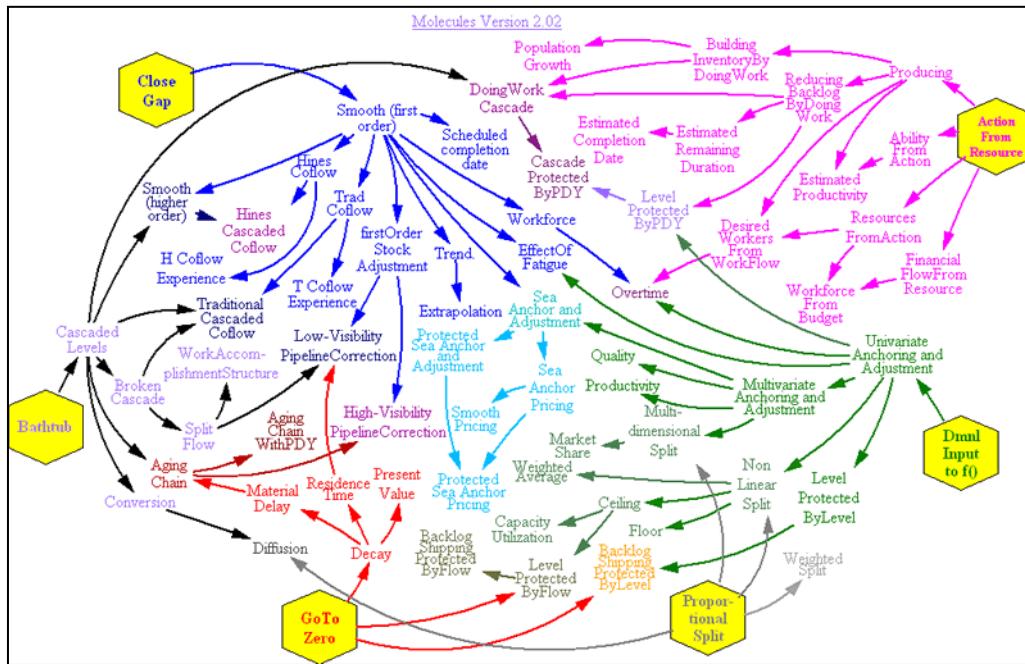
Galima rasti daug mokslinių eksperimentų, kuriems panaudota **Vensim** programinė įranga, siūloma kompanijos Ventana Systems. Yra daug šios programinės įrangos variacijų. Greta komercinių versijų, yra ir mokomosios bei nemokamos.



Šaltinis: www.vensim.com

54 pav. Srautų ir talpų diagrama Vensim modeliavimo aplinkoje

Tom Friddman puslapyje <http://www.metasd.com/models/index.html> galima rasti didelę modelių biblioteką, kurie yra sukurti naudojant Vensim programinę įrangą.



Šaltinis: www.vensim.com

55 pav. Vensim priežastinių kilpų dagrama

Galima paminėti ir tokius įrankius kaip **Anylogic**, Goldsim, Berkely Madonna, Sysdea, SimGua, MyStrategy..Pvz. **Anylogic** (56 pav.) sėkmingai naudojamas transporto, sveikatos apsaugos, tiekimo grandinės, gamybos, verslo analitikos srityse.

Šaltinis: <http://www.anylogic.com>

56 pav. AnyLogic programinė įranga

Taip pat verta atkreipti dėmesį į atviro kodo produktą Insight maker (57 pav.), kuris turi visas būtinias funkcijas, reikalingas sistemų dinamikai modeliuoti, tačiau yra nemokamas.

Šaltinis: <https://insightmaker.com>

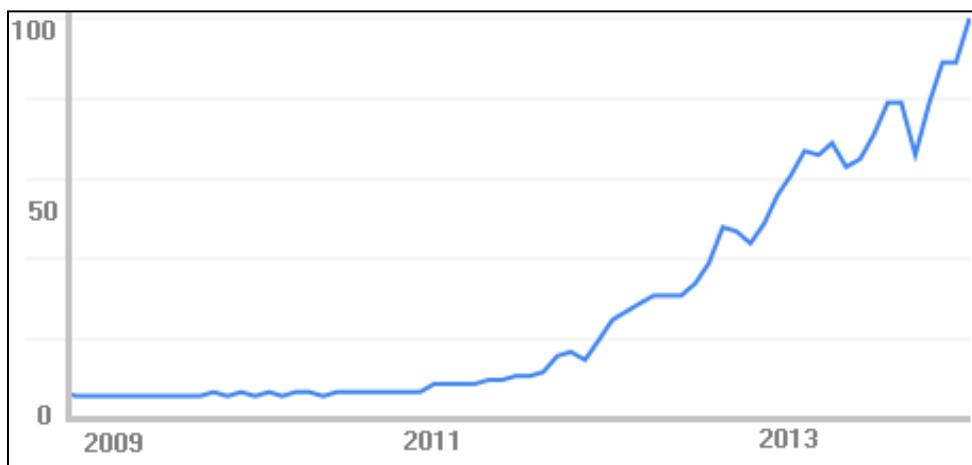
57 pav. Insight programinė įranga

3.2. Didelių duomenų analizei skirtos programinės įrangos analizė

Introduction 1

The economic growth and tremendous progress of IT have led to the massive amount of data being generated in financial institutions. Advanced data mining techniques and improved models of risk management could help to solve the problem of evaluating information adequately and discovering potential threats [25]. According to Han and Harcourt [64], data mining is extracting knowledge from large amounts of data, which is recently nominated as “big data” problem.

Big data can be described as high volume, big velocity and big variety information assets that demand cost effective, innovative forms of information processing for enhanced insights discovery and decision-making [43].



58 pav. Figure Interest to the term “big data” in Google search engine

(Source: Google Trends, 2014, [46])

The subject of “big data” used to be barely a twinkle in data analysts’ eyes, but starting from January 2012, the topic started to weave its way into business vernacular [135]. It’s related to rapid progress in IT infrastructure, network expansion and speed of information flow. The emanating problem of “big data” is how to use it effectively and get the maximum benefits.

Figure 1 shows steep trend of interest to the search term “big data” in Google engine since 2009. The chart doesn’t convey absolute search volume, but it reveals changes of rate of volume and trend in the scale from 0 to 100.

The main applications of data analysis in finance include forecasting the stock market and foreign exchange market, portfolio management, bankruptcy prediction, fraud detection [87]. However data volume is often too large or is generated too quickly to be screened by experts, so only data mining can contribute for solving such problems

that are not immediately apparent to managers [24]. The complexity of task I increased by need to combine several sources of information for decision purposes.

This is especially noticeable in online banking, where millions of transactions are made every second. The volume and speed of data makes it an impossible task for bank employees to adequately evaluate each transaction. Even for machines it's a big issue to deal with such enormous amount of data. There is a great need to find more effective ways to deal with big financial data for decision making support.

Introduction 2

The problems in financial sector that emanated after 2008 financial crisis showed the need to improve risk management. As the financial sector is distinguished by its large amounts of data generated by banking, insurance and other financial institutions, it is difficult to evaluate all the information adequately and discover potential threats. Data mining techniques and improved models of risk management could help to solve this problem.

Nowadays banks and other financial institutions use various business intelligence systems for analysis of their data repositories. Business intelligence is a data-driven decision support system that combines data gathering, data storage, and knowledge management with analysis to provide input to the business decision process [17]. It is quite common for banks to combine several tools for data analysis and to make considerable investments for data handling. However, they use conventional multi-purpose software such as Excel, Access, Statistica, SPSS or open source tools as well, for carrying out various managerial analytical tasks. Conventional software tools used in business have the required flexibility for processing and interpretation of analytical tasks. They are widely applied not only in large financial institutions such as banks- this type of tools is mostly widespread in small financial institutions, providing financial services, consulting, insurance.

McAfee (2012) revealed the important relationship: the more companies characterized themselves as data-driven, the better they performed according to measures of financial and operational results [91]. One of the key findings of Lavalle's (2011) assured that top-performing organizations use analytics five times more than lower performers [78].

According to IBM (2013) 2.5 quintillion bytes of data is created every day — as many as 90% of data in the world today has been created in the last two years alone.

The problem related to various aspects of handling contemporary data sources is often called “big data” problem.

Gantz and Reinse (2012) define the term "digital universe" as a measure of all the digital data created, replicated, and consumed in a single year [41]. They predict that during 2005 to 2020 the digital universe will grow from 130 exabytes to 40,000 exabytes, or 40 trillion gigabytes.

Big data usually is described as high volume, big velocity and big variety information assets that demand cost effective, innovative forms of information processing for enhanced insight and decision-making [42]. TechAmerica Foundation’s Federal Big Data Commission (2012) also determines big data as a phenomenon defined by the rapid acceleration in the expanding volume of high velocity, complex, and diverse types of data [132].

The data in financial institutions meet the criteria for big data: massive (e.g., terabytes in volume), temporally ordered, fast changing, potentially infinite. Kovalerchuk and Vitaev (2005) state that financial institutions produce huge datasets that build a foundation for approaching these enormously complex and dynamic problems with data mining tools in order to extract knowledge from large amounts of data [74].

It is notified that successfully harnessing big data can help banks achieve three critical objectives for banking transformation: create a customer-focused enterprise, optimize enterprise risk management and increase flexibility and streamline operations IBM (2013) [59]. Understanding and managing financial risk, credit rating, loan management, bank customer profiling and money laundering analyses are core financial tasks for data mining.

Data mining can contribute for solving business problems in banking and finance by finding patterns, causalities, and correlations in business information and market prices that are not immediately apparent to managers because the data volume is too large or is generated too quickly to screen by experts [104].

In this article we use conventional software packages in order to determine their suitability and limits for various aspects of big data analysis. Although we are aware of special large scale systems which can deal with tremendously huge sets of data, but we focus on situations where there are no possibilities to use powerful servers, specific databases, cloud systems or expensive data mining tools. We perform analysis with our big data example by using conventional hardware and tools that are open source or

common in business. The experimental data consists of monthly customer transaction data from medium size bank, extracted from several sources included to local data warehouse.

Data mining software is overviewed in the section

2 Data mining software solutions

According to Baru et al (2013) big data analytics has become a major force of innovation across enterprises of all sizes, but the vast selection of tools brings problems of their comparative evaluation and fit for enterprise purposes [11]. In general, data mining methods can be classified into the following categories: association rule mining, classification, clustering analysis, sequential pattern finding by using four main data mining techniques: neural networks(NN), genetic algorithms(GA), statistical inference(SI), data visualization(DV) [115].

We selected the tools that have main features of conventional analytical software, as they are either free or don't require large resources, potentially can handle big data and have basic set of functions (Table1). This should allow the companies that don't have resources for costly solutions to work with big data sets.

For further research we selected the four with the declared capacity of big data handling, namely Rapid Miner, Viscovery Somine, XLMiner and SPSS. Rapid Miner was selected because it's open source and has a wide range of intelligent analysis features. Viscovery Somine is also easily accessible tool designed for a particular data mining task. XLMiner was selected as one of the simplest ways to become ready for data mining. Finally SPSS was chosen in order to test how popular statistics tool can handle with big data.

RapidMiner, formerly called YALE (Yet Another Learning Environment), is an software environment for machine learning and data mining experiments oriented for both research and real-world. It enables experiments consisting of a huge number of arbitrarily unstable operators, which are made with the graphical user interface of RapidMiner [133] and detailed in XML files. RapidMiner is freely available open-source data mining and analysis system that runs on every major platform and operating system. It has GUI mode, server mode (command line), or access via Java API. RapidMiner contains more than 500 operators for data integration and transformation, data mining, evaluation, and visualization and also has extension mechanism. Machine learning library WEKA is fully integrated in this software. RapidMiner uses graphical process design for standard tasks and scripting language for arbitrary operations. It has

standardized XML interchange format for processes. Different data sources can be accessed: Excel, Access, Oracle, IBM DB2, Microsoft SQL, Sybase, Ingres, MySQL, Postgres, SPSS, dBase, Text files [106].

Table 1. Comparison of data mining tools

Tool	Free	Open Source	NN	GA	SI	DV	Features of data mining tools
R	Yes	Yes	+	+	+	+	Decision trees, clustering, association rules, text mining, tools for creating chart and graphs.
Datameer	No	No	-	-	-	+	Data visualization.
SAS	No	No	+	+	+	+	Clustering, time series analysis, text mining, forecasting trends.
Google Chart	Yes	No	-	-	-	+	Data visualization, web-based tool.
Orange	Yes	Yes	+	-	-	+	Data visualization, fast and versatile visual programming.
Rapid Miner	Yes	Yes	+	+	+	+	Text mining, predictive analytics, clustering, for research and real-world data mining tasks.
Weka	Yes	Yes	+	+	+	+	Regression, clustering, association rules, visualization, classification.
JHep Work	Yes	Yes	-	-	-	+	Data visualization, designed for scientists, engineers and students.
Knime	Yes	Yes	+	+	+	+	Data transformation, predictive analytics, visualization.
Rapid Analytics	Yes	Yes	+	+	+	+	Text mining, predictive analytics, clustering.
PSPP	Yes	Yes	-	-	+	+	Descriptive statistics, linear regression, T-tests, non-parametric tests, graphical user interface.
Rattle	Yes	Yes	-	-	-	+	Data transformation, data visualization.
SPSS	No	No	+	+	+	+	Predictive analytics.
Pentaho	No	No	-	-	-	+	Interactive dashboards, data visualization.
XLminer	No	No	+	-	+	+	Neural nets, classification and regression trees, logistic regression, linear regression, association rules, clustering, principal components.
Viscovery Somine	Yes	Yes	-	-	+	+	Visual cluster analysis, self-organizing maps.

RapidMiner has got references as the world-leading open-source system for data mining Koutonin (2013). It is claimed that thousands of applications of RapidMiner in more than 40 countries give their users a competitive edge [119].

Viscovery SOMine is a system which combines methods of classical statistics and self-organizing maps (SOM) for explorative data mining and predictive modeling. The SOM technology is used for representing and visualizing data distributions that may contain large number of variables data sets [142]. The visual interface allows direct, context-sensitive access to the original data records underlying the map formations and their complete statistics at any point in the analytical workflow. The system enables exploratory data mining, statistical analyses, profiling and

segmentation, visual cluster analyses, various approaches for classifications [134]. The system provides a number of classical statistical functions including descriptive statistics, group profiles, correlation analysis, principal component analysis, histograms, or scatterplots.

XLMiner is comprehensive data mining add-in for Excel, including numerous models, such as neural nets, classification and regression trees, logistic regression, linear regression, Bayes classifier, K-nearest neighbors, discriminant analysis, association rules, clustering, or principal components [38]. The authors of XLMiner claim that it is possible to sample data from virtually any database and clean it with a comprehensive set of data handling utilities including categorizing data and handling missing values. The visualization include wide selection of tools starting from simple bar, line and histogram charts to advanced multiple linked charts, one-click changes to axes, colors and panels, zooming and brushing.

IBM SPSS Statistics is the specialized statistical software for performing the data analysis process. It includes tools for loading data from various sources and preparing it for work by enabling necessary transformations, such as handling missing values, sorting variables). Different statistical methods are used for full data analysis and obtaining meaningful results. The results can be visualized in graphs and tables and the output data can be exported to various formats. SPSS is widely used environment, adopted by more than 300,000 companies over the world. Among the customers there are 95 percent organizations from the Fortune 1000 list of the most profitable businesses [58]. The encapsulated mathematical and statistical expertise enables to extract predictive knowledge that when deployed into existing processes makes them adaptive to improve outcomes [130].

4. INVESTAVIMO RIZIKĄ LEMIANČIŲ VEIKSNIŲ TYRIMAI

4.1. Veiksnių, įtakojančių kaupimo fonduose efektyvumą, tyrimas

2012 metais buvo atliktas veiksnių, turinčių įtakos kaupimo privačiuose pensijų fonduose efektyvumui, tyrimas. MS Exel aplinkoje sukurta speciali skaičiuoklė, kurios pagalba nustatyta kaupimo trukmės, įmokų dydžio, mokesčių, investicijų gražos įtaka sukauptai sumai. Nors tyrimo objektas buvo pensijų fondai, tačiau nustatyti principai lygiai taip pat sėkmingai pritaikomi ir investavimui į kitus finansinius instrumentus.

Įvadas

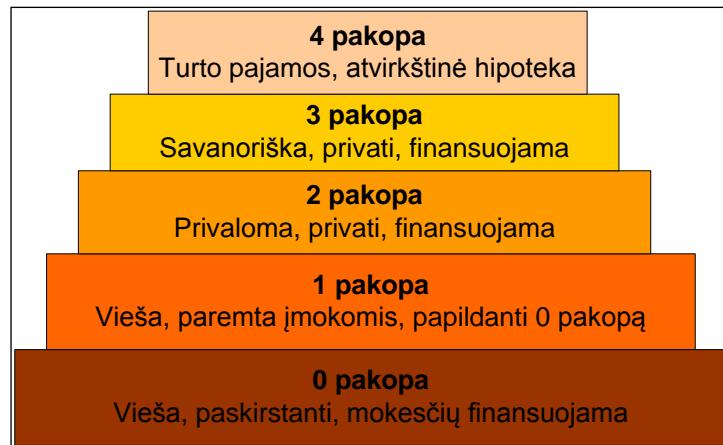
Nuo privačių pensijų fondų veiklos pradžios šioje kaupimo sistemoje išryškėjo kai kurios problemos ir trūkumai: mažas dalyvių finansinis raštingumas, neoptimalus pensijų fondų pasirinkimas ir emocijomis grįsta migracija tarp fondų. Kaupimo dalyvius būtina skatinti tobulinti finansų žinias ir aktyviau įsitraukti į savo pensijos kaupimo proceso valdymą. Tam gali pasitarnauti informacinės komunikacinių technologijos.

Lietuvoje iki 2013 metų veikė trijų pakopų pensijų sistem, šios trys pakopos buvo atskirtos viena nuo kitos. Tačiau Lietuvos Respublikos Vyriausybė 2011 m. pasiūlė (igyvendino 2013 m.) naują pensijų kaupimo sistemos modelį, kuris iš esmės apjungia kaupimą antros ir trečios pakopų pensijų fonduose. Šiame darbe tiriamos tokio modelio savybės, privalumai ir trūkumai.

Šiame skyriuje aprašomas sukurtas programinis įrankis, skirtas sumodeliuoti pensijų fonde įvairiomis sąlygomis sukauptas pinigų sumas, bei 2012 m. atlikto tyrimo rezultatai. Panaudojant įrankį atlikta investavimo efektyvumą lemiančių veiksnių analizę, remiantis LR Vyriausybės 2011 m. pasiūlytu kaupimo modeliu.

1. Lietuvos pensijų sistema

Nors nėra vieningos pensijų sistemos pakopų klasifikacijos, tačiau žemiau pateikiamas Pasaulio banko sudarytas daugiapakopės sistemos modelis.



Šaltinis: sudaryta autoriaus remiantis LR Vertybinių popierių komisijos ir Pasaulio banko duomenimis

1 pav. Daugiapakopė pensijų sistema

Pensijų sistemos įvairiose šalyse skiriasi ir nėra vieningo modelio. Paprastai yra derinamas valstybinis ir privatus kaupimas [102]. Valstybinės pensijos remiasi PAYG (angl. pay-as-you-go) principu, kai vykdomas einamuoju metu turimų lėšų perskirstymas. Privatūs pensijų planai dažniausiai yra savanoriški ir remiasi kaupimo principu.

Lietuvos pensijų sistemos reforma buvo atlikta 2004 metais. Iki 2013 metų veikė tokia trijų pakopų pensijų sistema [4]:

- Pirma pensijų pakopa – valstybinė pensija. Ji bus mokama iš ateityje dirbančiųjų sumokėtų mokesčių “Sodrai”.
- Antros pakopos pensijų fondai. Žmogaus asmeninėje sąskaitoje kaupiamą dalį dabar valstybės surinktų “Sodros” mokesčių.
- Trečios pakopos pensijų fondai. Žmogus savanoriškai investuoja savo asmenines lėšas. Valstybė tai skatina, taikydama mokesčių lengvatas.

Jeigu antroje pakopoje kaupimui skiriama tik dalis mokamų mokesčių ir tiesioginių papildomų išlaidų nepatiriamą, tai į trečios pakopos pensijų fondus gyventojai investuotoja savo turimas lėšas.

2. Modeliuojama pensijų sistema

Tyrime panaudoti Lietuvos Respublikos Vyriausybės pranešime (2011) aprašyti pensijų sistemos principai.

Pasiūlyta pensijų kaupimo tvarka numatė, kad žmogaus įmoka senatvės pensijai susidėtu iš trijų dalių – iš „Sodros“ biudžeto pervedamos įmokos, asmens lėšomis

mokamos įmokos ir valstybės mokamos skatinamosios įmokos už dalyvavimą privačiame kaupime.

Pirmoji įmokos dalis. I pravačius pensijų fondus ir draudimo įmones iš „Sodros“ yra pervedama 2 proc. dydžio įmoka nuo draudžiamujų pajamų.

Antroji įmokos dalis. Žmogus gali savo iniciatyva apsispręsti kaupti didesnę pensijos dalį privačiuose fonduose ir iš savo lėšų mokėti papildomas įmokas. Tokiu atveju žmogus nuo 2013 metų mokėtų 1 proc., o nuo 2016 metų – jau 2 proc. dydžio įmoką nuo draudžiamujų pajamų pravačiam pensijų fonui.

Trečioji įmokos dalis. Siekdama skatinti kaupimą pravačiuose pensijų fonduose, valstybė finansiškai skatintų žmogų, kuris savo lėšomis nuspręstų papildomai pensiją kaupti pravačiuose fonduose ir mokėtų papildomas įmokas į jį. Tokiu atveju i jo pensijų sąskaitą iš valstybės biudžeto būtų pervedama papildoma skatinamoji įmoka, kurios dydis nuo 2013 metų būtų 1 proc., o nuo 2016 m. – 2 proc. vidutinio darbo užmokesčio šalies ūkyje, kurį skelbia Statistikos departamentas

Be to, buvo siūloma nuo 2020 metų „Sodros“ pervedamą įmoką – pirmają įmokos dalį – didinti iki 3,5 procentų.

Esamiems pensijų kaupimo dalyviams, kurie pareikštū atsisakymą dalyvauti naujojoje sistemoje arba mokėti papildomą įmoką, kaip ir iki šiol, būtų pervedama tik 2 proc. dydžio kaupiamoji įmoka iš „Sodros“.

Skaičiavimo metodika

Kaupimo scenarijų modeliavimas atliekamas naudojant Microsoft Excel programa sukurtą skaičiuoklę. Joje galima keisti šiuos parametrus: dalyvio amžių, išėjimo į pensiją amžių, pradinį atlyginimo dydį bei jo tolesnį kitimą, pensijų fondų valdymo bendrovių taikomą įmokos ir turto mokesčių dydžius, prognozuojamą investicijų grąžą, Sodros pervedamos įmokos dydį. Pastarasis parametras atskirai nurodomas dviem laikotarpiams - iki 2020 m. sausio 1 d ir vėlesniams.

Atlyginimo dydis gali kisti per visą kaupimo laikotarpį. Jis yra suskaidytas į 5 metų intervalus. Kiekvienam 5 metų periodui nurodomas prognozuojamas atlyginimas, kurio dydis išreiškiamas procentiniu pokyčiu nuo pradinio atlyginimo. Pavyzdžiui, jeigu 1-5 metais pradinis atlyginimas yra 2000 Lt, tai 6-10 metais jis gali siekti 140% pradinio atlyginimo ir sudaryti 2800 Lt.

Skaičiuoklė modeliuoja sukauptą pinigų sumą dalyvaujant skirtingose kaupimo sistemose. Vienu atveju kaupama tik antros pakopos pensijų fonde, kitu atveju kaupama pagal Vyriausybės pasiūlytą sistemą. Šiuo atveju apjungiami trys įmokų

šaltiniai. Sodros įmokos išlieka tokios pačios kaip ir pirmu atveju, tačiau prisideda savanoriškos įmokos bei valstybės priedas. Iki 2016 sausio 1 d. savanoriška įmoka sudaro 1% atlyginimo, vėliau - 2%. Analogiškai kinta ir valstybės priedas, tik jis skaičiuojamas nuo vidutinio šalies darbo užmokesčio dydžio. Skaičiuoklėje šis rodiklis kiekvienais metais padidinamas 3%.

Iplaukos fondą pasieka kiekvieną mėnesį. Kiekvieną kartą prie jau sukauptos sumos pridedama nauja įmoka, prieš tai atėmus įmokos mokesčių. Taip pat kiekvieną mėnesį atskaitomi turto mokesčiai ir pridedama investicijų grąža arba atimami nuostoliai.

Vienu metu modeliuojamas tiek bendras sukaupto turto kitimas, tiek atskirų įmokų šaltinių kitimas. Dėl šios priežasties galima atlikti detalią pinigų srautų analizę.

Didelę įtaką prognozuojamai sukaupti sumai turi investicijų grąža. Skaičiuoklėje galima nurodyti, kiek tikimasi, kad vidutiniškai per metus paaugs kiekviena į fondą pversta įmoka.

LR Vertybinių popierių komisija (2010) atliko tyrimą, kurio metu suskaičiavo, kokią grąžą būtų davę skirtingų rizikos grupių fondai per 40 metų laikotarpį (nuo 1970 m. birželio 30 d. iki 2010 m. liepos 15d.). Papildomai nagrinėtiems fondams buvo suskaičiuotas vidinės grąžos normos (IRR) rodiklis, parodantis, kokių vidutiniu metiniu tempu augo į fondus pverstos įmokos per visą kaupimo laikotarpį. Akcijų fondo IRR buvo - 6,3%, konservatyvaus fondo – 6,9%, o subalansuoto - 7%.

Mes savo tyrime orientuojamės į 5% tikėtiną investicijų grąžą. Paprastai tokio tipo skaičiavimuose modeliuojamas tik galimas pelnas. Tačiau investuojant, ypač trumpesniams laikotarpiui, galimi ir nuostoliai, todėl modeliuojami ir tokie scenarijai.

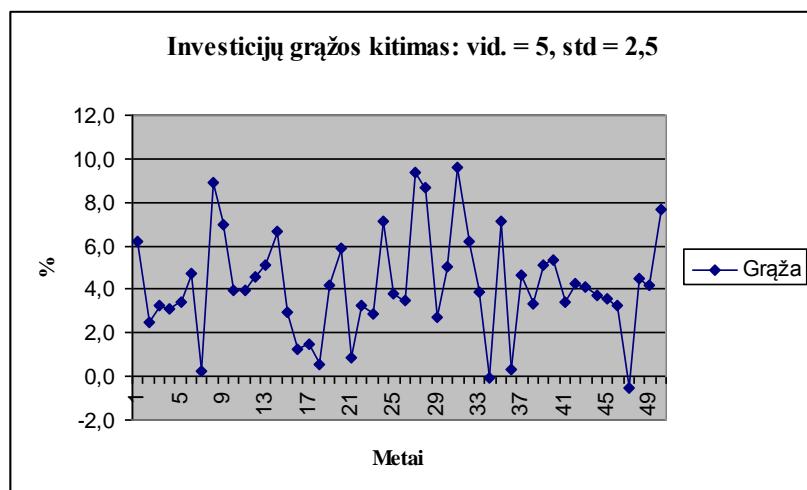
3. Pensijų fondų pelningumo ir jų įtakojančių veiksnių tyrimo rezultatai

Mūsų tyrimo tikslas yra išsiaiškinti, kokias pinigų sumas galima sukaupti, priklausomai nuo kaupimo sistemos, kaupimo trukmės, atlyginimo dydžio, investicijų grąžos, administravimo mokesčių. Taip pat siekiama nustatyti, kokią įtaką galutinei sukauptai sumai turi atskiri iplaukų šaltiniai: Sodros įmokos, asmeninės lėšos, valstybės priedai.

Pradžioje tiriamas **sukauptos sumos priklausomybė nuo atlyginimo ir kaupimo trukmės**. Skaičiavimo parametrai: pensijinis amžius – **65**, įmokos mokesčis (%) - **2%**, metinis valdymo mokesčis nuo turto **1 %**, Sodros pervedama dalis į fondą - **2%**, Sodros pervedama dalis į fondą nuo 2020 metų - **3,5%**, atlyginimo dalis pervedama į fondą nuo 2013 m. - **1%** (nuo 2016 m. - **2%**), fonde anksčiau sukaupta suma - **0 Lt.**

Atlyginimas per kaupimo laikotarpį kinta pradinio dydžio atžvilgiu: 1-5 metais sudaro 100%, 6-10 metais – 120% Lt, 11-15 metais – 140%, 16-20 metais – 200%, 21-25 metais – 200%, 26-30 metais – 180%.

Modeliuojama nepastovi investicijų grąža (2 pav.). Ji kinta pagal normalujį skirstinį. 50 metų laikotarpio vidutinė metinė grąža yra 5%, standartinis nuokrypis – 2,5. Grąža skirtinges metais svyruoja nuo -1% iki 10%.

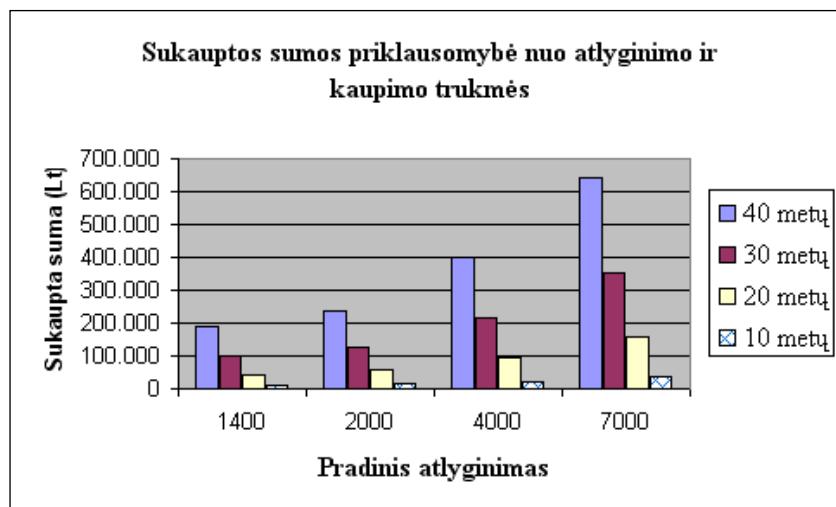


Šaltinis: sudaryta autoriaus

2 pav. Investicijų grąžos kitimas

Gauti rezultatai rodo, kad sukaupta suma yra tiesiogiai proporcinga gaunamam atlyginimui. Taip pat labai didelę reikšmę turi kaupimo trukmė.

3 pav. matyti, jog žmogus, gaunantis pradinį 2000 Lt atlyginimą ir kaupiantis 40 metų gali sukaupti tiek pat, kiek gaunantis 4000 Lt, tačiau kaupti pradėjęs 10 metų vėliau.



Šaltinis: sudaryta autoriaus

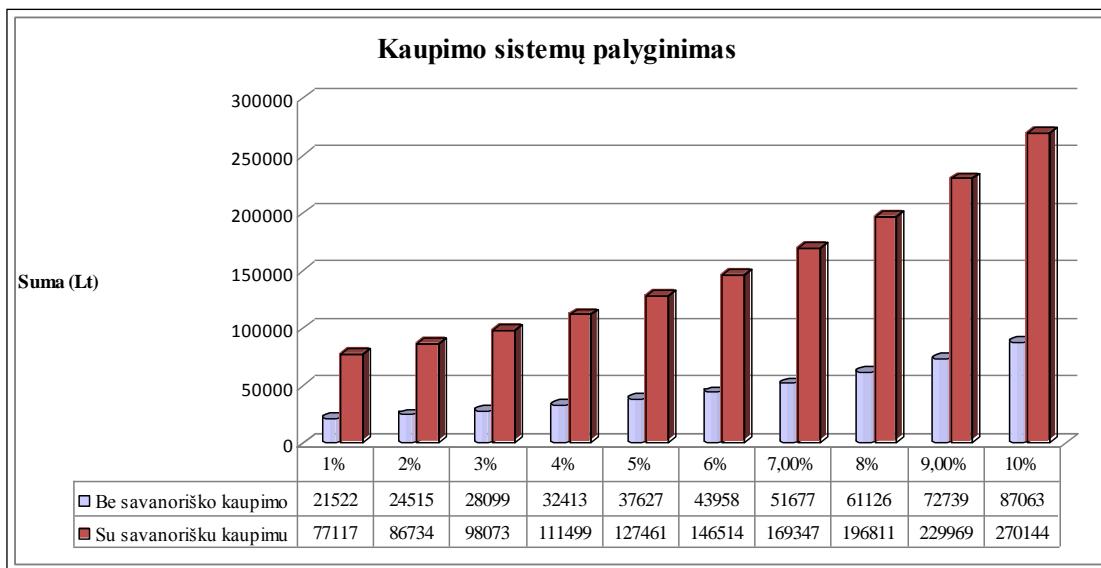
3 pav. Atlyginimo ir kaupimo trukmės reikšmė

Siekiant išsiaiškinti skirtinį investicijų grąžos skaičiavimo metodikų įtaką rezultatams, analogiškas modeliavimas atliktas naudojant nekintantį grąžos rodiklį. Šiuo atveju įmokos augo vienodu ir stabiliu 5% per metus tempu. Palyginus rezultatus, jie skyrėsi ne daugiau kaip 0,1%. Per kelių dešimtmečių laikotarpį sukauptų sumų skirtumai beveik išsilygino. Todėl, analizuojant kitus veiksnius, yra laikoma, jog visos įmokos auga vienodu vidutiniu metiniu tempu.

Tiesa, reikia pažymėti, jog norint tiksliau modeliuoti kaupimą rizikinguose fonduose, derėtų naudoti kintančią investicijų grąžą. Ypač tuomet, kai yra dideli investicinių vienetų vertės svyravimai ir lėšos į fondą mokamos netolygiai. Galima situacija, kai, pavyzdžiui, per pirmus 5 metus fondas uždirbs 6% metinę grąžą, tačiau į jį bus pervedamos mažos pinigų sumos. Tuo tarpu per kitus 2 metus gali būti pervedtos didelės pinigų sumos, tačiau fondas patirs staigų 20% vertės kritimą. Tuomet vidutinė metinė fondo grąža gali neatitikti realios investicijų grąžos. Siekiant tirti tokius atvejus, skaičiuoklėje turėtų būti galimybė generuoti atsitiktinį grąžos kitimą.

Toliau palyginamos skirtinios kaupimo sistemos įvertinant investicijų grąžą. Skaičiavimo parametrai: amžius – **35**, pensjinis amžius – **65**, kaupimo trukmė metais – **29**, įmokos mokesčis (%) - **2%**, metinis valdymo mokesčis nuo turto **1 %**, Sodros pervedama dalis į fondą - **2%** (nuo 2020 metų - **3,5%**), atlyginimo dalis pervedama į fondą nuo 2013 m. - **1%** (nuo 2016 m. - **2%**), fonde anksčiau sukaupta suma - **0 Lt**, pradinis atlyginimas - **2000 Lt.** **Atlyginimo kitimas pradinio dydžio atžvilgiu:** 1-5 metais – 100%, 6-10 metais – 120% Lt, 11-15 metais – 140%, 16-20 metais – 200%, 21-25 metais – 200%, 26-30 metais – 180%.

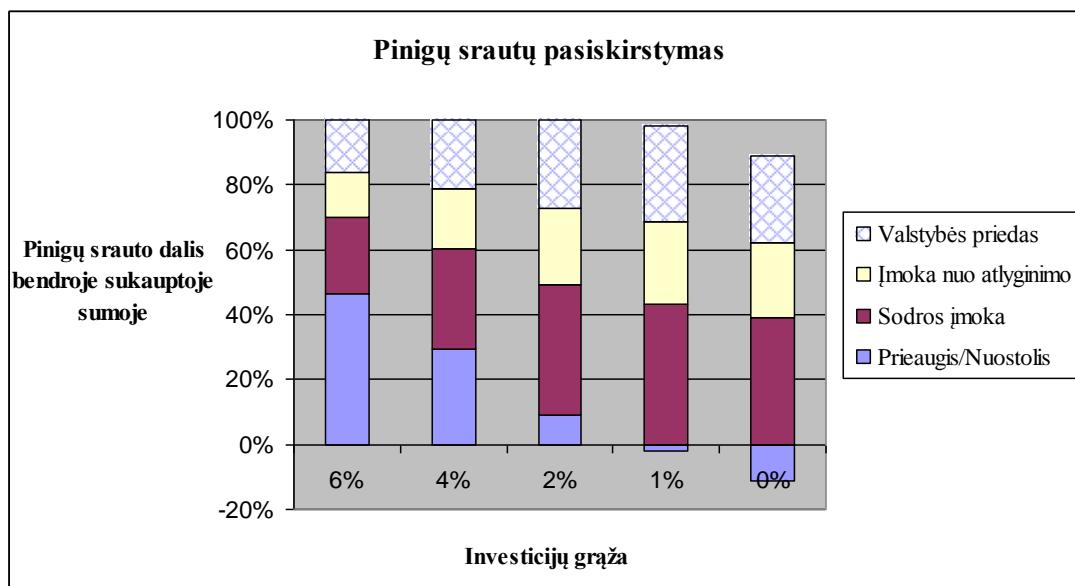
Rezultatai rodo, kad nuo 2013 m. kaupimui papildomai skiriant 1% nuo draudžiamujų pajamų, o nuo 2016m. - 2%, per 29 metų laikotarpį galima sukaupti iki 4 kartų didesnę sumą, nei kaupiant vien tik Sodros pervedamas įmokas. Labai svarbią reikšmę turi investicijų grąža. 2% grąža leistų sukaupti 86734 Lt, kai tuo tarpu esant vidutinei 7% metinei grąžai būtų sukaupta beveik dvigubai didesnė suma – 169347 Lt (4 pav.).



Šaltinis: sudaryta autoriaus

4 pav. Kaupimo sistemų palyginimas įvertinant investicijų grąžą

Investicinio prieaugio įtaka sukauptai sumai. Skaičiavimams atlikti naudojami tie patys parametrai kaip ir ankstesniame uždavinyje. Pinigų srautų pasiskirstymo diagramoje (5 pav.) matyti, jog Sodros įmokos, savanoriškos įmokos ir valstybės priedas bendroje sumoje pasiskirsto panašiomis dalimis ir šis santykis iš esmės nekinta keičiantis investicijų grąžai. Tuo tarpu pastarasis veiksny, kurį prognozuoti sunkiausia, turi labai didelę reikšmę galutinei sukauptai sumai.



Šaltinis: sudaryta autoriaus

5 pav. Pinigų srautų pasiskirstymas

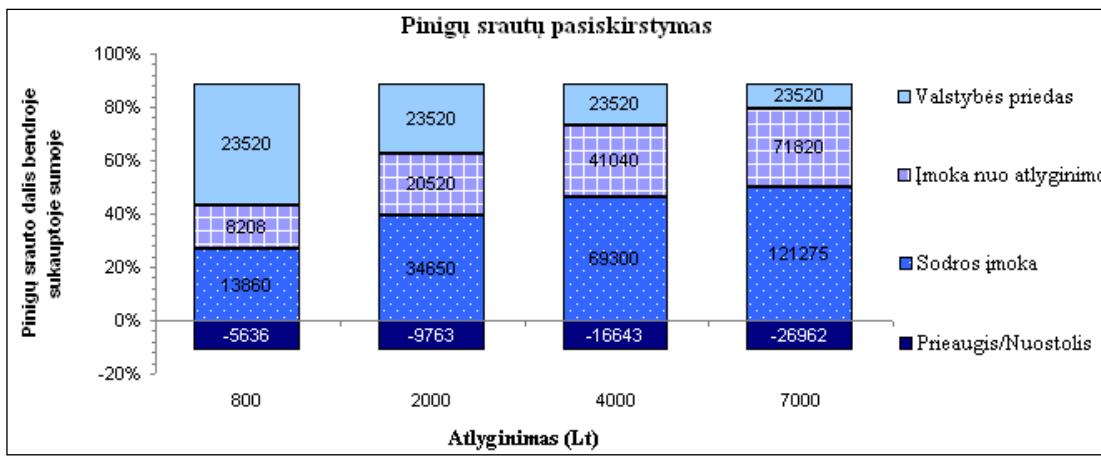
Yra priimta skaičiuoklėse naudoti 6% tikėtiną vidutinę metinę investicijų grąžą. Tokiu atveju beveik pusę sumos, kurią tikimasi sukaupti per 30 metų laikotarpį, turėtų sudaryti investicinis prieaugis. Lūkesčiams nepasitvirtinus, ši pinigų dalis nebūtų gauta. Tuo tarpu fondui pasiekus tik 1% metinę grąžą, jos neužtektų net mokesčiams padengti ir bendras prieaugis būtų neigiamas.

Dėl šių priežasčių svarbu atsakingai prognozuoti galimą investicijų grąžą, priimant sprendimus išanalizuoti įvairius galimus scenarijus.

Kitas svarbus faktorius yra draudimo įmonių taikomi mokesčiai. Iš pirmo žvilgsnio jie atrodo nedideli, tačiau skaičiavimai rodo, kad jie gali ženkliai sumažinti sukauptą sumą. Mokesčių įtaka gali būti skirtinga. Tyrimo metu siekta išsiaiskinti jų įtaką tiems investuotojams, kurių pajamos kelis kartus viršija vidutinį šalies darbo užmokestį. Nagrinėti keturi atvejai, kai kaupiama 30 metų, tačiau skiriasi gaunamas atlyginimas ir tuo pačiu įmokos į pensijų fondą. Pirmu atveju pradinis atlyginimas yra 800 Lt, antru – 2000 Lt, trečiu – 4000 Lt, ketvirtu – 7000 Lt. Visais atvejais modeliuojamas tokš atlyginimo kitimas, palyginus jį su pradiniu atlyginimu: 1-5 metais – 100%, 6-10 metais – 120%, 11-15 metais – 140%, 16-20 metais – 200%, 21-25 metais – 200%, 26-30 metais – 180%. Pavyzdžiui pradinis 7000 Lt atlyginimas kinta taip: 1-5 metais – 7000 Lt, 6-10 metais – 8400 Lt, 11-15 metais – 9800 Lt, 16-20 metais – 14000 Lt, 21-25 metais – 14000 Lt, 26-30 metais – 12600 Lt.

6 pav. pavaizduotas pinigų srautų pasiskirstymas galutinėje sukauptoje sumoje. Kadangi skaičiavimams naudojama 0% metinė investicijų grąža, gautas nuostolis atitinka valdymo įmonei sumokėtus mokesčius. Absoliutine išraiška daugiau uždirbantis investuotojas sumoka daugiau mokesčių, tačiau santykinių visais atvejais mokesčiams tenka vienoda pinigų srauto dalis.

Mažiausiai uždirbantis investuotojas iš viso sumokėtų 5636 Lt mokesčių. Tuo tarpu uždirbantis 7000 Lt – 26962 Lt mokesčių. Svarbu atkreipti dėmesį, kad šiuo atveju valstybės priedas sudarytų tik 23520 Lt ir būtų mažesnis už sumokėtus mokesčius.



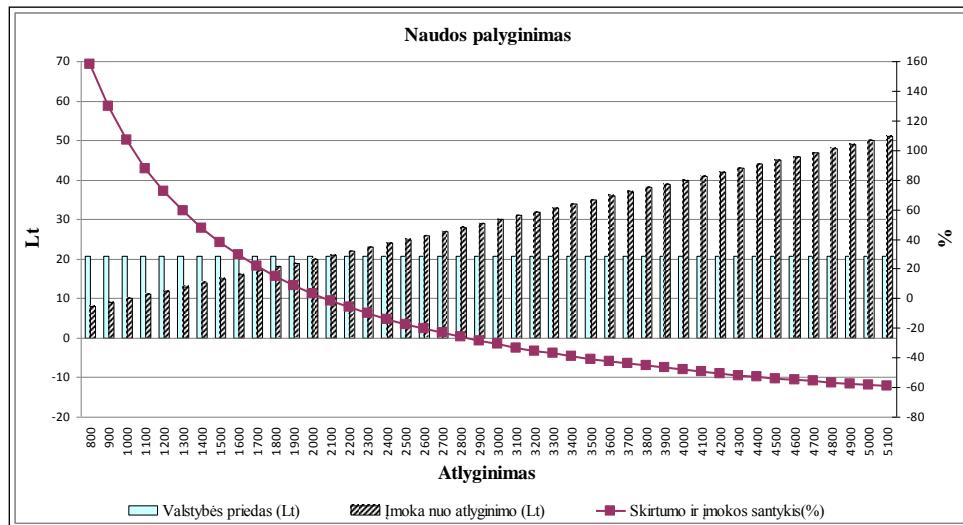
Šaltinis: sudaryta autoriaus

6 pav. Mokesčių įtaka: sukauptos pinigų sumos pjūvis pagal įmokų šaltinius

Šie skaičiavimai rodo, kad Vyriausybės siūloma sistema nemotyvuotų pagal ją kaupti daug uždirbančius žmones, nes valstybės priedo neužtektų net mokesčiams padengti. Taip atsitinka dėl to, jog priedas skaičiuojamas nuo vidutinio atlyginimo šalyje, o įmokos į fondą atskaitomos nuo keliskart didesnio atlyginimo.

Būtent valstybės taikomos mokesčių lengvatos skatina žmones kaupti lėšas senatvei. Tačiau įmanomos įvairios situacijos, kai šios lengvatos nepadengia investavimo kaštų, todėl prieš investuojant būtina atsakingai įvertinti konkrečias aplinkybes.

7 pav. palyginta valstybės priedo teikiama nauda skirtingas pajamas gaunantiems investuotojams.



Šaltinis: sudaryta autoriaus

7 pav. Naudos palyginimas

Valstybės priedas visais atvejais yra vienodas, tačiau savanoriškos įmokos skiriasi. Grafike pavaizduota linija žymi investuotojo „pelną“ – skirtumo tarp valstybės priedo ir savanoriškos įmokos santykį su pastaruoju dydžiu. Žmogus, uždirbantis 1000 Lt, gauna valstybės priedą, kuris dvigubai viršija jo savanorišką įmoką. Tuo tarpu uždirbantis 4000 Lt per mėnesį, gauna priedą, kuris sudaro tik pusę jo savanoriškai mokamos sumos.

Skaičiavimai rodo, kad teoriškai sistema yra palankesnė mažesnį nei vidutinį atlyginimą gaunantiems žmonėms. Tokiu atveju valstybės priedas viršija asmeninių įmokų dydį ir jis kompensuoja išlaidas kaupimo valdymui. Tačiau kyla problema, jog šiems žmonėms gali nepakakti lėšų kaupimui antros pakopos pensijų fonde.

Taigi, kaupimo efektyvumą lemia daug faktorių, kurių reikšmė skirtingomis sąlygomis yra nevienoda. Skiriasi investuotojų amžius, atlyginimas, rizikos tolerancija, lūkesčiai, galimybė naudotis lengvatomis bei kiti veiksnių, tačiau kiekvienu atveju būtina ieškoti optimalaus investavimo sprendimo. Šiuo metu viena iš didžiausių problemų yra žemas kaupimo sistemos dalyvių finansinio raštingumo lygis. Sprendimai priimami remiantis neteisinga informacija.

Siekiant išspręsti šias problemas, galima pasitelkti informacines komunikacines technologijas. Ir šiuo metu elektroninės bankininkystės sistemoje pateikiama pagrindinė informacija apie asmeninę pensijų fondo sąskaitą: sukauptą sumą, per tam tikrą laikotarpį atliktos įmokos, atskaičiuoti mokesčiai, investicinio prieaugio pokytis. Visų pirma būtina skatinti labiau domėtis finansų srityje ir aktyviau įsitraukti į kaupimo proceso valdymą. Taip pat galima išplėsti elektroninės bankininkystės sistemų funkcionalumą, jas papildant modeliavimo įrankiais. Kiekvienas pensijų fondo dalyvis turėtų turėti galimybę modeliuoti galimus kaupimo scenarijus naudojant jo asmeninius duomenis. Keičiant įvairius parametrus, stebint jų įtaką galimiems rezultatams bei tuo pačiu mokantis finansų pagrindų, būtų sudarytos prielaidos priimti geresnius investicinius sprendimus.

Išvados

Panaudojant Sodros įmokas, asmenines lėšas bei valstybės teikiamus priedus, galima sukaupti ženkliai didesnes sumas nei kaupiant tik antros pakopos pensijų fonduose. Tačiau Lietuvos Respublikos pensijų sistema sistema yra sudėtinga. Tai lemia keli skirtinės įmokų šaltiniai bei dubliavimasis su esama sistema. Nuo 2013 m. veikianti sistema yra palankesnė mažesnė nei vidutinė pajamas gaunantiems žmonėms, tačiau jie gali netūrėti laisvų lėšų tokiam kaupimui.

Sudarant pensijų kaupimo sutartis, būtina atsakingai išanalizuoti konkrečią situaciją bei įvertinti visus veiksnius turinčius įtakos kaupimo strategijos efektyvumui. Būtina atkreipti dėmesį į tai, kokią planuojamos sukaupti sumos dalį sudaro sunkiai prognozuojamos įplaukos.

Nors rinkų svyrapimai yra pavojingesni esant trumpesniam investavimo laikotarpiui, tačiau kaupiant ilgesnį laiką investavimo grąžą įgyja vis didesnę reikšmę galutinės sukauptos sumos dydžiui. Svarbu įvertinti administravimo mokesčius: esant nepakankamai investavimo grąžai galutinė sukaupta suma gali būti mažesnė už įmokėtą sumą.

4.2. Daugiakriterinis ilgalaikių taupymo priemonių pasirinkimo modelis

Panaudojus gautus tyrimų rezultatus sukurtas investicinio sprendimo priėmimo modelis, kuris realizuotas sprendimų paramos sistemoje.

1 Įvadas

Socialinės sistemos trūkumai, asmeninių finansų valdymas ir ilgalaikių taupymo priemonių taikymas tampa vis aktualesne problema, kuri tiriama ir moksliniame lygmenyje. Finansų teoretikai ir elgsenos ekonomikos krypties mokslininkai tiria, kaip žmonės elgiasi priimdami investicinius sprendimus. Teoriniai ir praktiniai darbai siekia sukurti optimalius asmeninių finansų valdymo modelius, būsimų finansinių srautų prognozavimo mechanizmus bei investavimo priemonių vertinimo metodikas. Reikalinga sukurti tokias ilgalaikio investavimo strategijas, kurios atsižvelgtų į daugelį faktorių: valstybės socialinę politiką, investavimo instrumentų savybes, investuotojo lūkesčius bei rizikos toleranciją, konkrečių fondų veiklos rezultatus. Taigi, šio darbo **objektas** yra trečios pakopos pensijų fondai ir investicinis gyvybės draudimas. Straipsnyje nagrinėjama **problema** - kaip teisingai pasirinkti šias ilgalaikio taupymo priemones, atsižvelgiant į jų paskirtį, galimą riziką ir pelningumą bei investuotojo poreikius. Darbo **tikslas** - pasiūlyti ilgalaikių taupymo priemonių pasirinkimo modelį. Straipsnyje terminai „taupymas“ ir „investavimas“ vartojami kaip sinonimai, nes šiuo atveju taupymui skirtos lėšos yra investuojamos finansų rinkose.

Siekiant priimti optimalius sprendimus, visų pirmą būtina nustatyti skirtingų taupymo priemonių – trečios pakopos pensijų fondų bei gyvybės draudimo – paskirtį. Taip pat reikia įvertinti jų lankstumą, riziką ir galimą pelningumą. Taupymo priemonės turi būti parenkamos atsižvelgiant į konkretaus žmogaus padėti: jo poreikius, finansines

galimybes, lūkesčius bei rizikos toleranciją. Pagal tai sukuriamas individualus asmeninių finansų valdymo modelis, sukuriama ilgalaikio investavimo strategija.

2 Egzistuojantys taupymo priemonių parinkimo ir fondų vertinimo metodai

Viena iš svarbiausių problemų yra tinkamos taupymo priemonės parinkimas. Ji turi tenkinti investuotojo poreikius bei galimybes, atitiki jo lūkesčius bei rizikos tolerancijos lygi. Svarbu išsirinkti tokį fondą, kuris generuotų didžiausią grąžą, kartu atitinkamas jam keliamus reikalavimus. Šiame skyriuje analizuojami jau sukurti metodai tokioms problemoms spręsti. Galima išskirti tris esminius etapus, parenkant ilgalaikiam investavimui skirtą fondą: investavimo priemonių grupės parinkimas (pensijų fondai ar investicinis gyvybės draudimas), investuotojo rizikos tolerancijos vertinimas, konkretaus fondo parinkimas.

2.1 Taupymo priemonių parinkimas

Lietuvos bankas [79] nurodo, jog gyvybės draudimo įmonės yra įpareigotos surinkti informaciją apie kliento asmenines aplinkybes ir finansinę būklę. Draudimo įmonė turi pasidomėti kliento amžiumi, šeimine padėtimi, vaikų skaičiumi bei jų amžiumi ir kitomis panašaus pobūdžio aplinkybėmis, kad galėtų susidaryti kuo aiškesnį vaizdą apie klientą. Finansinę būklę padeda nustatyti informacija apie darbovielę, pajamas, turtą, turimus ir planuojamus prisiimti įsipareigojimus, sudarytas sutartis. Bendrovės privalo išsiaiškinti kliento tikslus, įmokoms mokėti skirtiną pinigų sumą bei terminą, kuriam planuojama sudaryti sutartį.

Atlikta draudimo bendrovių taikomų metodikų analizė parodė, kad iš esmės visos jos naudoja panašias kliento poreikių nustatymo anketas. Pavyzdžiu, įmonė “Mandatum Life” [88] naudoja anketą, kurioje visų pirma kliento yra teiraujamas apie jo asmeninį gyvenimą: kliento šeimą ir išlaikomus asmenis, laisvalaikį bei ateities planus. Surinkus reikiamus duomenis apie kliento asmeninį gyvenimą, teiraujamas apie jo finansinę situaciją. Siekiama išsiaiškinti, kiek klientas yra finansiškai svarbus šeimoje, kokios vidutinės šeimos mėnesio išlaidos, koks yra disponuojamas turtas ir santaupos bei kokie yra šeimos įsipareigojimai. Norint sukurti klientui finansinį planą, teiraujamas apie jo ateities finansinius planus: kada ir ką planuojama įsigyti, kokia tam bus reikalinga suma ir kokie būtų tokio poreikio finansavimo šaltiniai.

Gyvybės draudimas gali būti panaudojamas ne tik apsidrausti nuo galimos rizikos, bet ir taupyti. Pvz., dalis lėšų nukreipama į draudiminę apsaugą, kita dalis – investiciniams vienetams pirkti. Santykis priklauso nuo konkretaus žmogaus poreikių. Trečios pakopos pensijų fondai yra skirti tik ilgalaikiam lėšų kaupimui.

2.2 Rizikos tolerancijos tyrimas

Lietuvos bankas [79] nurodo, jog būtina nustatyti kliento investavimo rizikos tolerancijos lygi ir įvertinti žinias, patirtį investavimo srityje bei kitą, įmonės manymu, svarbią informaciją. Tačiau pasak investicinio banko „GILD“ privataus bankininko Eimanto Viršilo, bankų turimi rizikos klausimynai neatspindi tikrosios padėties dėl investuotojo rizikos toleravimo, todėl reikalingi esminiai papildymai. Klausimynai turi būti tobulinami, kad būtų suprantamesni ir padėtu tiksliau įsivertinti riziką investuojams.

Pagal „Mandatum Life“ [88], kliento profilio vertinimas susideda iš dviejų dalių: kliento rizikos tolerancijos vertinimo ir kliento žinių bei patirties vertinimo. Kompanijos „Orion Securities“ [96] naudojamų klausimų anketą sudaro kelios pagrindinės dalys: kliento investavimo tikslai, investavimo laikotarpis, finansinė padėtis, investavimo patirtis bei žinios apie investavimą, kliento rizikos tolerancija. Panašiais principais sudarytos ir kitų analizuotų kompanijų anketos. Zvi Bodie, Alex Kane ir Alan Marcus [12] savo knygoje „Investments“ pateikia investuotojų rizikos tolerancijos vertinimo metodiką, kuri leidžia išliaiskinti, kaip žmogus linkęs rizikuoti bei kaip jis elgtusi tam tikroje situacijoje: investicijų vertei kylant arba smarkiai krentant. Svarbu nustatyti, ar deklaruojamas atsparumas rizikai atitinka galimus realius veiksmus sudėtingais momentais.

Lietuvos Respublikos vertybinių popierių komisija [85] atliko tyrimą, kurio metu nustatė, kokią grąžą (bei svyravimus) ilguoju periodu būtų parodę skirtingų turto klasių fondai. Svarbu atkreipti dėmesį į rezultatą, kuris buvo gautas simuliuojant nesékmingą fondų keitimą. Tokiu atveju sukaupta suma buvo net 7 kartus mažesnė už konservatyvaus fondo grąžą. Būtent žemas finansinis raštingumas, netinkamas fondų pasirinkimas bei emocijomis paremtas investavimo krypčių keitimas gali lemти didžiausius nuostolius. Laikomasi nuostatos, kad jauni žmonės turi rinktis rizikingesnes investicijas. Tačiau būtina atkreipti dėmesį į tai, jog dalis investuotojų, nepaisant savo jauno amžiaus, gali visiškai netoleruoti investavimo rizikos. Kyla grėsmė, jog tokio tipo žmonės nesulaiks, kol atsistatys smukusi aktyvų vertė, ir juos pardavę patirs nuostolių.

2.3 Fondų veiklos rezultatų vertinimas

Fondų veiklos rezultatai iš esmės nulemia investavimo sėkmę, todėl svarbu teisingai nustatyti, kurie iš jų yra efektyviausi, tam panaudojant tinkamus kriterijus. P. P. Antolin (2008) pateikė skirtingų žemynų šalyse veikiančių privačių pensijų fondų veiklos vertinimą. Buvo atsižvelgta į fondų veiklos reguliavimą bei investicijų

pasiskirstymą. Pagrinde buvo vertinama pagal investicijų grąžą. Autoriaus naudojamoje metodikoje svarbią vietą užėmė palyginamieji indeksai: vieni rodė kokią maksimalią grąžą galima pasiekti esant tam tikrai rizikos laipsniui, kiti dar atsižvelgę į šalyse veikiančius apribojimus arba bendrojo šalies augimo poveikį. P. Antolin rizikos vertinimui skaičiavo standartinį nuokrypi, taip pat naudojo Sharp rodiklį. Atlirkas tyrimas parodė, kad daugumos pensijų fondų rezultatai atsiliko nuo palyginamųjų indeksų reikšmių. Kai kuriais atvejais riziką valdantys ribojimai tik trukdė pasiekti gerus rezultatus [8].

Jurgita Klimaitė [71] pasiūlė pensijų fondų vertinimo modelį. Jame kriterijai suskirstyti pagal vertintojus. Esamiems pensijų fondų dalyviams siūloma atsižvelgti į pensijų fondų pelningumą, administravimo bei fondo keitimo mokesčių dydį, naudojamą investavimo strategiją [70].

Finansų institucijos vertindamos fondų rezultatus paprastai lygina jų apskaitos vieneto pokyčius. Siekiant įvertinti ilgesnio laikotarpio rezultatus, skaičiuojamas svertinis metinis apskaitos vieneto vertės pokytis. Neužtenka palyginti tik grąžą, būtina atsižvelgti į grąžos ir rizikos santykį. Tam skaičiuojamas vidutinis metinis vieneto vertės standartinis nuokrypis. Jeigu abu fondai generuoja panašią grąžą, tačiau vieno iš jų svyravimai yra ženkliai mažesni, geresniu laikomas pastarasis fondas. Remiantis šiais principais, autoriai 3.3 skyriuje pateikia savo fondų vertinimo metodiką.

Taip pat svarbu įvertinti finansų krizių poveikį pensijų fondams. Per 2008 metų finansų: krizę jų valdomo turto vertė sumažėjo 5 trilijonais dolerių palyginus su buvusiais 27 trilijonais dolerių. Esminis faktorius yra tai, kad tokie svyravimai daugiausiai žalos padaro vyriausiemis pensijų fondų dalyviams [102].

P. Antolin ir F. Stewart (2009) analizavo krizės poveikį pensijų fondams bei kokią atsakomybę turėtų prisiimti prižiūrinčios institucijos. Tyrimo tikslas buvo patobulinti pensijų fondų rinkos reguliavimo mechanizmus. Autoriai nustatė tokias pagrindines kryptis: būtinybę išlaikyti ir plėtoti privataus kaupimo sistemą, koncentruotis į ilgalaikį kaupimą, stiprinti kontrolės mechanizmus bei efektyvinti rizikos valdymą, naudoti lėšų išsaugojimo mechanizmus vėlyvojoje kaupimo stadijoje, rūpintis visuomenės finansiniu raštingumu [6].

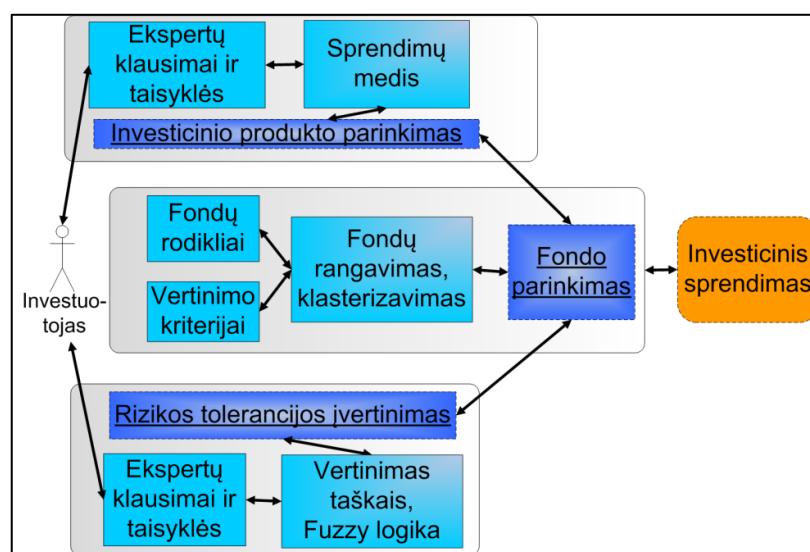
3 Siūlomas ilgalaikių taupymo priemonių pasirinkimo modelis

Egzistuoja įvairių metodų vertinti fondų veiklą bei jų pelningumą, taip pat tirti investuotojų toleranciją rizikai. Problema kyla dėl to, kad dažnai šie metodai yra

taikomi atskirai, vieno vertinimo rezultatai nėra objektyviai panaudojami kitame tyrime. Dėl to atsiranda tam tikri trūkiai konkretaus fondo parinkimo procese.

Viena iš situacijų, kai padaromas neteisingas sprendimas, yra kai žmogus, kuriam tikslingiau būtų rinktis trečios pakopos pensijų fondą, pasirenka gyvybės draudimą. Kitu atveju, net ir teisingai pasirinkus taupymo priemonę (pvz., gyvybės draudimą), gali būti netinkamai įvertinama kliento rizikos tolerancija ir pasiūlomas pernelyg rizikingo valdymo fondas. Dėl to atsiranda tikimybė, jog rinkoms susvyravus, investuotojas priims neracionalius sprendimus, investicijas parduos pačiu netinkamiausiu laiku ir praras pinigus. Taip pat pasitaiko atvejų, kai investuotojui teisingai parenkama investavimo priemonė (pvz., pasirenkami pensijų fondai), teisingai įvertinama rizikos tolerancija, tačiau investuojama ne į geriausiai dirbantį konkretų fondą. Tai gali lemti tiek paties investuotojo klaidingas pasirinkimas, tiek subjektivus finansų kompanijų produktų platinimas.

1 paveiksle pateikiamas modelis, kuris į vieną visumą sujungia taupymo priemonės parinkimą, rizikos tolerancijos tyrimą bei konkrečių fondų vertinimą bei parinkimą. Nusprenodus, koks produktas tinka geriausiai, bei ištýrus žmogaus galimybes prisiiimti riziką, atrenkama tinkamų fondų grupė. Tuomet įvertinama, kuris iš atrinktų fondų generuoja didžiausią grąžą bei geriausiai atitinka kitus kriterijus.



Šaltinis: sudaryta autoriaus

1 pav. Taupymo priemonių pasirinkimo modelis

3.1 Taupymo priemonių parinkimas

Siūlomame taupymo priemonių parinkimo modelyje visų pirma įvertinama, kokie yra tikslai: ar siekiama apsidrausti nuo galimos rizikos, ar norima sukaupti pinigų

ateičiai. Nustatoma, kokia investavimo priemonė ar jų derinys reikalingas. Žmogus turi atsakyti į ekspertų sudarytus klausimus, o tuomet pagal iš anksto parengtas taisykles priimamas sprendimas. Pavyzdžiu, žmogui, kurio pajamos sudaro didžiąją šeimos pajamų dalį ir kuris turi pačias paskolą, gali būti tikslingiau rinktis gyvybės draudimą, kuris ne tik leis kaupti ateičiai, bet ir suteiks apsaugą. Kita vertus, jaunam žmogui, negalinčiam garantuoti stabilių įmokų į fondą, tačiau ir neturinčiam didelių įsipareigojimų, tikslingiau rinktis trečios pakopos pensijų fondą. Šiuo atveju nėra įsipareigojimo daryti įmokas, bei paliekama laisvė bet kada pasitraukti iš fondo.

Vėliau įvertinami tokie faktoriai, kaip galimybė naudotis mokesčių lengvatomis ar reguliariai mokėti įmokas. Siekiama parinkti tokį produktą, kuris geriausiai atitiktų poreikius, būtų prieinamas bei finansiškai naudingas. Šiame etape labai svarbią įtaką daro šalyje galiojantys įstatymai bei jų garantuojančios lengvatos. Kaupiantys trečios pakopos pensijų fonduose arba turintys investicinį gyvybės draudimą gali pasinaudoti 15% pajamų mokesčio lengvata. Tuo tarpu įmonė, jei dalį pinigų darbuotojui kaip premiją nukreipia į jo pensijų ar gyvybės draudimo fondą, gali nemokėti pelno bei socialinio draudimo mokesčių. Sprendimo paramos sistema turi įvertinti, kokiomis lengvatomis konkretus žmogus gali pasinaudoti.

3.2 Rizikos tolerancijos tyrimas

Analizuojant finansų įmonių naudojamas anketas pastebėta atvejų, kai klausimai pateikiami nekorektiškai. Tokiais atvejais testo rezultatai gali parodyti aukštesnį rizikos tolerancijos lygi, nei yra iš tiesų. Daugiausiai tokį atvejų pastebėta tarp itin rizikingus investavimo instrumentus siūlančių įmonių. Tokie testai neatlieka pagrindinės savo funkcijos – sumažinti galimą investavimo riziką. Būtina naudoti tik objektyvius testo klausimus. Autorių sukurtas investuotojo rizikos tolerancijos nustatymo testas yra pritaikytas specialiai tam atvejui, kai ruošiamasi investuoti ilgam laikotarpiui. Teorinis įsivaizdavimas prieš pradedant investuoti dažnai skiriasi nuo realybėje atliekamų veiksmų, todėl svarbu nuolat iš naujo įvertinti investuotojo rizikos toleranciją remiantis jau realiais jo atlirkais investiciniais sprendimais.

3.3 Fondų vertinimas

Fondai vertinami pagal kelis kriterijus: ilgo ir trumpo laikotarpio vidutinį metinį investicinio vieneto vertės pokyčių (V1 ir V2), vertės svyravimo dydį - standartinį nuokrypi (ST), taikomus įmokos (IM), turto (TM), papildomus administravimo (PM), išėjimo (ISM) ir sėkmės (SM) mokesčius bei grynujų aktyvų vertę (AV). Didžiausias dėmesys skiriamas investicijų grąžai. Jeigu fondų grąžos rodikliai panašūs, tuomet

geriau vertinamas tas fondas, kurio rizikingumas (standartinis nuokrypis) yra mažesnis. Jeigu vertinamas nedidelis kiekis fondų, galima taikyti rangavimo metodą: už kiekvieną kriterijų skirti atitinkamą balų skaičių, ir taip išskirti daugiausiai balų surinkusį fondą. Svarbesniems kriterijams taikomas didesnis svorinis koeficientas.

Autorių siūloma vertinimo formulė:

(1)

$$FV_i = \left(V1_i - \frac{1}{n} \times \sum_{j=1}^n V1_j \right) + \left(V2_i - \frac{1}{n} \times \sum_{j=1}^n V2_j \right) \times 0,5 + \left(\frac{1}{n} \times \sum_{j=1}^n ST_j - ST_i \right) \times 0,5 - TM_i \times 0,3 - IM_i \times 0,15 - PM_i \times 0,1 + \frac{AV_i}{10^8} - ISM_i \times 0,05 - SM_i \times 0,1 F_i = \left(V1_i - \frac{1}{n} \times \sum_{j=1}^n V1_j \right) + \left(V2_i - \frac{1}{n} \times \sum_{j=1}^n V2_j \right) \times 0,5 + \left(\frac{1}{n} \times \sum_{j=1}^n ST_j - ST_i \right) \times 0,5 - TM_i \times 0,3 - IM_i \times 0,15 - PM_i \times 0,1 + \frac{AV_i}{10^8} - ISM_i \times 0,05 - SM_i \times 0,11$$

lentelėje pateikiamas pensijų fondų vertinimo pavyzdys. Pvz., tuo atveju, kai klientui geriausiai tinka trečios pakopos pensijų fondai, o jo rizikos tolerancijos lygis yra žemas, verčiausia būtų siūlyti fondą F_1 , kurio portfelyje akcijų dalis yra nedidelė, o įvertinimas - geriausias.

Lentelė Nr.1 Fondų vertinimas

Fondas	Akcijų dalies	V1	V2	ST	TM	IM	PM	ISM	Taškai
F_1	iki 30%	24,00	2,10	3,04	1	2	4	0	23,37
F_2	iki 50%	20,70	-8,40	5,93	1,5	2	1,65	2	13,42
F_3	iki 70%	14,07	-12,00	4,02	0,99	2	2,2	0,5	5,94
F_4	iki 30%	8,47	-5,02	2,82	1,5	3	1,25	0	4,24
F_5	iki 100%	13,70	-16,10	5,27	0,99	2	2,2	0,5	2,91
F_6	60% -100%	16,00	-16,51	16,73	1	3	4	0	-0,64
F_7	iki 100%	-19,00	-18,45	11,57	1,5	2	1,65	2	-34,30

4 Išvados

1. Dauguma šalių sunkiai sprendžia pagyvenusių žmonių sveikatos užtikrinimo ir finansinio stabilumo problemas. Tai susiję su visuomenės senėjimu, socialinių garantijų trūkumu bei priemonių jas užtikrinti stoka. Išskiriama tendencija, kad pereinama nuo vienpakopių prie daugiapakopių pensijų kaupimo sistemų. Skatinamas savanoriškas papildomas kaupimas. Šiam tikslui tarnauja trečios pakopos pensijų fondai ir investiciniis gyvybės draudimas

2. Sudarant kaupimo sutartis, būtina atsakingai išanalizuoti konkrečią situaciją bei įvertinti visus veiksnius, turinčius įtakos kaupimo strategijos efektyvumui.

Egzistuoja įvairių metodų vertinti fondų veiklą bei jų pelningumą, taip pat tirti investuotojų toleranciją rizikai. Problema kyla dėl to, kad dažniausiai šie metodai yra taikomi atskirai, vieno vertinimo rezultatai nėra objektyviai panaudojami kitame tyrime. Dėl to konkretaus investicinio fondo parinkimo procesas tampa neefektyvus.

3. Siūlomas modelis iš vieną visumą sujungia investicinio produkto parinkimą, rizikos tolerancijos tyrimą bei konkrečių fondų vertinimą bei parinkimą. Nusprendus, koks produktas tinkamai geriausiai, bei ištyrus žmogaus galimybes prisiimti riziką, atrenkama tinkamų fondų grupė. Tuomet įvertinama, kuris iš atrinktų fondų generuoja didžiausią grąžą bei geriausiai atitinka kitus kriterijus.

4. Teorinis modelis gali būti sėkmingai realizuotas praktiškai sukuriant sprendimų paramos sistemą. Tokia sistema leistų ir neprofesionaliems investuotojams atlikti daugiakriterinį strategijų modeliavimą bei priimti optimalius investicinius sprendimus.

4.3. Dinaminis investavimo procesų imitavimas ir investavimo strategijų tyrimas

Kitame etape nuo tradicinių skaičiuoklių pereita prie dinaminio realių procesų imitavimo. Powersim programine įranga sumodeliuotas investavimo į fondus procesas bei atlikti jo įvairių investavimo strategijų tyrimai.

Introduction

Many countries have a lot of problems while trying to ensure older people's health and financial stability. This is related to the aging population, lack of social guarantees and lack of measures to ensure them.

Both Lithuanian and foreign researchers study investment instruments. Research works mainly focus on investigation of social systems, and portfolio optimization. Summarizing we can state that researchers try to find the ways how to make simulation of real life processes more accurate. The ability to evaluate different scenarios by using advanced technologies could prevent from real problems. For example A. Rutkauskas (2006) uses the imitation technologies technique for an adequate portfolio development and management [108].

R. Klimaviciene (2010) states, that due to the instability of the world economy, increased longevity, higher healthcare and long-term care costs, an adequate retirement income level is a daunting challenge today. The author uses the dynamic stochastic simulation to identify the optimal portfolio allocations [72]. T. Ermolieva (2002)

analyzes optimization-based approaches for the social security simulation model under demographic and economic uncertainties. The design of optimal robust strategies is achieved by an adaptive simulation-based optimization procedure defined by non-smooth risk functions [30].

Risk management is one of the most important issues. G. Boendera (1997) suggests the decision support model that describes sustainable management of pension-funds in the strategic planning of the available asset and liability policy instruments. The main characteristic of the approach is that the relevant risk-drivers are modeled by scenarios, rather than by probability distributions. The author investigates the scenario generation methodology, and how the scenarios could be used by pension-fund managers to simulate and improve asset/liability strategies until the strategy is identified as good by all who carry responsibility for the pension-fund [13].

Researchers also analyze the methods for evaluating investment funds. In addition to determination of traditional indices I. Joksiene and A. Zvirblis (2011) propose to incorporate into evaluation the identification of key socioeconomic factors, qualitative analysis and complex quantitative assessment of the factors on the basis of the given models. Usually, constant values of salary and contribution to funds are used in spreadsheets. But these values are highly dependent on economic changes and investor opportunities, so in our model these values vary inconstantly [67].

Financial institutions also try to create methods and tools for decision support and better risk management. They use a variety of spreadsheets to calculate how much money a person can accumulate. It is important to use such tools which can simulate scenarios as closely as possible to real processes. New technologies allow this.

Table 1 shows the variables used in such spreadsheets and their default values.

Table 1. Variables used in spreadsheets

Institution/ input variable	SEB ²	MP Pension Funds ³	DNB ⁴
Annual return rate	8%	7% (unavailable to change) spreadsheet offers it's own suggestion according to income	7%
Contribution	100 Lt	-	100 Lt
Duration of investment	-	-	20 years
Periodicity of contributions	1 month	1 month (unavailable to change)	1 month
Contribution fee	3%	3% (unavailable to change)	3% (unavailable to change)
Date of birth	1970	-	-
Age at the end of investment process	55 years	-	-
Income	10000 Lt	+	-
Age	-	+	-
Gender	-	+	-

It should be noted that all spreadsheets use similar methods. In some of them initial variables are entered directly (e.g. accumulation time). In others they are calculated by the spreadsheet using additional variables (e.g. date of birth, age up to which contributions are paid).

The main variables used in spreadsheets are the following: duration of accumulation process, average annual return rate, contribution amount, contribution and asset fees. The problem is that the values of these variables remain constant during all calculation process.

Traditional spreadsheets use the same value of contributions for the entire accumulation period. The expected average return rate and tax rates remain constant too. These assumptions can lead to inaccurate calculation results.

In the previous research “Research of the factors, affecting pension funds efficiency” (2012) the authors found that in order to accurately simulate the accumulation of high-risk investments, a volatile return rate should be used. Especially when there are large variations in fund’s unit value and contributions are paid irregularly. There may be a situation when, for example, during the first 5 years fund’s annual return rate is 6%, but contributions to the fund are small. Meanwhile, over the next two years large sums of money may be paid, but the fund will suffer a sharp 20% drop in units’ value. Then, the declared average annual growth of fund’s unit value will not match the actual return of investments. In order to investigate such cases, the model should be able to generate a random variation of unit’s value, instead of using constant return rate.

The approach, which was implemented by using the Powersim software package, has been described in this work. The model, created by the authors in such environment, tries precisely to imitate the operations of pension funds. Volatile values of return rate, contribution amount and fees have been used in calculations. Simulation conditions can be adapted to specific investors' requirements by changing values of variables describing salary, duration of accumulation and other factors. Various scenarios can be simulated with the proposed tool in order to reduce risk and make a better decision.

We hope that this methodology can give more accurate results than traditional calculation methods.

Further in this section simulation environment and methodology is presented together with the case studies made by using the proposed simulation technique.

Simulation environment and methodology

This section presents a new methodology that we suggest using for imitating a real process of investment to the third-pillar pension fund. It's based on system dynamics. The model contains variables that affect each other in time.

As in traditional spreadsheets the investor specifies the investment period, the salary and the part of it that should be transferred to fund. The default frequency of contributions is one month, but this parameter can be changed. The investor can also specify the rates of fees. The tool simulates the changes of portfolio value depending on these factors and another important variable – funds' unit price. Unit prices are loaded from the file and may correspond to real historical data or be randomly generated.

Only the period of investment remains constant during all simulation. Funds' unit value, amount of contributions and rates of fees randomly fluctuate during the simulation. The proposed tool lets determine not only the initial values of contributions and fees, but also the limits they might change in the future. For example, you can specify that a monthly payment should fluctuate within 25% compared to the baseline, and the rates of fees should vary between 1-2.5% and change every 3 years.

The generalized model in Figure 1 describes the components of this process.

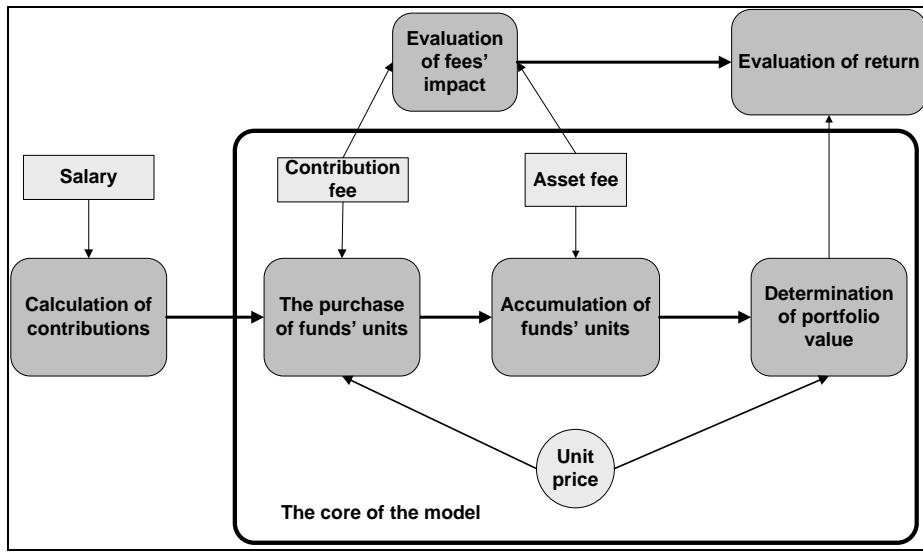


Fig. 1. The model of accumulation process

First of all, one module calculates the monthly contributions to the fund as part of investors' salary. The contribution fee is deducted from each payment. The remaining sum of money is used to buy the units of fund for the current units' price. The units are accumulated in personal account. The portfolio value depends on the fund's unit value. Each month asset fee is paid to asset management company. Finally, the impact of fees is investigated and the final return of all accumulation process is determined.

The model has been implemented using the Powersim software environment. The model is specially designed to simulate the accumulation in accordance to laws and procedures applicable in Lithuania. Generalized model in Figure 1 is explained in detail in the next 4 figures that are made in the Powersim environment.

Simulation begins with these steps:

Each month a certain part of salary is transferred to the fund: the initial payment (L_t) = salary (L_t) * contribution rate (%).

Contribution fee is deducted from the initial payment: monthly contribution after contribution fee (L_t) = initial payment (L_t) - initial payment (L_t) * contributions fee (%).

Each month the transferred sum of money is used to buy the funds' units for the current day price (units purchased per month = contribution per month / unit price).

The realization of funds' units purchase is presented in Figure 2.

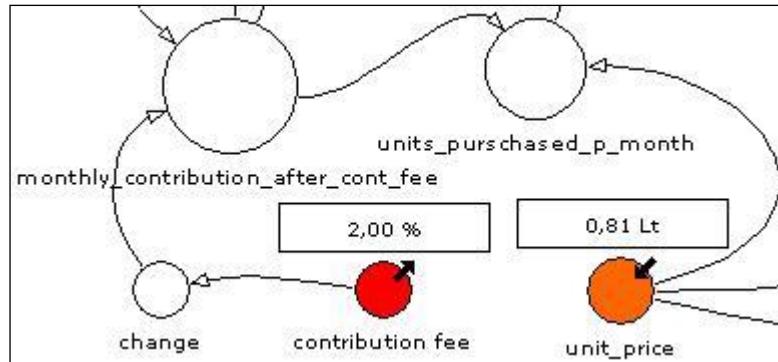


Fig. 2. The purchase of funds' units

Figure 3 presents the part of model that realizes accumulation of funds' units. New units are added to the previously purchased units. Each month asset fee is deducted from total portfolio value by reducing the amount of fund's units. The total amount of accumulated units increases each month.

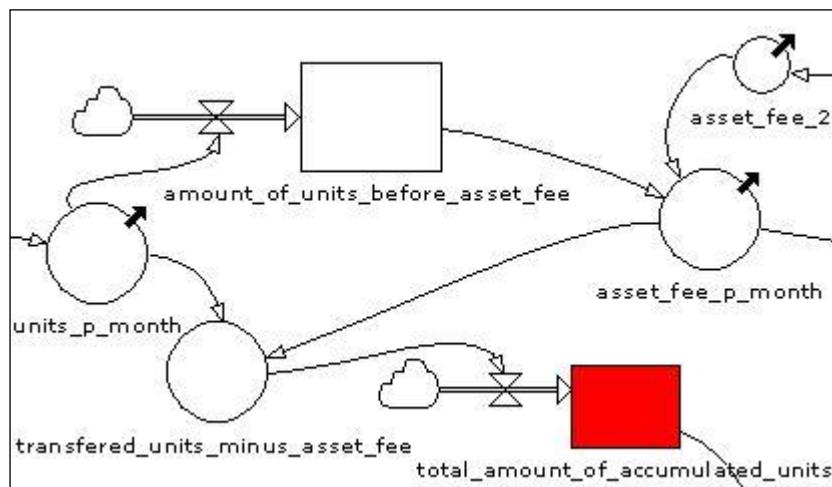


Fig. 3. The accumulation of funds' units

The actual portfolio value can be determined at any time. This is done by multiplying the number of units by the current unit price. Unit price is one of the key input variables in the model. It allows simulating the changes of investment returns. Simulation tool can use real historical data as well as randomly generated funds' unit values. Traditional spreadsheets use constant annual average return rate and give only final results. With this tool it is possible to analyze the changes of portfolio value during all investment period. The use of changing units' value realizes volatile return on investment rate. This part of model is presented in Figure 4.

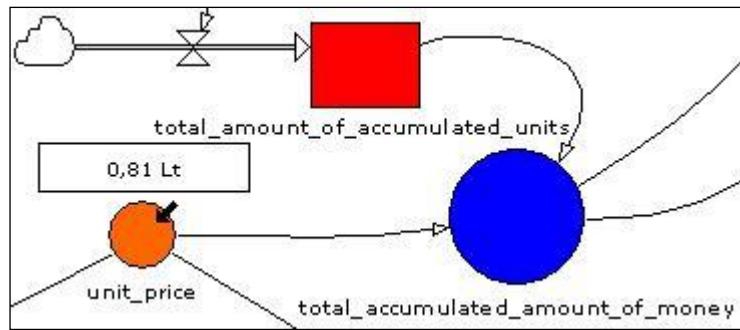


Fig. 4. The determination of portfolio value

Return of investment is calculated by deducting all contributions from the total accumulated amount of money (see Fig.5).

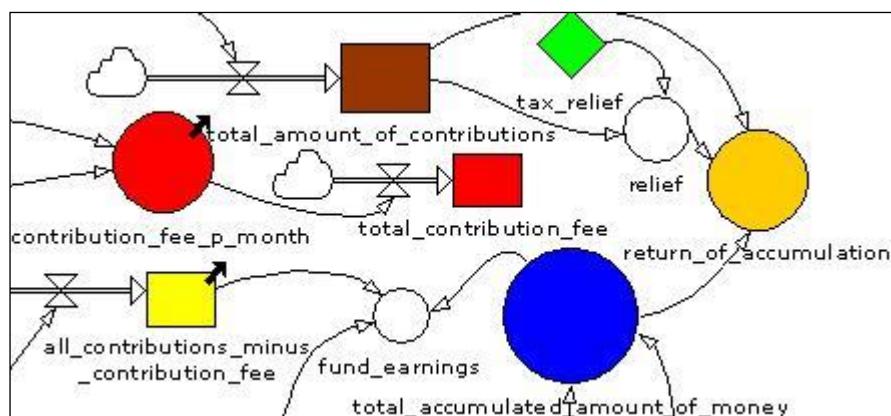


Fig. 5. Evaluation of fees' impact and investment return

It is very important to assess the impact of fees. Unprofessional investors often pay more attention to possible return rates rather than actual rates of fees. But there is common situation when total amount of fees exceeds investment returns and investor suffers losses.

Investing in the third pillar pension fund is similar to investing in life insurance funds and even traditional funds. Only structure of fees and ability to take advantage of tax relief differ in these cases. Basically, our simulator can be adapted to any kind of funds.

Case simulations

Two cases of typical problems that investors might encounter will be presented in this section. Simulation tool is used to analyze and display portfolio value changes in different situations.

In the first case we encounter with irregular growth of portfolio units' value. There is some key input variables used for simulation: duration - 21 years, initial salary - 4,000 Lt, part of the salary paid to the fund - 10%. Contribution rate changes every

year and varies randomly within 20%. The initial contribution fee - 2%, it varies for the entire period between 2% and 2.5%. Asset fee is 2%. We suppose that all random variables have normal distribution with varied mean and standard deviation.

For simulation process is very important truthfully imitate the funds' unit value variation over time. Figure 6 shows changes of funds' unit value that are generated by normal distribution. If average return rate is used in calculations, then unit value graph is linear. It does not reflect reality. In our case, the changes of units' value fairly reproduce the real process and uses normal randomness.

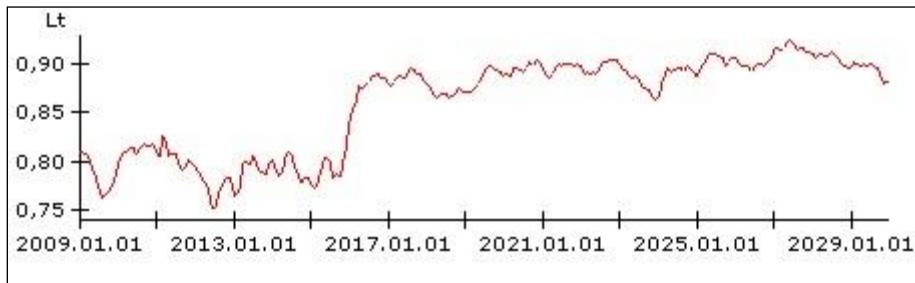


Fig. 6. The change of fund's unit value

Figure 7 shows the evolution of the total portfolios value when volatile values of return rate, contributions and fees are used for simulation. Instability of variables leads to irregular changes of portfolio value.

Calculations show that, despite the fact of increased fund's unit value by 10% during all period, the total accumulated amount of money is lower than the total amount of contributions. Although 122162 Lt was transferred to the fund, the final portfolio value is only 96.847 Lt. This loss occurs due to irregular change of unit value and unequal payments. Growth of value was higher in the first half of the period, but then stopped. Meanwhile, the asset fee has been paid from the increasing total portfolio value. Even if 18.324 Lt is got as tax refund, the final loss would be 6991 Lt.

Figure 7 illustrates such situation, but this is only one possible scenario. By changing various input parameters it is possible to obtain different nonlinear variations of portfolio value.

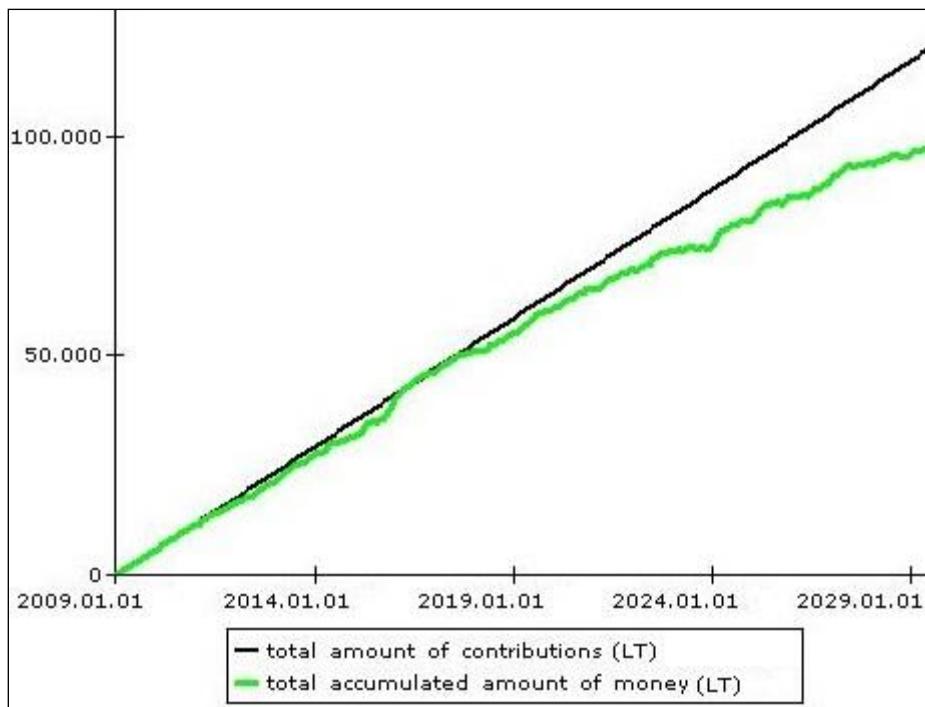


Fig. 7. Simulation results

In the second case we tried to investigate investors' behavior in crisis time. For this purpose we used funds' unit value variation adopted from real historical data of SPDR S&P 500 exchange traded fund from August 2006 to February 2012. This data is used to simulate accumulation process during the last financial crisis (Fig. 8).

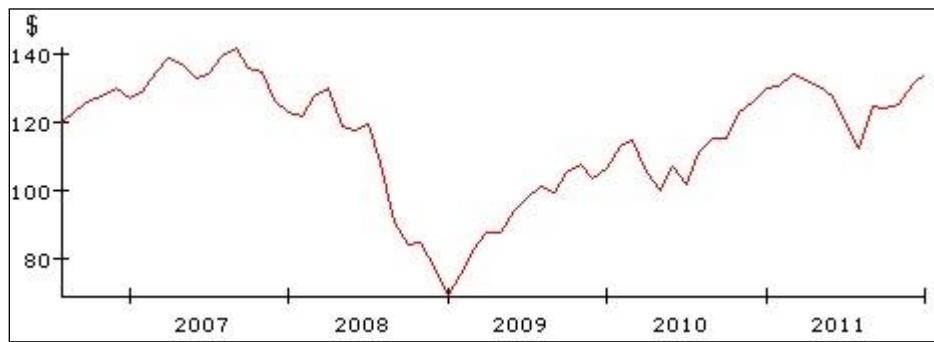


Fig. 8. The change of SPDR S&P 500 fund's unit value 2006-2011

All input values are the same as in the previous case, only duration and change of unit value differ. The simulation results are shown in Figure 9. In situation A contributions remain unchanged during all period of time while in situation B investor reduces monthly contributions from 400 Lt to 50 Lt at the peak of crisis.

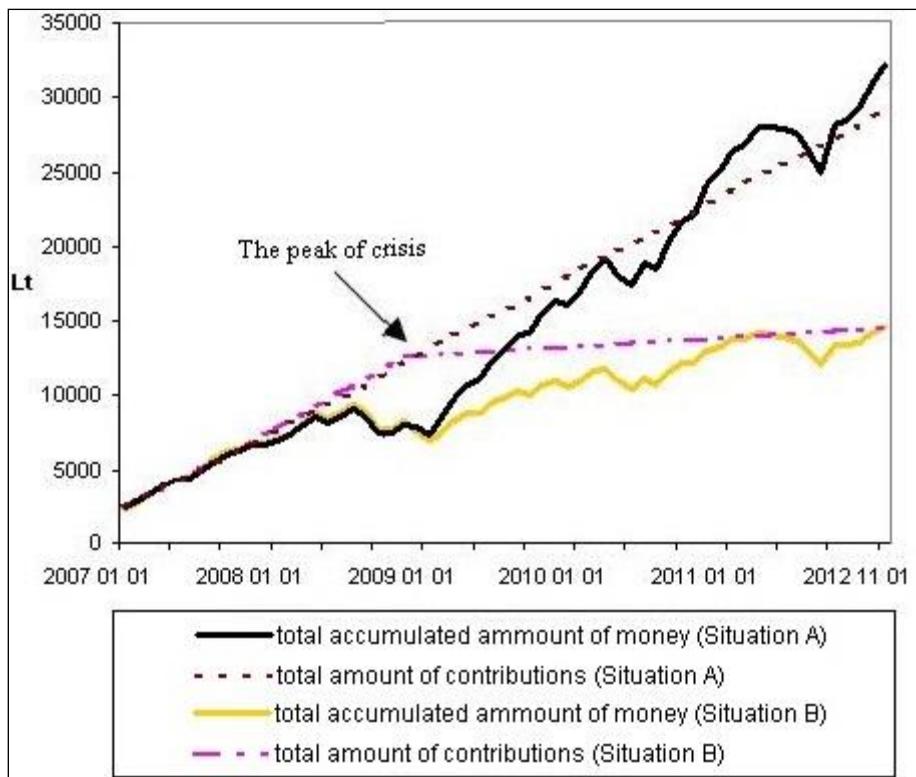


Fig. 9. Simulation results

This figure illustrates one of the most common situations, when portfolio value falls sharply during the peak of crisis. The other studies show that most unprofessional investors sell their financial asset exactly at this time and suffer losses. The results of our simulation let us conclude that if unchanged contributions had been paid during all period of time, then portfolio value would have reached the value of total amount of contributions at the end of 2010 and even exceed it in 2011 (Situation A in Fig. 9). It's important to understand that at the peak of crisis units are bought at a lower price. When units' value increases, it not only compensates the previous losses of the investments made before crisis, but also makes gains for investments made during and after it. If monthly payments had been reduced to 50 Lt at the peak of crisis (Situation B in Fig. 9), then investor wouldn't have suffered losses, but the final portfolio value would have been half the size of portfolio value in situation A.

These two examples show how the proposed simulation technique allows investigating different situations and monitoring the changes of portfolio value depending on various factors. Better understanding of various factors could reduce the risk of investment.

In order to better evaluate the advantages and disadvantages of the model more case studies should be done. The model should be tested in different conditions

(markets, periods, etc.). It should be also evaluated by unprofessional investors, because they are the target users of proposed tool.

Conclusions

The implementation of new three-pillar pension system in Lithuania brought in new needs for creating optimal investment portfolio and using advantage of tax allowance.

As the majority customers of the pension fund investment system lack financial literacy and computational skills for making information-based decisions and managing personal finances, there is a great need for professional and intelligent simulation models and tools.

The existing tools used by the pension fund companies are based on creating spreadsheets which use static parameters of customers' demographic information, their payment capacity, taxes and expected contribution rate. These tools have high marketing impact for acquiring new customers, but they become highly imprecise in the later periods of investment to personal pension portfolio.

The designed model serves as an innovative tool for simulation of pension fund investment strategies. The dynamic variables of volatile return rate, personal contributions capacity, risk of changes in taxes, government allowances and fees are applied instead of static parameters.

An important advantage of the described simulator is the ability to see not only the final portfolio value, but also all its development. This provides a better understanding of the accumulation process itself. The suggested simulation tool can assist unprofessional investors to raise their level of financial literacy and to better assess the potential risks.

The experimental research was performed by applying the Powersim software. Variables were generated as random normal distribution. The results present high influence of the introduced variables and their dynamic characteristics in the highly volatile markets and instability of tax system. The simulation results based on the characteristics of Lithuanian market showed that the spreadsheets using static parameters presented highly overestimated return value, preventing customers from timely and optimal decision of changing investment strategy or the type of pension fund.

The model relatively well imitates the real process of investment to the third pillar pension funds. But there is a need to make the simulation tool as much user-

friendly as possible, so that unprofessional investors could make appropriate decisions according to the simulation results.

4.4. Finansų rinkų prognozavimas remiantis investuotojų nuotaikų indikatoriumi

Anomaly detection in financial markets using investors sentiment indicator

Introduction

General instability of financial markets and recent financial crises led to intensive search for new ideas and methods in asset pricing and risk management. Recent research works confirm the idea of irrationality of financial markets versus their efficiency. Even the 2013 Nobel Memorial Prize in Economic Sciences was jointly received by Robert Shiller, Eugene Fama and Lars Peter Hansen for their empirical analysis of asset prices [33][19]. Robert Shiller strongly emphasized the irrationality of financial markets [117]. Financial markets are influenced not only by economic, social or geopolitical factors. Expectations and fears of investors, manipulation of information in media streams and social networks play very important role as well. Huge amount of information emanating from sources of various origin create factors which should be incorporated in financial markets forecasting. This is growing the demand for application of analytical methods capable to process information streams characterized as big data (Fig. 1).

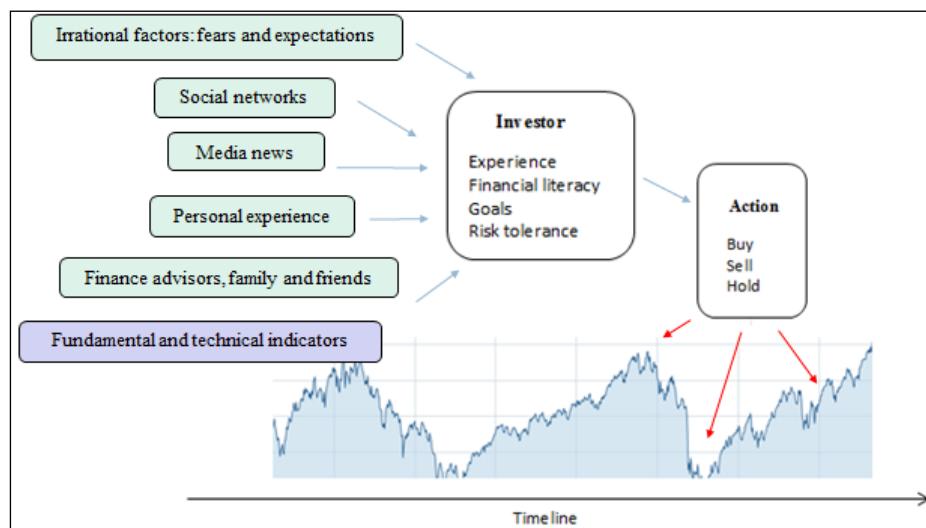


Fig. 2. Factors affecting investors decisions

Our research object is anomalies in financial markets and factors determining them. We perceive financial markets as dynamic systems of interacting agents which modelling and prediction are based on computer technology. The problem of increasing the effectiveness of identification of anomalous situations in financial markets is solved

in this article. The research approach deals with system dynamics and behavioural economics areas. The main objective is modelling complex economic processes, taking into account the influence of irrational factors. The models of real investment processes are designed and simulated in order to experimentally analyse various possible scenarios.

The research goal is to offer new methods for identification of anomalous situations. These methods should improve the investment performance and reduce risk level.

In our assumption, financial stability relies not only on good economic and financial fundamentals, but irrational behaviour of investors (as part of the system) must be evaluated too. As shown in Fig. 1, every single investor differs by his experience, financial literacy, goals and risk tolerance. And all of them are affected by their fears, expectations, impact of media news or social networks streams.

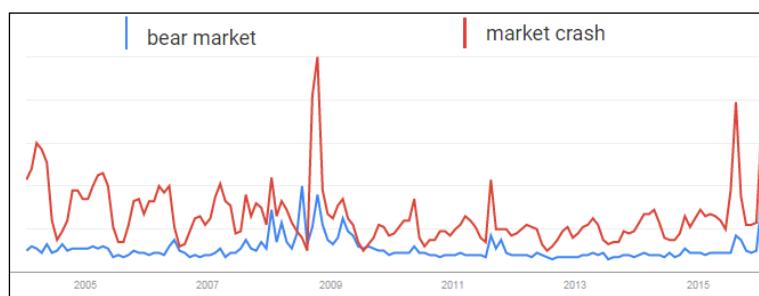


Fig. 2. Market sentiment according to “Google trend”

Today we can see the significant growth of interest of terms “bear market” and “market crash” in “Google trend” (Fig. 2). The numbers are almost the same as it was before the last financial crisis. From the behaviour finance perspective, it might be a signal of new crisis. Such facts increase the motivation for researches in this area.

In the second section we present the literature overview of existing methods for financial crisis – the most obvious anomalous situation - prediction. The third section is intended to overview both the financial and investors sentiments describing indicators. In this section we also present the general classification of both kinds of these indicators. The fourth section describes the methodology of our research. It uses indicator of investors’ mood to predict changes of asset prices. And finally the last section presents the results of three case studies. We simulated the investment process to three exchange traded funds (ETF): SPDR S&P 500, SPDR Euro STOXX and SPDR Gold Shares. The results reveal the advantages of proposed investment strategies.

2 Overview of existing financial crisis prediction models

4.4.1 Finansų krizių prognozavimo metodų apžvalga

Financial crises can be treated as the most obvious and biggest consequences having case of abnormal situation in financial markets. In this section we present the brief summary of surveys about existing financial crisis prediction models recently made by different authors.

Financial crises are usually described as failures of financial institutions or sharp falls in asset prices [136]. G. Tularam and B. Subramanian (2013) argue that it is useful to classify crises in four groups: currency crises; sudden stop (or capital account or balance of payments) crises; debt crises; and banking crises. According to T. Rajeshwar (2010) in the 19th and early 20th centuries many financial crises were associated with banking panics, and many recessions coincided with these panics, but other situations that are often called financial crises include stock market crashes and the bursting of financial bubbles, currency crises and sovereign defaults.

S. Claessens and M. Kose (2013) state that while it is easy to design quantitative methods to identify currency (and inflation) crises and sudden stops, the identification of debt and banking crises is typically based on qualitative and judgmental analyses. Another issue is that different types of crises are likely to overlap [22].

According to V. Bucevska (2011), T. Rajeshwar (2010) and R. Mariano et. al. (2002) the historical development of financial crisis prediction models can be grouped into three generations. In some latest works (e.g. G. Tularam and B. Subramanian (2013)) we can find financial crisis models categorized into four generations [16]. Each model reflects the distinct mechanism that is espoused as the major cause of such crises [89]. But I. Krznar (2004) claimed that these models do not offer consensus on the causes of financial crises since they identify different determinants of a crisis [77]. This causes the demand for further researches in financial crisis prediction area. The following parts of this section present the insights and findings made by these authors about financial crisis prediction models.

2.1 First-generation models

First-generation models of currency crises were based on macroeconomic fundamentals and speculations. They focused on long run, unique equilibrium, fiscal deficits and monetary policies. The models explained currency crises by poor domestic macroeconomic conditions. Also, they emphasized the relationship between speculation attack in foreign exchange market and macroeconomic variables. [136]

Initiated by the Latin American debt crisis at the beginning of 1980s and pioneered by Krugman (1979), the first generation of theoretical models of crisis focused on the role of the weak economic and financial fundamentals as potential early warning indicators of currency crisis [76]. They included such indicators as the gradual decline in international reserves, growing budget and current account deficits, domestic credit growth and gradual exchange rate overvaluation [16].

These models tended to focus on the role of such fundamentals as the unsustainable fiscal policies in the face of the fixed exchange rate as the major cause of an eventual currency crisis [89]. According to the first-generation models weak economic fundamentals are more vulnerable to speculative attacks [120].

2.2 Second-generation models

The second generation of models was developed by adding features of self-fulfilling expectations to currency crises. The main innovation of these models lies in identifying the role that the “expectations” of the economic agents (investors) may play in precipitating currency crises [16].

The development of these currency crises prediction models were motivated by the EMS currency crisis in 1992-93 where some countries such as the UK and Spain suffered crises despite having adequate international reserves, manageable domestic credit growth and non-monetized fiscal deficits [89].

Second-generation models of currency and banking crises introduced speculation based self-fulfilling expectations that need not be tied to fundamentals. The models focused on short run, multiple equilibria, government policies and speculations expectations. Second generation models explained the relationship between economic fundamentals and a speculative attack period. These models viewed currency crisis not as a result of bad policy but a shift in expectation. Second-generation models showed how a spontaneous speculative attack on a currency can cause a crisis, even if fiscal and monetary policies are consistent. [136]

These models do not reject the role of weak fundamentals, but suggests that self-fulfilling expectations appear to be the main cause of crises [120].

2.3 Third-generation models

After the Asian and the Latin American crisis during the middle 1990s, when the economic fundamentals of the affected countries were found to be rather sound before the outbreak of the crisis, it was found that problems in the financial sector trigger the financial crises. Therefore, the third generation of theoretical models

additionally included the financial sector indicators derived from aggregate balance sheets of banks. [16]

Third-generation models made a connection between banking and international currency markets. The models explained the relationship between financial fragility and currency crisis. In these models the macroeconomic fundamentals were strong in the context of high annual growth rates, a low inflation rate and budget deficits, strong capital inflows and manageable current account deficits. [136]

The third generation models combined weaknesses in the economic fundamentals of early generation models with weaknesses in the banking sectors. For this reason, the third generation models are also known as twin crises models. [120]

These models were based on the notion of 'contagion' where the mere occurrence of a crisis in one country increases the likelihood of a similar crisis elsewhere [89].

The joint occurrence of banking, currency and debt crises associated with the global financial crisis of 2008 motivated the interest in studying the determinants of the "crisis of the triad": banking, debt and currency crisis [16].

2.4 Fourth-Generation Models

G. Tularam and B. Subramanian (2013) distinguished 4 generations of crisis prediction models. According to them the causes of financial crises are multiple, but the models of financial crises revolve around four generational models [136].

According to them, Krugman (2001) proposed a fourth-generation crisis model which may not be a currency crisis model, but a more general crisis model in which asset prices other than the exchange rate play the major role [76]. They also highlighted Breuer (2004), who emphasized economic and financial rules and regulations, shareholder rights, transparency and supervision over the financial system, government distortions, political and sociological variables [136].

Recent early warning models typically use a wide array of quantitative leading indicators of vulnerabilities. Indicators capture vulnerabilities that stem from or are centred in the external, public, financial, nonfinancial corporate or household sectors and combine these with qualitative inputs. [22]

Another important statement of G. Tularam and B. Subramanian (2013) is that agent-based simulations can handle a far wider range of nonlinear behaviour than conventional equilibrium models [136].

The financial markets are complex systems and involve human activities and behaviour. Agent based modelling appears to be one of the better ways to explain the behaviour of the economic systems, since it does not assume that the economy can achieve a settled equilibrium. [136]

2.5 Two approaches for developing models of early warning systems

There are essentially two main approaches which have been used for developing of early warning models: the econometric approach and the “signals” approach. [16].

The econometric approach estimates limited dependent variable probability models (a probit or a logit model) for prediction of the outbreak of a financial crisis. These models estimate a probability relationship with a discrete dependent variable. They can tell which of the explanatory variables included in the model has a predictive power and can also show the probability of a future crisis. [16] Such approach was illustrated by Eichengreen and Rose (1998) for currency crisis and Demirguc-Kunt and Detragrache (1998) for prediction of banking crises [89].

Instead of summarizing the probability of crisis in one number between zero and one, the “signals” approach uses a non-parametric method to ascertain the risk of financial crisis: a variable is considered to be issuing a warning signal if it goes beyond a certain “threshold” level in the bad direction [16]. This methodology was adopted by Kaminsky and Reinhart (1996), and Kaminsky, Lizondo and Reinhart (1998) [89].

3 Combining financial and irrational indicators to forecast anomaly situations in financial markets

4.4.2 Finansiniai ir nuotaikų indikatoriai anomalijų prognozavimui

3.1 Financial indicators and methods used for anomaly detection

When constructing the model of early warning system there is a need to select the explanatory variables - the indicators of a financial crisis. Kaminsky et al. (1998) reviewed a large variety of indicators and grouped them into six categories [136]:

1. The external sector (capital account, external debt profile, current account international variables);
2. The financial sector (financial liberalization and other financial variables);
3. The real sector (real GDP growth, the output gap, employment/unemployment, wages, changes in stock prices);
4. The public finances (fiscal variables);
5. Institutional and structural variables;
6. Political variables.

R. Mariano (2002) suggested such the potential early warning indicators of speculative attacks: the gradual decline in international reserves, growing budget and current account deficits, domestic credit growth, and gradual exchange rate overvaluation [89].

V. Bucevska (2011) included a relatively wide array of potential early warning indicators and classified them into groups [16]:

1. Fiscal variables (government budget balance as a percentage of GDP);
2. Financial sector variables (ratio of domestic bank loans to GDP, decline in total bank deposits to GDP);
3. External sector (current account) variables (trade deficit as a percentage of GDP, current account deficit as a percentage of GDP, growth rate of exports, real effective exchange rate as a deviation from HP trend);
4. External sector (capital account) variables (real interest rate differential as a difference between domestic and foreign short-term interest rate, capital flight, ratio of gross external debt to export);
5. Domestic real sector variables: (real GDP growth rate);

G. Tularam and B. Subramanian (2013) argue that any set of indicators together may not provide an over-all picture, but interactions among indicators should be pursued. According to them, common sense and guesswork is used, but is not sufficient for representing real behaviour [136].

Since international financial markets can play multiple roles in transmitting and causing various types of crises, banking system measures, such as exposures to international funding risks and the ratio of non-core to core liabilities, have been found to help signal vulnerabilities [22].

Shen, G.C. and Jia, W.Y. (2014) studied financial crisis of listed companies in China Manufacture Industry. Firstly, the method of principle component analysis was used to abstract useful information from the training data. Secondly a prediction model of financial crisis was constructed with the method of Support Vector Machine [116].

R. Mariano (2002) argued for Markov Switching Modelling as a methodological approach to the issue of predicting financial and economic crises [89].

Liu and Lindholm (2006) used a fuzzy (c-means based fuzzy chestering) method to find important economic indicators for the prediction of crisis at the time of crisis as well as pre and post crisis [136].

3.2 Investors sentiment based financial markets forecasting

Behavioural economics tells us that emotions can affect individual behaviour and decision making. When trying to capture the patterns of investors' behaviour social media and web news can be very useful. Latest researches show the advantages of the methods that use social media to predict stock markets. Most of works focus on short term (e.g. next day) prediction of specific stocks. Our goal is to adapt these methods for risk level identification and prediction of financial crisis or bigger price falls. The possibility to identify anomalous collective behaviour of investors can also help to prevent market bubbles.

According to Ranco G. et. al. (2015) there are three major classes of data: web news, search engine queries and social media [105]. Summarizing we can state that one group of researches focus on the volume of messages or queries and another group explores the contents of them. Recent research suggests that news may be unpredictable, but that very early indicators can be extracted from online social media to predict changes in various economic and commercial indicators [14].

P. Houlihan and G. G. Creame (2014) investigated if sentiment extracted from social media and options market is correlated with future asset prices. They used both social media sentiment and investors' sentiment captured through the call-put ratio with several predictive models to forecast market price direction. Authors concluded that injection of news into the marketplace in conjunction with various trader behaviour of the options market help explain both the volatility and evolution of assets price [56].

Ranco G. et. al. (2015) investigated the relations between Twitter and financial markets. They found a significant dependence between the Twitter sentiment and abnormal returns during the peaks of Twitter volume and showed that sentiment polarity of Twitter peaks implies the direction of cumulative abnormal returns [105]. Bollen et al. (2010) extracted the mood state of a large number of users on a stock blogging site and used it to predict moves of the Dow Jones Industrial Average index [14].

Gruhl et al. (2005) showed that blogs can predict "real-world" behaviour. Studying data might result in the detection of a statistical relationship between a social media-based measure (e.g., the number of likes on Facebook) and the outcome of interest [47].

Ranco G. et. al. (2015) also reviewed various attempts to use social networks and found such approaches: the stock price reaction to news, the role of macroeconomic

news in stock returns, the role of news in trading actions, the relation between the sentiment of news and return predictability [105].

Another way to extract investors' sentiment is analysing search engine queries, e.g. Google trends. We showed such example in Fig. 2. Interesting works in this area were made by Bordino I. (2012) and Kristoufek L. (2013) [15][75].

However, extraction of investors' sentiment is not as easy as might seem. As Schoen H. (2013) emphasized, most of the models make assumptions that users are expressing their actual opinions instead of trying to "cheat" the market. This is why interpreting the opinion expressed in social media contents is difficult: some users are trying to "cheat" by either spreading misinformation or by producing an abnormally high volume of conversation by means of automated accounts. [114]

We can conclude that financial social media data do have a statistically significant impact on stock returns and such type indicators should be included in market prediction models.

3.3 The extended classification of different kind indicators

In our work we focus on prediction of anomaly situations in financial markets. In this section we suggest the classification of indicators most commonly used by researchers and financial experts to predict the stock market. The main contribution of us compared to previous works is the addition of irrational factors to the traditional sets of indicators (Fig. 3). The set of indicators can be more extended, but it shows the indicators most often used by authors of this paper.

Traditionally fundamental and technical analysis is used for market risk evaluation and asset pricing. As fundamental analysis can be divided into economic, industry and company categories, we separated economic analysis factors from financial markets indicators that can be used for analysis of single companies and entire industries.

In the *Economic factors* category there are such indicators as *Inflation rate* or *GDP growth* rate. We distinguished *Labour market indexes* (e.g. *Unemployment rate*, *New workplaces rate*), *Manufacturing indexes* (e.g. *FED Manufacturing index*, *Institute for supply management index*) and *Consumption indexes* (e.g. *Retail sales volume*, *Consumer confidence index*). *Political impact factors* (e.g. *Fragile stability index*) can be separated too.

When analysing the financial markets both fundamental analysis indicators (*P/E*, *P/BV*, *ROE* etc.) and technical analysis indicators (*RSI*, *MACD* etc.) are used.

However, in our approach we focus on irrational factors affecting investors' decisions. We distinguish some technical analysis indicators that represent the level of market fears (e.g. *Volatility index*) or expectations (e.g. *Put/Call ratio*, *Bullish percent index*, *Decision Point Volume Trend Oscillator*).

New technologies already allow analysing big data generated by social networks or media streams. This extends the scope of analysed factors and allows creating new ones. Such example is *CNN Money Fear and Greed Index* [35]. There are also successful attempts to create quantitative indicators of investors' expectations by analysing their social networks activities, e.g. *StockTwits sentiment index* [122], *Market Prophit social media sentiment index* [90], *HedgeChatter social media indicators* [54].

Our aim is to incorporate such information into prediction of anomalous situations in financial markets.

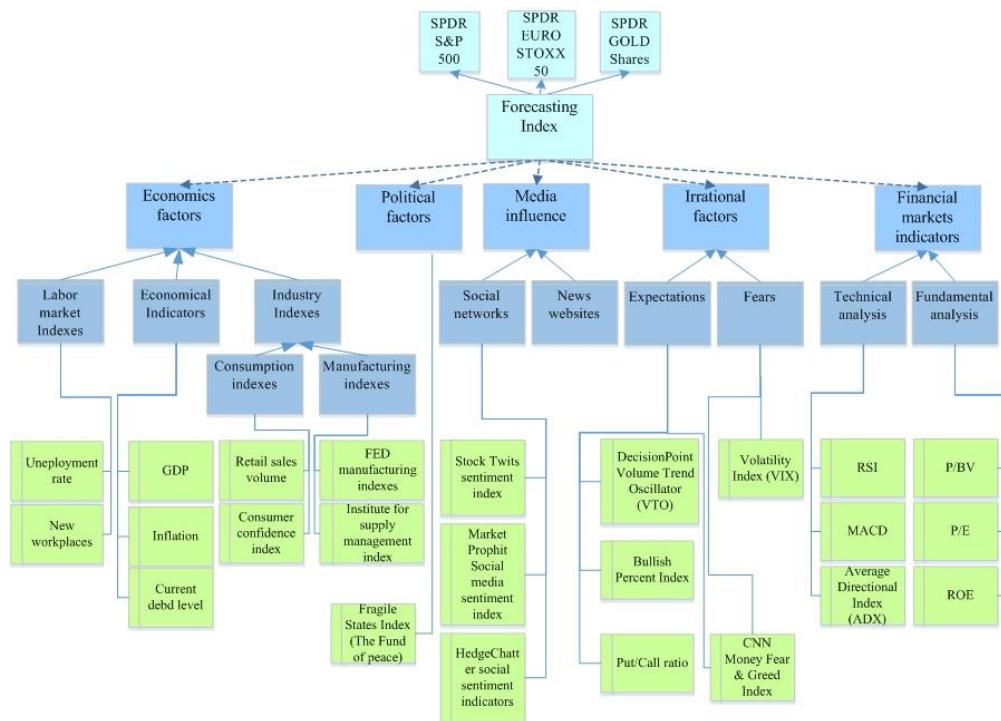


Fig. 3. Indicators for decision support systems

4 Research methodology

4.4.3 Nuotaikų indikatoriaus taikymo metodologija

4.1 Previous findings

During our previous research of the factors, affecting investment funds efficiency [84], the investment strategies were investigated in order to maximize returns and reduce risk. The special tool was created and used to simulate the accumulation depending on the rate of return, the accumulation period, the level of contributions, the

profitability of fund and other factors. It showed that a volatile return rate should be used to accurately simulate the accumulation of high-risk investments.

In the next step the dynamics of fund portfolio were investigated by using adaptive simulation models [83]. The model proposed by the authors introduced adaptive and dynamic variables used in the portfolio simulation. Volatile values of return rate, contributions and fees were used in calculations. An important advantage of the described simulator was the ability to see not only the final portfolio value, but also all its development. This provided a better understanding of the accumulation process itself.

The investigation of different investment strategies revealed that biggest losses during the peak of the crises are caused by emotion-based decisions and lack for financial literacy. The figure 4 illustrates how common behaviour of unprofessional investors leads to losses up to 50% [83]. Our goal is to find ways how to eliminate this gap caused by irrational factors.

4.2 Methodology for using indicator of investors' sentiment

In this research we use investors' sentiment indicator to eliminate the factor of irrational behaviour and increase the effectiveness of investment. Too much fear can sink stocks well below where they should be and too much greed can bid up stock prices way too far [35]. Commonly the indicators of investors' sentiment are used as signal to predict the stock price for the next day. We want to adapt such indicator for long-term periodical investment and cases when portfolio is evaluated weekly or monthly.

For our research we chose CNN Money Fear and Greed Index [35], which represents the current level of investors' sentiment. We calculated the sentiment index values using similar methodology as CNN Money do. There are 7 indicators used, each having equal power:

Market Volatility: the VIX index, which measures volatility;

Stock Price Momentum: the S&P 500 value versus its 125-day moving average;

Stock Price Strength: the number of stocks hitting 52-week highs compared to that hitting lows on the New York Stock Exchange;

Put and Call Options: the put/call ratio, which compares the trading volume of bullish call options relative to the trading volume of bearish put options;

Stock Price Breadth: the volume of shares trading in stocks on the rise versus those declining;

Safe Haven Demand: the difference in returns for stocks versus treasuries;

Junk Bond Demand: the spread between yields on investment grade bonds and junk bonds.

Figure 5 presents values of investors' sentiment indicator. When indicator value is above '50' it means investors are greedy. When it is below '50' it means there are more fears in the market. The period is from December 2013 to January 2016.

This data is used for calculations presented further in this paper.

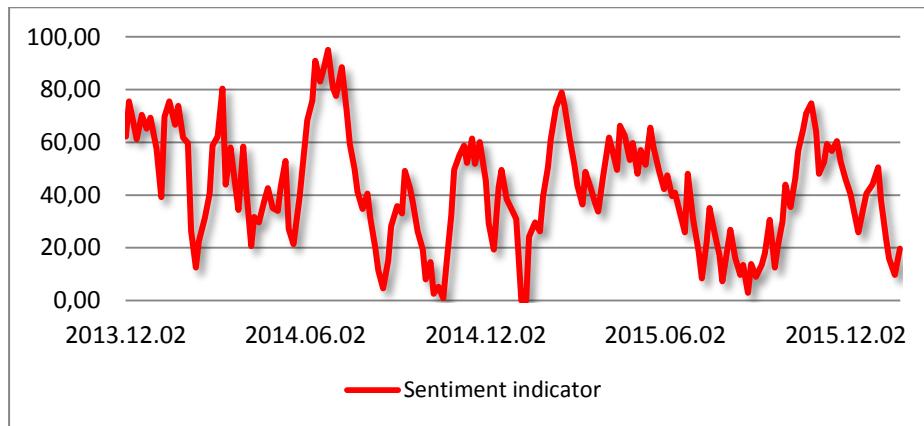


Fig. 5. Investors' sentiment indicator

In the future researches we will try to add Social media sentiment factor to this indicator.

4.3 Simulation of investment to ETF

This section presents a methodology that we used for simulating the real process of investment to exchange traded funds (ETF). It's based on system dynamics. The model contains variables that affect each other in time. The Figure 6 shows the components of this model.

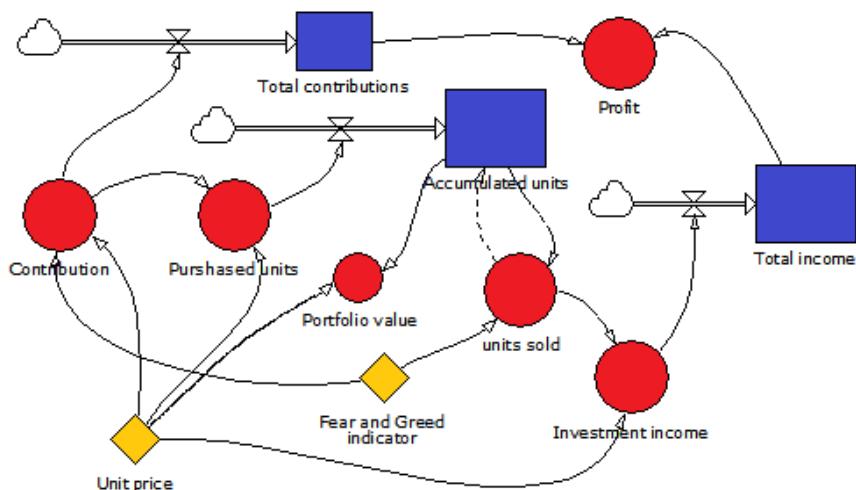


Fig. 6. The model of investment process

The tool simulates the changes of portfolio value depending on funds' unit price. Unit prices correspond to real historical data of selected ETF. All decisions to buy or sell assets are made accordingly to fear and greed indicator values.

First of all, the amount of contribution is calculated in accordance to indicator. When indicator value is extremely low – below Lower contribution threshold (LCT) - we can increase the amount of contribution: initial contribution (C) is multiplied by leverage (L1). Accordingly, the amount of contribution is lowered when indicator value is extremely high – above Upper contribution threshold (UCT).

IF ($G\&F < LCT$)

Then $C = C \times L1;$

Else If ($G\&F > UCT$)

Then $C = C \times L2;$

Else $C = C;$

This sum of money is used to purchase the units of fund (PU) for the current units' price (UP):

$$PU = C / UP$$

Newly purchased units (PU) are added to the accumulated units (AU). The total amount of accumulated units (AU) increases after each buy operation, but decreases if units are sold (US):

$$AU_t = AU_{t-1} + PU_t - US_t$$

The portfolio value (PV) depends on the fund's unit value. It can be determined at any time. This is done by multiplying the amount of units (AU) by the current unit price (UP). It allows simulating the changes of investment returns and analysing the changes of portfolio value during all investment period:

$$PV = AU \times UP$$

In accordance to sentiment indicator the portfolio assets are sold and the profit is taken when strong greed level is observed – exceeds the Sell threshold (ST) value. This is done to prevent sharp drops of portfolio value. At these moments we get Investment income (InI) that is accumulated during the all investment period.

IF ($G\&F > ST$)

THEN { $US = AU;$

$$InI = US \times UP\}$$

ELSE { $US = '0';$

$$InI = '0'\}$$

Finally, the return of all investment process (Pr) is determined. It is calculated by deducting all contributions (TC) from the total accumulated amount of money (TI):

$$Pr = TI - TC$$

The detailed description of various investment strategies and their performance is presented in the following section.

5 Research results

4.4.4 Anomalijų prognozavimo ir nuotaikų indikatoriumi paremtų investavimo strategijų tyrimo rezultatai

5.1 Case study of investing to SPDR S&P 500 ETF

In this section the results of simulation process of investment to the SPDR S&P 500 ETF (SPY) is presented. This ETF seeks to provide investment results that, before expenses, correspond generally to the price and yield performance of the S&P 500® Index [124]. The period is from December 2013 to January 2016. Figure 7 shows, that from the start of this period SPY value was continuously growing. But at the end of the period there were two price drops and the price almost returned to its initial value. This is typical situation then inexperienced investors suffer losses. Further in this section we analyse, how sentiment indicator can prevent from losses during the corrections of stock prices.

We investigate the case when periodical investments are made by unprofessional investors. It's common for such investment instruments as life insurance funds, pension funds or exchange traded funds (ETF). The frequency of contributions is 9 days. The standard amount of contribution is 100\$. The decisions to buy or sell fund units are made accordingly to indicator of investors' sentiment.

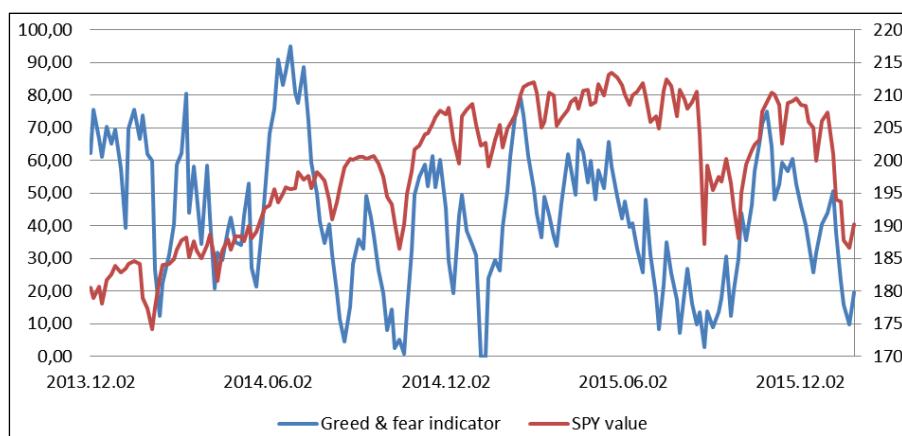


Fig. 7. SPDR S&P 500 ETF value versus Sentiment indicator

We investigated six different strategies, but all of them have the same principles:

When sentiment indicator is less than lower threshold (LCT), we increase the amount of contribution by multiplying it by leverage L1. Usually there are a lot of fears in the market when prices are at the bottom, so we try to use it as opportunity to buy cheaper assets.

If greed and fear indicator is higher than upper threshold (UCT), we minimize the amount of contribution by multiplying it by leverage L2. Possible values of L2 range from 0 to 1. This is done to prevent of buying overpriced assets.

If sentiment is higher than sell threshold (ST), we sell all accumulated units and take profit. This is done to prevent losses as the fall of stock prices is expected.

These principles are completely opposite to the common behaviour of unprofessional investors that lead to losses. The particular coefficients of different strategies are presented in table 1.

Table 1 Coefficients of strategies

	ST	L1	LCT	L2	UCT
Strategy Nr. 1	60	50	5	0	55
Strategy Nr. 2	50	10	10	0,5	60
Strategy Nr. 3	65	20	10	0,2	65
Strategy Nr. 4	70	30	10	1	70
Strategy Nr. 5	55	40	5	0,1	60
Strategy Nr. 6	65	20	20	0,2	50

The results of these strategies are presented in following figures. Figure 8 presents the total amounts of income and contributions. We can see that investing without using indicator and just following the index lead to losses. In contrast, all 6 strategies were profitable. Strategies nr. 4 and nr. 6 distinguish by large amounts of money, because they were more aggressive.

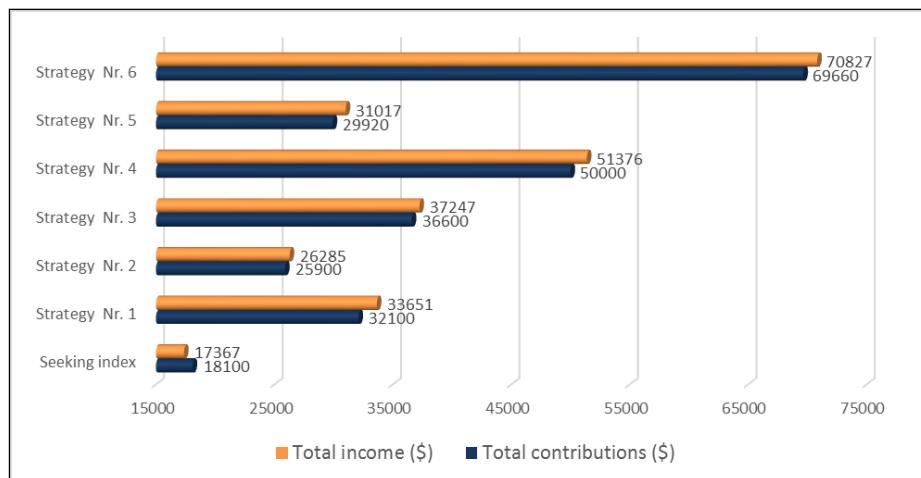


Fig. 8. Contributions vs. investment income

To get deeper insight of every strategy, figure 9 presents the profit/loss in net value and as percentage of contributions made. It shows that the best strategy (nr. 1) lead to profit of 4,83%, while not using indicator lead to loss of 4,05%. This means that the effect of using sentiment indicator was almost 9%. When comparing several strategies, the profit ratio is more important than profit in net value. For example, strategy nr. 4 gained more profit in net value, but strategy nr. 5 had better profit rate (3,67% versus 2,75%).

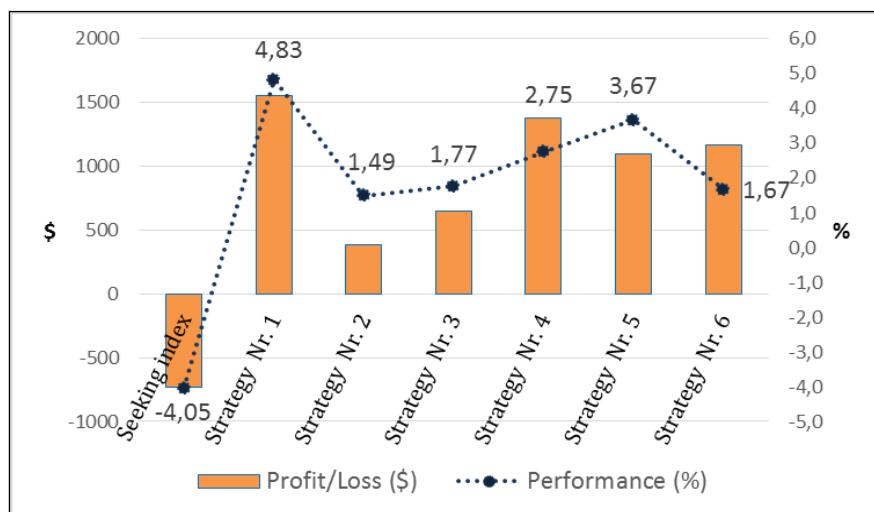


Fig. 9. Comparison of profits

Figure 10 compares the performance of strategy nr. 1 versus benchmark performance (SPDR S&P 500) and performance of periodical investment to ETF without using indicator. It looks that benchmark performance is much better. But this is the critical point that should be understood when investigating periodical investing. The performance of benchmark is calculated in accordance to the initial value of the asset price (at the beginning of investment period). When periodic contributions are

made, assets may be bought for higher price than that initial price. Then drops of price lead to bigger losses. This is why the graph of performance of investment without using indicator look similar to benchmark graph, but the results are worse.

Sentiment indicator partially solves this problem. It successfully forecasts price changes, fixes profits and prevent portfolio from big loss of value.

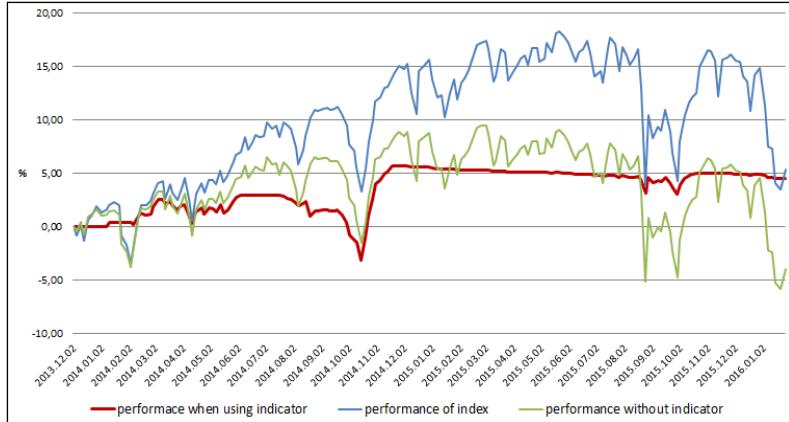


Fig. 10. Performance comparison

Figure 11 shows how changes the portfolio value versus total contributions made when using sentiment indicator and investing without it.

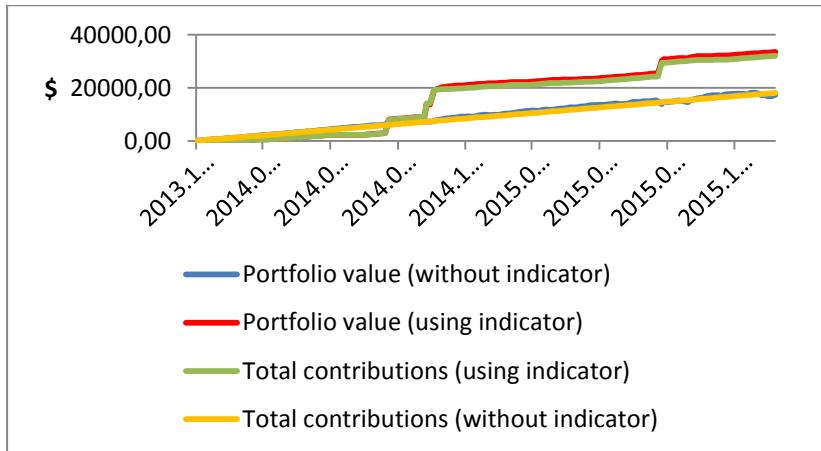


Fig. 11. The changes of portfolio value

We can see that in the case of using investors sentiment indicator the portfolio value (current portfolio value plus profit already taken off) do not fall below the level of total contributions made. This confirms our initial hypothesis that such indicator can help to predict falls of stock market and prevent losses.

5.2 Case study of investing to SPDR Euro STOXX 50

In the second case we investigated the performance of the same strategies when investing to Europe region stocks – SPDR Euro STOXX 50 ETF [123]. The condition and period was the same - from December 2013 to January 2016. But as can be seen in

figure 12, the dynamics of ETF price were absolutely different. At the beginning it was rising, however from June 2016 it began to fall sharply and the final result of the period was – 21%. Our goal was to check, if sentiment indicator can prevent from such big losses.

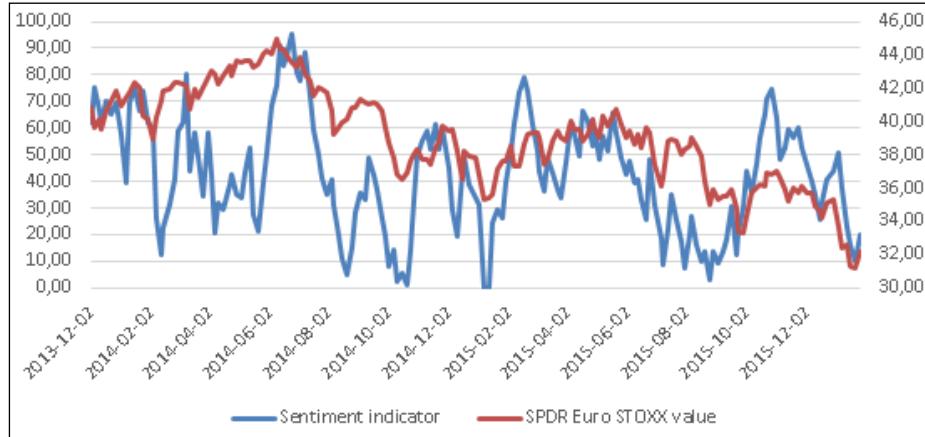


Fig. 12. SPDR S&P 500 ETF value versus Sentiment indicator

Figure 13 presents the comparison of results that were got by using strategies determined in table 1. Firstly, we can see the even without sentiment indicator, but making periodical contributions, reduced the losses to 7,27%. All strategies based on sentiment indicator had even better profit rates. The first strategy was the best again. Its profit rate was positive – 0,53%. This strategy absolutely protected portfolio from losses.

We have to mention, that in this case strategy nr. 6 wasn't successful. Although profit ratio was relatively good (-3,63%), but this strategy was very aggressive, much bigger contributions were made, so the loss in net value was the biggest.

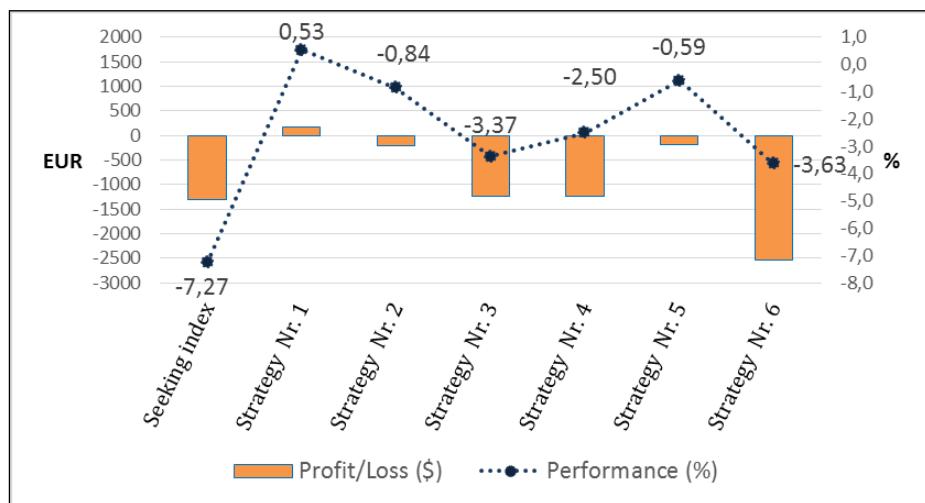


Fig. 13. Comparison of different strategies

Figure 14 compares the performance of the best strategy versus SPDR EURO STOXX index. It reveals how selling the assets at the right moment and fixing the profit maintains the portfolio profitable.

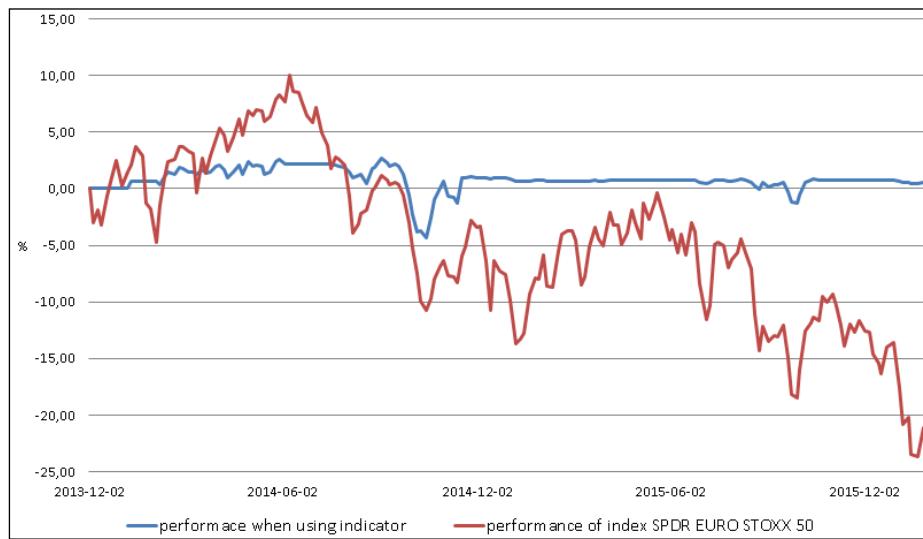


Fig. 14. Performance comparison

All strategies that use sentiment indicator have the same common characteristic – the total amount of contributions are much higher. This is because the periodical contributions are highly increased when sentiment indicator shows that asset prices are undervalued.

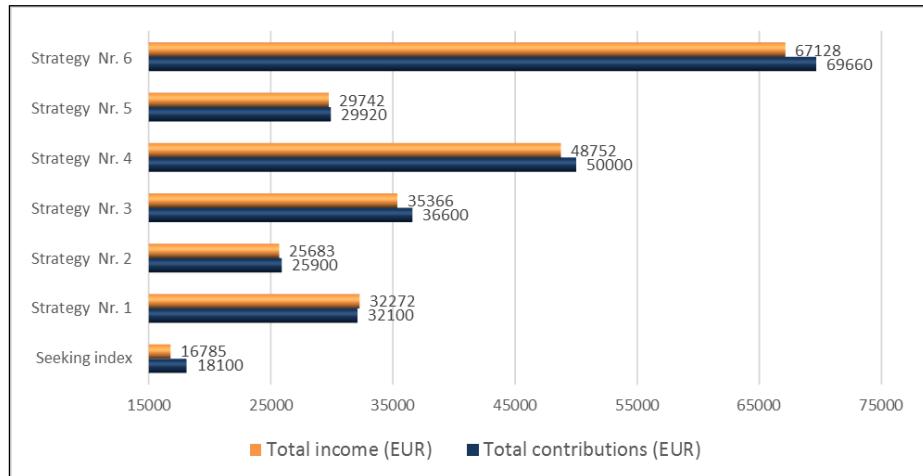


Fig. 15. Contributions vs. investment income

5.3 Case study of investing to SPDR GOLD SHARES

In the last case we focused on gold market forecasting which is closely related with market sentiment. For many years gold was used as hedging instrument and the demand for it increased during the financial crisis. Now it becomes more speculative

asset, but it is highly correlated with investors' mood. This research shows how investors' sentiment indicator can help to predict the prices of this asset. The process of periodical investment to SPDR Gold Shares ETF was simulated [124]. During the period from December 2013 to January 2016 the price of SPDR Gold Shares ETF was continuously decreasing, so this is also a good way to test if indicator can prevent from losses. The standard amount of contribution is the same 100\$. We used the same parameters of six strategies presented in table 1.

Figure 16 presents values of SPDR Gold ETF prices and Sentiment indicator.

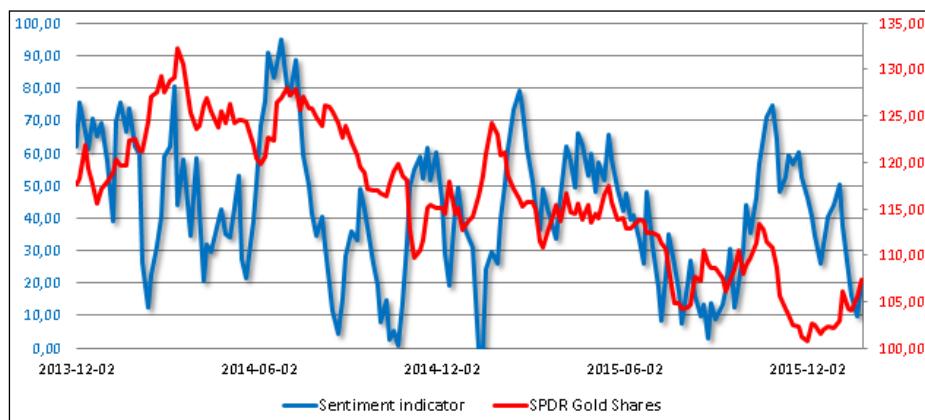


Fig. 16. SPDR Gold shares value versus Sentiment indicator

The figure 17 presents the results of these strategies compared to benchmark (SPDR Gold Shares index) - the profit/loss in net value and as percentage of contributions made.

We can see that investing without using sentiment indicator led to losses of 7,27 %. However, sentiment indicator enabled to gain much better results. Strategies nr. 1, 2 and 5 also led to losses, but they were smaller. The more important fact is that strategies nr. 3, 4 and 6 made profits during this period of declining gold prices.

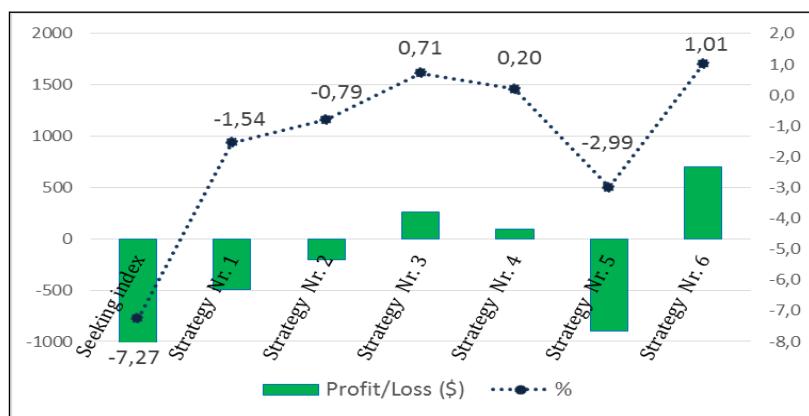


Fig. 17. Comparison of different strategies

In this case the most successful strategy was nr. 6, which gained 1,01% profit. Figure 18 shows how changes the portfolio value when using strategy nr. 6 in comparison to benchmark – SPDR Gold Shares index

We can see that gold price maintained the trend to decrease during all analysed period of time and its volatility was much higher. Fear and greed indicator successfully forecasted the correction of price and prevented from losses. The increase of contributions amount when the highest fear level was observed let to buy undervalued assets and gain profits.

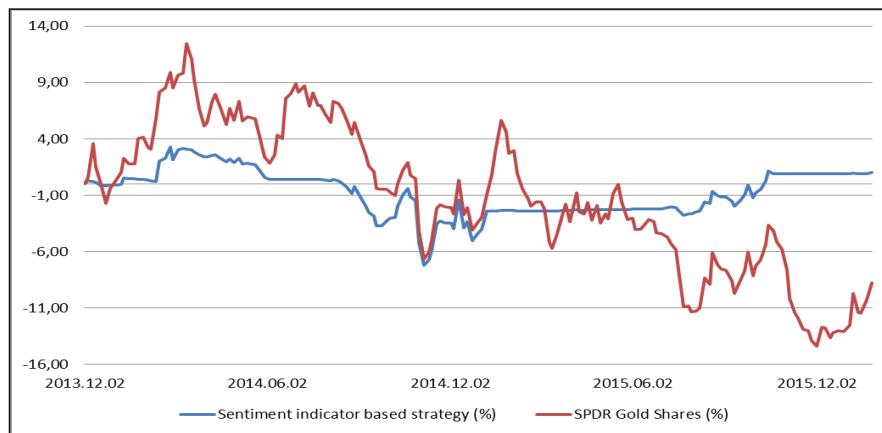


Fig. 18. Performance comparison

Conclusions

The research results reveal that emotions based investment decisions lead to losses. However, new applications of big data analytics allow extending the scope of indicators that can be used to eliminate this irrational behaviour and increase the investment efficiency. They reveal the hidden patterns of investors' behaviour and enable to better predict financial bubbles and markets crashes. In this research we focused on prediction of anomalous situations in financial markets that usually cause losses. We investigated if investors' sentiment indicator can solve this problem.

Firstly, we presented the literature survey of existing methods for financial crisis – the most obvious anomalous situation - prediction. We overviewed both the financial indicators and those determining investors mood. We also presented the general classification of both kinds of these indicators.

The methodology of using investors' sentiment to predict changes of asset prices were suggested. In this research we used indicator based on CNN Fear & Greed index. We adapted such indicator for long-term periodical investment case. In accordance to investors' sentiment indicator the portfolio assets were sold and the profit

was taken when strong greed level was observed. The amount of contribution was also calculated in accordance to greed and fear indicator to prevent of buying overpriced assets and try to buy cheaper assets. These principles are completely opposite to the common behaviour of unprofessional investors that lead to losses.

We focused on situations when periodical investments are made by unprofessional investors. It's common for such investment instruments as life insurance funds, pension funds or exchange traded funds. We simulated the investment process to three exchange traded funds: SPDR S&P 500, SPDR Euro STOXX and SPDR Gold Shares. Six different strategies were investigated. The specific period of time was selected with negative dynamics of asset process. This let to imitate the situations when most investors suffer losses due to irrational behaviour.

First case of investment to SPDR S&P 500 showed that the best strategy led to profit of 4,83%, while not using indicator led to loss of 4,05%. This means that the effect of using sentiment indicator was almost 9%.

Secondly we had the case where SPDR Euro STOXX fell by 21%. Our goal was to check, if sentiment indicator can prevent from such big losses. Even without sentiment indicator, but making periodical contributions, reduced the losses to 7,27%. All strategies based on sentiment indicator had better profit rates, but the first strategy was the best again and had positive profit rate – 0,53%. This strategy absolutely protected portfolio from losses.

In the last case the periodical investment to SPDR Gold Shares ETF was simulated. During the selected period of time the price of gold was continuously decreasing, so this was a good case to test if indicator can prevent from losses. The test results showed that investing without using sentiment indicator led to losses of 7,22 %. However, several strategies that were using sentiment indicator let to reduce the losses and three of them even gained profit.

The initial results confirm that indicators of investors mood can successfully forecasted the corrections of asset prices and prevent from losses. Now we need further researches to integrate such indicators to financial crisis prediction models.

LITERATŪRA

1. A. Andrejevas. Daugiakriterinio ekspertinio sprendimo priėmimo sistema. Vilnius, 2009
2. A. K. Menon. Random projections and applications to dimensionality reduction. School of Information Technologies, The University of Sydney, 2007.
3. Adema, W.; Einerhand. M. The Growing Role of Private Social Benefits., OECD Labour Market and Social Policy Occasional Papers, No. 32. 59 p. 1998.
4. Andriukaitis, D., et al.. Finansinių paslaugų vadovas. Vilnius, Lietuvos vartotojų institutas. 2009. ISBN 978-9955-783-03-9
5. Andriukaitis, D., et al.. Finansinių paslaugų vadovas. Vilnius, Lietuvos vartotojų institutas. 2009. ISBN 978-9955-783-03-9
6. Antolin, P. and F. Stewart. Private Pensions and Policy Responses to the Financial and Economic Crisis. *OECD Working Papers on Insurance and Private Pensions*, No. 36. [interaktyvus]. 2009 [žiūrėta 2011-12-02]. <<http://www.oecd.org/dataoecd/37/54/42601323.pdf>>
7. Antolín, P. Pension Fund Performance. *OECD Working Papers on Insurance and Private Pensions*. 2008, No. 20.
8. Antolin, P. Pension Fund Performance. *OECD Working Papers on Insurance and Private Pensions*, No. 20. [interaktyvus]. 2008 [žiūrėta 2011-12-05]. <http://www.oecd-ilibrary.org/finance-and-investment/pension-fund-performance_240401404057>
9. Anylogic programinė įranga. Prieiga per internetą: <http://www.anylogic.com>
10. Anylogic programinė įranga. Prieiga per internetą: <http://www.anylogic.com>
11. Baru C., Bhandarkar M. et al. Benchmarking big data systems and the big data top100 list. *Big Data*, 2013, 1(1): 60-64. doi:10.1089/big.2013.1509.
12. Bodie, Z., Kane, A., Marcus, A. Investments, 5/e. The McGraw–Hill Companies. 2001.
13. Boendera, G.: A hybrid simulation/optimisation scenario model for asset/liability management, *European Journal of Operational Research*, vol. 99, p. 126–135 (1997)
14. Bollen, J., Mao H., Zeng X.. Twitter Mood Predicts the Stock Market. 2010. <http://arxiv.org/abs/1010.3003>.
15. Bordino I, Battiston S, Caldarelli G, Cristelli M, Ukkonen A, Weber I. Web search queries can predict stock market volumes. *Plos One*. 2012; 7(7):e40014.

16. Bucevska, V. An analysis of financial crisis by an early warning system model: The case of the EU candidate countries. BEH - Business and Economic Horizons. Volume 4, Issue 1, January 2011, pp. 13-26. ISSN: 1804-1205.
17. Burstein, F., Holsapple, C., W. Handbook on Decision Support Systems 2: Variations, Springer-Verlag, New York, LLC , 2008. Pp.798. ISBN: 3540487158
18. Caginalp, Gunduz and Ilieva, Vladimira A. and Porter, David and Smith, Vernon L., Do Speculative Stocks Lower Prices and Increase Volatility of Value Stocks?. The Journal of Psychology & Financial Markets, Vol. 3, 2002. Available at SSRN: <http://ssrn.com/abstract=312421> or <http://dx.doi.org/10.2139/ssrn.312421>
19. Campbell, J. Y., Empirical Asset Pricing: Eugene Fama, Lars Peter Hansen, and Robert Shiller, 2014. Available: <http://ssrn.com/abstract=2417875>
20. Campbell, John Y., Empirical Asset Pricing: Eugene Fama, Lars Peter Hansen, and Robert Shiller (May 2014). Available at SSRN: <http://ssrn.com/abstract=2417875>
21. Chomik, R.; Whitehouse, E. R. Trends in Pension Eligibility Ages and Life Expectancy, 1950-2050. 2010.
22. Claessens, S., Kose, M. A. Financial Crises: Explanations, Types, and Implications. IMF Working Paper, 2013.
23. Clark, Sammut etc. Applied Metamodelling. A Foundation for Language Driven Development. Second edition. Ceteva (2008)
24. D.Rajanish, "Data Mining In Banking And Finance: A Note For Bankers", - Technical note, Note No.: CISG88., April 2006.
25. D.Tamasauskas, M.Liutvinavicius, V.Sakalauskas, D.Kriksciuniene, "Research of Conventional Data Mining Tools for Big Data Handling in Finance Institutions", Lecture Notes in Business Information Processing Volume 160, 2013, pp 35-46.
26. Den Haan, Wouter J. & Judd, Kenneth L. & Juillard, Michel, 2011. "Computational suite of models with heterogeneous agents II: Multi-country real business cycle models," Journal of Economic Dynamics and Control, Elsevier, vol. 35(2), pages 175-177, February.

27. Den Haan, Wouter J. & Judd, Kenneth L. & Juillard, Michel, 2011. "Computational suite of models with heterogeneous agents: Incomplete markets and aggregate uncertainty. *Journal of Economic Dynamics and Control*, Volume 34, Issue 1, pp. 1-3.
28. Dr. Domeniconi. Comparison of Principal Component Analysis and Random Projection in Text Mining. April 29, 2004. INFS 795
29. E.Turban, J. Aronson. etc. Decision support and business intelligence systems 2007.
30. Ermolieva, T.: Simulation-based optimization of social security systems under uncertainty, International Institute for Applied Systems Analysis, Schlossplatz (2004)
31. European commission: Green paper towards adequate, sustainable and safe European pension systems, Brussels (2010)
32. Europos komisija. ŽALIOJI KNYGA: Adekvačios, tvarios ir saugios Europos pensijų sistemos. 2010.
33. Fama, E., 1970, „Efficient Capital Markets: A Review of Theory and Empirical Work”, *Journal of Finance* 25, 283-417.
34. Fama, Eugene F., 1970, „Efficient Capital Markets: A Review of Theory and Empirical Work“, *Journal of Finance* 25, 283-417.
35. Fear & Greed Index. Available: <http://money.cnn.com/data/fear-and-greed/>.
36. Fraud detection, <https://www.statsoft.com/Textbook/Fraud-Detection>
37. From Crisis to Recovery. The Causes, Course and Consequences of the Great Recession. [interaktyvus]. 2009 [žiūrėta 2011-12-05]. <http://www.oecd-ilibrary.org/finance-and-investment/from-crisis-to-recovery/pensions-and-the-crisis_9789264077072-5-en>
38. Frontline Solvers. Available at <http://www.solver.com/xlminer-data-mining>
39. Fultz, E., Lazutka R. Pension Reform in the Baltic States. Budapest, International Labour Office. ISBN 92-2-118385-8. [interaktyvus]. 2006 [žiūrėta 2011-12-02].
[<http://www.ilo.org/public/english/region/eurpro/budapest/download/socsec/baltic_pension_reform.pdf>](http://www.ilo.org/public/english/region/eurpro/budapest/download/socsec/baltic_pension_reform.pdf)

40. G. Dzemyda, O. Kurasova, J. Žilinskas (2008) Daugiamatių duomenų vizualizavimo metodai. Matematikos ir informatikos institutas. ISBN 978-9986-680-42-0
41. Gantz J, Reinse D. The digital universe IN 2020: Big Data, Bigger Digi tal Shadows, and Biggest Growth in the Far East 2012. IDC iView
42. Gartner IT Glossary (2013). <http://www.gartner.com/it-glossary/big-data/>
43. Gartner IT Glossary, <http://www.gartner.com/it-glossary/big-data/>, 2013.
44. GCX Advanced Analytics LLC. Available at <http://www.gcxanalytics.com/>
45. Goal modeling. Michigan state university. Prieiga per internetą: <http://www.cse.msu.edu/~chengb/RE-491/Lectures/06-goal-modeling.pdf>
46. Google Trends, <https://www.google.com/trends/>, 2014
47. Gruhl, D., Guha R., Kumar R., Novak J., Tomkins A. The Predictive Power of Online Chatter. *Proceedings of the Eleventh ACM SIGKDD International Conference on Knowledge Discovery in Data Mining*, 78–87. KDD '05. New York, NY, USA.
48. Guardian Analytics, “A Practical Guide to Anomaly Detection: Implications of meeting new FFIEC minimum expectations for layered security”, 2011.
49. Gudas S. Organizacijų veiklos modeliavimas, Kaunas, Naujasis lankas, 2002. 134p.
50. Gudas S. Veiklos valdymo žinių modeliavimas. Paskaitų medžiaga. 2012.
51. Gudas S. Žiniomis grindžiamų sistemų kūrimo problemos. Paskaitų medžiaga. (2012).
52. Gudas S., Lopata A. Žiniomis grindžiama informacijos sistemų inžinerija - Informacijos mokslai, Mokslo darbai, T.30, Vilnius, Vilniaus Universiteto leidykla, 2004, p.90-98 ISSN 1392-0561
53. Gyvenimo ciklo fondų apžvalga ir galimo poveikio sukauptoms lėšoms vertinimas. LR Vertybinių popierių komisija [interaktyvus]. 2010 [žiūrėta 2011-10-30]. <<http://www.vpk.lt/new/documents/GCF%20apzvalga-%20update%2007%202015.pdf>>.
54. HedgeChatter. The Trusted Provider of Social Media Stock Analysis for the Markets. Available: <https://www.hedgechatter.com/>
55. Heinz, P. R. Challenges of the Lithuanian Pension System. World bank. 2009.

56. Houlihan, P., Creame, G. Can social media and the options market predict the stock market behavior? Stevens Institute of Technology. 2014. Available at SSRN: https://editorialexpress.com/cgi-bin/conference/download.cgi?db_name=CEF2015&paper_id=521
57. I. K. Fodor. A survey of dimension reduction techniques. Center for Applied Scientific Computing, Lawrence Livermore National Laboratory. June 2002
58. IBM SPSS Statistics. Available at <http://www.insol.lt/statistics/>
59. IBM. Deriving Business Insight from Big Data in Banking (2013). <http://www-01.ibm.com/software/data/bigdata/industry-banking.html>
60. Inga Blažytė. VEIKLOS TAISYKLIŲ MODELIAVIMO UML KALBOS PAGRINDU TYRIMAS. Kaunas, 2005. Prieiga per internetą: http://vddb.library.lt/fedora/get/LT-eLABa-0001:E.02~2005~D_20050115_194747-29835/DS.005.0.02.ETD
61. Insightmaker programinė įranga. Prieiga per internetą: <https://insightmaker.com>
62. Insightmaker programinė įranga. Prieiga per internetą: <https://insightmaker.com>
63. J.Grėbliūnas, M. Pažereckaitė. Veiklos ir reikalavimų modeliavimo metodas įvertinantis saugumą. 2011. Prieiga per internetą: http://vddb.laba.lt/fedora/get/LT-eLABa-0001:E.02~2011~D_20110831_135040-28935/DS.005.0.01.ETD
64. J.Han, M.Harcourt, Data Mining Concepts and Techniques, 2006.
65. Jan L.G. Dietz. Enterprise. Engineering Enterprise Ontology. 2006
66. John H. Miller & Scott E. Page. Complex Adaptive Systems: An Introduction to Computational Models of Social Life (Princeton Studies in Complexity). Princeton University Press Princeton, NJ, USA ©2007 ISBN:0691127026
67. Jokšienė I., Zvirblis A.: Principles of evaluation of the impact of economic and social factors on investment funds, Current Issues of Business and Law, ISSN 1822-9530 print / ISSN 2029-574X online, vol. 6(2), p. 335–348 (2011)
68. K. Šutienė. Imitacinis modeliavimas – sistemoms pažinti, analizuoti ir sprendimams priimti. (2011). Prieiga per internetą: <http://www.fmf.lt/ft/studiju>

- programos/taikomoji-matematika/S-17485/straipsnis/Imitacinis-modeliavimas--sistemoms-pazinti-analizuoti-ir-sprendimams-priimti-Video?p=1
69. K.Devi., Y.A.Prasad, "Study of Anomaly Identification Techniques in Large scale systems", 2012.
70. Klimaitė, J. Privačių pensijų fondų vertinimo kriterijai. [interaktyvus]. 2010 [žiūrėta 2012-12-18].
<http://www.lzuu.lt/jaunasis_mokslininkas/smk_2006/finansai/Klimaite%20Jurgita.pdf>
71. Klimaitė, J. Privačių pensijų fondų vertinimo kriterijai. Lietuvos žemės ūkio universitetas. 2010.
72. Klimaviciene, R.: Determination of asset allocation for a sustainable retirement portfolio using a dynamic stochastic simulation, Social sciences studies, vol .3(7), p. 59–79, ISSN 2029–2244, 2010
73. Koutonin M.R. The Best Data Mining Tools You Can Use for Free in Your Company (2013). <http://www.siliconafrica.com/the-best-data-minning-tools-you-can-use-for-free-in-your-company/>
74. Kovalerchuk B., Vityaev E. Data mining for financial applications. Data Mining and Knowledge Discovery Handbook, 2005, pp 1203-1224
75. Kristoufek L. Can Google Trends search queries contribute to risk diversification? Scientific reports. 2013; 3. doi: 10.1038/srep02713
76. Krugman, P. (2001) "Crises: The Next Generation?" Paper prepared for the Razin conference, Tel Aviv University, March.
77. Krznar, I., 2004. "Currency crisis: Theory and practice with application to Croatia", Working papers W-12, Croatian National Bank.
78. Lavalle S., Lesser E., et al. Big data, analytics, and the path from insight to value. MitSloan Management review (2011). Vol 52. No 2. 21-31.
79. Lietuvos bankas. Gyvybės draudimo įmonių kliento atmintinė. 2014
80. Ligita Šarkutė. Sprendimų priėmimo samprata ir tyrimų tradicijos. Sociologija. Mintis ir veiksmas 2009/2(25), ISSN 1392-3358. Prieiga per internetą:
http://www.ku.lt/wp-content/uploads/2013/04/2009-2-p_105-119.pdf

81. Lithanian securities commission: Valdymo įmonių valdomų papildomo savanoriško pensijų kaupimo pensijų fondų veiklos 2011 m. II ketvirčio apžvalga (2011)
82. Liutvinavicius M., Sakalauskas V.:Research of factors, affecting pension funds effieciency (presented in November 17, 2011, prepared to print in January 11, 2012)
83. Liutvinavicius, M., Sakalauskas, V. Dynamic Simulation of Pension Funds' Portfolio. BIS Workshops 2012, volume 127 of Lecture Notes in Business Information Processing, page 69-80. Springer, (2012).
84. Liutvinavicius, M., Sakalauskas, V. Research of Factors Affecting Pension Funds Efficiency. Social technologies, nr. 1(2), ISSN 2029-7564 (2011).
85. LR Vertybinių popierių komisija. Gyvenimo ciklo fondų apžvalga ir galimo poveikio sukauptoms lėšoms vertinimas. 2010.
86. LR Vyriausybės pranešimas [interaktyvus]. 2011 [žiūrėta 2011-09-28].
[<http://www.lrv.lt/lt/naujienos/aktualijos?nid=9005>](http://www.lrv.lt/lt/naujienos/aktualijos?nid=9005)
87. M.Shaikh, G.Chhajed, “Review on Financial Forecasting using Neural Network and Data Mining Technique”, 2012, Volume 05, No. 02, pp. 263-267.
88. Mandatum Life. Kliento poreikių anketos ir investavimo profilio klausimyno pildymo instrukcija. 2012.
89. Mariano, R., Gultekin, B., Ozmucur, S. Models of Economic and Financial Crises. Proceedings of the Middle East Economic Association, 2002. ISSN: 2334-282X
90. Market Prophit. Available: <http://marketprophit.com/>
91. McAfee A., Brynjolfsson E. Big data: the management revolution. Hardard business review 1-9 (2012).
92. Metamodeliavimas. <http://www.oszolomiony.info/y/ee7hseicvio51uwt.html>
93. MPI technology. Access: <http://www mpi-forum.org/docs/mpi-3.1/mpi31-report.pdf>
94. Muhammad Rizwan Abid, Daniel Amyot and Stéphane Sotèg Somé. A UML PROFILE FOR GOAL-ORIENTED MODELLING. University of Ottawa.
Prieiga per internetą: http://download-na.telelogic.com/download/ugcagenda/muhammad_abid_a_uml_profile_for_goal_oriented_modelling.pdf

95. Muhammad Rizwan Abid. UML Profile for Goal-oriented Modelling. University of Ottawa Ottawa, Ontario, Canada August 2008. Prieiga per internetą:
<http://jucmnav.softwareengineering.ca/ucm/pub/UCM/VirLibAbidMScThesis/AbidThesis-Final.pdf>
96. Orion securities. Rizikos testas. 2011.
97. Page, S. E. (1999), Computational models from A to Z. Complexity, 5: 35–41.
doi: 10.1002/(SICI)1099-0526(199909/10)5:1<35::AID-CPLX5>3.0.CO;2-B
98. Powersim Studio programinė įranga. Prieiga per internetą:
<http://www.powersim.com/>
99. Powersim Studio programinė įranga. Prieiga per internetą:
<http://www.powersim.com/>
100. Privačių pensijų programos: jų įtaka tinkamoms ir tvarioms pensijoms. Europos Komisija. Liuksemburgas: Europos Sajungos leidinių biuras. 2010. ISBN 978-92-79-15191-0
101. Private pension schemes: their role in adequate and sustainable pensions. European Commission. Directorate-General for Employment, Social Affairs and Equal Opportunities. 2010. ISBN 978-92-79-14657-2
102. Public and private pension expenditure in OECD. OECD Factbook 2010: Economic, Environmental and Social Statistics, OECD Publishing [interaktyvus]. 2010 [žiūrėta 2011-10-05]. <http://www.oecd-ilibrary.org/social-issues-migration-health/oecd-factbook-2010/public-and-private-pension-expenditure_factbook-2010-77-en>.
103. R. Chowdhury. Parallel Computing with OpenMP to solve matrix Multiplication. UCONN BIOGRID REU Summer 2010. Department of Computer Science & Engineering. University of Connecticut, Storrs, CT 06269
104. Rajanish Dass (2006), Data Mining In Banking And Finance: A Note For Bankers- Technical note, Note No.: CISG88., April 2006
105. Ranco, G, Aleksovski, D, Caldarelli, G, Grčar, M, Mozetič, I. The Effects of Twitter Sentiment on Stock Price Returns. PLoS ONE 10(9): e0138441. doi:10.1371/journal.pone.0138441 (2015).
106. RapidMiner. Available at <http://rapid-i.com/content/view/181/190/>

107. Respect-IT sa. A KAOS Tutorial. 2007. Prieiga per internetą: <http://www.objectiver.com/fileadmin/download/documents/KaosTutorial.pdf>
108. Rutkauskas, A.V.: Adequate investment portfolio anatomy and decisions applying imitative technologies, ISSN 1392–1258 (2006)
109. Sandra Svanidzaitė. Metodika, skirta įmonių į paslaugas orientuotos architektūros sistemų nefunkciniams reikalavimams rinkti ir valdyti. Modern Computing, Vol. 2, No. 3, 117-131 (2014) Prieiga per internetą: http://www.academia.edu/6027447/Metodika_skirta_%C4%AFmoni%C5%B3_%C4%AF_paslaugas_orientuotas_architekt%C5%ABros_sistem%C5%B3_n_efunkciniams_reikalavimams_rinkti_ir_valdyti_slides_in_lithuanian_language
110. Saulius Gudas (2012). Informacijos sistemų inžinerijos teorijos pagrindai. Monografija, Vilnius, Vilniaus universiteto leidykla, 2012, 382 p. ISBN978-609-459-075-7 (24 sp/l; 25 aut.l/)
111. Saulius Gudas. Enterprise Ontology. Theory and Methodology. Jan L. Dietz. MII PSIS seminaras. 2015.
112. Saulius Maskeliūnas. Ontologijos ir semantinis pasaulinis tinklas. Paskaitų medžiaga (2015).
113. Saulius Norvaišas, Vaidotas Sruogis. Sistemų dinamikos pradmenys. Paskaitų medžiaga. Prieiga per internetą: <http://www.culture.lt/science/SD/sd.htm>
114. Schoen, H., Gayo-Avello, D. et al. (2013) “The power of prediction with social media”, Internet Research, Vol. 23 Iss: 5, pp.528- 543. 10.1108/IntR-06-2013-0115
115. Shaikh M, Chhajed G. Review on Financial Forecasting using Neural Network and Data Mining Technique (2012). Volume 05 No. 02 Page No. 263-267 Dec 2012.
116. Shen, G. C., Jia, W.Y. (2014) The Prediction Model of Financial Crisis Based on the Combination of Principle Component Analysis and Support Vector Machine. Open Journal of Social Sciences, 2, 204-212. Available: <http://dx.doi.org/10.4236/jss.2014.29035>
117. Shiller, R. J., 2014. “Speculative Asset Prices”, American Economic Review, 104(6): 1486-1517. Available: <http://cowles.yale.edu/sites/default/files/files/pub/d19/d1936.pdf>

118. Shiller, Robert J. 2014. "Speculative Asset Prices." American Economic Review, 104(6): 1486-1517. Prieiga interne: <http://cowles.yale.edu/sites/default/files/files/pub/d19/d1936.pdf>
119. Silicon Africa. Available at <http://www.siliconafrica.com/the-best-data-minning-tools-you-can-use-for-free-in-your-company/>
120. Singh, T. R. An ordered probit model of an early warning system for predicting financial crisis in India. Proceedings of the IFC Conference on "Initiatives to address data gaps revealed by the financial crisis", Basel, 2010.
121. Sistemų dinamika. Prieiga per internetą: http://studento.vikis.lt/wiki/index.php/Sistem%C5%B3_dinamika
122. Social Network for Investors and Traders. Available: <http://stocktwits.com/>
123. SPDR Euro STOXX 50 ETF. Available: <http://finance.yahoo.com/q?s=FEZ>
124. SPDR Gold Shares ETF. Available: <http://finance.yahoo.com/q?s=G>
125. SPDR S&P 500 ETF. State Street Global Advisors. Available: <https://www.spdrs.com/product/fund.seam?ticker=SPY>
126. Spreadsheet of DNB bank: <http://www.dnb.lt/lt/skaiciuokles-privatiems-klientams/papildomos-pensijos-skaiciuokle/>
127. Spreadsheet of MP Pension Funds Baltic: <http://www.mppf.lt/main.php?id=87/lang/1>
128. Spreadsheet of SEB bank: <http://fin.seb.lt/vbfin/calc/pensionCalculator.fw?lang=lt>
129. Sprendimų priėmimas. Intelektualios sistemos. T120B120. Įmonių informacinių technologijos. 2010. Prieiga per internetą: http://www.oksl.ktu.lt/studijos/T120B120/slide/iit2010/08_Intel.pdf
130. SPSS Software and Solutions. Available at <http://www.spss.com.hk>
131. Stella ir iThink programinė įranga. Prieiga per internetą: <http://www.iseesystems.com/>
132. TechAmerica Foundation's Federal Big Data Commission (2012). Demystifying Big Data: A Practical Guide to Transforming the Business of Government.

133. TechSource. Available at <http://www.junauza.com/2010/11/free-data-mining-software.html>
134. The Data Mine. Available at <http://www.the-database-mine.com/Software/ViscoverySOMine>
135. The financial brand. Banking Trends, 2013, <http://thefinancialbrand.com/35019/google-trends-in-banking-2013>
136. Tularam, G., Subramanian, B. Modeling of financial crises: a critical analysis of models leading to the global financial crisis. Global journal of business research. Volume 7, nr 3. 2013
137. Valdymo įmonių valdomų papildomo savanoriško pensijų kaupimo pensijų fondų veiklos 2011 m. II ketvirčio apžvalga. LR Vertybinių popierių komisija [interaktyvus]. 2011 [žiūrėta 2011-10-03]. <http://www.vpk.lt/new/documents/VPK_2011%20m_I%20ketvircio III pak opos PF apzvalga 08_08.pdf>.
138. Valstybinio socialinio draudimo įmokos dalies kaupimo pensijų fondų veiklos 2011 m. II ketvirčio apžvalga. LR Vertybinių popierių komisija [interaktyvus]. 2011 [žiūrėta 2011-10-03]. <http://www.vpk.lt/new/documents/VPK_DPK_2011%20m_I_pusmeicio_PF_apzvalga_08_04.pdf>.
139. Valstybinio socialinio draudimo įmokos dalies kaupimo pensijų fondų 2010 metų veiklos ataskaitose pateikiamų rodiklių apžvalga. LR Vertybinių popierių komisija [interaktyvus]. 2010 [žiūrėta 2011-10-28]. <http://www.vpk.lt/new/documents/VPK_DPK_2010%20m_%20PF_apzvalga_07_15_galutinis_2.pdf>
140. Vensim programinė įranga. Prieiga per internetą: <http://vensim.com/>
141. Vensim programinė įranga. Prieiga per internetą: <http://vensim.com/>
142. Viscovery. Available at <http://www.viscovery.net/somine/>
143. Žalioji knyga: Adekvačios, tvarios ir saugios Europos pensijų sistemos. Europos komisija. Briuselis. 2010.