

VILNIAUS GEDIMINO TECHNIKOS UNIVERSITETAS

Nijolė MAKNICKIENĖ

PARAMOS SISTEMA INVESTUOTOJUI  
VALIUTŲ RINKOJE

DAKTARO DISERTACIJA

SOCIALINIAI MOKSLAI,  
EKONOMIKA (04S)

Vilnius  2015  
LEIDYKLA  
TECHNIKA

Disertacija rengta 2012–2015 metais Vilniaus Gedimino technikos universitete.

#### **Mokslinis vadovas**

doc. dr. Jelena STANKEVIČIENĖ (Vilniaus Gedimino technikos universitetas, ekonomika – 04S).

Vilniaus Gedimino technikos universiteto Ekonomikos mokslo krypties disertacijos gynimo taryba:

#### **Pirmininkas**

prof. habil. dr. Romualdas GINEVIČIUS (Vilniaus Gedimino technikos universitetas, ekonomika – 04S).

#### **Nariai**

prof. habil. dr. Remigijs POČS (Rygos technikos universitetas, ekonomika – 04S),

prof. habil. dr. Rimvydas SIMUTIS (Kauno technologijos universitetas, informatikos inžinerija – 07T),

doc. dr. Rima TAMOŠIŪNIENĖ (Vilniaus Gedimino technikos universitetas, ekonomika – 04S),

prof. habil. dr. Edmundas Kazimieras ZAVADSKAS (Vilniaus Gedimino technikos universitetas, vadyba – 03S).

Disertacija bus ginama viešame Ekonomikos mokslo krypties disertacijos gynimo tarybos posėdyje **2015 m. balandžio 27 d. 10 val.** Vilniaus Gedimino technikos universiteto senato posėdžių salėje.

Adresas: Saulėtekio al. 11, LT-10223 Vilnius, Lietuva.

Tel. (8 5) 274 4956; faksas (8 5) 270 0112; el. paštas doktor@vgtu.lt

Pranešimai apie numatomą ginti disertaciją išsiųsti 2015 m kovo 26 d.

Disertaciją galima peržiūrėti interneto svetainėje <http://dispace.vgtu.lt/> ir Vilniaus Gedimino technikos universiteto bibliotekoje (Saulėtekio al. 14, LT-10223 Vilnius, Lietuva).

VGTV leidyklos TECHNIKA 2312-M mokslo literatūros knyga

ISBN 978-609-457-780-2

© VGTV leidykla TECHNIKA, 2015

© Nijolė Maknickienė 2015

*nijole.maknickiene@vgtu.lt*

VILNIUS GEDIMINAS TECHNICAL UNIVERSITY

Nijolė MAKNICKIENĖ

THE SUPPORT SYSTEM FOR THE INVESTOR  
IN CURRENCY MARKET

DOCTORAL DISSERTATION

SOCIAL SCIENCES,  
ECONOMICS (04S)

Doctoral dissertation was prepared at Vilnius Gediminas Technical University in 2012–2015.

**Scientific supervisor**

Assoc Prof Dr Jelena STANKEVIČIENĖ (Vilnius Gediminas Technical University, Economics – 04S).

The Dissertation Defense Council of Scientific Field of Economics of Vilnius Gediminas Technical University:

**Chairman**

Prof Dr Habil Romualdas GINEVIČIUS (Vilnius Gediminas Technical University, Economic – 04S).

**Members:**

Prof Dr Habil Remigijus POČS (Ryga Technical University, Economics – 04S),

Prof Dr Habil Rimvydas SIMUTIS (Kaunas University of Technology, Informatics Engineering – 07T),

Assoc Prof Dr Rima TAMOŠIŪNIENĖ (Vilnius Gediminas Technical University, Economics – 04S),

Prof Dr Habil Edmundas Kazimieras ZAVADSKAS (Vilnius Gediminas Technical University, Management – 03S).

The dissertation will be defended at the public meeting of the Dissertation Defence Council of Economics in the Senate Hall of Vilnius Gediminas Technical University at **10 a. m. on 27 April 2015**.

Address: Saulėtekio al. 11, LT-10223 Vilnius, Lithuania.

Tel.: +370 5 274 4956; fax +370 5 270 0112; e-mail: doktor@vgtu.lt

A notification on the intend defending of the dissertation was send on 26 March 2015.

A copy of the doctoral dissertation is available for review at the Internet website <http://dspace.vgtu.lt/> and at the Library of Vilnius Gediminas Technical University (Saulėtekio al. 14, LT-10223 Vilnius, Lithuania).

## Reziumė

Disertacijoje nagrinėjamos investavimo valiutų rinkoje, naudojant dirbtinį intelektą, galimybės. Literatūros analizė atskleidė, kad vienu metu pasaulyje formavosi dvi skirtingos mokslinių tyrimų kryptys: universalioji dirbtinio intelekto teorija ir investicijų teorija. Pirmoji kryptis turėjo įtakos universalios prognozės galimybės teorijos atsiradimui, tai lėmė įvairių dirbtinio intelekto algoritmų ir jų sistemų sukūrimą. Antroji kryptis vystėsi kartu su racionalaus numatymo teorija, kuri padėjo pagrindus moderniosios portfelio teorijos atsiradimui. Šiame darbe siekiama susieti šias dvi mokslines kryptis valiutų rinkos prognozavimui.

Pagrindinis disertacijos tikslas – sukurti investicinių sprendimų priėmimo paramos sistemą investuotojui valiutų rinkoje tikslingai pritaikant dirbtinio intelekto algoritmus ir moderniąją portfelio teoriją. Darbe sprendžiami pagrindiniai uždaviniai: suformuoti valiutų rinkos prognozavimo modelį dirbtinio intelekto algoritmų pagrindu, integruoti investicinio portfelio optimizavimo principus į prognozavimo modelį, empiriškai aprobuoti modelio efektyvumą ir patikimumą investuojant valiutų rinkoje. Finansų rinkų prognozavimui tikslingai pritaikius dirbtinio intelekto algoritmus ir į juos integravus moderniąją portfelio teoriją, sukurta patikima ir efektyvi paramos sistema investuotojui.

Disertaciją sudaro įvadas, trys skyriai, bendrosios išvados, naudotos literatūros ir autoriaus publikacijų sąrašai. Įvadiniame skyriuje aptariama tiriamoji problema, darbo aktualumas, aprašomas tyrimų objektas, formuluojamas darbo tikslas ir uždaviniai, aprašoma tyrimų metodika, darbo mokslinis naujumas, darbo praktinė reikšmė, ginamieji teiginiai. Pirmasis skyrius skirtas literatūros analizei, jame pateikti finansų rinkų būties ypatumai, procesų analizė, valdymo ir reguliavimo aspektai globalioje ekonomikoje, prognozavimo dirbtinio intelekto sistemomis analizė bei investicinių portfelių formavimo strategijų analizė. Antrajame skyriuje teikiamos teorinės dirbtinio intelekto sukūrimo prielaidos, Evolino RNN pritaikymo produktyviam sprendimui teoriniai pagrindai, investicinio portfelio teorijos principų taikymo galimybės. Trečiajame skyriuje pateikiama prognozavimo modelių architektūra, įvertinamas jų patikimumas. Atsižvelgiant į pelningumą ir rizikingumą, lyginamos įvairios investavimo strategijos.

Disertacijos tema paskelbti 4 straipsniai: 2 – ISI Web of Science žurnaluose, 2 – kituose recenzuojamuose žurnaluose. Perskaityti 9 pranešimai tarptautinėse konferencijose iš jų: 2 – konferencijų medžiaga *Thomson ISI Proceedings* duomenų bazėje, 7 – recenzuojamoje tarptautinių konferencijų medžiagoje.

## Abstract

This dissertation examines investment opportunities in the currency market, and analyses the theoretical and practical aspects of forecasting under uncertainty. At one time the world was formed of two distinct research areas: universal artificial intelligence theory and the theory of investment. The first area was influenced by the possibility of universal theory predictions for the emergence of what has been created for the results of various artificial intelligence algorithms and their systems. The second research area evolved as a rational prediction of the theory which laid the foundations for the emergence of modern portfolio theory. The paper attempts to link these two scientific areas to the forecasting of currency market.

The main goal of this thesis is to create an investment decision-making support system targeting investors in the currency market, by adapting artificial intelligence algorithms and modern portfolio theory. In order to achieve the goal the following specific objectives are used: to create a forecasting model based on artificial intelligence algorithms, to integrate investment optimisation principles in predictive models, and to empirically substantiate the efficiency and reliability of the support system for investment in the currency market. The support system for investors was created with a targeted application of artificial intelligence algorithms to financial market forecasting, and by integrating them into modern portfolio theory.

The dissertation consists of an introduction, three chapters, a general conclusions, the reference list and a list of the author’s publications. The introductory chapter discusses the research problem and the relevance of the research, its aim and objectives, the research methodology, scientific innovation, practical significance and defended statements. The first chapter describes peculiarities of the financial markets, analyses of financial processes in the global economy, forecasting by artificial intelligence algorithms and an analysis of modern portfolio theory and investment strategies. The second chapter describes theoretical assumptions of the creation of artificial intelligence, the theoretical basis for adaptation of the Evolino recurrent neural networks (RNN) to productive work and provides an evaluation of portfolio efficiency. The third section presents the support system for investor in exchange market.

Four articles have been published on the dissertation topic: two in IS Web of Science journals and two in other reviewed journals. Nine papers were presented at international conferences: two as conference materials in *ISI Proceedings*, seven were reviewed international conference proceedings.

---

## Žymėjimai

### Santrumpos

ACF – autokoreliacinė funkcija  
AFSA – dirbtinio žuvų spiečiaus optimizavimo algoritmas  
ANFIS – adaptyvi neuroninė neraiškiosios sklaidos sistema  
APG1L – APB „Apranga“ akcijos  
ARIMA – autoregresinis integruotas slankusis vidurkis  
ASSR – pritaikyta Sharpe rodiklio asimetrija  
DAN2 – dinaminis neuroninis tinklas  
DIJA – Don Džonso industrijos indekso vidurkis  
DJIA – Don Džonso indekso vidurkis  
EDR – kintančių sprendimų taisyklės  
EMH – Efektyvioji rinkos hipotezė  
EPVY – tikėtinos teisingos informacijos indeksas  
ESP – priverstinės subpopuliacijos  
EUR/CHF – euro ir Šveicarijos franko santykis  
EUR/GBP – euro ir Didžiosios Britanijos paundo santykis  
EUR/JPY – euro ir Japonijos jenos santykis  
EUR/USD – euro ir Jungtinių Amerikos Valstijų dolerio santykis  
EVOLINO – evoliucinis rekurentinio neuroninio tinklo algoritmas  
FAM – neuro-neraiškioji asociatyvinė atmintis

FDM – neraiškiosios sklaidos Delfi metodas  
FLANN – funkcinio ryšio neuroniniai tinklai  
Fuzzy – neraiškioji sklaida  
GA – genetiniai algoritmai  
GAFD – genetinis algoritmas ateities diskretizavimui  
GARCH – hibridinis neuroninis tinklas naudojantis generuotą autoregresiją  
GBP/AUD – Didžiosios Britanijos svarų sterlingų ir Australijos dolerio santykis  
HTM – hierarchinė laikinė atmintis  
JAV – Jungtinės Amerikos Valstijos  
KOSPI – Korėjos akcijų kainų indeksas  
LMST – ilgalaikės atminties ląstelė  
LSM – standartinis minimalus kvadratinis nuokrypis  
MAPE – vidutinė procentinė paklaida  
MBNN – daugiasluoksnis neuroninis tinklas  
MLP – daugiasluoksnis parceptonas  
NASDAQ – Jungtinių Amerikos Valstijų akcijų birža  
NYDJA – Niujorko Don Džonso vidurkis  
NYKKEY – 225-ių geriausiai įvertintų Japonijos įmonių akcijų indeksas  
NN – neuroniniai tinklai (ang. *Neural networks*)  
NZD/CAD – Naujosios Zelandijos dolerio ir Kanados dolerio santykis  
OMXB – Baltijos šalių lyginamasis indeksas  
OMXR – visų Latvijos akcijų indeksas  
OMXT – visų Estijos akcijų indeksas  
OMXV – visų Lietuvos akcijų indeksas  
PPO – kainos procentinis osciliatorius  
QG – dujų kaina Jungtinių Amerikos Valstijų doleriais  
QM – naftos kaina Jungtinių Amerikos Valstijų doleriais  
RBFNN – radialinės bazinės funkcijos neuroniniai tinklai  
RNN – rekurentinis neuroninis tinklas  
RSPOP – neraiškiosios sklaidos pagrindu sukurtas produktas  
SVM – sustiprinto vektoriaus mašina  
TALIT – Talink Group akcijos  
TEO1L – TEO LT, AB akcijos  
TOPIX – Tokijo akcijų indeksas  
TSK – Takagi-Sigeno-Kang banginė sistema akcijų kainoms prognozuoti  
USD/CHF – Jungtinių Amerikos Valstijų dolerio ir Šveicarijos franko santykis  
USD/JPY – Jungtinių Amerikos Valstijų dolerio ir Japonijos jenos santykis  
XAGUSD – sidabro kaina Jungtinių Amerikos Valstijų doleriais  
XAUUSD – aukso kaina Jungtinių Amerikos Valstijų doleriais



---

# Turinys





I V A D A S . . . . .	1
Problemos formulavimas . . . . .	1
Darbo aktualumas . . . . .	2
Tyrimų objektas . . . . .	2
Darbo tikslas . . . . .	3
Darbo uždaviniai . . . . .	3
Tyrimų metodika . . . . .	3
Darbo mokslinis naujumas . . . . .	4
Darbo rezultatų praktinė reikšmė . . . . .	4
Ginamieji teiginiai . . . . .	5
Darbo rezultatų aprobavimas . . . . .	5
Disertacijos struktūra . . . . .	6
1. INVESTAVIMO FINANSŲ RINKOSE GALIMYBIŲ STUDIJA . . .	7
1.1. Finansų rinkos globalioje ekonomikoje . . . . .	7
1.1.1. Finansų rinkų būties ypatybės . . . . .	8
1.1.2. Finansų rinkos procesų analizė . . . . .	13
1.1.3. Finansų rinkų valdymo ir reguliavimo aspektai . . . . .	18
1.2. Finansų rinkų prognozavimas dirbtinio intelekto algoritmais . . .	21
1.2.1. Moduliniai neuroniniai tinklai . . . . .	22

1.2.2.	Genetiniai algoritmai . . . . .	24
1.2.3.	Neraiškioji logika . . . . .	26
1.2.4.	Ekspertinės arba agentų sistemos . . . . .	28
1.2.5.	Hibridinės sistemos . . . . .	30
1.3.	Investicinio portfelio suformavimo principai . . . . .	33
1.4.	Pirmojo skyriaus išvados ir disertacijos uždavinių formulavimas	37
2. SPRENDIMO PRIĖMIMO NEAPIBRĖŽTIES SĄLYGOMIS		
	TEORINIAI PAGRINDAI . . . . .	39
2.1.	Universaliosios dirbtinio intelekto teorijos galimybių analizė .	39
2.1.1.	Dirbtinio intelekto sąvoka . . . . .	39
2.1.2.	Universaliosios prognozės galimybė . . . . .	43
2.2.	Evolino rekurentinio neuroninio tinklo pritaikymas produktyviam sprendimui . . . . .	44
2.2.1.	Evolino rekurentinis neuroninis tinklas . . . . .	44
2.2.2.	Prognozavimo įrankio architektūra . . . . .	49
2.2.3.	Maži rekurentinių neuroninių tinklų ansambliai . . . . .	51
2.2.4.	Dideli rekurentinių neuroninių tinklų ansambliai . . . . .	56
2.3.	Investavimo procesų teoriniai aspektai . . . . .	57
2.3.1.	Investicijų valdymas . . . . .	57
2.3.2.	Modernioji portfelio teorija . . . . .	59
2.3.3.	Trimatis portfelio vertinimas (pelningumas, rizika, patikimumas) . . . . .	62
2.3.4.	Investicinio portfelio efektyvumas . . . . .	64
2.4.	Antrojo skyriaus išvados . . . . .	65
3. PARAMOS SISTEMA INVESTUOTOJUI VALIUTŲ RINKOJE . . . . .		
3.1.	Dirbtinio intelekto algoritmų pritaikymas finansų rinkos priemonių prognozavimui . . . . .	67
3.1.1.	Evolino rekurentinio neuroninio tinklo derinimas ir įvesčių parinkimas . . . . .	68
	Prognozavimo modelis, kai Evolino rekurentinių neuroninių tinklų skaičius ansamblyje yra mažas . . . . .	72
	Prognozavimo modelis, kai Evolino rekurentinių neuroninių tinklų skaičius ansamblyje yra didelis . . . . .	75
3.2.	Sprendimo priėmimas rizikos ir neapibrėžties sąlygomis . . . . .	78
3.2.1.	Investicijų portfelio optimizavimas naudojant prognozavimo modelį su mažu Evolino rekurentinių neuroninių tinklų skaičiumi . . . . .	79

3.2.2. Investicijų portfelio optimizavimas naudojant prognozavimo modelį su dideliu Evolino rekurentinių neuroninių tinklų skaičiumi . . . . .	83
3.2.3. Paramos sistemos testavimas realioje rinkoje . . . . .	88
3.3. Trečiojo skyriaus išvados . . . . .	95
BENDROSIOS IŠVADOS . . . . .	99
LITERATŪRA IR ŠALTINIAI . . . . .	120
AUTORĖS MOKSLINIŲ PUBLIKACIJŲ DISERTACIJOS TEMA SARAŠAS . . . . .	121
SUMMARY IN ENGLISH . . . . .	123
PRIEDAI <sup>1</sup> . . . . .	141
A priedas. Paramos sistemos investuotojams schema . . . . .	141
B priedas. Bendraautorių sutikimai teikti publikacijų medžiagą disertacijoje . . . . .	141
C priedas. Autoriaus mokslinių publikacijų disertacijos tema kopijos	141

---

<sup>1</sup>A footnote without marker



---

# Contents





INTRODUCTION . . . . .	1
Problem formulation . . . . .	1
Relevance of the thesis . . . . .	2
Object of the research . . . . .	2
Aim of the thesis . . . . .	3
Objectives of the thesis . . . . .	3
Research methodology . . . . .	3
Scientific novelty of the thesis . . . . .	4
Practical value of research findings . . . . .	4
Statements to be defended . . . . .	5
Approval of research findings . . . . .	5
Structure of the thesis . . . . .	6
1. OPPORTUNITIES STUDY OF INVESTMENT IN FINANCIAL MARKETS . . . . .	7
1.1. Financial market in the global economic . . . . .	7
1.1.1. Properties of existence of finance market . . . . .	8
1.1.2. Analysis of finance market processes . . . . .	13
1.1.3. Aspects of management and regulation of finance markets . . . . .	18

1.2. Forecasting of finance market by algorithms of artificial intelligence . . . . .	21
1.2.1. Modular neural networks . . . . .	22
1.2.2. Genetic algorithms . . . . .	24
1.2.3. Fuzzy logic . . . . .	26
1.2.4. Expert systems . . . . .	28
1.2.5. Hybrid systems . . . . .	30
1.3. Principals of investment portfolio formation . . . . .	33
1.4. Conclusions of the first section and the formulation of the objectives of the thesis . . . . .	37
2. THEORETICAL BACKGROUND OF DECISION-MAKING UNDER UNCERTAINTY . . . . .	39
2.1. Analysis of opportunities of Universal artificial intelligence theory . . . . .	39
2.1.1. Conception of artificial intelligence . . . . .	39
2.1.2. Opportunity of universal prognosis . . . . .	43
2.2. Adaptation of Evolino recurrent neural network for productive solution . . . . .	44
2.2.1. Evolino recurrent neural network . . . . .	44
2.2.2. Architecture of forecasting tool . . . . .	49
2.2.3. Small ensembles of recurrent neural networks . . . . .	51
2.2.4. Large ensembles of recurrent neural networks . . . . .	56
2.3. Theoretical aspects of investment processes . . . . .	57
2.3.1. Management of investment . . . . .	57
2.3.2. Modern portfolio theory . . . . .	59
2.3.3. Three-dimensional evaluation of the portfolio (profitability – risk – reliability) . . . . .	62
2.3.4. Efficiency of investment portfolio . . . . .	64
2.4. Conclusions of the second section . . . . .	65
3. SUPPORT SYSTEM FOR INVESTORS IN THE CURRENCY MARKET . . . . .	67
3.1. Adaptation of algorithms of artificial intelligence for financial tools forecasting . . . . .	67
3.1.1. Combination and inputs selection for Evolino recurrent neural network . . . . .	68
Forecasting model, when number of Evolino recurrent neural networks is small . . . . .	72

. Forecasting model, when number of Evolino recurrent neural networks is large . . . . .	75
3.2. Decision making under uncertainty and risk . . . . .	78
3.2.1. Optimisation of investment portfolio using forecasting model with small number of Evolino recurrent neural networks . . . . .	79
3.2.2. Optimisation of investment portfolio using forecasting model with large number of Evolino RNN . . . . .	83
3.2.3. Testing of support system in real market . . . . .	88
3.3. Conclusions of the third section . . . . .	95
GENERAL CONSLUSIONS . . . . .	99
REFERENCES . . . . .	120
LIST OF SCIENTIFIC PUBLICATIONS BY THE AUTHOR ON THE TOPIC OF THE DISSERTATION . . . . .	121
SUMMARY IN ENGLISH . . . . .	123
ANNEXES <sup>1</sup> . . . . .	141
Annex A. Scheme of support system for investor . . . . .	141
Annex B. The coauthors’ agreements to present publications material in the dissertation . . . . .	141
Annex C. Copies of scientific publications by the author on the topic . . . . .	141

---

<sup>1</sup>A footnote without marker  
<sup>1</sup>A footnote without marker





---

# Įvadas

## Problemų formulavimas

Gebėjimas prognozuoti ekonominius procesus lemia geresnius sprendimus tiek valstybiniu, tiek įmonės ar asmeniniu lygmeniu. Visi finansų rinkos modeliavimo ir prognozavimo procesai vyksta neapibrėžtyje ir nuolat kinta. Neapibrėžtumą lemia ekonominės ir finansų politikos pokyčiai, skirtingi ekonomikos augimo tempai, produktyvumo kaita, karai, teroro aktai, klimato kaita, stichinės nelaimės ir kita. Ekonominis neapibrėžtumas yra neišvengiamybė, prie kurios privalo prisitaikyti visi ekonomikos subjektai. Prognozuojant visada egzistuoja tam tikros nežinomos rizikos galimybė, kuri nebuvo numatyta, todėl prognozuojant naudotina tikimybinė ekonomikos prognozės išraiška. Valiutų rinkos prognozavimas – stochastinis procesas, todėl galimas tik euristinis artėjimas prie maksimalaus rezultato, kurį geriausiai atspindi galimybių skirstiniai. Tokiems uždaviniams spręsti dažnai naudojamos sprendimo priėmimo paramos sistemos.

Paramos sistemos investuotojui kuriamos pasitelkiant naujausius įvairių sričių mokslinius technologinius pasiekimus. Vienas jų – dirbtinio intelekto algoritmai, jungiantys matematikos, informatikos, biologijos, psichologijos mokslų žinias. Tinkamai sukurtas, eksperimentiškai patikrintas ir optimizuotas prognozavimo modelis, naudojantis dirbtinio intelekto algoritmus, gali tapti

investuotojui patikima, pelninga ir nuosaikiai rizikinga paramos sistema. Modelio prognozavimo rezultatas gali būti ne tik taškinis, bet ir stochastiškai informatyvus tikėtinų verčių skirstinys.

Moderniosios portfelio teorijos integravimas į modelį leidžia pasiekti optimalų pelno ir rizikos santykį. Paramos investuotojui sistema gali būti sėkmingai taikoma ne tik asmeniniam spekuliaciniam valiutų rinkoje, bet ir investicinių fondų veikloje bei valstybės finansų valdyme.

## Darbo aktualumas

Valstybės finansų valdymas, investicinių fondų veikla bei atskiro investuotojo siekis efektyviai panaudoti uždirbtas lėšas reikalauja patikimo finansinių procesų prognozavimo bei modeliavimo sistemos, įgalinančios priimti geresnius finansinius sprendimus ir sumažinti neapibrėžties lygmenį.

Efektyvioji rinkos teorija nepajėgi paaiškinti visų chaotinių rinkos elgsenos dėsningumą ir atsižvelgti į informacijos asimetriją. Naujų technologijų pažanga skverbiasi į finansų rinkas. Interneto, informacinių sistemų tobulėjimas sudarė sąlygas finansų rinkos dalyviams greitai ir efektyviai priimti sprendimus valiutų ir akcijų rinkose, stebėti ir analizuoti rezultatus realiu laiku. Todėl disertacijoje buvo siekiama gilinti supratimą apie valiutų rinkos funkcionavimą, pagrindinius veiksnius ir būsenas. Disertaciniame darbe panaudoti evoliucinių rekurentinių neuroninių tinklų algoritmai, sujungti į skirtingus istorinius duomenis įvertinantį ansamblį, leidžia gauti stochastiškai informatyvų tikėtinų verčių skirstinį, atspindintį prognozuojamo valiutų kurso elgseną ateityje. Į tokį prognozavimo įrankį integravus moderniąją portfelio teoriją įmanoma prognozuoti finansų rinkos procesus, pažinti esmines finansų rinkos savybes, o tai leidžia didinti valiutų rinkos veiklos efektyvumą ir sudaro prielaidas racionaliau paskirstyti ribotus pasaulio išteklius.

## Tyrimų objektas

Disertacijoje tiriama paramos sistema investuotojui valiutų rinkoje, naudojant dirbtinio intelekto algoritmus.

## Darbo tikslas

Sukurti investicinių sprendimų priėmimo paramos sistemą investuotojui valiutų rinkoje, tikslingai pritaikant dirbtinio intelekto algoritmus ir moderniąją portfelio teoriją.

## Darbo uždaviniai

1. Išanalizuoti mokslinę literatūrą apie finansų rinkų globalioje ekonomikoje aspektus ir dirbtinio intelekto prognozavimo algoritmus. Išsiaiškinti sinergijos efekto tarp skirtingų mokslo šakų, naujausių technologinių atradimų ir moderniosios portfelio teorijos galimybes, siekiant gauti efektyvų, kokybiškai naują, socialiai harmoningą, inovatyvų prognozavimo įrankį.
2. Suformuoti valiutų rinkos prognozavimo modelį universaliosios dirbtinio intelekto teorijos, universaliosios prognozės galimybės ir moderniosios portfelio teorijos pagrindu.
3. Integruoti moderniąją portfelio teoriją į prognozavimo modelį, siekiant gauti efektyvią paramos sistemą investuotojui valiutų rinkoje.
4. Empiriškai patikrinti paramos sistemos efektyvumą ir patikimumą investuojant valiutų rinkoje realiu laiku, patikrinti moderniąją portfelio teoriją.

## Tyrimų metodika

Siekiant įgyvendinti darbe numatytus tikslus, pasitelkta mokslinių šaltinių analizė, sintezė ir apibendrinimas, teorinių ir eksperimentinių tyrimų analizė, taikant analitinius skaitinius metodus bei eksperimentus, naudojant istorinius ir realaus laiko valiutų rinkos duomenis. Formuojant evoliucinių neuroninių tinklų ansamblį, naudojami ekonomikos prognozavimo metodai. Dirbtinio intelekto sistemos išvestims pritaikyti ekspertinio vertinimo metodai: Delfi metodas ir grupės nuomonių suderinamumo įvertinimas. Didelio Evolino rekurentinių tinklų ansamblio išvestims nagrinėti taikomi skirstinių analizės metodai. Investicinio portfelio galimybių analizei naudoti stochastinio optimizavimo ir grafinio vaizdavimo bei analizavimo metodai.

## Darbo mokslinis naujumas

1. Pasiūlyta investicinių sprendimų priėmimo paramos sistema investuotojui valiutų rinkoje, tikslingai pritaikant dirbtinio intelekto algoritmus ir moderniąją portfelio teoriją.
2. Valiutų rinka buvo analizuojama kaip chaotinis procesas, kurį paveikė išteklių rinkos elementai. Istorinių valiutų kursų ir išteklių kainų parinkimas, siekiant maksimaliai priartėti prie duomenų ortogonalumo, pagerina prognozavimo statistinius rezultatus ir sutrumpina rekurentinių neuroninių tinklų mokymosi laiką.
3. Evoliucinių rekurentinių neuroninių tinklų algoritmai, sujungti į skirtingus istorinius duomenis įvertinančią ansamblį (8–1008 elementų), sukuria kokybiškai naujas prognozavimo, rinkos lūkesčių įvertinimo galimybes.
4. Sukurto prognozavimo modelio rezultatas yra stochastiškai informatyvus tikėtinų verčių skirstinys, atspindintis prognozuojamo valiutų kurso elgseną ateityje. Skirstinių kompozicija atveria galimybes efektyviau prekiauti realioje rinkoje.
5. Modelio prognozėms pritaikyti investicinių portfelių optimizavimo ir ortogonalumo principai įgalina naudoti sukurtą Evolino rekurentinių neuroninių tinklų modelį dideliu neapibrėžtumu pasižyminčioje aplinkoje kaip patikimą paramos sistemą investuotojui.

## Darbo rezultatų praktinė reikšmė

Disertaciniame darbe teikiama paramos sistema investuotojui valiutų rinkoje, kuri atspindi valiutų rinkos elgseną ateityje, įvertina investuotojo finansinių lūkesčių pelningumą, rizikingumą ir patikimumą. Paramos sistemos informacija suteikia investuotojui pranašumą priimant investicinius sprendimus, lyginant su neinformuotais rinkos žaidėjais. Todėl paramos sistemą investuotojui valiutų rinkoje naudojant investicinių fondų veikloje, valstybės finansų valdyme ar reinvestuojant pinigines lėšas galima išspręsti socialines, kultūrinės ir kitas gyvybiškai svarbias visuomenės problemas.

## Ginamieji teiginiai

1. Finansų rinkų prognozavimui tikslingai pritaikius dirbtinio intelekto algoritmus ir į juos integruojant moderniąją portfelio teoriją galima sukurti patikimą ir efektyvią paramos sistemą investuotojui.
2. Tikėtinų verčių skirstiniai ir jų kompozicija suteikia investuotojui papildomos informacijos ir geriausiai atspindi valiutų rinkos pokyčius ateityje.
3. Dirbtinio intelekto algoritmai gali būti sėkmingai taikomi finansų rinkų prognozavimui, suderinant vidinius sistemos parametrus, tinkamai parenkant įvestis ir pasirenkant dirbtinio intelekto sistemos architektūrą.
4. Į modelį integruojant investicinio portfelio optimizavimo lygtis ir pritaikius portfelio ortogonalumo principą investavimo sprendimai rizikos ir neapibrėžties sąlygomis tampa efektyvesni.
5. Paramos sistemos investuotojui testavimas realioje rinkoje geriausiai įvertina investavimo įrankį ir investavimo strategiją, suteikia papildomos informacijos apie rinkos dalyvius.

## Darbo rezultatų aprobavimas

Disertacijos tema paskelbti 4 straipsniai: 2 *ISI Web of science* žurnaluose (Rutkauskas *et al* (2014), Maknickienė, Maknickas (2013)), 2 kituose recenzuojamuose žurnaluose (Maknickienė *et al* (2011), Rutkauskas *et al* (2014)). Perskaiityti 9 pranešimai tarptautinėse konferencijose iš jų: 2 konferencijų medžiaga, kuri paskelbta *ISI Proceedings* duomenų bazėje, Maknickienė, Maknickas *et al* (2012), Rutkauskas *et al* (2010)), 7 – recenzuojamose tarptautinių konferencijų medžiagose (Stankevičienė *et al* (2014), (Maknickienė (2014), Maknickienė, Maknickas (2013), Maknickas, Maknickienė (2012), Maknickienė (2012), Rutkauskas *et al* (2011)).

Disertaciją sudaro trys skyriai. Pirmame skyriuje nagrinėjamos finansų rinkos būties ypatybės, procesų analizė, valdymo ir reguliavimo aspektai globalioje ekonomikoje, finansų rinkų prognozavimas dirbtinio intelekto algoritmais. Antrasis skyrius skirtas dirbtinio intelekto, prognozavimo, ekspertinių metodų ir investavimo teorinių pagrindų nagrinėjimui, detaliam Evolino rekurentinio neuroninio tinklo veikimo principo aprašymui, neuroninių tinklų an-

samblių architektūros pasirinkimo principams. Trečiame skyriuje pateikiami dirbtinio intelekto algoritmų parengimo produktyviam darbui etapai, eksperimentinis paramos sistemos investuotojui patikimumo, pelningumo ir rizikingumo įvertinimas, investicinių portfelių optimizavimo strategijų eksperimentinis įvertinimas. Taip pat šiame skyriuje aprašyti paramos sistemos testavimo realioje rinkoje rezultatai ir investicinio portfelio optimizavimas, atsižvelgiant į skirstinių kompoziciją. Pabaigoje pateikiamos bendrosios išvados.

## Disertacijos struktūra

Darbo apimtis yra 145 puslapiai, kuriuose pateikta: 49 formulės, 26 paveikslai ir 4 lentelės. Disertacijoje remtasi 222 kitų autorių literatūros šaltiniais.

# 1

## Investavimo finansų rinkose galimybių studija

Šio skyriaus tikslas yra apžvelgti finansų rinkos globalioje ekonomikoje aspektus, pateikti finansų rinkos priemonių prognozavimo modelių apžvalgą, įvertinti investicinio portfelio efektyvumo prielaidas. Šio skyriaus rezultatai buvo paskelbti dviejuose straipsniuose: Maknickienė *et al* (2011), Rutkauskas, Stasytė, Maknickienė (2014), ir pristatyti trijose konferencijose: Maknickas, Maknickienė (2012), Maknickienė, Maknickas (2013a), Stankevičienė, Maknickienė, Maknickas (2014).

### 1.1. Finansų rinkos globalioje ekonomikoje

Dvidešimt pirmame amžiuje pasaulio ekonomika susiduria su rimtais iššūkiais. Vykstanti globalizacija yra naudinga daugeliui pasaulio ekonomikos dalyvių, tačiau tuo pačiu metu generuoja naujas problemas. Kai kurios jų yra trumpalaikės, tokios kaip besaikio skolinimosi sukeltos krizės ar bankinio sektoriaus krizės. Daugumai pasaulio šalių tai trumpalaikis šokas, kurį kiekviena šalis pajėgia įveikti savarankiškai ar su kaimyninių šalių pagalba. Kitos pasaulio ekonomikos problemos yra ilgalaikės ir reikalauja strateginio požiūrio į galimų sprendimų aibę. Šios problemos – tai didėjanti nelygybė ir nelygi ekonominė plėtra, didėjantis dalies pasaulio gyventojų skurdas, neatsinaujinančių išteklių išsekimas, spartus aplinkos išteklių išsekvojimas, visuotinis atšilimas ir

sisteminės problemos, susijusios su nepakankamu finansų rinkų reguliavimu. Prognozavimo įrankių gausa ir jų patikimumo ribotumas suformavo dvejopą požiūrį į ekonomikos prognozavimą: skeptiškai manoma, kad tai neįmanoma dėl neapibrėžties, arba tikima, kad prognozavimo modeliai gali sumažinti neapibrėžties lygmenį ir sudaryti sąlygas priimti geresnius sprendimus. Finansų rinkos prognozavimo modeliai, kurie remiasi efektyviaja rinkos teorija, investuotojų racionalumu, iš esmės remiasi tam tikra pusiausvyros būseną. Tačiau tikrovėje pasiekti tokią tobulą būseną yra neįmanoma, todėl finansų rinkų prognozavimui ieškoma kitų įžvalgių (angl. *intelligence*) algoritmų, kurie grindžiami ne tik matematine logika, bet ir įvairiais gamtoje susiformavusiais elgsenos modeliais. Finansų rinkos procesų prognozavimas ir modeliavimas reikalauja gilinti supratimą apie valiutų rinkos funkcionavimą, pagrindinius veiksnius ir būsenas.

### 1.1.1. Finansų rinkų būties ypatybės

Antroje XX a. pusėje vyravo populiarė finansų rinkos teorija – efektyviosios rinkos hipotezė (EMH angl. *Effective Market hypothesis*), kuri teigia, kad visa visuomenės informacija yra įtraukta į turto kainas. Net mažiausia informacija apie nuokrypį nuo šios kainos labai greitai pasiekia prekybininkus, kurie siekdami optimizuoti savo pelną atkuria kainos pusiausvyrą. Pagal šią teoriją rinkos kainos kinta taip, lyg visi prekybininkai, turėdami išsamią informaciją, labai racionaliai siektų savanaudiškų tikslų.

Efektyviosios hipotezės tėvu laikomas Nobelio premijos laureatas Eugenijus Fama. Jis darbe (Fama 1970) pateikė dvi lemiamas koncepcijas, kurias apibrėžia efektyvią rinką. Pirma, jis pasiūlė trijų rūšių efektyvumą: stiprų, pusiau stiprų ir silpną. Efektyvumą lemia informacijos kiekis kainų tendencijos kontekste. Silpną rinkos efektyvumą lemia disponavimas tik istorinėmis kainomis ir prognozė atspindi tik istorines tendencijas, todėl iš jos pelno neįmanoma gauti. Pusiau stiprus rinkos efektyvumas reikalauja, kad visa vieša informacija, kaip bendrovių pajamų deklaracijos, metiniai pranešimai, atspindėtų kainų pokyčiuose. Stiprus rinkos efektyvumas reiškia, kad visi informacijos rinkiniai, įskaitant asmeninę informaciją, yra įtraukti į kainos kitimo tendenciją. Čia nėra monopolinės informacijos, t. y. viešai neatskleista informacija negali tapti pasipelnymo šaltiniu stiprios formos efektyviojoje rinkoje.

Antra, E. Fama parodė, kad rinkos efektyvumo sąvoka negali būti atmes-ta, neatsižvelgiant į rinkos pusiausvyros (pvz., kainų nustatymo mechanizmo) modelį. Rinkos veiksmingumas parodo, kaip informacija yra įskaičiuota į kainą, 1981 metais Shiller paskelbė straipsnį (Shiller 1980), kuriame ginčijo efek-



tyviosios rinkos hipotezę, kuri tuo metu dominavo ekonomikos teorijoje. Jis nagrinėjo JAV akcijų rinkos dinamiką nuo 1920 metų ir padarė išvadą, jog akcijų kainų kintamumas viršija racionalų rinkos dalyvių ateities vertinimą. Tęsiant tyrimus nustatyta, kad daugeliu atvejų sprendimai priimami daugiau emocionaliai, negu racionaliai. Taigi baigiantis XX amžiui EMH teorija buvo užginčyta Trimis aspektais. Pirma, visa eilė įvykių rinkoje, kurie pasėjo abejo- nę šiomis prielaidomis: 1987 metų akcijų kainų kritimas, 1990 metų NIKKEY indekso staigus kritimas. Antra, spartus informacinių technologijų vystymasis, interneto spartos didėjimas sąlygojo naujų technologijų įmonių atsiradimą, o jų akcijų kainos viršijo tikėtinas racionalias kainas. Trečia, eksperimentinės ekonomikos pradininko Vernon L. Smith, kuris 2002 metais įvertintas Nobelio premija, eksperimentai. Bendradarbiaujant su Gerry Suchanek, Arlington Wil- liams ir David Poter atlikti eksperimentai realioje rinkoje nepatvirtino tikėtinų, klasikinės ekonomikos ir žaidimų teorijos rezultatų.

Istoriškai išnagrinėjus daugelį efektyviosios rinkos hipotezės tyrėjų (Bail- lie *et al.* 1983, Sephton, Larsen 1991, Lim, Brooks 2011, Sewell 2011), galima daryti išvadą, kad pilna arba ideali informacija visiems rinkos dalyviams yra nepasiekiamo, todėl ir visiškai efektyvi rinka egzistuoti negali. Tačiau asimp- totišką artėjimą prie pilnos informacijos patvirtina kainos kitimo tendencijas ir daro šią hipotezę viena svarbiausių socialiniuose moksluose.

2013 metais daugelio darbų apie neracionalų rinkos elgesį autorius Shil- ler buvo pagerbtas Nobelio premija už novatorišką indėlį į finansų rinkų ne- pastovumą ir turto kainų dinamiką. Lars Peter Hansen idėjos apie rizikos ir neapibrėžties skirtumą (žinomą kaip Knight santykį) ir iš jo sekantį sisteminės rizikos matą taip pat įvertintos 2013 metų Nobelio premija už pagrindinį in- dėlį į mūsų supratimą apie tai, kaip ūkio subjektai prisitaiko prie rizikingos ir besikeičiančios aplinkos.

Pagrindiniai finansų teorijos dėsniniai, į kuriuos būtina atsižvelgti, ti- riant finansinius procesus, yra neapibrėžtis, ekonominių procesų cikliškumas, daugiakriteriškumas ir informacijos simetrija. Visi modeliuojami procesai vyksta neapibrėžtyje ir nuolat kinta. Visada egzistuoja tam tikros nežinomos rizikos galimybė, kuri nebuvo numatyta. Ir atvirkščiai, yra grėsmė atsisakyti sėkmingų bandymų, atsižvelgiant į pernelyg platų rizikos spektrą.

Daugelyje ekonominių situacijų sprendimai priimami neapibrėžties sąly- gomis, t. y. prognozuojamų procesų tikimybės nėra žinomos. Finansų rinkos neapibrėžtis susijusi su dinamine aplinka, kurioje nuolat keičiasi daugelis pa- rametrų. Netikrumą generuoja ekonominės ir finansų politikos pokyčiai, skir- tingi ekonomikos augimo tempai, produktyvumo kaita, karai, terorizmo aktai, klimato kaita, stichinės nelaimės ir daugelis kitų. Ekonominis neapibrėžtumas

yra neišvengiamybė, prie kurios privalo prisitaikyti visi ekonomikos subjektai. „Neapibrėžtumas yra vienas iš pagrindinių faktų gyvenime. Jis neišvengiamas verslo sprendimuose, kaip ir bet kurioje kitoje srityje. Neapibrėžtumo lygis gali būti sumažintas keliais būdais, kaip matėme. Visų pirma, galime padidinti mūsų žinias ateityje atliekant mokslinius tyrimus, kaupiant ir tiriant reikiamus duomenis. Ši veikla reikalauja sąnaudų, išteklių išlaidų, kurios turi būti paimtos iš kitų veiklų. Kitas būdas mažinti neapibrėžtį yra per daugialypį įvairių formų organizavimą. Šis veiksmas taip pat apima išlaidas, ir ne tik išteklių panaudojimo prasme. Tai susiję su individo laisvės praradimu, integruojant jį į organizaciją, o taip pat daugumos asmenų įtakos veiklai praradimu integruojantis į organizaciją, nors tai gali užtikrinti sukonzentruoto autoriteto įtakos padidėjimą. Trečias būdas taip pat yra įmanomas, jis taip pat turi savo kainą, tai – padidinti kontrolę ateityje. Ir čia vėl susiduriama su abiem išlaidų rūšimis – didelių sąnaudų ir žmogiškųjų resursų nuostolių per organizaciją. Galiausiai, neapibrėžtumas gali būti dar labiau sumažintas beveik neribotai sulėtinant pažangą, tai, žinoma, apima tiesioginius nuostolius, apimančius abi jau aprašytas sąnaudų formas“ (Knight 2012). Autorius, pateikdamas keturis galimus neapibrėžties mažinimo būdus nepasiūlo racionalaus būdo ją išmatuoti, juk kiekvieną išspręstą problemą pakeičia kitos nemažiau žmonijai svarbios problemos, sugražindamos ateities netikrumo ir neprognozuojamumo būvį.

Moksliniai šaltiniai galimybę išmatuoti ekonomikos neapibrėžtumą vertina gana prieštaringai, nors šaltiniuose gausu tokių vertinimų kaip „aukštas“, „žemas“ neapibrėžtumas, „didinti“, „mažinti“ ir kt. Informacijos teorijoje bandymo rezultato neapibrėžtumo matas yra entropija. Autoriai (Briggs *et al.* 2012) teigia, kad geriausias būdas išmatuoti neapibrėžtumą yra EPVI (ang. *expected value of perfect information*) indeksas, kuris jungia neteisingo sprendimo priėmimo tikimybę su tikėtinų nuostolių funkcija. Taip pat vertinant finansų rinkas siūloma matuoti ją internetinių paieškų skaičiumi socialiniame tinkle (Dzielinski 2012). Autoriai (Gilchrist *et al.* 2014) teigia, kad „nėra objektyvių priemonių išmatuoti ekonominių neapibrėžtumą laike“.

Visi ekonominiai procesai yra stochastiniai. Stochastinis (gr. *stochasis* — nuspėjimas), atsitiktinis, tikimybinis, Stochastinis procesas – procesas, kurio kitimas priklauso nuo atsitiktinumo. Jiems vertinti naudojami stochastiniai metodai.

Kita svarbi ekonominių procesų savybė yra jų cikliškumas, atspindintis gamtos ir gyvybinių procesų pasikartojamumą. Ši savybė leidžia įvertinti procesų neapibrėžties skirtumus esant laipsniškiems pokyčiams, cikliniams svyravimas ar išsišokantiems ekstremaliems pokyčiams.

Ekonomikos svyravimai paprastai apima cikliška pasikartojančius didelio augimo laikotarpius ir ekonomikos lėtėjimo ar netgi neigiamo augimo laikotarpius. Šių ekonominių svyravimų prognozavimas yra sudėtingas dalykas, kuris įkvėpė daugelį ekonominių teorijų. Viena plačiai paplitusi ekonomikos ciklo teorija remiasi įvairių ekonominės veiklos rūšių pusiausvyros tarp pasiūlos ir paklausos svyravimais. Tam tikros ekonominės veiklos augimas ir paklausos didėjimas sukelia prekių ir paslaugų kainas. Kadangi prekės ir paslaugos tampa brangios, paklausa mažėja ir ūkinė veikla sulėtėja. Tai, savo ruožtu, skatina prekių ir paslaugų pigimą ir tai vėl atveda į naują ekonominės veiklos augimo etapą.

Paprastai vienas ciklas trunka nuo aštuonių iki dešimties metų. Ekonominis ciklus akylai stebi investuotojai, jiems tai suteikia svarbių užuominų, kaip kis finansinių instrumentų kainos, įskaitant vertybinius popierius, obligacijas ir žaliavų kainas. Kai ekonomika pereina iš vieno ciklo etapo į kitą, investuotojų nuomonės apie tai, kas yra teisinga finansinio turto kaina, keičiasi. Tai ir yra viena iš finansų rinkų svyravimų priežasčių. Tačiau ryšys tarp finansų rinkų ir ekonomikos ciklų nėra toks paprastas, akcijų rinka tiesiog atspindi įmonių pelningumą, o tuo pačiu ir ekonomikos sveikatą. Investuotojas, siekdamas pirkti akcijas pačiame dugne, gali paskubėti ir nusipirkti akcijas per anksti, prieš akcijų vertę dar labiau krintant. Ir atvirkščiai, galima tikėtis, kad akcijų kaina jau pasiekė maksimumą ir imti pardavinėti, o iš tikrųjų akcijų kaina kyla toliau. Per ekonomikos nuosmukį JAV 2007–2009 metais, akcijų kainos dugną pasiekė aštuoniais mėnesiais anksčiau, nei ekonomikos rodikliai ėmė kilti. Taip atsitinka todėl, kad investuotojai prieš priimdami sprendimus vertina ne dabartines akcijų kainas, o lūkesčius, kokios kainos bus ateityje. Todėl finansų rinkų svyravimai pralenkia ciklinius ekonomikos svyravimus.

Ryšys tarp valiutų kursų svyravimų ir ekonomikos ciklų taip pat egzistuoja. Tik čia vertinama tam tikros šalies pinigų paklausa, lyginant ją su kitos šalies paklausa. Svarbų vaidmenį čia vaidina palūkanų normų skirtumas šalyse. Valiutų kursas koreguojasi siekiant kompensuoti palūkanų normų skirtumą ar santykį, o tai rodo aiškų ryšį tarp valiutų kursų ir ekonomikos ciklų. Ekonomikos pakilimas lemia pinigų paklausos augimą ir palūkanų normų skirtumo didėjimą. Kapitalo srautai į palūkanų normos skirtumų pokyčius reaguoja nepakankamai elastingai, todėl valiutų kursai kinta, reaguodami į turto paklausos ir pasiūlos pokyčius.

Investuotojai finansų rinkose neišvengiamai susiduria su daugiakriteriškumu (angl. *multifaktorial*), gausybe įvairiai matuojamos ir neišmatuojamos informacijos, dideliu rinkai įtaką darančiu duomenų kiekiu. Dideli duomenų kiekiai (angl. *Big data*) – tai terminas, sugalvotas žiniasklaidos, vartojamas

struktūrinių ir nestruktūrinių duomenų eksponentiniam augimui ir prieinamumui aprašyti. Tai labai svarbi finansų savybė. Daugiau duomenų lemia tikslesnę analizę. Tikslesnė analizė – patikimesni sprendimai. O patikimesni sprendimai gali reikšti didesnę veiklos efektyvumą, sumažintas sąnaudas ir sumažintą riziką.

Ohlhorst (2012) suformavo didelio duomenų kiekio apibrėžimą kaip 4V: apimtis (angl. *volume*), greitis (angl. *velocity*), įvairovė (angl. *variety*), teisingumas (angl. *veracity*)

Daug veiksmų prisidėjo prie duomenų apimtys padidėjimo: didėjantys kompiuterių atminties resursai ir duomenų perdavimo greitis, nestruktūrinių duomenų transliacijos iš socialinės žiniasklaidos, mažėjančios duomenų saugojimo sąnaudos ir kita. Didėjanti duomenų apimtis sukuria naujas problemas – tinkamo pasirinkimo, greitos paieškos, duomenų patikimumo. Tampa sudėtinga pasirinkti metodus, kriterijus, susisteminti ir analizuoti duomenis siekiant sukurti vertę.

Milžiniškas duomenų perdavimo greitis leidžia gauti duomenis beveik realiu laiku, tai sudaro sąlygas reaguoti ir priimti sprendimus nedelsiant. Mažėja finansinių tarpininkų reikšmė.

Duomenys yra visokiausių formų: struktūriniai, skaitmeniniai – tradicinėse duomenų bazėse, nestruktūriniai – tekstiniai dokumentai, elektroninio pašto, video, audio ir k. t. įrašai. Sudėtingu uždaviniu tampa duomenų grupavimas, valdymas ir sprendimų priėmimas. Duomenų valdymą taip pat apsunkina jų nenutrūkstamas kintamumas. Gaunami duomenų srautai turi skirtingus periodus, sezoniškumą ar net paveikiami socialinės žiniasklaidos. Šiandienos duomenys ateina iš skirtingų šaltinių. Investuotojui tenka nelengva užduotis atrinkti ir susieti duomenis į vieną kompleksinę duomenų bazę, priskirti jiems hierarchijas ir patikimumo lygius.

Naudojant didelius duomenų kiekius padidėja klaidų ir paklaidų tikimybė, gaunant didelius kiekius informacijos iškyla jos patikimumo ir teisingumo problema, nes visko patikrinti neįmanoma. Dideli duomenų kiekiai lemia didesnę ekonometrinių metodų pasirinkimą (Einav, Levin 2013). Didelis duomenų kiekis, prognozuojant finansų rinkas neapibrėžtyje, priimant sprendimus realiu laiku, yra labai didelis pranašumas (Peat *et al.* 2013).

Kita svarbi ekonominių procesų savybė yra informacijos simetrija. Neoklasikinė ekonomika remiasi tobula informacija, kai sandorių dalyviai disponuoja vienoda, lengvai prieinama informacija. Informacijos asimetrija susijusi su sprendimų priėmimu sandoriuose, kai viena šalis turi daugiau arba geresnės informacijos nei kita. Šio disbalanso priežastimi gali būti neteisinga informacijos atranka, moralinės priežastys ir informacijos monopolis. Už rinkos infor-

macijos asimetrijos tyrimus 2001 Nobelio ekonomikos premija atiteko George Akerlof, Michaelas Spence ir Joseph E. Stiglitz. Straipsnyje (Akerlof 1970) iškeltos informacijos neapibrėžties ir asimetrijos problemos ir galimi tų problemų sprendimo būdai darbo rinkoje prieštarauja efektyviosios rinkos teorijai. Michaelas Spence nagrinėja informacijos srautų, signalų dinamiką (Spence 1973), (Spence, Michael 1974), informacinius rinkos struktūros aspektus (Spence 1976). J. E. Stiglitz moksliniuose darbuose (Stiglitz, Weiss 1981, Stiglitz 1984) nagrinėjami darbo rinkos asimetrijos aspektai, darbo užmokesčio efektyvumas.

Klasikiniais makroekonominiais modeliais sunku paaiškinti valiutų rinkos ypatumus. Pernelyg dideli dieniniai valiutų kursų svyravimai, milžiniškos dienos apyvartos leidžia daryti prielaidas, kad informacija yra platinama nevienalyčių veiksmų rinkoje. Jei visa informacija yra vieša, mažai tikėtina, kad spekuliantai valiutomis seka vienas kito veiksmus, tačiau, jei kažkuri rinkos dalyvių dalis yra labiau informuota, galimas taip vadinamas bandos elgesys, kai sprendimai priimami stebint kitus spekuliantus. Informacijos viešumo ir privatumo valiutų rinkoje tyrimai yra palyginti nauji. E. Onur (Onur 2008) atliko empirinį tyrimą ir palygino labiau informuotų ir mažiau informuotų prekyautojų valiutų rinkoje rezultatus. Autoriai (Pontines, Rajan 2011) nagrinėjo intervenciją į Azijos valiutų rinką. Asimetrijos buvimą taip pat patvirtina ir P.Wang darbe (Wang 2014) bei siūlo metodus, kaip tai panaudoti sudarant valiutų portfelį ir atsižvelgiant į finansinę riziką. Autoriai (Gau, Wu 2014) nagrinėjo prekybininkų orderių pasirinkimą valiutų rinkoje ir nustatė, kad labiau informuoti prekybininkai, išnaudodami informacijos privalumus prekiauja agresyviau. Privačios informacijos šaltiniu gali tapti piniginiai srautai, kuriuos stebi bankai, ar ryšys su šaltiniais vyriausybjėje.

Prigimtiniai finansų rinkų ypatumai lemia procesus, vykstančius globalioje rinkoje, kurie daro įtaką visų rinkos dalyvių elgsenai.

### 1.1.2. Finansų rinkos procesų analizė

Viena svarbiausių ekonomikos funkcijų – racionalus išteklių, produktų, finansų paskirstymas. Finansų rinkos – viena svarbiausių kiekvienos valstybės finansų sistemos dalių, kuri perskirsto laikinai laisvas lėšas tarp valstybės ūkio subjektų, kartu įtraukdamos į investavimo procesą individualius asmenis, kurie nėra verslo žmonės. Tai visa eilė institucijų, mechanizmų ir susitarimų, per kuriuos veikia lėšų pasiūlos bei paklausos jėgos. Tai tokie sambūriai, kanalai, kuriais pasinaudodami lėšų tiekėjai ir lėšų ieškotojai atlieka finansines operacijas. Vertybinius popierius išleidžia ir platina rinkoje emitentai (angl. *issuers*), t. y.

įmonės ir finansinės institucijos, kurioms reikalingos lėšos nuosavam kapitalui suformuoti, arba kurios nori skolintis. Perka tos įmonės ar asmenys, kurios turi lėšų, t. y. investuoja. Tokiu būdu laisvos lėšos veiksmingai paskirstomos pinigų naudotojams. Finansų rinkos prekė yra arba kreditas, arba nuosavybė. Šios rinkos dalyviai yra pasipelninti siekiantys lėšų tiekėjai ir vartotojai. Tai gali būti spekuliantai arba arbitrai. Spekuliantai siekia pasipelninti iš ateities rinkų prognozių. Jie atlieka svarbią funkciją, išlygindami vertybinių popierių kainas. Arbitrai perkelia lėšas iš vienos rinkos į kitą, jei jų kainos skirtingose rinkose yra nevienodos. Jie padeda palaikyti artimas kainas skirtingose rinkose. Gerai išvystytos, sklandžiai veikiančios finansų rinkos gali atlikti svarbų vaidmenį prisidedant prie ekonomikos sveikatos ir efektyvumo. Finansų ir ekonomikos augimo ryšį pirmą kartą apibrėžė Joseph Schumpeter 1911 metais (Schumpeter 1934). Schumpeterio teorija teigia, kad „kūrybinės destruktijos“, inovacijos ir verslumas yra varomosios ekonominio augimo jėgos. Jis domėjosi finansais kaip esmine šio proceso dalimi. Inovacijos ir verslumas klesti, kai ekonomika gali sėkmingai taupyti, efektyviau paskirstyti išteklius, sumažinti informacijos asimetrijos problemas ir gerinti rizikos valdymą, visa tai garantuoja išsivysčiusių finansų sektorių paslaugos.

Yra stiprus teigiamas ryšys tarp finansų rinkos raidos ir ekonomikos augimo. Beck *et al.* 2004b teigia, kad „Nors tyrimai rodo, kad finansų sektoriaus vystymasis pagreitina bendrą ekonomikos augimą, ekonomistai negali išspręsti prieštarų teorinių prognozių ir vykstančių politinių ginčų dėl poveikio pasiskirstymo įmonėms. Naudojant įvairių pramonės šakų, skirtingų šalių duomenis, gauti rezultatai yra suderinami su nuomone, kad finansų srities vystymasis daro neproporcingai teigiamą poveikį mažoms įmonėms“. Šie rezultatai leidžia reformuoti finansų sistemą ir tikėtis teigiamo poveikio šalies ekonomikos augimui. Finansų rinkos padeda efektyviau nukreipti santaupas ir investicijas į ekonomiką taip, kad augintų kapitalo kaupimą ir prekių bei paslaugų gamybą. Gerai išsivysčiusių finansų rinkų ir įstaigų darba, taip pat aibė įvairių finansinių produktų ir priemonių, tenkina skolininkų ir skolintojų poreikius, o kartu tarnauja ir visai ekonomikai.

Nors finansų sektoriaus įtaka ekonominiam augimui buvo plačiai aprašyta ir įrodyta empiriniais tyrimais, ypatingai 1960–1990 metais, šių dienų tyrimai rodo, kad šis ryšys nėra toks stiprus arba nepamatuotas bandymas skatinti augimą turi pašalinių poveikių. Pastebėtas ryšys tarp finansinių krizių dažnio ir bandymų daryti įtaką intensyvumo ekonominei augimą (Rousseau, Wachtel 2011). Autoriai, siekdami nustatyti, kodėl finansinėmis priemonėmis nepavyksta užtikrinti ekonominio augimo, įvardija keletą priežasčių. Pernelyg greitas kreditų augimas galėjo lemti infliacijos augimą ir bankų sistemos prob-

lemas, o tai savo ruožtu lėmė finansines krizes šalyse. Be to, finansų rinkų liberalizavimas ir teisinio reguliavimo trūkumas taip pat galėjo būti ekonomikos lėtėjimo priežastimi. Tarp akcijų rinkos ir ekonominio augimo susidaro nepaneigiamas ryšys. „Empiriniai duomenys rodo, kad akcijų rinkų plėtra Kinijoje, JAV, Jungtinėje Karalystėje, Japonijoje ir Honkonge turi savarankiškai stiprią teigiamą koreliaciją su šių šalių ekonominiu augimu. Rezultatas iškelia svarbų teoriją patvirtinanti teiginį, kad akcijų rinkos vystymasis yra vienas iš pagrindinių ekonomikos augimą lemiančių veiksnių išsivysčiusiose ir besivystančiose šalyse, nepriklausomai nuo jų ekonominio išsivystymo ir ekonominės sistemos“ (Wong, Zhou 2014). Autoriai (Law, Singh 2014) pateikė naujų įrodymų apie finansų sistemos ir ekonominio augimo ryšį. Ištyrę 87 išsivysčiusias ir besivystančias šalis jie gavo tokius rezultatus: finansų ir ekonominio augimo santykiyje yra tam tikras slenkstis. Žemiau šio finansų išsivystymo slenkščio finansų plėtra darys teigiamą poveikį ekonomikos augimui. Finansavimo poveikis ekonomikos augimui bus neigiamas, jei finansinis vystymasis viršys slenkstį. Didesnis finansavimas ne visada yra geriau, todėl čia svarbus optimizavimas.

Kita globalios ekonomikos problema, kurią gali padėti išspręsti finansų rinkos tobulinimas, yra didėjanti nelygybė ir didėjantis dalies pasaulio gyventojų skurdas. Autoriai (Beck *et al.* 2004a) teigia, kad „Nors daugeliu mokslinių tyrimų nustatyta, kad finansų srities vystymasis skatina bendrą ekonominį augimą, mes nustatėme, kad finansinis vystymasis neproporcingai padidina neturtingųjų pajamas ir mažina skurdą. Naudodami daugelio šalių pavyzdžius, mes išskyrėme konkuruojančias teorines prognozes apie finansinio sektoriaus plėtros poveikį pajamų pasiskirstymo pokyčiui ir skurdo mažinimui. Manome, kad finansų sektoriaus vystymasis mažina pajamų nelygybę neproporcingai padidindamas neturtingųjų pajamas. Šalys, kuriose geriau išvystytos finansinių tarpininkų priemonės, patiria greitesnę tiek skurdo tiek pajamų nelygybės sumažėjimą“. Finansinės plėtros poveikiu paveikti ekonominį augimą ir taip mažinti skurdą bei socialinę atskirtį galima suskaidžius į keletą komponentų. Pirma, nustatyti kanalus, per kuriuos finansinės priemonės (kreditai, pinigai ar kt.) pasiekia neturtingus žmones. Tai gali būti tiesioginiai finansų sektoriaus produktai, suteikiantys galimybę užtikrinti pajamų šaltinį, ar galimybę gauti išsilavinimą ir taip užtikrinti savo šeimos gerovę, ar netiesioginiai – skatinantys bendrą šalies ekonomikos augimą ir tuo pačiu kiekvieno žmogaus gerovę. Kita komponentė – tai finansinis nestabilumas. Finansinė plėtra susijusi su finansinėmis krizėmis, kurios labiausiai paliečia neturtingiausius gyventojus (Jeanneey, Kpodar 2011). Autoriai (Bae *et al.* 2012) tyrimais taip pat įrodė, kad „galimybė gauti finansavimą turi teigiamą poveikį mažinant pajamų nelygybę



ir skurdo lygį.“ Netolygus pasaulio valstybių vystymasis generuoja globalias ateities kartų problemas. Finansų rinkos vaidina svarbų vaidmenį generuojant kapitalą ir prekių bei paslaugų gamybą. Kredito ir investicijų gražos kaina teikia signalus finansų rinkos dalyviams. Šie signalai padeda nukreipti indėlininkų, namų ūkių ir įmonių lėšas privatiems ir viešojo sektoriaus vartotojams. Investuotojai, kurie norėtų skolintis, susiejami su tais, kurie vertina lėšas labiausiai, t. y. pasirenkę mokėti didesnę kainą ar palūkanų normą. Panašiu būdu tvirtos finansų rinkos ir institucijos pagyvina tarptautinius pinigų srautus tarp šalių.

Be to, veiksmingos finansų rinkos ir institucijos yra linkusios sumažinti paieškos ir sandorių išlaidas. Teikiant daug įvairių finansinių produktų su skirtingomis rizikos ir kainodaros struktūromis, gerai išvystyta finansų sistema siūlo produktus dalyviams, kurie tenkina konkurencingus skolininkų ir skolintojų poreikius. Asmenys, įmonės ar vyriausybės, kuriems reikia lėšų, gali lengvai nustatyti, kokios finansinės institucijos arba kurios finansų rinkos gali suteikti finansavimą ir kokia kaina bus skolinama. Tai leidžia investuotojams palyginti tikėtiną kapitalo gražą ir investicijų sąnaudas, todėl įgalina investicijų pasirinkimą, kuris geriausiai atitinka jų poreikius. Tokiu būdu finansų rinkos reguliuoja kreditų pasiskirstymą visoje ekonomikoje ir palengvina prekių bei paslaugų gamybą.

Finansiniu požiūriu Europos Sąjungos susikūrimo sprendimas yra unikalus – sujungta daug mažų finansų rinkų ir institucijų į vieną bendrą finansų rinką ir įvesta bendra valiuta – euras. Euro naudojimas palengvina investavimo, taupymo, skolinimo ir skolinimosi galimybes ne tik eurozonos šalims, bet ir kitoms pasaulio šalims. Visos eurozonos šalys kartu tampa patrauklesnės investuotojams dėl sumažėjusios atskiros mažos šalies valiutų rinkos rizikos ir didesnio finansinių produktų pasirinkimo bei likvidumo. Euro „tėvu“ vadinamas Robertas Mundell dar 1961 metais pasauliui pasiūlė Optimalių valiutos zonų teoriją, už kurią autoriui 1999 metais buvo paskirta Nobelio ekonomikos premija (Mundell 1961), (Mundell 1973). Susikūrus Europos Sąjungai Pasaulio valiutų rinkoje susidarė valiutų tripolis: doleris, euras ir jena. Nauja situacija kelia kai kuriuos senus klausimus: kokia valiutų konfiguracija yra optimali pasaulio ekonomikai? Kiek ir kokių valiutų pasauliui reikia? Kurioms šalims reikalingos naujosios valiutos, o kurioms geriau likti prie istoriškai įprastosios? Koks yra optimalus valiutos zonos dydis? (Mundell 2000). Ar įmanomas Azijos valiutų zonos susikūrimas ir kokią tai darytų įtaką Azijos šalių ir Pasaulio ekonomikai (Mundell 2003b), (Mundell 2003a)? Taip pat nagrinėjama ir pasaulio valiutos zonos sukūrimo galimybė (Mundell 2012).



Atsižvelgiant į cikliškai pasikartojančias ekonomines krizes, natūralu abejoti, ar finansų rinkos yra pakankamai gerai išvystytos, ar jos nesukelia daugiau problemų nei naudos? Tyrėjai, kurie teigia, kad visos finansų rinkos turi teigiamą poveikį ekonomikos augimui, visada tvirtina, kad tai pastebima ilgalaikėje perspektyvoje. Kai finansų rinkose pastebimos problemos, vyriausybės bando išsikišti ir „patobulinti“ kapitalo paskirstymą tarp įmonių. Tačiau nėra garantijos kad valdžia, net su geriausiais ketinimais, gali geriau nustatyti, kas nusipelno daugiau kapitalo nei kiti rinkos dalyviai. Ekonomikos istorija rodo, kad šansai yra ne vyriausybių naudai. Be to, sunku pasitikėti politikais, kurie sudaro palankias sąlygas tam tikroms grupėms. Įmonė gal ir nusipelno vyriausybės nukreipto kredito iš pradžių, bet laikui bėgant gali imti dirbti arba naudoti savo kapitalą neefektyviai. Kraštutinumai ir piktnaudžiavimas finansų rinkose gali pakenkti ekonomikos augimui ilgalaikėje perspektyvoje.

Taip pat kyla klausimas, jei finansų rinkų geriau nereguluoti, tai kodėl kai kurių šalių finansų rinkos yra efektyvesnės nei kitų? Naujausi tyrimai šia tema randa atsakymus šalių institucijų veikloje, ypač jų teisinėje sistemoje ir įstatymuose. Lyginant tradicinę anglų bendrąją teisę, vokiečių, prancūzų ir skandinavų civilines teises, nustatyta, kad stipriausių investuotojų apsaugą garantuoja tradicinė anglų bendroji teisė, silpniausia – prancūzų, o per vidurį vokiečių ir skandinavų teisės aktai. Šis investuotojų apsaugos stiprumas paaiškina skirtingus šių šalių ekonomikos augimo tempus. Be įstatymų leidybos, sritis, kur žmogaus kūrybingumas gali daryti teigiamą įtaką, finansų rinkoms yra inovatyvių produktų ir paslaugų kūrimas. Kai kurie naudingi finansų rinkos produktai ir paslaugos, pavyzdžiui, draudimo polisai, gali nedaryti įtakos ekonomikos augimui, nes jie skirti stiprinti ekonominę gerovę, geriau paskirstyti riziką, o ne tiesiogiai skatinti ekonomiką.

Siekis investuojant gauti ne tik finansinę grąžą, bet ir socialinės gerovės vadinamas socialiai atsakingu investavimu (SRI angl. *socially responsible investment*). SRI arba tvarus investavimas apima neigiamą atranką (angl. *negative screening*), t. y. neįtraukimą tam tikrų vertybinių popierių, kurie neatitinka pagrindų socialinių ar gamtosauginių kriterijų arba atsisakymą tam tikrų etinių ar nefinansinių prieštaravimų turinčių vertybinių popierių. Taip pat SRI pasireiškia per akcininkų aktyvumą nukreipti įmonių valdymą, siekiant per tam tikrą laiką pagerinti finansinius rezultatus ir akcininkams, klientams, darbuotojams, tiekėjams ir bendruomenėms didinti gerovę.

Pozityvus investavimas yra naujos kartos socialiai atsakingas investavimas, kuris leidžia investuotojams teigiamai išreikšti savo vertybes, net jei tenka aukoti investicinio portfelio diversifikavimą ar trumpalaikį efektyvumą. Tačiau ilgalaikėje perspektyvoje ši idėja sėkmingai konkuruoja (Ghoul *et al.* (2011)).

Edmans (2011) savo tyrimais bando atsakyti į klausimą, ar akcijų rinka atspindi nematerialųjį turtą? Gauti tyrimo rezultatai patvirtina tris pagrindinius poveikius. Pirma, patvirtinant į žmogiškąjį kapitalą orientuotą teoriją, gauta, kad įmonės darbuotojų pasitenkinimas teigiamai koreliuoja su akcininkų pelnu. Antra, akcijų rinka atspindi ne tik materialųjį kapitalą. Trečia, tam tikras socialiai atsakingas investavimas gali padidinti investicinę grąžą.

### 1.1.3. Finansų rinkų valdymo ir reguliavimo aspektai

Egzistuoja du pagrindiniai požiūriai į finansų rinkų reguliavimą: pirmasis – leisti finansų rinkoms laisvai veikti, antrasis – monetarinė politika yra vienas pagrindinių makroekonominės politikos įrankių. Laisvosios finansų rinkos šalininkai teigia, kad bet koks finansų rinkos reglamentavimas paprastai iškreipia rinką, be to, finansų rinkos sugeba apeiti reguliavimus. Jei pasaulis yra nenuspėjamas – turime išmokti tikėtis netikėtumo. Galimas tik stochastinis finansų rinkos modeliavimas ir prognozavimas.

Finansų rinkos reguliavimas yra finansinio reguliavimo ir priežiūros forma, kai tam tikros vyriausybės ar nevyriausybės institucijos kelia tam tikrus reikalavimus, apribojimus ar gaires finansinėms institucijoms, siekiant užtikrinti finansų sistemos vientisumą. Paprastai už finansų rinkos reguliavimą ir reglamentavimą yra atsakingos valstybinės institucijos. Finansinio reguliavimo šalininkai, atsižvelgdami į finansų rinkos informacijos asimetriją, išskiria keletą labai svarbių finansinio reguliavimo tikslų:

- rinkos patikimumo užtikrinimas. Tinkamas reguliavimas gali padėti išvengti finansinių krizių ir išsaugoti pasitikėjimą finansų sistema;
- finansinis stabilumas. Vienas iš unikalių aspektų yra tai, kad finansinės institucijos skolina viena kitai ir vieno banko žlugimas gali sukelti visos sistemos griūtį. Reguliavimas gali apsaugoti nuo griūties ir sustiprinti finansų sistemą;
- vartotojų apsauga. Asimetrija tarp sudėtingų finansinių produktų, parduotųjų ir pirkėjų paprastai subalansuojama taikant taisykles, reglamentuojančias, kaip produktus galima parduoti, kas juos gali parduoti, o kartais ir ką galima parduoti.
- finansinių nusikaltimų prevencija. Finansų reguliavimas turi sumažinti finansinius nusikaltimus tiek, kiek tai įmanoma.

Kita įtakos finansų rinkoms forma yra intervencija. Autoriai (Sarno, Taylor 2001) nagrinėja oficialiosios intervencijos į valiutų rinką mechanizmą, kai įtakingos institucijos ar asmenys perka arba parduoda didelius užsienio valiutų kiekius, paprastai santykyje su sava valiuta, siekiant padaryti įtaką valiutų

kursui. Intervencija portfelio balanso kanalu – kai staiga parduodamas ar perkamas tam tikros šalies finansinis turtas siekiant pakelti savos šalies finansinio turto vertę. Intervencija signaliniu ar lūkesčių kanalu – kai per agentus paskleidžiama informacija apie tam tikros šalies politikos pokyčius, siekiant geresnio savos valiutos santykio su tos šalies valiuta. Kadangi valiutų kursų svyravimai pralengia ekonominius svyravimus, bet kokie signalai apie šalies ekonomiką ateityje tiesiogiai paveikia dabartinį valiutų kursą. Koordinuota intervencija į užsienio šalies valiutų rinką – kai intervencijos veiksmus atlieka keli centriniai bankai vienu metu. Taip pat minėtieji autoriai tyrimais patvirtino intervencijos į valiutų rinką, spekuliatyvių atakų įtaką valiutų krizei.

Finansų rinkų reguliavimu, reglamentavimu ir intervencija gali užsiimti tik labai įtakingi rinkos dalyviai. Paprastesni būdai dalyvauti finansų rinkos procesuose yra investavimas ir spekuliacijos.

Investavimas yra profesionalus įvairaus turto valdymas – vertybinių popierių (akcijų, obligacijų ir išvestinių vertybinių popierių) ir kito turto (pvz., nekilnojamojo turto) – siekiant patenkinti konkrečius investuotojų investicinius tikslus. Jam būdingos trys charakteristikos – investavimas yra iš dalies ar visiškai negrįžtamas procesas, investavimo grąža yra neapibrėžta ir investavimas yra neapibrėžtas laike.

Investavimo sėkmę lemia 3 P – filosofija, procesas ir žmonės (angl. *Philosophy, process, people*).

Filosofija yra susijusi su pamatiniais įsitikinimais ir investavimo tikslais. Investuojama siekiant apsaugoti santaupas nuo infliacijos ar siekiant papildomų pajamų, o gal investuoti skatina nežinomybė dėl ateities. Vienos investicijos trunka ilgą laikotarpį, o kitos remiasi dieniniais ar valandiniais svyravimais. Damodaran (2012) knygoje išskiriamos dvi pagrindinės investavimo filosofijos: rinkos pokyčių laike (angl. *market timing philosophy*), kuri orientuota į tam tikrus istorinius duomenis ir tikėtinus rinkos pokyčius laike, ir saugumo pasirinkimo filosofija (angl. *security selection*), kuri orientuota į grąžos ir rizikos subalansavimą.

Procesas susijęs su tuo, kaip apskritai filosofija įgyvendinama. Investuotojai naudoja tam tikras strategijas, remiasi technine ar fundamentaliąja analize, labiau pasitiki skaičiais, algoritmais ar gauda naujausias žinias informaciniame lauke, naudoja vieną, gerai atidirbtą metodiką ar susikuria kelių strategijų taisyklių rinkinį.

Investuotojai, pavieniai asmenys ar kolektyvai susidūrę su neapibrėžtimi, elgiasi skirtingai. Vieni labiau linkę pasiduoti „bandos“ elgesiui, kiti daugiau pasikliauja savimi, vieni labiau linkę rizikuoti, kiti stengiasi apsidrausti, vieni agresyviai siekia pelno, o kiti laikosi nuoseklesnės, atsargesnės pozicijos.

Saeedi, Chahardeh (2013) pastebėjo, kad kai neapibrėžties lygis aukštas, investuotojai labiau pasitiki konfidencialia informacija, kai vidutinis – labiau atsižvelgia į viešąją nuomonę ir seka kitus investuotojus. O kai neapibrėžties lygis žemas, investuotojai remiasi beveik vien viešąja informacija.

Jei investuotojai turi tikslios reikiamos informacijos, jie daro kompetetingus sprendimus. Efektyvioji rinkos teorija remiasi prielaida, kad finansų rinkos ir investuotojai elgiasi racionaliai, t. y. visada savo sprendimais siekia maksimalios gražos ir minimalios rizikos. Tačiau tiksli reikiama informacija yra siekiamybė, bet ne realybė. Laimi tie investuotojai, kurie labiau informuoti, kurie gauna informacijos anksčiau arba anksčiau ją įsisavina, kurių informacija yra pilnesnė, tikslesnė ir patikimesnė. Laimi tie, kurie geriau orientuojasi neapibrėžtyje, priima ateitį kaip galimybių aibę, įvertindami ne tik finansų rinkas bet ir asmenines savybes.

Informacijos sklaidos greitį šiuo metu lemia internetinės prieigos sparta, galimybė gauti istorinius duomenis ir prekiauti realiu laiku. koncepcija, kad viena galva gerai, o dvi dar geriau, investuotojų bendruomenei reiškia dalijimąsi informacija. Klubai, forumai, internetinės svetainės, prekybos platformos su gausybe investuotojui skirtų funkcijų išplėtė šią bendruomenę ir palengvino greitą keitimąsi informacija tarp daugelio žmonių.

Dideli istorinių duomenų kiekiai, daugialypės informacijos gausa, teisingo pasirinkimo ir patikimumo poreikis, technologinis progresas suformavo prielaidas sprendimų paramos sistemų investuotojui atsiradimui. Sąveika tarp mokslinių tyrimų, žinių ekonomikos, technologijų vystymosi ir investuotojų praktiškų yra neabejotinai sudėtingas reiškinys, kuris reikalauja tvirtų mokslinių žinių ir veiksmingų technologinių sprendimų. Straipsnyje (Melnikas, Samulevičius 2010) suformuoti pagrindiniai, šios sąveikos sėkmingo vystymosi principai:

- orientacija į sinergijos efekto gavimą;
- siekis gauti naują kokybę;
- harmonijos ir darnos principas;
- bendrų interesų pirmumo principas;
- inovacijų principas;
- sistemingumo ir integralumo principas.

Šie principai svarbūs ir kuriant paramos sistemas investuotojui. Čia susipina skirtingų mokslo šakų (ekonomikos, matematikos, psichologijos, biologijos), naujausių technologinių atradimų (internetinių atsiskaitymų, dirbtinio intelekto) ir investuotojų patirtis su tikslu gauti efektyvų, kokybiškai naują, socialiai harmoningą, inovatyvų įrankį. Sukurta paramos sistema turi lengvai integruotis į jau esamas prekybos platformas ir būti konkurencinga kitoms paramos sistemoms. Ir atvirkščiai, rinkos duomenys realiu laiku turi integruotis į

paramos sistemas, kad mokyty priimti sprendimus ir modeliuoty dirbtines rinkas. Paramos sistemos investuotojui valiuty rinkoje kurimui pasirinktas dirbtinis intelektas (angl. *artificial intelligence*) kaip viena pazangiausių, sparčiai populiarujančiu technologiju pasaulyje. Šiame darbe naudosime terminą dirbtinio intelekto algoritmai, kuris reiskia ne pavienį neuroninį tinklą, genetinį algoritmą ar kitą modulį, o tam tikrą įvairių skirtingų algoritmų junginį ar ansamblį.

## 1.2. Finansų rinkų prognozavimas dirbtinio intelekto algoritmais

Visi metodai, kurie remiasi istoriniais duomenimis ir jų statistine analize, negali tiksliai apskaičiuoti finansų rinkos verčių ateityje. Nėra nė vieno dėsnio, formulės ar teoremos, kurie užtikrintų tikslų akcijų, valiutų ar kapitalo rinkos įrankių apskaičiavimą. Nepaisant to, žmonių, sėkmingai prekiaujančių biržose ilga laiką, yra nemažai. Naudojami euristiniai rinkos prognozavimo įrankiai leidžia sukurti įvairias paramos investuotojui sistemas. Todėl nenuostabu, kad vos atsiradus dirbtinio intelekto sistemoms, jos imtos taikyti finansų rinkų įrankių prognozavimui. Terminas „dirbtinis intelektas“ yra labai neapibrėžtas. Jis apima visas mokslo studijas, skirtas imituoti intelektualų elgesį. Dirbtinis intelektas skiriasi nuo įprastų kompiuterinių algoritmų, nes geba mokytis – ne tik atsiminti ir pakartoti, bet ir elgtis kitaip, priklausomai nuo prieš tai atliktų veiksmų – apibendrinti, klasifikuoti, grupuoti, prognozuoti. Psichologijos terminais tai vadinama produktyviu mąstymu, o pakartojimas to, kas išmokta, vadinamas reproduktyviu mąstymu (Rimkutė 2007).

Dirbtinio intelekto tyrimai remiasi psichologijos ir neurologijos, matematikos ir logikos, komunikacijos teorijos, fizikos, filosofijos ir lingvistikos mokslų duomenimis. Dirbtinio intelekto tyrimuose dažnai kuriami supaprastinti teoriniai modeliai gyvų organizmų nervų sistemos pagrindu. Jie vadinami dirbtiniais neuroniniais tinklais (angl. *Neural Networks*).

Neuroniniai tinklai dažniausiai naudojami ten, kur sunku nustatyti tikslias taisykles. Kartais lengviau aprašyti problemą ir jos sprendimo būdus, pateikiant pavyzdžius. Jei duomenų pakanka, neuroniniai tinklai gali apsimokyti problemos sprendimui. Finansų rinkos kaip tik atitinka tokius reikalavimus – istorinių duomenų yra daug ir jie lengvai gaunami, bet investuotoją domina tik ateities prognozės. Teigiama, kad dažniausiai neuroniniai tinklai taikomi gamybos (53,5 %) ir finansų (25,4 %) srityse. Išskiriamos keturios pagrindi-

nės prognozavimo dirbtinio intelekto pagrindu sukurtų sistemų grupės: neuroniniai tinklai, genetiniai algoritmai, neraiškioji logika ir ekspertinės (agentų) sistemos. Be to sukurta daug kombinuotų, hibridinių prognozavimo sistemų.

### 1.2.1. Moduliniai neuroniniai tinklai

Moduliškumas yra labai svarbi sąvoka gamtoje, jis apibrėžiamas kaip sudėtingesnių objektų padalinimas į paprastesnius. Moduliškumas sutinkamas visur – tiek gyvuose tiek negyvuose objektuose. Žemiausiame lygyje esantys elektronai, pozitronai, neuronai sudaro atomus, kurie yra paprastesnis medžiagos modulis, iš kurio viskas sudaryta. Gyvuose organizmuose proteinais, aukštesniame lygyje ląstelės, gali būti nagrinėjami kaip komponentai. Ši modulių idėja gali būti tęsiama toliau į vis sudėtingesnes struktūras. Netgi žiūrint į visatą, galima matyti modulius, panašius į Saulės sistemą. Žmogaus daugiafunkcinės galimybės ir negalimybės taip pat paaiškinamos smegenų moduline ir lygiagrečiąja struktūra. Tai nagrinėja biologai, psichologai, neurologai. Schmidt (1996) teigia, kad moduliniai neuroniniai tinklai yra dviejų tipų:

- sudėtingesnis neuroninis tinklas sukonstruojamas sujungiant paprastesnius neuroninius tinklus kaip blokus;
- moduliai išskiriami sudėtingesnio neuroninio tinklo viduje ir jie vietoje pilnai sujungiami.

Kimoto *et al.* (1990) pasiūlė keletą mokymo algoritmų ir prognozavimo metodų TOPIX (angl. *Tokyo Stock Exchange Prices Indexes*) prognozavimo sistemai. Šių metodų tikslas – prognozuoti geriausią laiką pirkti ir parduoti akcijų paketą vieno mėnesio laikotarpyje. Prognozavimo modelis sukurtas modulių NN pagrindu, kuriame yra trys sluoksniai: įvesčių, paslėptasis ir išvesčių. Įvestis sudaro keletas ekonominių ir techninių indeksų: palūkanų norma, NYDJA (angl. *NEW YORK Don Jouns average*) indekso vidurkis, valiutų kursai, apyvarta, ir kt. Mokymui naudoti TOPIX indekso vidurkių tam tikrą savaitę istoriniai duomenys. Visi įvesčių duomenys normuojami [0; 1] intervale. Pirmame žingsnyje autoriai naudojo 5000 iteracijų, antrame 1000 iteracijų. Išvestyje naudojo sigmoidinę funkciją. Naudodami savo sukurtą sistemą, autoriai pasiekė 0.527 koreliacijos koeficientą TOPIX indekso prognozavime.

Patel, Marwala (2006) naudoja daugiasluoksno parceptono ir radialinės bazinės funkcijos neuroninių tinklų architektūrą DJIA ir Nikkey 225, NASDAQ, Johanesburgo akcijų rinkos indeksų uždarymo kainos prognozavimui. Pateikta ilgalaikė „pirkti ir laukti“ (angl. "*Buy and hold*") prekybos strategija investuotojui. Geriausias ir blogiausias prognozavimo tikslumas buvo 72 % ir 64 % DJIA ir Nikkey 225 indeksams atitinkamai.

Kulkarni (1996) pasiūlė rekurentinių neuroninių tinklų (angl. *Recurrent neural networks*) modelį akcijų kainų modelio atpažinimui ir sukūrė naują metodą įvertinti techninėje analizėje naudojamą klasikinių figūrų atpažinimui. Bandymų metu trikampiai buvo tinkamai atpažįstami. Šis metodas tinkamas eliminuoti iš dalies netinkamus modelius.

Tiesiniai ir netiesiniai informacijos perdavimo būdai taip pat sutinkami mus supančioje aplinkoje – ši savybė, panaudota neuroninių tinklų ARIMA (angl. *Autoregressive integrated Moving Average*) pagrindu kūrimui. Wang, Leu (1996) sukūrė Taivano akcijų rinkos prognozavimo sistemą ARIMA neuroninių tinklų pagrindu. Jie panaudojo rekurentinį neuroninį tinklą ir pasiūlė modifikuotą grįžtamojo ryšio mokymo algoritmą, tiesinį ir nestacionarų modelį. Autokoreliacijos funkcija (ACF) naudojama nustatyti, ar serija stacionari, ar nestacionari. ARIMA pagrindu sukurtas modelis su 7 paslėptais sluoksniais, naudodamas 4 metų savaitinius duomenis, jų antrąją išvestinę įvestyse, pajėgus su pakankamu tikslumu prognozuoti 6 savaitių rinkos prekybą į ateitį.

Amnesic neuroniniai tinklai imituoja žmogaus pažintinio elgesio savybę pamiršti. Tradicinių neuroninių tinklų taikyme dažnai remiamasi prielaida, kad dalyvių elgesys nekinta duomenų naudojimo laikotarpiu. Tačiau realiaame pasaulyje subjekto elgesys gali net labai pasikeisti. Qiang *et al.* (2005) pasiūlė sudaryti neuroninių tinklų mokymo duomenų rinkinius, atspindinčius skirtingus elgesio modelius skirtingu laiku. Sukurtas patobulintas Amnesic neuroninis tinklas, imituojantis užmiršimą duomenų atrankos etape. Šis modelis buvo sėkmingai taikytas Kinijos akcijų rinkos akcijų prognozavimo eksperimente.

Yamashita *et al.* (2005) straipsnyje buvo tirtas TOPIX (Tokijo vertybinių popierių biržos kainų indeksai) prognozavimas naudojant daugiasektorinį neuroninį tinklą (MBNN angl. *MULTI-branch NN*). Naudojant TOPIX istorinius duomenis ir kitą informaciją, MBNN gali sėkmingai išmokti indekso verčių kitimo savybes ir numatyti kitos dienos TOPIX kainą ir, palyginus su paprastu neuroniniu tinklu, gali turėti gana aukštą prognozavimo tikslumą.

Funkcinio ryšio neuroniniai tinklai (FLANN) yra vieno sluoksnio vieno neurono neuroninis tinklas, kuriame kiekviena įvestis pereina funkcinių išplėtimą per bazinių funkcijų tinklą. Funkcinis išplėtimas generuoja tiesiškai priklausomų funkcijų tinklą. Majhii *et al.* (2009) straipsnio autorių pasiūlytą modelį trigonometrinių FLANN pagrindu naudojanti LSM (standartinis minimalus kvadratinis nuokrypis (angl. *Standard least mean square*) algoritmą tinklo mokymo taisyklės parinkimui. Bandymai akcijų rinkos prognozavime parodė geras modelio prognozavimo galimybes.

Elgsenos ekonomika teigia, kad emocijos gali stipriai paveikti individo elgesį ir investuotojos sprendimo pasirinkimą. Bollen *et al.* (2011) ištyrė kolek-



tyvinės nuotaikos, išmatuotos socialiniame tinkle „Tweeter“, įtaką DJIA (angl. *Dow Jones Industrial Average*) kainų indekso kainoms. Nuotaika įvertinama šešiomis dimensijomis ir naudojama neuroninių tinklų įvestyse kartu su DJIA indekso istoriniais duomenimis. Gautas 86,7 % prognozavimo tikslumas ir nedidesnė nei 6 % MAPE (angl. *Mean Average Percentage Error*) paklaida.

Shen *et al.* (2011) darbe akcijų indeksų prognozavimui naudojami radialinės bazinės funkcijos neuroniniai tinklai (RBFNN angl. *radial basis function neural network*) ir dirbtinio žuvų spiečiaus optimizavimo algoritmas (AFSA angl. *artificial fish swarm algorithm*). Gautas labai paprastas naudoti ir pakankamai tikslus neuroninis tinklas. Hsieh *et al.* (2011) akcijų kainų prognozavimui naudojo rekurentinius neuroninius tinklus, sukurtus bičių kolonijos pavyzdžiu.

Guresen *et al.* (2011) palygino keleto skirtingų žinomų neuroninių tinklų gebėjimą prognozuoti akcijų indeksus. Autoriai naudojo daugiasluoksnį perceptroną (MLP angl. *multi-layer perceptron*), dinaminį dirbtinį neuroninį tinklą (DAN2 angl. *dynamic artificial neural network*) ir hibridinį neuroninį tinklą GARCH (angl. *the hybrid neural networks which use generalized autoregressive conditional heteroskedasticity*) NASDAQ indekso prognozavimui, įvertino ir palygino jų tikslumą.

AbuHamad *et al.* (2013) techninės ir fundamentaliosios analizės indikatorius modeliuoja dirbtiniais neuroniniais tinklais, sėkmingai prognozuoja trijų valiutų santykius su JAV doleriu. Giebel, Rainer (2013) padidindami neuroninių tinklų mokymosi efektyvumą ir sumažindami mokymuisi reikalingu duomenų kiekį iki 10 paskutinių dienų, pakankamai tiksliai prognozuoja tiek chaotinių akcijų kainų kitimą, tiek valiutų kursų svyravimus.

### 1.2.2. Genetiniai algoritmai

Genetiniai algoritmai (GA) – tai algoritmai, paremti biologijos žiniomis apie gyvybės evoliuciją. Genetiniai algoritmai yra algoritmų klasė, kuri imituoja gamtoje egzistuojančius evoliucijos mechanizmus: paveldėjimą, mutaciją, natūralią atranką ir rekombinaciją. Genetinių algoritmų naudojimas leidžia priartėti prie teisingo užduoties sprendimo tose srityse, kur tikslūs užduoties sprendimai yra nežinomi. „Individas“ genetiniuose algoritmuose atitinka sprendinį, „populiacija“ – sprendinių aibę, o „individo vertė“ – siejama su tikslo funkcijos reikšme duotajam sprendiniui. Genetiniams algoritmams būdingos šios savybės: 1. Dirbama su viena ar daugiau sprendinių „populiacijų“, kurios tarpusavyje gali būti labai įvairiai siejamos (arba visiškai nesusiję). 2. Atskiri sprendiniai yra atrenkami ar grupuojami pagal tam tikrą euristinę taisyklę, teikiant



pirmenybę tiems sprendiniams, kurie labiau atitinka norimas (atitinkančias keliamus uždavinius) tikslo funkcijos reikšmes ar kitus kriterijus. 3. Naudojamas tam tikras „mechanizmas“ naujiems sprendiniams ar jų savybėms gauti, atliekamas tam tikros sprendinių perturbacijos. Visa tai kartojama keletą kartų. 4. Sprendinių „populiacija“ atnaujinama pašalinant iš jos tam tikrus mažiau pageidaujamus sprendinius, mažiau atitinkančius tikslo funkcijos reikšmes, o kartais ir visus sprendinius pakeičiant naujais.

Genetiniai algoritmai, kaip vienas optimizavimo algoritmų, plačiai taikomi ekonomikos sričių uždaviniams spręsti. Kim, Han (2000) pasiūlė naują genetinių algoritmų ir dirbtinio neuroninio tinklo hibridą, kuris prognozuoja Korėjos akcijų kainų indekso (KOSPI) pokyčio kryptį. Jie įvestyse naudojo 12 istorinių duomenų rinkinių, kur istoriniai duomenys buvo keičiami 0, jei sekančios dienos indeksas yra mažesnis už praėjusios dienos indeksą, ir priskiriamas 1, jei sekančios dienos indeksas yra didesnis. Genetinių algoritmų taikymas padėjo eliminuoti didelę dalį neteisingų prognozių, gautas GAFD (angl. *Genetic Algorityms approach to feature discretization*) išsiskyrė geresniu akcijų indeksų prognozavimu, palyginus su kitais neuroniniais tinklais. Paprastą genetinį algoritmą, teisingų prognozių rodiklio pagrindu, pasiūlė Szeto, Fong (2000). Į modelį įvestas atsitiktinės naujienos efektas, imituojantis investuotojų elgesį, gavus žinių prieštaraujančių jų ankstesnėms prognozėms. Atsitiktines naujienas generuoja baltasis triukšmas, turintis lygias galimybes sukurti tiek gerą, tiek blogą naujieną.

Akcijų kaina nekinta izoliuotai, Choudhry, Garg (2008) pastebėjo, kad vienu akcijų kaina ženkliai koreliuoja su kitų akcijų kaina, todėl kai kurių akcijų kainas galima prognozuoti kitų akcijų kainų pagalba. Todėl pirmiausia randama  $m$  kompanijų, kurių akcijų kainų tarpusavio koreliacija yra geriausia. Finansų ekspertai, naudojantys techninę analizę akcijų rinkų prognozavimui, išskyrė 35 svarbius akcijų rinkos indikatorius. Taigi prognozavimui paruoštos,  $35 \times m$  galimos įvestys. Koreliacijos koncepcija, genetiniai algoritmai, kurių funkcija atrinkti pagrindines savybes iš  $35 \times m$  galimų ir SVM (angl. *Support Vectors Mashine*) sujungimas leido pasiekti 60–62 % tikslumą prognozuojant akcijų kainas.

Konkurencingą neuro–evoliucinį trumpalaikį akcijų indekso prognozavimo metodą pasiūlė Maridziuk, Jaruszewicz (2007). Duomenys yra renkami iš Vokietijos akcijų biržos (tikslinė rinka) ir kitų dviejų rinkų (Tokijo vertybinių popierių biržoje ir Niujorko vertybinių popierių biržoje) kartu su EUR / USD ir USD / JPY valiutų kursais. Neuroninius tinklus papildė genetinis algoritmas (GA), naudojamas kaip prognozavimo sistema, randanti optimalius įvesties kintamuosius vienos dienos prognozavimui. Nebenaudingi kintamieji

keičiami naujais, o labai vertingi kintamieji paliekami tolesniuose GA žingsniuose.

Bodas-Sagi *et al.* (2013) pasiūlė lygiagretizuoti genetinius algoritmus techninių rinkos indikatorių optimizavimui. Tai žymiai pagreitino skaičiavimus ir leido investuotojui turėti pakankamai laiko sprendimų priėmimui. Mohapatra, Das (2013) naudoja evoliucinius ir spiečių algoritmus akcijų rinkų prognozavimui. Gabrielsson *et al.* (2013) optimizuoja prekybą akcijų rinkoje naudodami genetinius algoritmus, suskurtus Hierarchinės laikinės atminties (HTM angl. *Hierarchical Temporal Memory*) pagrindu.

### 1.2.3. Neraiškioji logika

Neraiškioji logika turi analogijos su žmogaus pojūčiais. Ji praplėtė dvinarę logiką tarp „0“ ir „1“ įterpdama tarpinių loginių reikšmių intervalą, išplėtojo narystės funkcijas ir aibes. Panašiai žmogus suvokia spalvas: raudona, rausva, rožinė... ir daugybę kitų atspalvių, arba skonius, garsus ar paviršiaus grubumą. Neraiškioji logika nusako tam tikros reikšmės priklausymo skirtingoms kategorijoms laipsnį. Pavyzdžiui, abiturientas turi dvi galimybes: įstoti mokytis trokštamos specialybės arba neįstoti. Bet pats jis savo galimybes prognozuoja naudodamas platesnę galimybių skalę: „įstosiu“, „turėčiau įstoti“, „galbūt įstosiu“, „galbūt neįstosiu“, „ko gero neįstosiu“, „neįstosiu“. Jo savęs vertinimas remiasi turima informacija apie savo žinias, mokyklą, mokytojus ir t. t. Abituriento savęs vertinimas priskiriamas net kelioms skalės aibėms.

Neraiškiasias aibes 1965 m. pristatė Lofti Zadeh. Jis pasiūlė praplėsti klasikinę aibių teoriją, numatančią reikšmės priklausymą arba nepriklausymą aibei ir nenumatančią jokių tarpinių variantų. Anot L. Zadeh, reikšmė gali priklausyti kelioms aibėms, jeigu priklausymas aibei aprašomas vadinamosiomis narystės funkcijomis, leidžiančiomis reikšmei priklausyti kelioms aibėms vienu metu.

Raposo *et al.* (2005) pasiūlė pritaikyti neraiškiuosius neuroninius tinklus Brazilijos kompanijų akcijų kainų prognozavimui. Įvestyse buvo naudojami 9 įvairūs fundamentaliosios akcijų rinkos analizės indikatoriai, neraiškiojo neuroninio tinklo atrinkti iš 52, kuriuos pasiūlė ekonomikos analitikai. Naudojamas 9 paslėptųjų sluoksnių neuroninis tinklas, o išvestys trys: „pirkti“, „parduoti“, „laikyti“. Tiriant tik vieno sektoriaus akcijų rinką – tekstilės pramonės – buvo gauti pakankamai tikslūs rezultatai vieno mėnesio akcijų kitimo prognozavimui. Straipsnyje (Tome, Carvalho 2005) pasiūlytas rinkų prognozavimo modelis Neraiškiosios logikos neuroninių tinklų (angl. *Fuzzy boolean neural networks*) pagrindu, kurie pasižymi galimybėmis išmokti tam tikras taisykles ir

jas taikyti. Pasiektas geras akcijų rinkos pokyčio krypties prognozavimo rezultatas, prognozuojant sekančios dienos akcijų rinkos indeksų vertes.

Kaip ir kiekvienas investavimas, investavimas į akcijas yra rizikingas. Rizika yra dviejų tipų – sisteminė ir paklaidos. Paklaidos rizika gali būti sumažinta rizikos diversifikavimo strategijos dėka, o geras prognozavimo modelis gali sumažinti arba net visai panaikinti sisteminę riziką. Tokį tikslą sau iškėlė Chang, Fan (2008), naudodami KST tipo neraiškiają sistemą. Įvestims jie pasirinko 8 techninės analizės indeksus, keisdami neraiškiosios sistemos taisyklių skaičių nuo 2 iki 15, pastebėjo, kad geriausiai modelis prognozuoja, kai taisyklių skaičius yra 7. Modelis bandytas Taivano akcijų rinkos akcijoms – Taivano elektronikos akcijų indeksui, gautas 97,6 % tikslumas.

Kadangi investuotojui yra svarbesnis pelnas negu statistiniai rezultatai, Ang, Quek (2006) pasiūlė prekybos akcijomis modelį RSPOP (angl. *rough set based pseudo outlet product*), kuris prognozuoja akcijų kainos skirtumą. Neuro neraiškiosios sistemos pagrindu sukurtas modelis naudoja slankiojo vidurkio prekybos taisykles. Realioje rinkoje išbandytas modelis įrodė, jog naudojant modelį, gaunama tikslesnė prognozė, nei prekybos be modelio atveju.

Chang, Fan (2008) pasiūlė banginę TSK (Takagi-Sigeno-Kang) neraiškiosiomis taisyklėmis grįstą sistemą akcijų kainoms prognozuoti. Furje transformacija pritaikyta duomenims sudaryti Haar bazėje. Čia taip pat naudoti techninės analizės indikatoriai neraiškiosios sistemos taisyklėms sudaryti. Gauti rezultatai parodė, kad prognozės tikslumas siekia 99,1 %, prognozuojant Taivano akcijų rinkos indeksą.

Agrawal *et al.* (2010) straipsnyje pasiūlyta inovatyvi akcijų rinkos prognozavimo sistema ANFIS (angl. *Adaptive Neuro-Fuzzy inference System*), naudojanti įvestyse techninės analizės indikatorius: slankių vidurkį, divergenciją ir RSI (angl. *Relative Strength index*). Šie indikatoriai padėjo sukurti neraiškiosios logikos taisykles. Sistema buvo testuota įvairių ekonomikos sektorių akcijoms, t. y. automobilių, naftos, dujų ir kitoms. Sistemos apmokymui naudoti istoriniai duomenys: savaitės vidutinė, aukščiausia ir žemiausia kainos, 52 taškai. Išvestyse galimi du signalai – artimas 10 reiškia „buy“, artimas 0 reiškia „sell“, artima vidurkiui tarp šių reikšmių reiškia, kad užtikrintai veikti negalima, reikia palaukti. Testuota sistema parodė, kad neuro-neraiškioji sistema, tokia kaip ANFIS, gali su 76–96 % tikslumu prognozuoti investuotojo veiksmus rinkoje ir ženkliai sumažinti riziką.

Quek *et al.* (2011) straipsnis aprašo neuro-neraiškiosios asociatyvinės atminties (FAM angl. *fuzzy associative memory*) architektūros modelio pritaikymą akcijų rinkos prognozavimui ir prekybai akcijomis. Įvestyse naudojamas kainos procentinis osciliatorius (PPO angl. *price percentage oscillator*), išves-

tyse prekybai reikalinga akcijų rinkos pokyčio kryptis. Bhattacharyya *et al.* (2011) investicinio portfelio pasirinkimo problemą patikėjo neraiškiosios sklaidos ir genetinių algoritmų hibridui. Optimistinis, pesimistinis ir kombinuotas portfeliai demonstravo efektyvią prekybą rinkoje.

Chakravarty, Dash (2012) palygino šešių skirtingų neraiškiosios sklaidos ir neuroninių tinklų sistemų gebėjimą prognozuoti akcijų kainų indeksus, įvertino prognozių tikslumą. Bernardo *et al.* (2012) neraiškiają logiką derino su kintančių sprendimų taisyklių (EDR angl. *Evolving Decision Rule*) procedūra prognozuoti arbitražo galimybes finansų rinkoje.

Escobar *et al.* (2013) pritaikė neraiškiosios logikos principus techninei finansų rinkos analizei. Šis modelis naudoja ne tik techninės analizės matematinės išraiškas, bet ir leidžia atsižvelgti į rizikingumą, analizuoja sprendimo priėmimo argumentus. Jo rezultatas – „pirkti“ arba „parduoti“ akcijas.

Anghelache, Trifan (2013), naudodami neuro-neraiškiają logiką, prognozavo investuotojų elgesį Rumunijos kapitalo rinkoje, pritaikę efektyvios rinkos teoriją.

#### 1.2.4. Ekspertinės arba agentų sistemos

Agentų sistemos yra algoritmų klasė, kuri imituoja žmonių ir organizacijų tarpusavio santykius: bendravimą, bendradarbiavimą, individualumą, gebėjimą siekti tikslo, emocijas ir daugelį kitų. Agentų sistemos išsivystė iš ekspertinių sistemų, kai specialistų veiksmai buvo patikėti kompiuterinėms sistemoms. Ekspertinė sistema – tai žiniomis grindžiama sistema, kuri pateikia tam tikros srities problemų sprendimą, naudojant duomenų ir taisyklių rinkinį, sudarytą tos srities specialistų. Ekspertu gali būti tiek žmogus, tiek kompiuterinė sistema. Programinis agentas – tai kompiuterinė sistema, veikianti virtualioje aplinkoje ir gebanti atlikti savarankiškus veiksmus, kuriais pasiekiami nustatyti tikslai.

Kiekvienas agentas, daugiau ar mažiau gali turėti tokias savybes (Etzioni, Weld 1995, Franklin, Greasser 1996):

- Reaktyvumas (angl. *reactivity*): galimybė atrankos būdu jausti ir veikti.
- Autonomiškumas (angl. *autonomy*): iniciatyvus ir savarankiškas funkcionavimas.
- Bendradarbiavimas (angl. *collaborative behavior*): galimybė dirbti išvien su kitais agentais siekiant bendro tikslo.
- „Žinių lygio“ bendravimas (angl. „*Knowledge-level*“ *communication*):

galimybė bendrauti su asmenimis ir kitais agentais, kalba, kuri panaši į žmonių kalbą, o ne įprastiniais simbolinio lygio „programa-su-programa“ protokolais (Newell 1982).

- Dedukciniai gabumai (angl. *inferential capability*): pasinaudojus sukauptomis žiniomis apie bendruosius tikslus ir pageidaujamus metodus, agentas gali veikti su abstrakčiomis užduotimis. Agentas gali turėti tikslus savo, vartotojo, situacijos ir kitų agentų modelius.
- Laikinas tolydumas (angl. *temporal continuity*): tapatybės ir būsenos išlaikymas ilgais laiko tarpais.
- Individualybė (angl. *personality*): galimybė išreikšti charakterio bruožus, tokius kaip emocijos ir pan.
- Prisitaikomumas (angl. *adaptivity*): galimybė mokytis ir tobulėti su patirtimi.
- Mobilumas (angl. *mobility*): galimybė savarankiškai migruoti numatyta kryptimi iš vienos platformos į kitą.

Pakankamai sudėtinga kiekvieną kartą įvertinti konkretaus agento savybes bei jų kombinacijas, todėl mokslininkai pasiūlė daugybę agentų klasifikavimo būdų. Dirbtinio intelekto atstovai vertina agentus siaurąja (angl. *strong*) ir plačiąja (angl. *weak*) prasme. Siaurąja prasme agentai projektuojami taip, kad turėtų aiškiai išreikštas mentales bei emocines savybes (Shoham 1997). O plačiąja prasme agentai charakterizuojami pagal gebėjimą spręsti problemas.

Tikrovės socialiniams reiškiniams imituoti jau sukurta daug agentais pagrįstų skaičiavimo modelių: kainų pusiausvyros decentralizuotose rinkose (Albin, Foley 1992), transporto spūsčių (Nagelod, Rasmussenaf 1994), kooperacijos žaidimuose (Huberman, Glance 1993, Miller 1996); gerovės pasiskirstymo (Plikynas 2008), organizacijų elgsenos (Prietula *et al.* 1998), kultūrų raidos (Axelrod 1997), sąjungų susidarymo (Axelrod 1997), erdviniai nedarbo (Cederman 1997, Topa 2001), darbo eigos (Singh, Huhns 1999), erdvinio gyvenviečių pasiskirstymo, ekonominių klasių susidarymo (Axtell *et al.* 2001), prekybinių tinklų (Tsfatsion, Judd 2006), vertybinių popierių kainų susidarymo (Homann *et al.* 2007), finansinių institucijų sisteminės rizikos valdymo (Ye *et al.* 2008).

Agentų sistemos neretai modeliuojamos tarsi ekonominiai žaidimai. Johnson *et al.* (2001) gavo vilčių teikiančius rezultatus, kad akcijų rinka gali būti prognozuojama pasitelkiant agentų žaidimus. LeBaron (2002) sukūrė Santa Fe dirbtinę akcijų rinką. Situngkir, Surya (2004) pasiūlė primitivyvų modelį, kurį

sudaro agento su fundamentalistine strategija ir triukšmo mikromodeliavimu, skirtu sumodeliuoti vertybinių popierių rinkos lūkesčius. da Silva *et al.* (2005) nagrinėjo besiformuojantį kolektyvo elgesį dirbtinėje finansų rinkoje.

Finansų rinkų modeliavimas agentų pagalba yra svarbus dviem aspektais: siekiama pilnai automatizuoti finansų rinkos darbą ir siekiama sukurti papildomas galimybes investuotojui. Streltchenko *et al.* (2005) pasiūlė modelį, kuris agentams suteikia šiuos vaidmenis: rinka, investuotojas, brokeris, investicinių sprendimų priėmėjas, brokerio sprendimų priėmėjas. Kiekvienam šių agentų priskiriamos tam tikros savybės, aprašomi jų interesai ir porinės tarpusavio sąveikos. Modelis sėkmingai pritaikytas įvairioms finansų rinkoms, skirtingiems rinkos instrumentams. Rutkauskas, Ramanauskas (2009) straipsnyje siūlomas dirbtinis akcijų rinkos modelis, grindžiamas nevienalyčių veiksmų sąveika, kurių elgesys formuojamas saviapsimokymo algoritmus derinant su tam tikromis evoliucinės atrankos procedūromis. Modelis (Ramanauskas, Rutkauskas 2009) grindžiamas rinkos savireguliacijos sugebėjimais, rinkos veiksmingumo ir naujai atsirandančių savybių finansų rinkoje, lemiančių veiksmų, analize. Aprašomi optimalių sprendimų paieškos eksperimentai įvairiose kapitalo rinkose. Mathieu, Brandouy (2010) teigia, kad agentais pagrįsta virtuali aplinka ypač naudinga studijuoti įvairius finansų rinkos aspektus visiškai kontroliuojamoje aplinkoje, atverti naujas perspektyvas politikos formuotojams, institucijų ir įmonių valdymui, modeliuoti verslo sprendimus finansų sektoriuje.

Kitu aspektu – Finansų rinkas, kaip greitai besikeičiantį chaotinį procesą, nagrinėjo Š. Raudys, Zliobaite (2006). Pasiūlyta multi-agentų sistema sumažina vieno ateities kainos prognozės taško spėjimo paklaidą, atrinkdama pačius sėkmingiausias, tarpusavyje evoliucionuojančius ir konkuruojančius agentus. Chen *et al.* (2008) agentų pagrindu sukūrė evoliucinį mix-žaidimą, gebantį prognozuoti finansines laiko eilutes su tikslumu 52–56 %. Neri (2011) pateikė conceptualiai paprastą modelį, derinantį mokymosi imitavimą su agentų sistema ir prognozuojantį akcijų rinkos pokyčius. Marwala (2013) naudoja multiagentų sistemą ekonomikos modeliavimui pasitelkdamas žaidimų teoriją, neuroninių tinklų ansamblius, genetikos dėsnius ir akcijų rinkos taisykles.

### 1.2.5. Hibridinės sistemos

Aprašytosios neuroninių tinklų, genetinių algoritmų, neraiškiosios logikos ir ekspertinės (agentų) sistemos neveikia visiškai izoliuotai. Jos dažnai jungiamos ir kombinuojamos tarpusavyje siekiant gauti naują dirbtinio intelekto sistemą su tobulesnėmis savybėmis.

Ishikawa (1993) pasiūlė neraiškiųjų tinklų teoriją Delfi metodui FDM (angl. *Fuzzy Delfi Method*). Kuo *et al.* (1996) sujungė FDM ir ARIMA neuroninius tinklus ir pritaikė akcijų rinkos prognozavimui. Modifikuoto Delfi metodo žingsniai buvo šie: a) kokybiniai vertinimai padalinami į šešias grupes (ekonominiai, politiniai, žinių, finansiniai, techniniai, internacionaliniai) ir iš jų suformuojamas pirmas klausimynas ekspertams; b) gražintiems atsakymams priskiriamos Neraiškiosios logikos narystės funkcijos; c) kiekvieno eksperto atsakymams apskaičiuojamas vidurkis, minimali, maksimali vertės; d) ekspertai supažindinami su atsakymais ir, jei atsakymai konverguoja – apklausa baigta, jei ne – apklausa tęsiama. Konverguojantys duomenys naudojami rekurentinių neuroninių tinklų įvestyse. Neraiškiosios logikos Delfi metodo ir ARIMA neuroninio tinklo sujungimas padidino akcijų rinkos prognozavimo tikslumą ir patikimumą. Chang, Wang (2006) sujungė FDM su rekurentiniu neuroniniu tinklu ir pritaikė šią sistemą pardavimų prognozavimui. Čia ekspertų kokybiniai įverčiai buvo verčiami kiekybiniais ir naudojami kaip įvestys neuroniniams tinklams, stipriai padidindami prognozės tikslumą ir patikimumą.

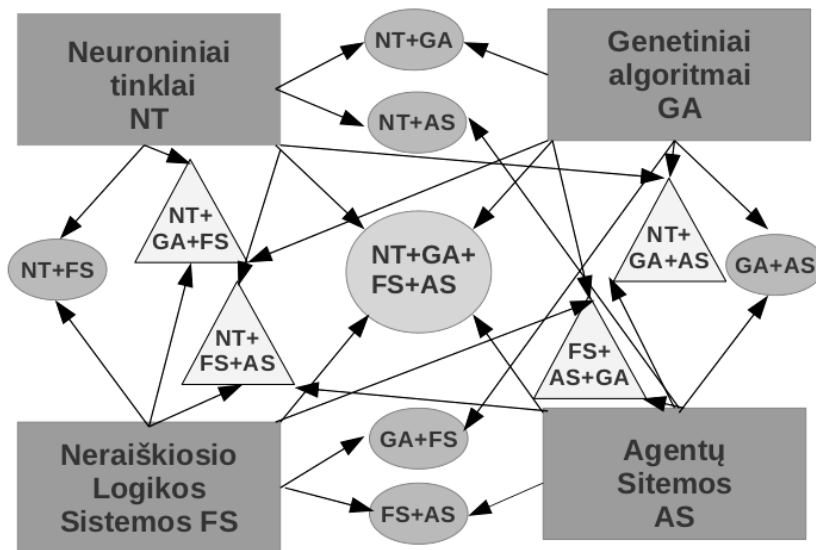
Hussan *et al.* (2007) darbe sujungtos ekspertinės sistemos, neuroniniai tinklai ir genetiniai algoritmai akcijų rinkos prognozavimui. Ypač daug yra hibridinių sistemų, jungiančių ne tik įvairias dirbtinio intelekto sistemas, bet ir įvairiausių žinomus metodus. Genetinių algoritmų ir neuroninių tinklų mokymosi pagerinimo algoritmo Levenberg-Marquardt (LM) hibridą Asadi *et al.* (2012) pritaikė akcijų rinkos prognozavimui. Autoriai išsamiai nagrinėjo akcijų rinkos dalyvius ir kūrė sistemas, optimizuojančias įvesčių parinkimą. Khashei, Bijari (2012) jau straipsnio pavadinimu teigia „Valiutų kainų prognozės yra tikslesnės, prognozuojant hibridiniais neuroniniais tinklais“. Panašias tezes įrodinėja ir kitame straipsnyje Khashei *et al.* (2013). Guo, Yang (2012) hibridinį modelį naudoja investavimo rizikos analizei ir prognozavimui. Zhang, Sun (2013) finansų rinkų prognozavimui sėkmingai naudoja neuroninių tinklų ir genetinių algoritmų hibridą.

Kaboudan, Conover (2013) naudoja Neuroninių tinklų, genetinių algoritmų ir neraiškiosios sklaidos hibridą akcijų indeksų prognozavimui. Makridou *et al.* (2013) naudoja neuroninių tinklų ir neraiškiosios sklaidos modelių hibridą aukso kainos prognozavimui.

Valiutų rinka yra didžiausia ir viena iš labiausiai likvidžių rinkų pasaulyje. Ši rinka visada buvo viena iš sudėtingiausių rinkų tiek trumpalaikiam, tiek ilgalaikiam prognozavimui. Rinkos chaotiškumas, didelis triukšmas ir duomenų nestacionarumas lemia, kad geriau prognozuoti vienai-trims dienoms arba savaitei. Evans *et al.* (2013) prognozuodami valiutų kursus dirbtinių neuroninių tinklų ir genetinių algoritmų hibridu, pasiekė 75,2 % tikslumą ir, testuodami



realioje rinkoje, gavo 23 % grynąją metinę investicijų grąžą. Khashei *et al.* (2013) naudodami klasikinio ARIMA ir neraiškiosios sklaidos modelių hibridą, gauna skirtingus prognozuojamų valiutų kursų skirstinius ir, pritaikę klasifikavimo algoritmus, prognozuoja valiutų kursus, naudodami labai nedidelius istorinių duomenų rinkinius ir pakankamai greitai. Dirbtinio intelekto sistemų ir jų galimų hibridų schema pateikta 1.1 paveiksle.



1.1 pav. Dirbtinio intelekto sistemų ir jų galimų hibridų schema

Fig. 1.1 Artificial intelligence systems and all possible hybrids

Apibendrinant visas apžvelgtas finansų rinkų prognozavimo sistemas, naudojantias dirbtinį intelektą, galima teigti, kad šių sistemų taikymo uždavinys susiveda į teisingą įvesčių parinkimą siekiant gauti numatytąsias išvestis. Pačios kompiuterinės sistemos naudojamos suderinant jų parametrus, kombinuojant ir grupuojant keletą sistemų ar jų modulių, tol, kol gaunamas reikiamas prognozavimo tikslumas. Įvestyse naudojami tiek techninės, tiek fundamentinės analizės istoriniai duomenys, kurie adaptuojami pasirinktai sistemai, ieškoma jų tarpusavio ryšio. Nei įvesčių skaičius (nuo 1 iki 15), nei duomenų kiekis (nuo 52 iki keletu tūkstančių taškų) neapibrėžia modelio tikslumo. Išvestyse dominuoja įvairiai išreiškiama rinkos pokyčio kryptis, kaip svarbiausias parametras investuotojui.



Dirbtinio intelekto algoritmai ir jų sistemos gali tapti patikimu prognozavimo įrankiu, priimat sprendimus investavimo finansų rinkose. Sujungiant prognozavimo modelius, naudojančius dirbtinį intelektą su moderniaja portfelio teorija, galimas sinergijos efektas.

### 1.3. Investicinio portfelio suformavimo principai

Aktyvus investicinių popierių portfelio valdymas reikalauja veiksmingos išteklių atrankos strategijos. Sėkmę lemia du pagrindiniai investavim etapai: prognozavimo metodo pasirinkimas ir turto alokacija (angl. *asset allocation*).

Portfelio valdytojas, priimdamas sprendimą investuoti į tam tikrą instrumentų rinkinį, sprendimą priima neapibrėžties sąlygomis. Jis turi tam tikrų lūkesčių, kad tas ar kitas finansų rinkos instrumentas ateityje elgsis pagal tam tikras taisykles, t. y. per tam tikrą investicinį laikotarpį bus gauta tam tikra tikėtina grąža. Savo lūkesčius jis dažniausiai grindžia ankstesniu instrumento kitimu. Jis daro prielaidą, kad rytoj bus kaip vakar, kitais metais bus kaip praėjusiais metais, ir apskritai būsimus įvykius galima prognozuoti remiantis praeitimi.

Nemaža ateities prognozių dalis yra grindžiama vidurkiais: aritmetiniu, geometrinu, harmoniniu ir daugybe jų svertinių hibridų. Atsižvelgiant į vidurkių skirtumus, yra parašyta nemažai mokslinių straipsnių apie vieno privalumus prieš kitą, apie jų santykinus privalumus. Roll (1983) atkreipė dėmesį į tikėtinos grąžos aritmetinio vidurkio prognozavimo tikslumo svarbą, palygino jį su kitais pirmenybių nustatymo metodais. Jean (1984) lygino aritmetinio ir harmoninio vidurkių naudojimą tikėtinos grąžos nustatymui. Missiakoulis *et al.* (2010) pasiūlė akcijų rinkos instrumentų prognozavimo metodą ilgalaikiam investavimui, grindžiamą aritmetiniu vidurkiu.

Geometrinio vidurkio panaudojimo investavimui strategiją pirmasis ekonominėje literatūroje aprašė Latane (1959), siekdamas optimizuoti investavimo strategijos pasirinkimą neapibrėžties sąlygomis. Weide *et al.* (1977) nagrinėja investavimo strategijas, kai investicijų grąža didėja, jei geometrinis tikėtinos investicijų grąžos vidurkis yra maksimizuojamas, tiriamos sąlygos, kai investicinės grąžos skirstinys yra diskretusis. Pirmenybę aritmetiniam vidurkiui deklaruoja ir Cooper (1996), pasiūlydamas prognozavimo metodą, naudojančią aritmetinio ir geometrinio vidurkių hibridą. Modeliavimo metodu Indro, Lee (1997), parodo, kad svertiniu aritmetinio ir geometrinio vidurkių hibrido būdu pasiekiamas geresnis prognozavimo tikslumas ilgalaikėje perspektyvoje nei aritmetiniu ar geometrinu vidurkiais atskirai. Nors geometrinio vidurkio

taikymas finansų rinkų prognozavimui yra labai populiarus, Missiakoulis *et al.* (2007) įrodo, kad geometrinis vidurkis investicinio portfelio vertinimui netinka. Straipsnyje autoriai Santiago, Estrada (2011) įvertino tikėtiną, stebimą ir simuliuojamą geometrinio vidurkio dinamiką. Zhang (2012) teoriškai pagrindė, kad geometrinis vidurkis yra svarbi akcijų rinkos grąžą apibūdinanti savybė, nors tėra tik atskiras Kelly kriterijaus atvejis. Praktiškai naudoti stochastiniai modeliai su savifinansavimo prielaida patvirtino teorinius rezultatus. Markowitz (2012) ištyrė šešių prognozavimo metodų, naudojant aritmetinį ir geometrinį vidurkius, dvi duomenų bazes, tikslumą.

Missiakoulis *et al.* (2012), palyginę visus tris vidurkius, atlikę empirinę prognozavimo tikslumo analizę, pirmenybę teikia harmoniniam vidurkiui, teigdami, kad ilgalaikėje perspektyvoje harmoninis vidurkis geriausiai atitinka investuotojo lūkesčius.

Kitas svarbus prognozavimo metodas – Sharpe indekso maksimizavimo metodas. Jis taip pat remiasi prielaida, kad Finansų rinkos instrumentai ateityje elgsis taip pat kaip praeityje.

Estrada (2009) tyrimais įrodė, kad nors teoriškai Sharpe indekso maksimizavimo metodas investuojant yra geresnis, nei geometrinis vidurkis, praktiškai yra visiškai atvirkščiai.

Haven *et al.* (2012) pritaikė chaotinių procesų triukšmo sumažinimo bangelių (angl. *wavelet*) metodą istoriniams kainų duomenims ir gavo patikimesnę prognozavimą ir mažesnę investavimo rizikingumą.

Apibendrinant, galima teigti, kad tikėtinos grąžos optimizavimas yra glaudžiai susijęs su prognozavimo metodo pasirinkimo problema. Turint pakankamai patikimas tikėtinų grąžų prognozes, natūraliai kyla poreikis efektyviai paskirstyti investuojamus išteklius skirtingiems finansiniams instrumentams.

Turto alokacija (angl. *asset allocation*) yra sprendimo, kaip paskirstyti investuojamą turtą tarp skirtingų šalių ir turto klasių investavimo tikslais procesas. Valdant ir investuojant turimas vertybes plačiai naudojamas finansinis instrumentas – diversifikavimas. Anderson, Frankle (1980), Jorion (1986) nagrinėja portfelio diversifikavimo problemą, eksperimentiškai nustato kiek portfelyje reikia įrankių, kad investicija būtų saugi.

Efektyvusis portfelis, kuris apibūdinamas kaip portfelis, kuris turi didžiausią pelningumą duotam rizikos lygiui, remiasi tikėtinos grąžos maksimizavimu. Piero, Mosevich (2011) pasiūlė portfelio pasirinkimo vertinimo metodą, naudojant portfelio grąžų praeityje skirstinio parametrus: vidurkį, standartinį nuokrypį, Sharpe indeksą, asimetriją ir smailumą.

Portfelis, kuris turi mažiausią riziką duotam pelningumui remiasi rizikigumo minimizavimu.

Vienas populiariausių rizikos mažinimo metodų yra ortogonalinių portfelių sudarymas. Roll (1980) pirmasis suformulavo portfelio ortogonalumo sąlygą:  $\sum_{i,j} r_{ij} \sigma_i \sigma_j = 0$ , čia  $r_{ij}$  portfelio elementų  $i, j$  tarpusavio koreliacijos koeficientas;  $\sigma$  yra atitinkamo portfelio elemento standartinis nuokrypis. Jobson, Korkie (1982), Asgharian (2011) kuria sąlyginį turto paskirstymo modelį su latentiniais veiksniais, remiantis portfelio ortogonalumo sąlyga.

Harvey, Siddique (2000) susiejo sisteminę turto grąžos skirstinio asimetriją su papildoma rizikos premija, maždaug 3,6 % per metus. Mažesnę turto grąžą turintiems skirstiniams būdinga didesnė asimetrija.

Efektyvaus portfelio pasirinkimas neapibrėžties sąlygomis – stochastinis sprendimas, kur tikėtina grąža esant tam tikram rizikos lygiui galima su tam tikra tikimybe.

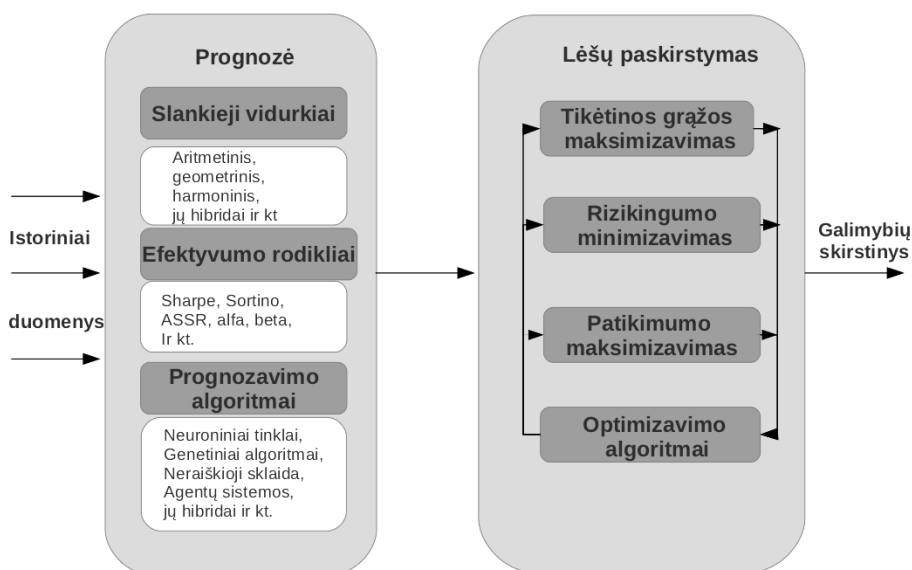
Rutkauskas (2000) pasiūlė adekvatų investicinį portfelį, kuris sujungia pelningumą, rizikingumą ir patikimumą. Investuojant neapibrėžties sąlygomis finansinė analizė iš įprastos dvimatės – *pelningumas-rizikingumas* – virsta trimate – *pelningumas-rizikingumas-patikimumas* (Rutkauskas 2001). Adekvačiojo portfelio verčių sritis yra išlikimo funkcijų rinkinys kiekvienam rizikingumo laipsniui. Tai seka ne tik iš pelningumo ir rizikingumo atitikimo, bet ir apima galimybių ir rizikingumo atitiktį (Rutkauskas, Stankevičienė 2003). Sujungiant adekvačiojo portfelio analizę su imitacinėmis technologijomis (Rutkauskas 2006), investicinių sprendimų priėmimas įgalina tikėtis sėkmės įvairiose finansų rinkose (Rutkauskas 2008,

Investavimo strategija yra investicinių sprendimų rinkinys, kuris leidžia investuotojui gauti geriausią pelningumo, rizikingumo ir patikimumo kompoziciją. Šiam tikslui naudojami įvairūs optimizavimo algoritmai. Atsiradus dirbtinio intelekto sistemoms, jos taip pat imtos taikyti investicinio portfelio optimizavimui.

Portfelio optimizavimas naudojant genetinius algoritmus aprašytas Xia *et al.* (2000), taip pat pateiktas palyginimas su klasikiniu Markovitz portfelio optimizavimu. Stochastinį požiūrį į investicinio portfelio optimizavimo problemos sprendimą iliustruoja dalelių spiečiaus optimizavimo (ang. *Particle Swarm Optimization*) algoritmai. Šie algoritmai yra grindžiami socialinės psichologinės tam tikrų gyvių elgsenos modeliais. Jie yra taikomi siekiant optimizuoti netiesines funkcijas.

Sudaryti optimalų portfelį naudojant dalelių spiečių optimizavimo algoritmą bandė Kendall, Su (2005), Xu *et al.* (2007), Cura (2009), Zhu *et al.* (2011), naudodami skirtingus finansų rinkos instrumentus bei testuodami sukurtus modelius skirtingais investavimo laikotarpiais. Golmakani, Fazel (2011), naudodami dalelių spiečiaus optimizavimą, parenka elementus investavimui atsižvel-

giant į turimas lėšas, investuotojų polinkį investuoti į įmones su didesne kapitalizacija ir mažesne rizika. Rezultatus lyginant su genetiniais algoritmais, gauta, kad PSO algoritmai yra žymiai efektyvesni. Apibendrinant nagrinėtus investicinių portfelių sudarymo metodus sudaryta 1.2 paveiksle pavaizduota schema.



1.2 pav. Apibendrinta investicinio portfelio sudarymo schema

Fig. 1.2 Scheme of investment portfolio formation

Chaotinis finansinių instrumentų kitimas turi atmintį. Tai, kas vyko praeityje, daro įtaką įvykiams ateityje. Pirmame investicinio portfelio sudarymo žingsnyje randamas tam tikras kitimo dėsningumas praeityje. Antrame žingsnyje investuojamos lėšos paskirstomos investiciniams instrumentams, atsižvelgiant į pirmame žingsnyje rastą dėsningumą. Investavimo sprendimas priimamas neapibrėžtyje, teikiant pirmenybę labiau tikėtinam prognozuojamam įvykiui, kurį nusako galimybių skirstinys.

## 1.4. Pirmojo skyriaus išvados ir disertacijos uždavinių formulavimas

1. Pilna arba ideali informacija visiems rinkos dalyviams yra nepasiekiamą, todėl ir visiškai efektyvi rinka egzistuoti negali. Tačiau asimptotinis artėjimas prie pilnos informacijos patvirtina kainos kitimo tendencijas ir daro šią hipotezę viena svarbiausių socialiniuose moksluose.
2. Kuriant paramos sistemas investuotojams stebimas sinergijos efektas tarp skirtingų mokslo šakų (ekonomikos, matematikos, psichologijos, biologijos), naujausių technologinių atradimų (internetinių atsiskaitymų, dirbtinio intelekto) ir investuotojų patirties, siekiant gauti efektyvų, kokybiškai naują, socialiai harmoningą, inovatyvų įrankį.
3. Chaotinis valiutų kursų svyravimo procesas turi atmintį. Tai, kas buvo praeityje, daro įtaką tam, kas vyks ateityje.
4. Tikėtinos gražos optimizavimas yra glaudžiai susijęs su prognozavimo metodo pasirinkimo problema.
5. Dirbtinio intelekto sistemos yra vienos perspektyviausių prognozavimo įrankių. Neuroninių tinklų, genetinių algoritmų, neraiškiosios sklaidos, agentų sistemų ar jų hibridų įrankis naudojamas finansų rinkų prognozavimui, parenkant tinkamas įvestis, suderinant jų parametrus, kombinuojant ir grupuojant keletą sistemų ar jų modulių, tol, kol gaunamas reikiamas finansų instrumento prognozavimo tikslumas.
6. Turint patikimą prognozavimo įrankį, investuojamų lėšų paskirstymo sprendimas priimamas įvertinant tikėtiną gražą, esant tam tikram rizikos lygiui su tam tikra tikimybe.
7. Efektyvaus portfelio sudarymui gali būti pasitelkti dirbtinio intelekto algoritmai, gebantys atpažinti, grupuoti, klasifikuoti, apibendrinti ir optimizuoti.
8. Investavimo sprendimai priimami neapibrėžties sąlygomis, todėl galimas tik euristinis artėjimas prie maksimalaus rezultato, kurį geriausiai atspindi galimybių skirstiniai.
9. Sprendimų finansų rinkose priėmimo paramos sistemos, gebančios tinkamai įvertinti istorinius duomenis, naudojančios inovatyvius algoritmus, suteikia papildomos informacijos investuotojams, tokiu būdu jie įgauna pranašumą prieš kitus rinkos dalyvius.

10. Analizuoti moksliniai šaltiniai leidžia formuluoti uždavinius disertacijos tikslui pasiekti: siekiant gauti efektyvią paramos sistemą būtina suformuoti patikimą prognozavimo modelį ir jį integruoti moderniąją portfelio teoriją. Sukurtą paramos sistemą investuotojui būtina patikrinti imitacinėje rinkoje realiu laiku.

# 2

## Sprendimo priėmimo neapibrėžtyje teoriniai pagrindai

Šiame skyriuje apibrėžta dirbtinio intelekto sąvoka, pagrindinės jo sukūrimo sąlygos, perspektyvos ir grėsmės, išskirtas vienas finansų rinkoms svarbus procesas – prognozavimas. Čia nagrinėjamas Evolino rekurentinis neuroninis tinklas ir jo sėkmingo veikimo parametrai, ansamblio sukūrimo prielaidos. Taip pat analizuojami investicijų, investicinio portfelio sudarymo ir jo efektyvumo teoriniai aspektai. Šio skyriaus rezultatai pateikti šiuose moksliniuose darbuose: Rutkauskas, Maknickienė, Maknickas (2010), Maknickienė *et al*(2011), Rutkauskas, Stasytė, Maknickienė (2011), Maknickas, Maknickienė (2012), Maknickienė (2012), Maknickienė, Maknickas (2013), Maknickienė, Maknickas (2013a). Šio skyriaus tikslas yra pateikti modelio teorinį pagrindimą.

### 2.1. Universaliosios dirbtinio intelekto teorijos galimybių analizė

#### 2.1.1. Dirbtinio intelekto sąvoka

1931 m. Gödel (1992) padėjo teorinius pagrindus kompiuterių atsiradimui. Jis parodė, kad tradicinė matematika nepajėgi išspręsti tam tikrų uždavinių ir tam reikalinga formali kalba. 1936 metais Turing (1936) performulavo K. Godel

40 2. SPRENDIMO PRIĖMIMO NEAPIBRĖŽTYJE TEORINIAI PAGRINDAI

teoriją ir pasiūlė Turingo mašiną, kuri tapo pagrindiniu kompiuterių mokslo įrankiu. 1936–1938 K. Zuse sukonstravo pirmąjį pasaulyje programų valdomą kompiuterį. 1950 metais McCarthy (McCarthy, Lifschitz 1991/1950) įvedė terminą „dirbtinis intelektas“ (AI angl. *Artificial intelligence*). 1960 metais Solomono pasiūlė universalią dirbtinio intelekto teoriją (Solomono 1960), įvesdamas universalios prognozės sampratą. 1940–1990 metais pasiekimai tikimybių teorijoje sudarė sąlygas tikram dirbtinio intelekto sistemų atsiradimo proveržiui: neuroniniai tinklai – McCulloch ir Pitts penktame dešimtmetyje (McCulloch, Pitts 1943); Kohonen (Kohonen 1988), Minsky (Minsky 1963), Papert, Amari (Amari 1960) septintame dešimtmetyje; Werbos (Werbos 1982) aštuntame ir daugelis kitų, Neraiškioji Logika – Zadeh (Zadeh 1965) septintojo dešimtmečio gale, dirbtinės evoliucinės sistemos – Rechenberg (Rechenberg 1973) septintame, Holland (Goldberg, Holland 1988) aštuntame, „atstovavimas be“, dirbtinis intelektas (knygos), dirbtinės skruzdės – Dorigo (Dorigo *et al.* 1996), Gambardella (Dorigo, Gambardella 1997) dešimtam, statistinė mokymosi teorija ir paramos vektorinės mašinos – Vapnik ir kt (Cortes, Vapnik 1995, Vapnik 2000). 1990–2000 metais vyko didžiulis progresas praktinio dirbtinio intelekto kūrime, kurį lėmė didžiulis kompiuterinių skaičiavimų greitėjimas. Atsirado hipotetinės skaičiavimo mašinos – kvantinio kompiuterio idėja. Šios mašinos galėtų atlikti skaičiavimus, pasitelkdamos fizikines sistemas, kurioms galioja kvantinio susiejimo ir kvantinės superpozicijos dėsniai. Klasikiniuose kompiuteriuose informacija yra operuojama diskrečiais bitais, o kvantiniuose kompiuteriuose – tolygiai kintančiomis kvantinėmis būsenomis – kubitais. 1994 m. mokslininko P. Šoro sukurtas faktorizavimo (skaičiaus išskaidymas į daugiklius) algoritmas kvantiniams kompiuteriams, o 1996 m. L. Groverio (Grover (1996)) pasiūlytas kvantinis greitos paieškos nesutvarkytoje duomenų bazėje algoritmas išsklaidė skeptikų abejones, ar toks kompiuteris įmanomas. Naujasis tūkstantmetis prasidėjo proveržiu teoriškai optimalių ir praktiškai įmanomų algoritmų srityse, tokiose kaip prognozavimas, paieškos sistemos, induktyvioji interferencija, problemų sprendimas, sprendimų priėmimas, savisustiprintas mokymasis ir kt.

Dirbtinis intelektas gali būti apibrėžtas kaip mokslas, kuris kuria kompiuterines sistemas, imituojančias intelektualius procesus, paprastai būdingus žmonėms. Egzistuoja du dirbtinio intelekto supratimai: kompiuterinės sistemos turi veikti kaip žmogus arba mąstyti kaip žmogus. Vienas intelekto, kuris „veikia kaip žmogus“, gynėjų buvo 1950 m. Alan Turing (Turing 1950). Jo apibrėžtas gerai žinomas Turingo testas nusako žmogaus ir kompiuterio santykį, kad sistema būtų pripažinta dirbtiniu intelektu. Testas turi nustatyti, ar atsakymas atėjo iš kompiuterio, ar iš žmogaus kitame terminalo gale.



Atliekant testą, jei mokslinių tyrimų sritį ar sukurtą kompiuterinę sistemą siekiama priskirti dirbtiniam intelektui, kompiuteris turėtų sugebėti įvykdyti šiuos uždavinius:

1. Galimybė sukurti pakankamą ryšį su kompiuterine sistema kokia nors žmonių kalba.
2. Atpažinti žinias prieš ir po bandymo.
3. Automatiškai prisitaikyti, naudojant turimas žinias, ir daryti naujas išvadas iš tų žinių.
4. Mokymosi procesas turi prisitaikyti prie naujų aplinkybių.

Šiam testui nebūtina imituoti žmogų, pakanka sukurti objektus, kurie būtų pripažinti gebantys atlikti intelektualius veiksmus.

Mokslininkai, kurie mano, kad intelektas yra „tas, kuris mąsto, kaip žmogus“, mokslinių tyrimų veiklą nukreipė visų pirma į žmogaus smegenų funkcijas, savistabą, neurologijos atradimus arba į psichologinius eksperimentus. Tai leido atrasti naują teoriją, kur elektrinės schemos atkartoja žmogaus smegenų darbą. Taip gimė visa eilė neuroninių tinklų modifikacijų.

Racionalus požiūris gina idėją, kad protinga sistema turi būti racionali, o tai reiškia, jog sistema atlieka teisingus veiksmus, be klaidų, nors tai nebūtinai atsitinka žmonių elgesį. Šis metodas pagrįstas matematikos naudojimu, ypač logikos naudojimu ir inžinerija. Jei mes norime, kad algoritmai padėtų mums atlikti pasikartojančias ar rizikingas užduotis, jie turi būti padaryti kuo geriau. Tačiau informacija, kurią mes turime, dažniausiai būna nepilna ir netiksli, todėl ji ne visada gali būti išreiškiama formalia logika. Be to, laiko, reikalingo rasti geriausią loginį sprendimą, gali prireikti daugiau, negu mes jo turime. Norint išspręsti šią problemą, buvo atrasti euristiniai metodai. Šie metodai kuria strategijas, kurios leidžia artėti prie teisingo sprendinio, nors vienintelis teisingas atsakymas nėra pateikiamas, rezultatas praktiškai yra pakankamai geras (Legg, Hutter (2007)).

Searle dirbtinio intelekto hipotezė (Searle (1980)) teigia: Tinkamai suprogramuotas kompiuteris su teisingomis įvestimis ir išvestimis turi protą ta pačia prasme, kaip žmonės turi protą. Todėl dirbtinio intelekto algoritmai gali daryti tai, ką žmogus sugeba suprogramuoti. Mokslininkai jau šiandien bando sukurti tokius kognityvius procesus (Hutter 2012b):

Apibendrinimas iš esmės yra indukcinė išvada. Indukcija yra procesas, skirtas padaryti išvadą, atsižvelgiant į bendrąsias taisykles ar modelius, iš stebėjimų arba ieškant dėsningumų istoriniuose ar kituose duomenyse. Šis intelekto bruožas yra esminis.

Prognozė yra susijusi su ateities paaiškinimu, grindžiamu praeities stebėjimų duomenimis (Solomono 1960 Legg, Hutter 2007).

Atpažinimas yra susijęs su klasifikavimo procesu. Duomenyse atrenkami tam tikrą požymį ar jų klasę turintys elementai.

Asociacija. Du elementai ar reiškiniai yra susiję, jei egzistuoja ryšys tarp jų. Stebėjimų rinkinys gali būti sugrupuotas į skirtingas panašias kategorijas.

Samprotavimas yra neabejotinai žymiausia žmogaus intelekto savybė. Dedukcija ar logika nėra išreiškiami kaip dirbtinio intelekto architektūros dalis. Dažniausiai dirbtinis intelektas atlieka tam tikrus logiškus sprendimus tik ten, kur neapibrėžtis yra labai maža, t. y. tikimybė artėja prie 0 arba 1.

Problemų sprendimas gali būti apibrėžiamas kaip kryptingas, pagrįstas argumentais artėjimas prie tam tikro tikslo.

Planavimas – gebėjimas optimizuoti ateities įvykius, t. y. maksimizavimo ir minimizavimo funkcijų pagalba randamas tam tikras išsidėstymas laike ar erdvėje, kuris tenkina tam tikrą taisyklių rinkinį.

Kūrybiškumas yra gebėjimas generuoti novatoriškas idėjas ir įgyvendinti jas realybėje. Kūrybingi žmonės dažnai yra sėkmingesni nei tie kuriems trūkta šios savybės. Kūrybingumas – tai gebėjimas spręsti optimizavimo uždavinius ten, kur jų niekas dar nesprenė.

Žinios. Dirbtinis intelektas saugo visą veiklos istoriją ir puikiai geba atsiminti ir panaudoti saugomas žinias. Pavyzdžiui, LMST atminties ląstelė Schmidhuber *et al.* (2005). Ar dirbtinio intelekto atmintis yra trumpalaikė, ilgalaikė, santykinė ar hierarchinė dar nėra pakankamai ištirta.

Veiklumas. Dirbtinis intelektas gali paveikti aplinką, kuri reaguoja į tarpininką. Sprendimai gali turėti ilgalaikes pasekmes, į kurias dirbtinio intelekto kūrėjas turėtų tinkamai atsižvelgti. Čia rūpestį kelia mokymosi ir planavimo sąveika.

Mokymasis – žinių optimizavimo uždavinys. Yra daug įvairių mokymosi formų: su mokytoju, be mokytojo, pusiau su mokytoju, sustiprintas, kopijavimas, asociatyvus ir daugelis kitų. Mokymasis yra viena pagrindinių dirbtinio intelekto savybių.

Savęs pažinimas yra svarbi aukšto intelekto savybė. Svarbu atpažinti ir įvardinti savo minčių priežastis, ypač bendraujant su kitomis intelekto formomis. Techniškai visa tai gali būti reikalinga, kai agentai naudoja imitacinį modelį ir atpažįsta savo algoritmus modelyje.

Sąmonė yra galbūt labiausiai paslaptinga žmogaus proto savybė, todėl ne nuostabu, kad apie jos egzistavimą ir naudojimą dirbtinio intelekto sistemose yra per mažai duomenų.

Kompiuterinių sistemų pažanga neišvengiamai skverbsis į įvairias gyvenimo sritis, spartindama visuomenės vystymosi pažangą. Mokslininkai numato ne tik teigiamas technologijų vystymosi puses, bet ir išpėja apie grėsmes.

Hutter (2012b) nurodo tokias vidines grėsmes: dirbtinis intelektas gali išmokti mokyti ir perimti mokytojo funkcijas, išmokti dauginimosi, savižudybės, savęs tobulinimo, manipuliavimo, žudymo, egoizmo kenkimo iš smalsumo ir kt. procesus. Kitame straipsnyje autorius Hutter (2012a) nurodo ir išorines grėsmes: tai visuomenės, kuri greitai prisitaikys prie tobulėjančių technologijų, ir visuomenės, kuri neprisitaikys, atskirtis ir nesusikalbėjimas tarp šių grupių.

Toliau bus nagrinėjama tik viena dirbtinio intelekto savybė – prognozavimas, kuri yra labai svarbi siekiant numatyti finansų rinkos tendencijas.

### 2.1.2. Universaliosios prognozės galimybė

Prognozavimas visada yra tikimybinio pobūdžio, ar tai būtų paprastas dienos darbų planavimas, ar sudėtingų procesų mokslinis įvertinimas. Paprastai visada egzistuoja tam tikra tikimybių aibė trokštamam įvykiui įvykti, labai mažos tikimybės visame galimybių skirstinyje yra ignoruojamos, o atsižvelgiama į labiau tikėtinus įvykius. Sprendimai priimami arba naudojantis racionaliais principais ar taisyklėmis, arba remiantis sukaupta patirtimi ir žiniomis.

Remiantis autoriais Merhav, Feder (1998), Hutter (2003), Hutter, Zaelon (2005), Hutter (2012b), nagrinėjančiais universalios prognozės galimybes, kiekvienas prognozuojamas įvykis gali būti aprašomas kaip jau įvykusių įvykių seka  $x_1, x_2, \dots, x_{t-1}$ , ir siekiant rasti sekantį įvykį  $x_t$ . Visos galimos prognozuojamos reikšmės priklauso tikimybių skirstiniui  $\mu$ . Pagrindė sprendimas, pasirenkant labiausiai tikėtiną įvykį, priklauso nuo turimų žinių apie skirstinį  $\mu$ , tačiau dažniausiai jis yra nežinomas. Tada prognozė yra daroma remiantis spėjamu skirstiniu  $\rho \in \mu$ . Imama, kad prognozavimas, remiantis skirstiniu  $\rho$ , yra pakankamai geras, jei  $\rho$  artėja prie  $\mu$  arba tam tikra prasme konverguoja į  $\mu$ . Tegul  $M := \nu_1, \dots, \nu_n$  yra baigtinė galimų tikimybių skirstinių seka. Taigi galime naudoti svorinius vidurkius kiekvienam  $M$ :

$$\xi := \sum w_\nu \nu(x); \sum w_\nu \leq 1; w_\nu > 0. \quad (2.1)$$

Iš šių lygčių seka, kad  $\xi$  yra skirstinys, nes svoriai yra teigiami ir normuoti į 1, o  $\nu \in M$  yra tikimybės.  $\xi$  vadinamas universalium santykiu su  $M$ , kaip dominuojantis daugiklis visuose aibės  $M$  skirstiniuose.

$$\rho \geq \xi = \sum w_\nu \nu(x); \text{ visiems } \nu \in M. \quad (2.2)$$

$M$  yra žinomas ir jam priklauso tikrasis skirstinys  $\mu$ . Jei pasirinktas  $M$  yra pakankamai didelis, tai  $\rho$  artėja prie  $\mu$ .

Kaip prognozuoti, jei tikroji tikimybių būsena nežinoma, bet žinoma, kad ji  $\mu \in M$ ? Yra sukurta įvairių principų, kurie remiasi skirtingais svorių  $w_\nu$  pasirinkimais. Klasikiniais laikomi trys principai: simetrijos, maksimalios entropijos ir paprastumo.

Tarkime, turime seką  $x_1, x_2, \dots, x_{t-1}$ , ir tam tikram sprendimui priimti tikimės rasti prognozuojamą  $x_t$ , kuris:

- yra skaičius, raidė, ženklas ar loginė frazė. Pavyzdžiui, finansų rinkų prognozės atveju sprendimas „pirkti“ arba „parduoti“. Tokiu atveju sprendimo priėmėjui svarbu žinoti su kokia tikimybe bus gautas trokštamas rezultatas;

- yra skaičius intervale  $[a; b]$ , kur ribas nustato ekspertai arba sprendimo priėmėjas, atsižvelgdami į galimybes. Šiuo atveju sprendimas priimamas atsižvelgiant į tikimybę, kad rezultatas bus tam tikrame intervale;

- taškų aibė, kuriuos apibūdina tikimybių skirstinys  $\rho$ , kurio forma ir parametrai – vidurkis, modos, asimetrija, smailumas – yra žinomi. Tada sprendimas priimamas atsižvelgiant į visą turimą informaciją.

Labai svarbu žinoti prognozavimo paklaidas, ribas. Tai nagrinėta eilėje mokslinių darbų (Hutter 2001, Schmidhuber 2002, Hutter 2007). Jų autorių teigimu  $LM(n)$  ir  $Lp(n)$  yra tikėtinos  $n$  pirmųjų įvykių  $M$  prognozės ir atitinkamai  $p$ -prognozės paklaidos. Tada  $LM(n) - Lp(n)$  yra ne daugiau kaip  $\sqrt{Lp(n)}$ . Tai yra,  $M$  yra artimas  $p$ . Jei  $p$  yra determinuotas dydis, tada  $M$ -prognozė negali turėti jokių paklaidų. Jei  $p$  yra visų suskaičiuojamų skirstinių aibė, tai  $M$  tampa universalio prognoze.


Tam, kad turėtume optimalų prognozavimą, reikia turėti optimalų sprendimų priėmėją arba savisustiprinantį apsimokymą. Tai yra, kiekviena dirbtinio intelekto sistema turi turėti savioptimizuojančius algoritmus taip, kad atsižvelgdama į istorinius duomenis, galėtų apskaičiuoti vertę, asimptotiškai artėjančią prie optimalios reikšmės, atitinkančios vertę ateityje.

## 2.2. Evolino rekurentinio neuroninio tinklo pritaikymas produktyviam sprendimui

### 2.2.1. Evolino rekurentinis neuroninis tinklas

2005 metais straipsniuose (Schmidhuber *et al.* 2005, Schmidhuber *et al.* 2006) pasiūlytas naujos klasės rekurentinio neuroninio tinklo mokymosi algoritmas EVOLINO (angl. *Evolution of recurrent systems with Optimal LINear Output*). Evolino yra laikinių sekų prognozavimo sistema, kuri sujungia neuroevo-

liucinį metodą su tradiciniu optimizavimo metodu, tokiu kaip tiesinė regresija. Tiesiniai modeliai dažnai gali išspręsti daugelį problemų, tuo tarpu netiesiniai reiškiniai gali būti prognozuojami tiesinių sistemų pagalba tik naudojant evoliuciją. Evolino rekurentinio neuroninio tinklo schema pateikta 2.1 paveiksle.



**2.1 pav.** Evolino rekurentinio neuroninio tinklo schema (šaltinis: Schmidhuber *et al.* 2005)

**Fig. 2.1** Scheme of Evolino recurrent neural network (source: Schmidhuber *et al.* 2005)

Evolino tinklą sudaro dvi dalys: 1 – netiesinis rekurentinis subtinklas, kuris gauna įvestis, 2 – tiesinis paslėptasis sluoksnis, kuris išdėsto subtinklo struktūrą išvesties jungtims. Rekurentinės dalies svoriai evoliucionuojami, tada išvesties sluoksnio svoriai suskaičiuojami analitiškai. Pirmajame etape, mokymo sekų rinkinys, gaunamas iš sistemos  $\{u^i d^i\}, i = 1..k$ , kiekviena ilgio  $l^i$  reikšmė yra pateikiama tinklui. Kiekvienai sekai  $u^i$ , pradedant laiko momentu  $t = 0$ , kiekvienas įvesties darinys  $u^i(t)$  yra sėkmingai praėjęs rekurentinį tinklą ir transformavęsis į vektorių  $\phi^i(t)$ , kurie yra saugomi  $n \times \sum_i^k l^i$  matricioje  $\phi$ . Tikslinis vektorius  $d^i$  matricioje D yra susijęs su kiekvienu  $\phi^i(t)$  ir kiekvienu laiko momentu išvesties vertės yra teisingos. Kadangi visi sekos k yra žinomi, išvesties svoriai W yra skaičiuojami naudojant tiesinę regresiją nuo  $\phi$  į D. Vektoriai iš matricos  $\phi$  (t. y. kiekvienas n išvesčių reikšmių iš mokymo rinkinio) iš neortogonalios bazės tiesiškai artėja nuo W prie D (Schmidhuber *et al.* 2005).

Antrajame etape, mokymo duomenų rinkinys vėl paduodamas į tinklą, bet dabar įvestys pereina rekurentinį tinklą, kur suskaičiuojamos prognozuojamos vertės  $y(t)$ . Prognozės paklaida arba liekamosios paklaidos minimizuojamos evoliucijos būdu, kaip tikslumo matą naudojant teorinės ir prognozuojamos reikšmių paklaidą.

Neuroevoliucija paprastai naudojama apmokymui, kai teisingos išvestys yra iš anksto nežinomos. Evolino nenaudoja evoliucijos proceso tiesioginiam prognozavimui. Čia tinklo išvestys suformuoja vektorių rinkinį, kuris tampa duomenų baze paklaidai suskaičiuoti. Intuityviai manoma, kad taip sudaryti duomenų bazę yra paprasčiau, negu tiesiogiai ieškoti neuroninių tinklų svorinių daugiklių.

Priverstinės subpopuliacijos (ESP angl. *Enforced SubPopulations* nuo paprastos evoliucijos skiriasi tuo, kad evoliucionuoja ne visas tinklas, o tik atskiros neuroninių tinklų komponentės. Evoliucija ESP vyksta sekančiu būdu:

1. Inicijacijos. Paslėptųjų jungčių  $H$  skaičius tinkluose, kurie evoliucionuos, suskirstomas į subpopuliacijas su  $n$  chromosomų, sujungtų su kiekviena paslėptąja jungtimi. Kiekviena chromosoma koduoja įvestis, išvestis ir rekurentinių jungčių svorius atsitiktinių realiųjų skaičių eilutėmis.

2. Evoliucija. Neuronas yra atrenkamas iš kiekvienos subpopuliacijos  $H$  atsitiktinės atrankos būdu. Ir kartu suformuojamas rekurentinis tinklas. Tinklas yra testuojamas tam tikrai užduočiai ir įvertinamas. Prie kiekvieno dalyvaujančio procese neurono pridodamas suminis tinkamumas (angl. *cumulative fitness*).

3. Rekombinacija. Kiekvienos subpopuliacijos neuronai yra ranguojami pagal tinkamumą. Ketvirtis geriausių neuronų yra rekombinuojamas naudojant kryžminimą ir mutuojamas naudojant *Couchy* skirstinio triukšmą, siekiant sudaryti naujus neuronus, kurie pakeistų žemiausiai ranguojamus neuronus.

4. Evoliucijos-rekombinacijos ciklas kartojamas tol, kol gaunami tinklo svoriniai daugikliai.

Naudojant atskiras subpopuliacijas, ESP paspartina neuronų specializavimąsi į skirtingas subfunkcijas, reikalingas suformuoti gerus neuroninius tinklus, nes skirtingai evoliucionuojančios tų pačių neuroninių tinklų funkcijos turi būti apsaugotos nuo dubliavimosi. Subpopuliacijos taip pat sumažina triukšmą, kad kiekvienam evoliucionuojančiam neuronų tipui būtų suformuojamas atskiras tinklas. Tai leidžia ESP sukurti rekurentinius neuroninius tinklus, kurių negalėjo sukurti ankstesni modeliai.

Jeigu ESP veikimas ilgą laiką nepasiekia iš anksto nustatyto norimo tikslumo, naudojama taip vadinama sprogimo mutacija (angl. *burst mutation*). Šio metodo pagrindinė idėja – ieškoti gerų mutacijų iš gaunamų sprendimų. Kai

veiksmas nebesivysto iš anksto nustatytame generacijų kiekyje, naujos subpopuliacijos yra sukuriamos pridedant triukšmą į geriausius rezultatus pateikusius neuronus. Kiekviena nauja subpopuliacija turi neuronų, kurie skiriasi nuo geriausiųjų. Vėl vyksta evoliucija, bet dabar ieškoma geriausių ankstesnių neuronų kaimynystėje. „Sprogimo mutacija“ gali būti taikoma kelis kartus iš eilės, sėkmingai panaudodama naujų neuronų skirtumus nuo geriausiųjų. Daroma prielaida, kad geriausiais sprendimas jau yra gautas, todėl daugelio svorių jau nereikia radikaliai keisti. Siekiant užtikrinti, kad pokyčiai būtų maži, nors kai kuriuose svoriuose vyksta dideli pokyčiai, ESP naudoja Coughy skirstinį triukšmo generavimui (Schmidhuber *et al.* 2005):

$$f(x) = \frac{\alpha}{\pi(\alpha^2 + x^2)}. \quad (2.3)$$


Esant tokiam skirstiniui 50% verčių patenka į intervalą  $\pm\alpha$  ir 99,9% verčių patenka į intervalą  $318,3 \pm \alpha$ . Ši subpopuliacijos „įkrovimo“ technika išsaugo galimybę ESP toliau tęsti evoliucijos procesą ir artėti prie sprendimo.

Ilgalaikės atminties ląstelė (LSTM angl. *Long Term Sort Memory*) yra rekurentinis neuroninis tinklas, tikslingai sukurtas išmokti ilgalaikes priklausomybes per pažymėtą gradientą. Unikalus LSTM architektūros bruožas yra atminties ląstelė, pajėgi išlaikyti savo aktyvumą neribotą laiką (2.2 pav.). Atminties ląstelę sudaro tiesinės jungtys (tamsūs rutuliukai) su paslėptąja ląstelės būseną (S) ir treji vartai, kurie gali atsiverti ir užsiverti. Įvesties vartai ( $G_I$ ) „apsaugo“ neuronus nuo įvesties ir tik tada, kai jie atviri, įvestys gali daryti įtaką vidinei neurono būsenai. Išvesties vartai ( $G_O$ ) išleidžia vidinę neurono būseną į kitas tinklo dalis, o užmaršties vartai ( $G_F$ ) užrakina būsenos aktyvumą, kai jis nėra naudojamas. Vartai taip pat gauna įvestis iš kitų neuronų ir funkcijos ( $\Sigma$ ) (paprastai sigmoidinės funkcijos) įvestyse nusprendžia ar vartai turi atsiverti, ar užsiverti. Ar atminties ląstelės vartai  $g_i$  yra atviri, ar uždari laiko momentu  $t$ , yra apskaičiuojama pagal sekančias formules (Schmidhuber *et al.* (2005)):

$$g_i^{in} = \sigma\left(\sum_j \omega_{ij}^{in} c_j(t-1) + \sum_k \omega_{ik}^{in} u_k(t)\right), \quad (2.4)$$

$$g_i^{foget} = \sigma\left(\sum_j \omega_{ij}^{foget} c_j(t-1) + \sum_k \omega_{ik}^{foget} u_k(t)\right), \quad (2.5)$$

$$g_i^{out} = \sigma\left(\sum_j \omega_{ij}^{out} c_j(t-1) + \sum_k \omega_{ik}^{out} u_k(t)\right), \quad (2.6)$$



2.2 pav. Ilgalaikės atminties ląstelės (LSTM) schema  
**Fig. 2.2** Long Term Sort Memory

čia  $\omega_{ij}^{in,foget,out}$  yra ląstelės  $j$  svoris iš išvesties  $c_j$  į vartus  $i$ , o  $\omega_{ik}^{in,foget,out}$  yra svoris nuo įvesties  $u_k$  į vartus  $i$ ,  $\sigma$  yra standartinė sigmoidinė funkcija. Išorinės įvestys į ląstelę ( žymimos kaip  $\Sigma$ ) ir pridedamos prie  $net_i(t)$ :

$$net_i^t = h\left(\sum_j \omega_{ij}^{cell} c_j(t-1) + \sum_k \omega_{ik}^{cell} u_j(t)\right), \quad (2.7)$$

čia  $h$  yra kita slenksčio funkcija, o ląstelės  $i$  vidinė būseną:

$$s_i(t) = net_i(t)g_i^{in}(t) + g_i^{foget}(t)s_i(t-1). \quad (2.8)$$

Išvesties vartai kontroliuoja ląstelės išvestis  $c_i$ , kurios išreiškiamos per tangento funkciją:

$$c_i(t) = \tanh(g_i^{out}(t)s_i(t)). \quad (2.9)$$



Evolino neuroninis tinklas sujungia LSTM ląsteles, ESP tiesinę regresiją ir evoliuciją į vieną sistemą. ESP evoliucionuoja atminties ląstelių subpopuliacijas vietoje standartinių rekurentinių neuronų. Kiekviena chromosoma yra eilutė, sudaryta iš išorinės įvesties svoriu, įvesties, užmaršties ir išvesties vartų svorių, iš viso  $4 * (I + H)$  svorių kiekvienoje atminties ląstelės chromosomoje, kur  $I$  – įvesčių skaičius, o  $H$  – yra atminties ląstelių neuroniniame tinkle skaičius. Yra 4 komplektai  $I + H$  svorių, nes treji vartai (2.4–2.6) ir pati ląstelė gauna įvestis tiek iš išorės, tiek iš kitų ląstelių. Kiekviena chromosoma subpopuliacijoje užkoduoja jungčių svorius įvesties, išvesties ir užmaršties vartuose ir išorinėse įvestyse. ESP naudoja kryžminę neuronų rekombinaciją, tačiau pirmuose Evolino variantuose ESP naudojo tik mutaciją. Geriausių neuronų ketvirtis kiekvienoje subpopuliacijoje yra kopijuojamas ir kopija mutuojama *Coychy* triukšmu (2.3 formulė) visoms svorių reikšmėms.

Teisinės regresijos metodas, naudojamas išvesties svoriams  $W$  apskaičiuoti, yra Moore-Penrose pseudo-inversijos metodas, kuris buvo ir greitas, ir optimalus, nes jis minimizuoja vidutinę standartinę paklaidą. LSTM tinkluose vektorius  $\phi(t)$ , kuris naudojamas išvesties sluoksnio svoriams apskaičiuoti, priklauso tiek nuo ląstelės išvesties  $c_i$  (2.9 formulė), tiek nuo vidinės būsenos  $s_i$  (7 formulė). Pseudo-inversija apskaičiuoja po du jungčių svorius kiekvienai atminties ląstelei. Nustatomas ryšys tarp vidinės būsenos išvesties „plyšelio“ ir neuroninio tinklo išvesties, tuomet (Schmidhuber *et al.* 2005):

$$y_i(t) = \sum_j c_j(t) \omega_{ij}^{standart} + \sum_k s_k(t) \omega_{ik}^{peophole}. \quad (2.10)$$

Sekančios funkcijos generavimui, grįžtamasis ryšys naudojamas taip, kad prognozuojama išvestis tampa įvestimi sekančiame žingsnyje. Mokymo metu geros vertės gražinamos, siekiant, kad išvesties vertės artėtų prie teisingos vertės. Testavimo metu tinklui gražinamos prognozuojamos vertės.

## 2.2.2. Prognozavimo įrankio architektūra

Siekiant pritaikyti turimą dirbtinio intelekto sistemą tam tikram produktyviam veiksmui, tyrėjas turi galimybę pasirinkti vidinius ir išorinius parametrus, juos tinkamai paruošti darbui. Galima naudoti vieną arba visą tų elementų ansamblių. Atskirai detaliau aptarsime Evolino RNN įvestis, vidinius parametrus, vieno RNN, nedidelio ansamblio ir didelio ansamblio galimybes, išvesčių savybes ir prognozavimo patikimumo matavimą.

50 2. SPRENDIMO PRIĖMIMO NEAPIBRĖŽTYJE TEORINIAI PAGRINDAI

Dirbtinio intelekto sistemos įvesčių sluoksnis – tai neuronai, priimantys informaciją iš išorinių šaltinių ir siunčiantys ją apdoroti sistemai. Tai gali būti jutiklių įvestys arba tinklo išorėje esančių sistemų siunčiami signalai. Vienos sistemos išvestys gali būti kitos sistemos įvestimis. Teisingai parinktos įvestys leidžia gauti tikėtinas išvestis. Apžvelgdami mokslininkų, prognozavusių finansinius procesus, kada nors naudotas įvestis, pastebėjome, kad pasirinkimas yra labai platus: visi galimai susiję techninės ir fundamentaliosios analizės rodikliai, ekonomikos rodikliai, indeksai ir kt. O juk gali būti ir iš pažiūros nesusiję procesai, tokie, kaip saulės aktyvumas arba žemės drebėjimų aktyvumas. Nėra jokių apibrėžtų taisyklių, kokie duomenys turi būti naudojami įvestyse. Taupant laiko ir atminties resursus, prognozavimui Evolino neuroniniu tinklu labai svarbu rasti optimalų duomenų kiekį. Disertaciniame darbe pasirinkti ir prognozavime dalyvauja istoriniai prognozuojamo valiutų kurso duomenys ir tokios pat apimties „mokytoju“ pasirinktas biržos elemento kainų intervalas. Pastarasis duomenų intervalas gali turėti labai daug variantų, todėl buvo ieškoma tam tikro ryšio tarp abiejų įvesčių duomenų. Arba tie duomenys yra labai susiję, arba visiškai nesusiję, arba jų tarpusavio ryšys yra visiškai nereikšmingas ir galima rinktis bet kokių duomenų intervalą. Ryšiui tarp įvesčių duomenų nustatyti buvo pasitelktas duomenų tarpusavio ortogonalumas. Įvesčių ortogonalumas yra prilyginamas  $n$  dimensijų vektorių ortogonalumui. Vektorių ortogonalumas seka iš dviejų vektorių  $f$  ir  $g$ :

$$\langle f, g \rangle_w = \sum_n f(n) * g(n) * w(n), \quad (2.11)$$

čia  $w(n)$  yra ne neigiamas svorio vektorius, apibrėžtas vidinės sandaugos. Šie vektoriai yra ortogonalūs, jeigu tenkinama sąlyga:

$$\sum_n f(n) * g(n) * w(n) = 0. \quad (2.12)$$

Šis metodas buvo pasirinktas geriausių įvesčių radimui, siekiant pritaikyti Evolino mokymo procesą valiutų rinkų prognozavimui. Tuo tikslu apskaičiuojama skaliarinė sandauga:

$$\left| \sum_n f(n) * g(n) \right| = \varepsilon. \quad (2.13)$$

Čia absoliuti  $\varepsilon$  vertė nusako ortogonalumo laipsnį, kadangi tikras ortogonalumas (2.12) finansų rinkų duomenų eilutėms negali būti pasiektas, neneigiamas svorio vektorius  $w(n) = 1$ . Įvesčių duomenims apskaičiavę  $\varepsilon$  turėsime duo-

menų tarpusavio ryšio matavimų skalę. Evolino rekurentinio neuroninio tinklo kūrėjai (Schmidhuber *et al.* (2005)) sudarė galimybę įrankio taikytojams pasirinkti vidinius parametrus: duomenų kiekį, iteracijų skaičių, neuronų skaičių. Taikytojo uždavinys – suderinti šiuos parametrus pasirinktam tikslui pasiekti. Vieno Evolino rekurentinio neuroninio tinklo prognozavimas yra labai nestabilus – jis gali būti ir labai tikslus, ir visiškai neatitikti realybės.

Psichologė Rimkutė (2007), tyrinėjanti žmogaus mąstymą, išskiria produktyvų mąstymą, kuris tik atkartoja jau žinomas žinias, ir produktyvų mąstymą, kuris sukuria kažką naujo. Kiekvienos problemos sprendimui reikalingas tam tikras žinių kiekis, tačiau ne kiekvienas, turintis daug žinių geba jas panaudoti produktyviai. Nėra tiesioginės priklausomybės tarp turimo žinių kiekio ir produktyvaus mąstymo (Rimkutė 2007).

Stebint Evolino rekurentinio neuroninio tinklo prognozavimo procesą, matomas analogiškas reiškinys – geresnis rekurentinio neuroninio tinklo mokymosi procesas, matuojamas mažesniu vidutiniu kvadratinu nuokrypiu, negarantuoja tikslesnio prognozavimo. Tiriant chaotinius procesus, dažniausiai nėra taip svarbu atkartoti proceso praeitį, kaip numatyti ateities vertes ar kitimo kryptį. Finansų rinkos prognozavimo uždavinys susiveda į tokį modelio sukūrimą, tokį dirbtinio intelekto sistemos parametrų parinkimą, kad skirtumas tarp prognozės  $L_n$  ir realios prognozuojamos vertės  $A_n$ , tikrinant prognozavimo patikimumą, būtų mažiausias. Naudojant Evolino rekurentinį neuroninį tinklą, nuosekliai keičiami tam tikri parametrai – iteracijų arba pakartojimų skaičius, neuronų skaičius ir istorinių duomenų apimtis – ir stebimas prognozavimo tikslumas. Eksperimentiniu būdu surandama tokia parametrų kitimo sritis, kad prognozavimo tikslumas  $L_n - A_n$  būtų kuo mažesnis. Trumpai tai vadinama kalibravimu.

Suderinus vidinius Evolino rekurentinio neuroninio tinklo parametrus, galima naudoti jį vieną ir gauti prognozę su tam tikru tikslumo patikimumu, bet galima sujungti keletą Evolino rekurentinių neuroninių tinklų į ansamblius.

### 2.2.3. Maži rekurentinių neuroninių tinklų ansambliai

Remiantis Rashid (2009), ansambliu vadinama tam tikrų atskirų neuroninių tinklų grupė, kur kiekvienas neuroninis tinklas apmokomas atskirai, bet jų išvestys yra apjungiamos vienam galutiniam sprendiniui gauti. Siekiama gauti tokį galutinį sprendinį, kuris būtų tikslesnis už atskirus neuroninių tinklų sprendinius. Ansambliai gali būti vienalyčiai ir nevienalyčiai. Vienalytis ansamblis gauna galutinį sprendinį iš vienodų neuroninių tinklų su vienodu mokymosi duomenų rinkiniu. Nevienalytis ansamblis gauna galutinį sprendinį iš

vienodų neuroninių tinklų, bet su skirtingais mokymosi duomenų rinkiniais. Taikymo uždavinys yra paskirstyti svorius gautiems sprendiniams taip, kad patikimesni sprendiniai, disertaciniame darbe – prognozės, gautų didesnius svorius, o mažiau patikimi – mažesnius, arba visai lygius 0. Ansamblius naudojo visa eilė mokslininkų: Zhou *et al.* (2002), Tsakonas, Dounias (2005), Nguyen, Chan (2004), Siwek *et al.* (2009), kurie naudojo nuo 2 iki 12 neuroninių tinklų. Visi šie autoriai teigia, kad ansamblio prognozė yra tikslesnė ir patikimesnė nei vieno neuroninio tinklo. Čia išryškėja skirtumas, kiek neuroninių tinklų yra naudojama ansamblyje. Ansamblio elementų kiekį riboja turimi atminties ir laiko resursai. Todėl pirmiausia aptarsime mažesnius ansamblius  $\leq 10$ . Daugelis eksperimentų buvo atlikti su 8 Evolino rekurentinių neuroninių tinklų ansambliu. Siekiant atmesti pačias nelogiškiausias prognozes ir naudoti tik pačias tiksliausias iš jų, pasirinkti ekspertiniai vertinimo metodai.

Dirbtinio intelekto sistemose išvesčių sluoksnyje atsispindi sistemos kūrėjų tikslas. Išvesties procesas yra informacijos perdavimo arba paėmimo procesas. Vienos sistemos išvestys gali būti kitos sistemos įvestimis. Prognozuojant finansų rinkas, galutinis rezultatas būna labai įvairus: 1) kainos kitimo kryptis, kils kaina arba kris, pirkti, parduoti arba laukti; 2) kaina tam tikru laiko momentu ateityje; vidurkis, atidarymo, uždarymo, minimali, maksimali; 3) kainų intervalas tam tikru laiko momentu ateityje.

Išvestys turi būti aiškios ir patogios naudojimui, lengvai apdorojamos ir vaizdžiai pateikiamos. Labai svarbi išvesčių savybė – patikimumas. Todėl prieš pradėdant naudoti dirbtinio intelekto sistemą, tiriamas prognozės sutapimas su realiais duomenimis, paprastai matuojamas nuokrypis arba koreliacija.

Naudojant Evolino rekurentinį neuroninį tinklą išvestyse, gaunama prognozuojama pasirinktos dienos valiutų rinkos uždarymo kaina, kurios patikimumas gali būti įvertintas testuojant.

Rekurentinių neuroninių tinklų ansamblių, kurių elementų kiekis mažas, elementų išvestys apjungiamos vieningam galutiniam sprendimui gauti, naudojant ekspertinius vertinimo metodus.

Ekspertinis vertinimas suprantamas kaip apibendrinta ekspertų grupės nuomonė, kurios gavimui pritaikomos specialistų ekspertų žinios, patirtis ir intucija. Ekspertu vadinamas specialistas, turintis tam tikros srities žinių ir patyrimo (lot. *Expertus* – patyręs). Ekspertiniai vertinimo metodai taikomi:

1) kai informacijos yra daug, tačiau ji yra kokybinio pobūdžio arba daugiakriterė;

2) kai informacijos nepakanka, t. y. prognozavimo uždaviniuose.

Ekspertinio vertinimo metodologija grindžiama šiomis prielaidomis: 1. Ekspertas yra sukaupęs didelį kiekį racionaliai apdorotos informacijos ir to-

dėl gali būti informacijos šaltiniu. 2. Ekspertų grupės nuomonė nedaug skiriasi nuo tikrojo problemos sprendinio. Ar dirbtinio intelekto sistemos gali sudaryti ekspertų grupę ir jų vertinimams gali būti taikoma ekspertinio vertinimo metodologija? Evolino rekurentinis neuroninis tinklas, pritaikytas valiutų rinkos prognozavimo uždaviniui spręsti, geba pateikti sprendinį su tam tikra paklaida. Naudojant keletą Evolino rekurentinių neuroninių tinklų sprendimų, atliekamų tuo pačiu metu, ir taikant jiems ekspertinio vertinimo metodologiją, galima sumažinti prognozavimo paklaidą.

Ekspertinio vertinimo patikimumas priklauso nuo: 1. Ekspertų grupės dydžio. 2. Ekspertų sudėties pagal specialybę. 3. Ekspertų savybių. Taupydami sprendimo priėmimo laiką, pasirinkome minimalų galimą ekspertų skaičių – 8 ekspertus, t. y. Evolino rekurentinių neuroninių tinklų ansamblio sprendimus. Šiame darbe naudojami Evolino rekurentiniai neuroniniai tinklai su vienodomis savybėmis, parametrais, bet skirtinga istorinių duomenų baze. Ekspertų grupė, o taip pat ir Evolino rekurentinių neuroninių tinklų ansamblis, duoda patikimesnį sprendimą negu atskiras ekspertas arba Evolino rekurentinis neuroninis tinklas. Kelis kartus kartojant eksperimentą, ansamblio sprendimai statistiškai dažniau sutampa, negu atskirų rekurentinių neuroninių tinklų.

Dirbtinio intelekto „ekspertai“ visiškai nepriklauso nuo socialinių ir bendruomeninių ar visuomeninių pirmenybių, nes jų paprasčiausiai neturi. Jie turi tik individualias savybes, kurios apibrėžiamos ir naudojamos dirbtinio intelekto sistemos parametru, kuriuos dažniausiai galima keisti ir pasirinkti. Evolino rekurentinio neuroninio tinklo prognozavimo savybes lemia neuronų skaičiaus, iteracijų (pakartojimų) skaičiaus ir įvesčių duomenų apimtys bei duomenų bazės pasirinkimas. Visi šie parametrai eksperimentiniu būdu suderinami pasirinktam tikslui.

, Vienas iš ekspertų grupės vertinimo metodų – Delfi metodas, savo pavadinimą gavęs nuo Graikijos miesto Delphi ir išminčių senovėje, garsėjusių ateities prognozėmis. Delfi metodas gali įvertinti tiek kiekybinę, tiek kokybinę informaciją, kaip reglamentuoja specialistų prognozavimo galimybes. Pirmieji šį metodą pasiūlė Dalkey ir Hamler (1963). Dalkey (1969) pateikia išsamią eksperimentinę grupės nuomonės studiją. Ištirta grupės nuomonės patikimumo priklausomybė nuo jos dydžio, palyginti rezultatai esant viešai ir anoniminei apklausai, ištirtas kraštutinių nuomonių poslinkis link medianos po kiekvienos iteracijos. Nustatyta, kad kuo toliau nuomonė yra nuo medianos, tuo jos pokytis po apsikaitimo nuomonėmis didesnis. Grupės narių individualus mokymasis, esant grįžtamajam apsikaitimui nuomonėmis ir argumentais, veda prie tikslesnio sprendinio ar prognozės. Autoriai taip pat ištyrė ir palygino moterų ir vyrų nuomonių pokytį po kiekvieno Delfi apklausos etapo (po kiekvienos

iteracijos), atsakymui skirto laiko įtaką tikslumui bei grupės nuomonės paklaidos priklausomybę nuo savęs įvertinimo. Į šiuos eksperimentinius rezultatus buvo atsižvelgta sudarant disertacinio prognozavimo modelį.

Delfi metodas apima eilę nuosekliai atliekamų procedūrų kai siekiama suformuoti grupės nuomonę apie tam tikrą problemą, apie kurią nepakanka informacijos. Klasikiniam Delfi metodui yra būdingi sekantys etapai:

1. Kiekvienas iš  $n$  ekspertų pateikia atsakymą  $E_n$  į suformuluotą klausimą. Visi atsakymai sudaro atsakymų aibę  $E = E_1, E_2, \dots, E_n$ .

2. Antrame etape ekspertams pateikiama visa atsakymų aibė ir prašoma suteikti kiekvienam iš jų įverčius, datas ar rangus  $A_n$  ir nurodyti priežastis, kodėl tas įvertis yra būtent toks. Tada organizatoriai sudaro naują aibę  $A = A_1, A_2, \dots, A_n$ , išdėsto įverčius didėjimo tvarka  $A = A^1, A^2, \dots, A^{i/2}, \dots, A^i$  čia  $i = 1, 2, \dots, n$ , randa medianą  $A^{i/2}$  ir kvartilius – tai yra intervalai  $[A^1; A^{i/4}]$  ir  $[A^{1-i/4}; A^i]$ . Šiuo būdu gaunami rodikliai yra grupės įverčio skirstinio charakteristikos. Mediana yra grupinio atsakymo charakteristika, o pageidaujamas kvartilių intervalas  $[A^{i/4}; A^{1-i/4}]$  – individualių nuomonių išsibarstymo rodiklis. Kiekvienam ekspertui pateikiamos šių charakteristikų vertės. Ekspertai, kurių vertinimai yra kraštiniuose kvartiliuose, prašomi pagrįsti savo atsakymus, t. y. nusakyti neatitikimo su grupės nuomone priežastis. Ekspertai gali naudoti visokius argumentus ar prieštaravimus, taip pat kaip per diskusiją. Bet šie argumentai yra anonimiški. Ekspertai gali peržiūrėti savo požiūrį ir, jei nori, ištaisyti. Su gautais pagrindimais supažindinami likę ekspertai, nenurodant, kieno jie yra. Ši procedūra leidžia visiems ekspertams atsižvelgti į aplinkybes, kurias jie galėjo netyčia praleisti.

3. Kartojamas antras žingsnis, atsižvelgiant į visus argumentus, prieštaravimus. Vėl skaičiuojama mediana, kvartilės ir gaunama nauja prognozė  $B = B^1, B^2, \dots, B^{i/2}, \dots, B^i$ , čia  $i = 1, 2, \dots, n$ .

4. Ekspertai supažindinami su rezultatais ir argumentais, vėl kartojama visa procedūra ir gaunama nauja prognozių aibė  $C = C^1, C^2, \dots, C^{i/2}, \dots, C^i$  čia  $i = 1, 2, \dots, n$ .

Nebūtina atlikti visas keturias apklausas, kartais nuomonės susiderina jau antrame ar trečiame metodo taikymo etape. Ekspertai, nepakeitę savo įverčių, paprastai duoda tikslesnį įvertį. Vidutinis ekspertų, pakeitusių savo nuomonę, įvertis slenkasi vidutinio grupės įverčio kryptimi. Todėl  $C^{i/2}$  slenkasi link tikrosios prognozuojamos vertės  $P$ . Yra sukurta nemažai šio metodo modifikacijų, padedančių išspręsti kai kuriuos metodo trūkumus, tačiau išlieka pagrindinės Delfi metodo prielaidos: 1) klausimo formulavimas turi leisti skaitinę atsakymo išraišką; 2) ekspertai turi turėti pakankamai informacijos įvertinimui; 3) atsakymas į visus klausimus (įvertis) turi būti eksperto pagrįstas.

Delfi technika ypač išgalėjo srityse, kur nėra vienareikšmių sprendimų. Šis metodas tapo universaliu įrankiu politikoje ir valstybės valdyme (Strauss, Zeigler (1975), Preble (1983)). Taip pat plačiai Delfi metodas naudojamas medicinoje, prognozuojant tolimesnę ligos eigą, parenkant tinkamą gydymą (Walker, Selfe (1996), Windle *et al.* (2004)). Plačiai taikant Delfi metodą, atsirado daug jo modifikacijų, bet jos nepašalino pagrindinių metodo trūkumų – didelės darbo apimties ir aukštos kainos. Sparčiai greitėjant informacinių technologijų tobulėjimui, atsiradus ekspertinėms kompiuterinėms sistemoms, Delfi metodas rado naują ir labai efektyvų pritaikymą dirbtinio intelekto sistemų taikyme. Buvo sukurtas ir sėkmingai taikomas Fuzzy Delfi metodas (Duru 2010, Hsu *et al.* 2010, Hanafizadeh, Mirzazadeh 2011). Čia dirbtinio intelekto sistemų įvesčių parinkimui pasitelkiami ekspertai, o jų įverčiai ranguojami pasitelkiant Delfi metodą. Ekspertai neuroninių tinklų ansamblyje – Evolino RNN – pateikia skaitines prognozes, remdamiesi skirtingais istorinių duomenų rinkiniais. Visi atsakymai išdėstyti didėjimo tvarka sudaro atsakymų aibę  $E = E_1, E_2, \dots, E_n$  (mūsų modelyje  $n = 8$ ). Atliekami visi 2 žingsnyje aprašyti veiksmai. Jei prognozės pasiekia tam tikrą suderinamumą, grupės prognozė laikoma patikima, jei ne – prognozavimas kartojamas.

Ekspertų grupės veiklos vertinimas gali būti laikomas pakankamai patikimu tik esant geram ekspertų įverčių suderinamumui, apimančiam suderinamumo laipsnio įvertinimą ir nevienalytiškumo priežasčių nustatymą. Gautų iš ekspertų įverčių pasiskirstymas atspindi ekspertų nuomones apie tam tikro įvykio rezultato (požymio) tikimybę. Yra du pagrindiniai sklaidos matavimo metodai: variacinis diapazonas (svyravimų amplitudė) ir vidutinis nuokrypis – tai vidutinis atskirų rezultatų atstumas nuo tam tikros centrinio rezultato vertės. Variacinis diapazonas tarp kvartilų yra lygus skirtumui tarp trečio ir pirmo kvartilio  $Q_3 - Q_1$ . Šiuo atveju lyginant variantus, galima apskaičiuoti interkvartilinį variacijos koeficientą, atitinkantį interkvartilinės variacijos ir medianos santykį (Kronholm, Schweizer (2003)):

$$q = \frac{Q_3 - Q_1}{Me}, \quad (2.14)$$

čia  $Q_3$  yra trečias kvartilis,  $Q_1$  yra pirmas kvartilis ir  $Me$  yra mediana. Interkvartilinis koeficientas svyruoja nuo 0 iki +1 ir artėja prie nulio, kai skirstinys yra simetriškas su labai maža variacija. Mūsų modelyje suderinamumas laikomas geru, kai interkvartilinis koeficientas yra intervale  $[0; 0,02]$ . Šis kriterijus buvo naudotas statistiniame modelio patikimumo įvertinime.

Sukurtas prognozavimo modelis Evolino rekurentinių neuroninių tinklų pagrindu naudoja Delfi metodą ne įvestims, kaip Fuzi Delfi metode, o išvesčių



įvertinimui. Aštuonių Evolino rekurentinių tinklų ansambliui pateikiami skirtingi istoriniai duomenys, o išvestyse gaunamoms prognozėms įvertinti taikomas Delfi metodas. Evolino rekurentinis neuroninis tinklas nepateikia žodinio pagrindimo, bet sprendimo priėmėjas mato grafinę kiekvieno Evolino rekurentinio neuroninio tinklo prognozę ir gali analizuoti prognozių skirtumus. Lengviausia yra atmesti visiškai nelogiškas, išeinančias iš realaus intervalo prognozes.

#### 2.2.4. Dideli rekurentinių neuroninių tinklų ansambliai

Kai elementų kiekis ansamblyje  $\geq 60$ , prognozės gali būti nagrinėjamos kaip skirstinys, turintis visus skirstinio parametrus – vidurkį, medianą, modą, asimetriją, smailumą ir kt. Svariai suteikiami ansamblio prognozėms, atsižvelgiant į gautąjį skirstinį.

**Prognozavimo patikimumas** suprantamas kaip realių ir prognozuojamų verčių sutapimas. Tam reikia tam tikrą laikotarpį paskutinius istorinius duomenis naudoti sutapimo patikrinimui, jų nenaudojant modelio įvestyse. Tegul kiekvienam  $t = 1, \dots, N$ , yra reali  $y(t)$  vertė laiko momentu  $t$ , o  $y_p(t)$  – prognozuojama vertė laiko momentu  $t$ ,  $e(t)$  – prognozės paklaida laiko momentu  $t$  –  $e(t) = y(t) - y_p(t)$ . Modelio patikimumas skaičiuojamas pagal Pirsono koreliacijos koeficiento ( $r$ ) formulę vertėms  $y(t)$  ir  $y_p(t)$  (Hatcher, O’Rourke 2014):

$$r = \frac{\sum_{t=1}^N (y(t) - \bar{y}(t))(y_p(t) - \bar{y}_p(t))}{\sqrt{\sum_{t=1}^N (y(t) - \bar{y}(t))^2} \sqrt{\sum_{t=1}^N (y_p(t) - \bar{y}_p(t))^2}}. \quad (2.15)$$

Vertinant ekonominius procesus, paprastai sutapimo patikimumas skirstomas taip: jei Pirsono koreliacijos koeficientas yra intervale  $[0,995; 1]$  prognozės patikimumas yra labai aukštas, jei intervale  $[0,6; 1]$  – geras, jei intervale  $[0; 1]$  – sutampa tik proceso kitimo kryptis; jei intervale  $[-1; 0]$  – prognozė nepatikima ar netgi priešinga.

Tikslumui matuoti naudojama ir paklaida MAPE (angl. *Mean Absolute Percentage Error*) (Hatcher, O’Rourke 2014):

$$MAPE = 100 - \frac{100}{N} \sum \frac{|Y_i - \bar{Y}_i|}{Y_i}, \quad (2.16)$$

čia  $N$  – stebėjimų skaičius,  $Y_i$  – reali reikšmė,  $\bar{Y}_i$  – prognozuota reikšmė. Prognozavimas laikomas pakankamai tikslu, jei MAPE viršija 95 %. Šie rodikliai bus naudojami modelio tikslumui ir patikimumui nustatyti. Turint patikimą



prognozavimo modelį, natūralu į jį integruoti moderniosios portfelio teorijos taikymo principus, siekiant, kad sprendimo priėmimas finansų rinkose įgautų naują kokybę.

## 2.3. Investavimo procesų teoriniai aspektai

### 2.3.1. Investicijų valdymas

**Neapibrėžtis.** Investavimas neišvengiamai susiduria su rizika, su nepakankama, netikslią ir neišsamia informacija apie investavimo sąlygas, su tam tikra tikimybe gauti pelną ir nuostolį (Rutkauskas 2000).

Sprendimo rezultatų nepastovumas pilniausiai ir geriausiai gali būti apibūdinamas pagal tikimybių skirstinius. Tikimybė yra kiekybinis įvykio matas ir apibrėžiama kaip procentinė įvykio pasirodymo galimybė. Tikimybės gali būti apibrėžtos ir objektyviai, ir subjektyviai. Objektyvus apibūdinimas pagrįstas anksčiau įvykusių panašių įvykių rezultatais, o subjektyvus – tik individo nuomone apie galimybę, kad įvykis įvyks. Sprendimai, kurie dažnai kartojami, gali remtis objektyviomis tikimybėmis, o nauji sprendimai priimami pagal subjektyvias tikimybes. Versle dažniausiai jomis ir remiamasi, o jų nauda nėra mažesnė, lyginant su objektyviomis tikimybėmis (Rutkauskas (2001)).

Modeliavimo neapibrėžtis nusako prognozės kintamumą, kurį lemia įvesčių neapibrėžtis  $x$ , modelio neapibrėžtis  $m$  ir išvesčių neapibrėžtis  $y$  (Rutkauskas 2001).

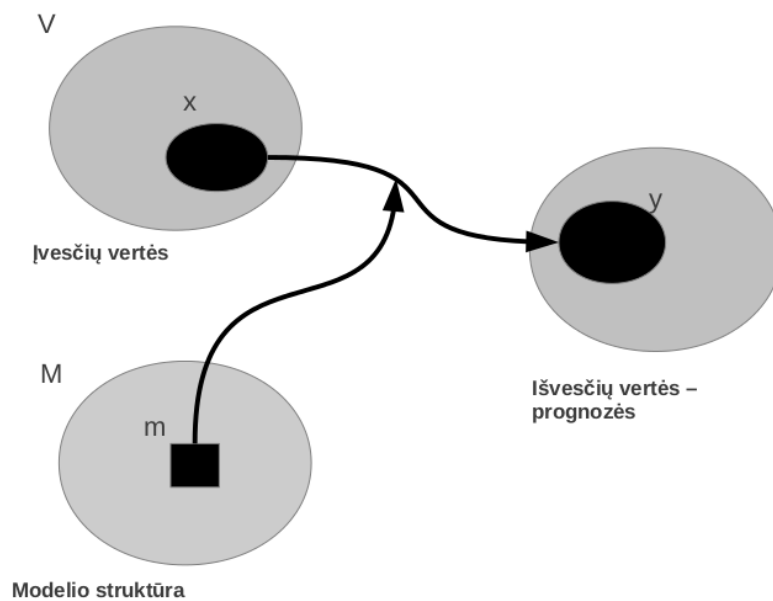
$$f_y \sim f(x, V, m), \quad (2.17)$$

čia  $V$  yra galimų įvesčių aibė  $x \in V$ ,  $f_x$  – įvesčių tikimybių tankio funkcija aibei  $V$ , o  $f_y$  – išvesčių tikimybių tankio funkcija.

Įvesčių neapibrėžtį lemia istorinių duomenų surinkimo, matavimo ir pasirinkimo galimybės. Įvesčių galimybių vertinimas iš dabarties perspektyvos vadinamas jautrumo analize. Ji nusako, kaip pakinta ateities (prognozės išvestyse) tikslumas ir patikimumas keičiant įvestis.

Pasak McKay (1995), modelis yra matematinė abstrakcija, dažniausiai funkcijų šeima, jo struktūra turi didelę įtaką prognozavimo neapibrėžtumui. Naudojant vieną modelį, modelio struktūros neapibrėžtį galima laikyti fiksuota, kaip tam tikrą matavimų ar skaičiavimų paklaidą.

Išvestis, arba prognozavimo neapibrėžtis, vertinama ne tik kaip įvesčių ir modelio neapibrėžčių rezultatas, bet turi ir globalią prasmę – bet koks įvykis ateityje turi nenulinę tikimybę įvykti. 2.3 pav. parodyta įvesčių, modelio ir išvesčių neapibrėžčių tarpusavio priklausomybės schema.




**2.3 pav.** Prognozės neapibrėžties priklausomybė nuo įvesčių ir modelio neapibrėžčių (šaltinis: McKay 1995)

**Fig. 2.3** Dependence of forecasting uncertainty from uncertainty of model (source: McKay 1995)

Šios priklausomybės yra labai svarbios vertinant prognozes. 2.4 paveiksle parodytos atsitiktinės prognozės tankio funkcijos a) ir priklausomos nuo įvesčių prognozės tankio funkcija b).

Imant prognozę, kaip dirbtinio intelekto sistemos skirstinį, atsiranda galimybė priimti investavimo sprendimus atsižvelgiant į tikimybių tankio funkcijos skirstinio parametrus: histogramą, vidurkį, medianą, modą ir kt. Sprendimas priimamas atsižvelgiant į skirstinio vidurkį, kaip labiausiai tikėtiną vertę, verčių išsibarstymą kaip riziką suklysti ir tikimybes, kad priimtas sprendimas duos tikėtiną rezultatą.



**2.4 pav.** Tankio funkcijos grafikai a) atsitiktinės prognozės; b) priklausomos nuo įvesčių prognozės (šaltinis: McKay 1995)

**Fig. 2.4** Graphs of density function a) random projection b) dependent from outputs projection (source: McKay 1995)

### 2.3.2. Modernioji portfelio teorija

**Pelningumas, rizikingumas ir patikimumas.** Investicijų portfelis – tai įvairių investicijų fondas, kurį investuotojas naudoja siekdamas gauti pelną (ar pajamas), tuo pačiu metu siekiant išsaugoti investuotą (pagrindinę) sumą. Portfeliai gali būti vienalyčiai – sudaryti iš vienaarūšių instrumentų (pvz tik akcijų, tik valiutų ir kt.) ir nevienalyčiai, kurie sudaromi iš skirtingų rūšių instrumentų.

Turto alokacija (angl. *asset allocation*) yra sprendimo, kaip paskirstyti investuotojo turtą tarp skirtingų investavimo instrumentų investavimo tikslais, procesas. Informacija, kurią investuotojas turi prieš priimdamas sprendimą, yra labai neapibrėžta, jos yra labai daug ir įvairios, ji nuolat sparčiai kinta. Todėl siekiant sėkmingai investuoti, reikia turėti patikimą investavimo politiką, mokėti įvertinti finansines, ekonomines ir politines sąlygas. Taip pat svarbu laikytis pasirinkto plano drausmės, gebėti valdyti emocijas, nuolat tobulinti įgūdžius, atsižvelgiant į patirtį ir teorines žinias.

Paprasčiausias būdas apibrėžti investicijų portfelį – nurodyti jo sudėtį, t. y. nurodyti vienos ir kitos investicijų rūšies, įeinančios į portfelį, kiekį, arba nurodyti vertinę vienos ar kitos investicijos dalį tarp bendros portfelyje esančios investicijos vertės. Tegul investicinį portfelį sudaro  $n$  instrumentų aibė;

$$A = \{a_1, a_2, \dots, a_n\}. \quad (2.18)$$

60 2. SPRENDIMO PRIĖMIMO NEAPIBRĖŽTYJE TEORINIAI PAGRINDAI

Kiekvienas aibės instrumentas turi ne tik pavadinimą, savo gyvavimo istoriją, santykį su investuotoju ir kitus kokybinius rodiklius, bet ir tiesiogiai išmatuojamus bei numanomus rodiklius. Jei planuojamas instrumento  $i$  pelningumas yra  $ER_i$ , o investuojamų pinigų procentas, skiriamas instrumentui  $i$ , yra  $W_i$ , tai planuojamas portfelio pelningumas yra (Kancerevičius 2009):

$$ER_p = \sum_{i=1}^n W_i * ER_i, \quad (2.19)$$

jei investuojama suma yra pastovi, tuomet

$$\sum W_i = 1. \quad (2.20)$$

Standartinio modelio atveju (Markowitz (1952)) yra papildoma sąlyga – visiems  $i$  turi būti  $W_i \geq 0$ . Tai reiškia, kad investuojant galimas tik pirkimas (angl. *long position*), negalimi instrumentų pardavimai (angl. *short position*). O Bleko modelyje (Black (1974)) tokio apribojimo nėra. Valiutų rinkoje galimi tiek, pirkimai tiek pardavimai, todėl galimas didesnis pelningumas.

Tobino, Šarpo ir Lintnero (TŠL) modelis (Todd 2000) numato, jog egzistuoja nerizikinga investicija, kurios pelningumas nepriklauso nuo rinkos būklės ir visada turi vieną ir tą pačią reikšmę. Pagal šį modelį portfelį galima suskaidyti į rizikingo ir nerizikingo portfelio tiesinę kombinaciją. Toks suskaidymas sudaro galimybę įvertinti aktyvus.

Investicinio pasiūlymo rizikos laipsnis išreiškiamas šiomis statistinėmis charakteristikomis:

**Dispersija  $D$ .** Nepastovumą geriausiai apibūdina dispersija. Taip susidaro prielaida dispersiją arba vidutinį kvadratinį nuokrypį įvardinti absoliučiu rizikingumo matu, kuris apskaičiuojamas naudojant formulę (Kancerevičius 2009):

$$D = \sum p_t (NPV_t - NPV')^2, \quad (2.21)$$

čia  $NPV_t$  – investicinio pasiūlymo  $t$  laikotarpio grynoji dabartinė vertė;  $NPV$  – investicinio pasiūlymo vidutinė grynoji dabartinė vertė;  $p_t$  –  $t$  laikotarpio pinigų srauto tikimybę išreiškiantis koeficientas.

Dispersija įvertina galimų gryniosios dabartinės vertės reikšmių nuokrypio nuo vidutinės laukiamos gryniosios dabartinės vertės laipsnį ir yra rizikos, susijusios su šia grynąja dabartine verte, matas. Be to, dispersija įvertina ne tik galimų gryniosios dabartinės vertės reikšmių nuokrypių nuo vidutinės reikšmės dydį, bet ir šių nuokrypių tikimybes.

**Standartinis nuokrypis**  $\sigma$ . Standartinis nuokrypis apibrėžiamas kaip absoliutus rizikingumo matas. Standartinis nuokrypis yra statistinis dispersijos matas, kuris apskaičiuojamas pagal formulę (Kancerevičius (2009)):

$$\sigma = \sqrt{D} = \sqrt{\sum p_t (NPV_t - NPV')^2}. \quad (2.22)$$

Standartinis nuokrypis matuoja investicinių pasiūlymų rezultatų nepastovumą, t. y. rizikingumo lygmenį. Kuo didesnis standartinis nuokrypis, tuo platesniu diapazonu gali svyruoti laukiamas rezultatas, tuo rizikingesnis investicinis pasiūlymas, ir atvirkščiai.

Rizikingumas apskaičiuojamas remiantis istoriniais duomenimis, darant prielaidą, kad instrumento vertės dinamika ateityje bus tokio pat pobūdžio, kaip ir praeityje. Tuo tarpu nustatyti planuojamus instrumentų pelningumus yra žymiai sudėtingiau. Naudojamas slankusis aritmetinis vidurkis (Roll 1983, Missiakoulis *et al.* 2010), slankusis svorinis harmoninis vidurkis (Jean 1984, Missiakoulis *et al.* 2012), geometrinis vidurkis (Latane 1959, Weide *et al.* 1977, Santiago, Estrada 2011) ir jų hibridai (Cooper 1996, Indro, Lee 1997, Markowitz 2012). Tokie vertinimai visada yra tikimybinio pobūdžio. Rutkauskas (2000) pasiūlė „investicijų kompoziciją nagrinėti kaip atsitiktinį dydį arba, kita vertus, kad atsitiktinio dydžio analizės metodika būtų visiškai pritaikyta portfelio analizei, visų pirma tikslinga panagrinėti, kaip atrodo visų galimų portfelių aibė, kai vietoje vidurkio imamas bet kuris investicijų kompoziciją nusakančio skirstinio kvantilis“. Pagal priimtą atsitiktinių dydžių terminologiją, skirstinio  $\alpha$  lygmens kvantiliu vadiname tokį tašką (galimybę)  $a$ , kad  $P\{\xi \geq a\} = p_\alpha$  arba  $P\{\xi \leq a\} = 1 - p_\alpha$ . Savo ruožtu tikimybė  $P\{\xi \geq a\}$  suprantama kaip patikimumo arba garantijos rodiklis, kad jūsų galimybė bus nemažesnė už  $a$ .

Taigi, sudarant investicinių portfelių, atsižvelgiama į tris pagrindinius kiekybinius rodiklius – pelningumą, rizikingumą ir patikimumą.

**Portfelio optimizavimas.** „Geras“ portfelis nereiškia, kad jį sudaro pavienės „geros“ investicijos. Portfelio sudarymo esmė yra ta, kad investicijos, kokios jos bebūtų, yra susijusios viena su kita. Dėl to, konstruojant optimalų portfelį, reikia į tą ryšį atkreipti deramą dėmesį (?).

Efektyvus dvimatis portfelis (pelningumas-rizika) yra apibūdinamas kaip portfelis, kuris turi mažiausią riziką duotam pelningumui arba didžiausią pelningumą duotam rizikos lygiui (Kancerevičius 2009).

$$\begin{cases} \max & ER_p \\ \min & \sigma^2 \end{cases} .$$

čia

$$ER_p = \sum_{i=1}^n W_i ER_i; \quad (2.23)$$

$$\sigma^2 = \sum_{i=1}^n W_i^2 \sigma_i^2 + 2 \sum_{i=1}^n \sum_{j=i+1}^n W_i W_j r_{ij} \sigma_i \sigma_j, \quad (2.24)$$

su sąlyga  $\sum W_i = 1$ . Čia  $ER_p$  yra investicinio portfelio tikėtina graža;  $ER_i$  – portfelio įrankio  $i$  tikėtina graža;  $W_i$  yra investicija į įrankį  $i$ ;  $W_j$  yra investicija į įrankį  $j$ ;  $r_{ij}$  yra koreliacijos koeficientas tarp portfelio įrankių  $i$  ir  $j$ ;  $\sigma_i$  yra įrankio  $i$  standartinis nuokrypis;  $\sigma_j$  yra įrankio  $j$  standartinis nuokrypis.

Roll (1980) suformulavo investicinio portfelio sąlygą, kuri padeda išspręsti efektyvaus portfelio optimizavimo uždavinį – ortogonalus portfelis yra tas, kuris tenkina sąlygą:

$$Var = \sum_{ij} r_{ij} \sigma_i \sigma_j = 0. \quad (2.25)$$

### 2.3.3. Trimatis portfelio vertinimas (pelningumas, rizika, patikimumas)

Efektyvus trimatis portfelis yra apibūdinamas kaip portfelis, kuris turi mažiausią riziką duotam pelningumui su tam tikra tikimybe arba didžiausią pelningumą duotam rizikos laipsniui su tam tikra tikimybe (Rutkauskas 2008). Tikimybė šiuo atveju padeda investuotojui realiai įvertinti investavimo galimybes.

Jeį prognozavimo įrankis yra dirbtinio intelekto sistema, ansamblis, kurio elementų kiekis yra didelis  $N$ , o prognozė yra skirstinys, tada vieno investicinio portfelio elemento prognozuojamas pelningumas yra  $ER_i = W_i(ER_d - Me)$ . Čia  $ER_d$  yra momentinė dabartinė instrumento vertė, o  $Me$  prognozuojama skirstinio mediana.  $\sigma_i$  – skirstinio standartinis nuokrypis, o patikimumą nusako tikimybė  $P(i) = \frac{f}{n}$ , čia  $f$  yra medianos dažnis histogramoje. Kadangi investuotojui svarbesnė yra instrumento vertės kitimo kryptis, o ne pati vertė, galime vietoje  $f$  naudoti  $f_L = \sum f_{Me > ER_d}$ , kai elementą reikia „pirkti“ ir  $f_S = \sum f_{Me < ER_d}$  – kai „parduoti“. Tuomet pelningos investicijos tikimybė bus žymiai didesnė.

Straipsnių (Rutkauskas 2000, Rutkauskas 2006) autorių pasiūlyto adekvataus portfelio lygtys tada atrodys taip:

$$\begin{cases} \max & ER_p \\ \min & \sigma^2 \\ \max & P_p \end{cases},$$

čia

$$ER_p = \sum_{i=1}^n W_i (ER_{di} - Me_i); \quad (2.26)$$

$$\sigma^2 = \sum_{i=1}^n W_i^2 \sigma_i^2 + 2 \sum_{i=1}^n \sum_{i=j}^n W_i W_j r_{ij} \sigma_i \sigma_j; \quad (2.27)$$

$$P_p = \Pi_i \frac{f_i}{N}. \quad (2.28)$$

Sąlyga  $\sum W_i = 1$  ir ortogonalumo sąlyga (Roll (1980))  $\sum_{ij} r_{ij} \sigma_i \sigma_j = 0$  palengvina optimizavimo uždavinio nagrinėjimą.

Iš 2.6–2.8 lygčių matome, kad gavus prognozių skirstinį, atsižvelgiant į jo formą, galima gauti daug informacijos investavimo sprendimui priimti. Apskaičiuoti skirtumai  $(ER_d - Me)$  nusako, kokį veiksmą reikia atlikti – pirkti ar parduoti portfelio instrumentą. Kuo skirstinys smalesnis, tuo sprendimo tikimybė yra didesnė, tuo patikimesnė investicija į instrumentą. Kuo labiau yra išsibarsčiusios prognozės, tuo didesnis  $\sigma_i$ , tuo didesnė rizika investuoti į pasirinktą instrumentą. Investuojant patogiu nusistatyti taisyklę, pavyzdžiui,  $\sigma_i < 20\%$ , ir jos laikytis. Iš lygties 2.8 seka, kad tikimybė, jog visi portfelio elementai elgsis kaip prognozuojama, visada yra maža. Neapibrėžties sąlygomis investuojant taip ir yra, maksimalaus pelno pasiekti neįmanoma, bet uždirbti investuojant galima ir kai dalis prognozių portfelyje yra neteisingos. Viskas priklauso nuo prognozavimo įrankio tikslumo ir patikimumo. Investavimo sprendimui priimti informacijos daugiau suteikia atskirų prognozių tikimybių aibė. Ją taip pat galima įvairiai apibrėžti, t. y. įtraukti į portfelį tik tuos elementus, kurių tikimybės yra didesnės nei pasirinktas dydis.

Atskiro dėmesio reikalauja portfelio ortogonalumo sąlyga. Kadangi rasti instrumentus, kurių tarpusavio koreliacija  $r_{ij}$  būtų lygi 0, yra beveik neįmanoma, analogiškai kaip ir dirbtinio intelekto įvestyse formulėje 2.13 įvedame artumo ortogonalumui laipsnį  $\varepsilon$ :

$$\left| \sum_{ij} r_{ij} \sigma_i \sigma_j \right| = \varepsilon. \quad (2.29)$$

Ši sąlyga leidžia investuotojui sudaryti portfelį iš investavimo įrankių, kurie tarpusavyje mažiausiai susiję, kurių koreliacijos koeficientas  $r_{ij}$  yra mažiausias. Taip pat, gavus prognozių skirstinį iš dirbtinio intelekto sistemos, galima įvertinti instrumentų rizikingumus  $\sigma_i$  ir  $\sigma_j$ , derinti didesnius standartinius nuokrypius su mažesniais, optimizuojant investicinį portfelį.

### 2.3.4. Investicinio portfelio efektyvumas

Skaičiuojant vidutinę grynąją dabartinę vertę, dispersiją bei standartinį nuokrypį, nustatoma tik absoliuti rizikos reikšmė, todėl norint įvertinti ir palyginti keletą investicinių priemonių, naudojami indeksai, įvertinantys pelningumo ir rizikos santykį. Willjamo F. Sharpe (1994) pasiūlytas Sharpe indeksas, apskaičiuojamas pagal formulę:

$$S_p = \frac{\bar{r}_p - r_f}{\sigma_p}, \quad (2.30)$$

čia  $\bar{r}_p$  – vidutinis investicinės priemonės pelningumas;  $r_f$  – vidutinė nerizikinga palūkanų norma;  $\sigma_p$  – portfelio pelningumo standartinis nuokrypis.

Sharpe indeksas nusako tikėtiną kapitalo grąžą vienam rizikos vienetui lyginant su saugia investicija. Šis rodiklis naudojamas kai reikia palyginti keletą investicinių priemonių, pasirinkti investavimo strategiją. Sharpe rodiklis, apskaičiuotas naudojant istorinius daugelio periodų  $T$  duomenis, leidžia tikėtis atitinkamos investavimo sėkmės ir ateityje. Jis nenusako koreliacijos, jis tiesiog palygina investiciją su saugia investicija, kaip su standartu. Tinkamai naudojamas Sharpe indeksas gali labai palengvinti investicijų valdymą.

Sudarant investicinį portfelį, Sharpe rodiklio maksimizavimo uždavinys atitinka geriausios investavimo strategijos pasirinkimą (Jobson, Korkie (1982)).

Pritaikyta Sharpe rodiklio asimetrija (ASSR angl. *Ajusted for Skewness Sharpe Ratio*) – tai investicinių portfelių rodiklis, kuris praplečia Sharpe rodiklio naudojimo galimybes (Koekebakker, Zakamouline 2007).

$$ASSR = S_p \sqrt{1 + b \frac{Skew}{3} S_p}, \quad (2.31)$$

čia  $S_p$  – standartinis Sharpe rodiklis,  $b$  – investuotojų realioji pirmenybė skirstinio asimetrijai,  $Skew$  – tikėtinos grąžos funkcijos asimetrija.

$$skew = \frac{1}{nD^{\frac{3}{2}}} \sum_{i=1}^n (x_i - \bar{x})^3, \quad (2.32)$$



čia  $n$  – bandymų skaičius,  $D$  – skirstinio dispersija,  $\bar{x}$  reikšmių vidurkis. O skirstinio smailumas apskaičiuojamas pagal formulę:

$$kurt = \frac{\sum (x - \bar{x})^4}{n\sigma^4} - 3. \quad (2.33)$$

Zakamouline, Koekebakker (2009) pristato ASSR kaip rodiklį, kuris matuoja portfelio gražos skirstinio asimetriją, aprašo jo sąsajas su naudingumo funkcija. ASSR maksimizavimas tiesiogiai susijęs su tikėtinos naudingumo funkcijos maksimizavimu. Standartinis normalusis skirstinys atitinka atsitiktinį pelningumą, skirstinys su kairiąja asimetrija – pelningumo sumažėjimą, o su dešiniąja – pelningumo padidėjimą.

Tačiau Sharpe rodiklio trūkumas yra tas, kad į jo skaičiavimą įtraukiamas ir teigiamas svyravimas, o tai nėra svarbu investuotojams. Todėl tinkamesnis yra Sortino rodiklis (Sortino, Price 1994), kurio formulė labai panaši į Sharpe rodiklio, tik vietoj standartinio nuokrypio naudojamas neigiamas standartinis nuokrypis.

$$S_p = \frac{\hat{r}_p - \hat{r}_f}{\sigma_j}, \quad (2.34)$$

čia  $\hat{r}_p$  – vidutinis investicinės priemonės pelningumas;  $\hat{r}_f$  – vidutinė nerizikinga palūkanų norma;  $\sigma_j$  – neigiamų portfelio gražų standartinis nuokrypis.

Didelė Sortino rodiklio reikšmė rodo žemą nuostolių riziką.

## 2.4. Antrojo skyriaus išvados

1. Prognozavimo finansų rinkose įrankio galimybes atskleidžia universalioji dirbtinio intelekto teorija.
  - 1.1. Evolino rekurentinis neuroninis tinklas, pritaikytas prognozavimui, tenkina Turingo testo nuostatą – automatiškai prisitaikyti, naudojant turimas žinias, ir daryti naujas išvadas iš tų žinių. Todėl jis gali būtų pripažintas dirbtinio intelekto algoritmu.
  - 1.2. Prognozavimo sistemos pasirinkimas, vidinių ir išorinių parametru suderinimas, ansamblių naudojimas atveria galimybes gauti pasirinkto pobūdžio instrumentą.
2. Prognozės vertinimo aspektus lemia universaliosios prognozės galimybių teorija.

66 2. SPRENDIMO PRIĖMIMO NEAPIBRĖŽTYJE TEORINIAI PAGRINDAI

---

- 2.1. Ekspertiniai metodai turi savybių, kurios leidžia taikyti juos ne tik žmonių-ekspertų, bet ir dirbtinio intelekto sistemų įverčių vertinimui.
- 2.2. Prognozavimas visada vyksta neapibrėžties sąlygomis ir prognozė galima tik atsižvelgiant į jos vyksmo tikimybes.
3. Investicinio portfelio parinkimo principus nusako modernioji portfelio teorija.
  - 3.1. Naudojant trimatį efektyvaus portfelio vertinimą (pelningumas – rizikingumas – patikimumas) prognozių skirstiniams, gautiems iš dirbtinio intelekto sistemos, adekvačiojo portfelio lygtys tampa labai informatyvios ir sudaro sąlygas pelningam investavimui.
  - 3.2. Portfelio ortogonalumo sąlyga, naudojant artumo ortogonalumui laipsnį, gali būti naudojama rangavimui investicinių instrumentų portfelyje.
  - 3.3. Portfelio efektyvumo matavimo indeksai suteikia investuotojui papildomos informacijos vertinant investicijas.

# 3

## Paramos sistema investuotojui valiutų rinkoje

Šiame skyriuje pateikiama paramos sistema investuotojui valiutų rinkoje, apjungianti dirbtinio intelekto sistemas su šiuolaikine investicinio portfelio teorija. Čia analizuojamos paramos sistemos sukūrimo prielaidos, veikimo principas, prognozavimo modelių tikslumo ir patikimumo eksperimentinis vertinimas. Nuosekliai nagrinėjamas vienetinės, intervalinės ir skirstinių prognozės teikiamas informatyvumas ir tikslumas. Stochastiškai informatyvi didelio rekurentinių tinklų ansamblio prognozė pritaikyta adekvačiojo portfelio suformavimui valiutų rinkoje. Sukurta paramos sistema investuotojui testuota imitacinės Forex valiutų rinkos duomenimis realiu laiku. Skyriaus rezultatai pateikti šiuose moksliniuose darbuose: Maknickienė, Maknickas (2013), Maknickienė, Maknickas (2013a), Stankevičienė, Maknickienė, Maknickas (2014), Rutkauskas, Stasytė, Maknickienė (2014), Maknickienė (2014), Rutkauskas, Levickaitė, Maknickienė (2014).

### 3.1. Dirbtinio intelekto algoritmų pritaikymas finansų rinkos priemonių prognozavimui

Finansų rinkų prognozavimui labai svarbus tinkamo metodo, algoritmo ar įrankio pasirinkimas, jo galimybių tikslumo ir patikimumo žinojimas. Kita vertus,

finansų rinkos instrumentų ir duomenų gausa, galimybė gauti didelį kiekį istorinių duomenų, prekiauti realiu laiku tiek realioje, tiek imitacinėje rinkoje, sudaro puikias sąlygas prognozavimo įrankių kūrėjams kurti, testuoti ir tobulinti savo kūrinius.

### 3.1.1. Evolino rekurentinio neuroninio tinklo derinimas ir įvesčių parinkimas

Siekiant prognozuoti, pirmiausia sukuriama finansinių priemonių, reikalingų tyrimui, istorinių duomenų bazė. Pasirenkami akcijų indeksų, tauriųjų metalų, žaliavų, akcijų ar valiutų kursų istoriniai duomenys. Siekiant tirti valiutų rinką, sukurta duomenų bazė, apimanti šiuos valiutų kursus: USD/JPY (Jungtinių Amerikos Valstijų dolerio ir Japonijos jenos), EUR/USD (Euro ir Jungtinių Amerikos Valstijų dolerio), EUR/JPY (Euro ir Japonijos jenos), EUR/CHF (Euro ir Švedijos franko), GBP/USD (Jungtinės Karalystės svarų sterlingų ir Jungtinių Amerikos Valstijų dolerio), GBP/AUD (Jungtinės Karalystės svarų sterlingų ir Australijos dolerio), NZD/CAD (Naujosios Zelandijos dolerio ir Kanados dolerio), USD/CHF (Jungtinių Amerikos Valstijų dolerio ir Švedijos franko), nagrinėjanti dviejų metų dieninius istorinius duomenis, kasdien juos papildant naujais. Taip pat tauriųjų metalų: XAUUSD (aukso kaina Jungtinių Amerikos Valstijų doleriais), XAGUSD (sidabro kaina Jungtinių Amerikos Valstijų doleriais); žaliavų: QM (Naftos kaina Jungtinių Amerikos Valstijų doleriais), QG (Dujų kaina Jungtinių Amerikos Valstijų doleriais). Pirmiausia atliekamas tyrimas tik su istoriniais duomenimis, todėl dešimt paskutinių duomenų naudojami prognozavimo sutapimui įvertinti, vėliau testuojama ateities prognozė. Dieniniai duomenys geriausiai atitinka naudojamas skaičiavimo resursų technines galimybes.

Taip pat tirtos Baltijos akcijų rinkos dalyvės – APG1L (Apranga), TAL1T (Talink Group), TEO1L (TEO LT) ir Baltijos biržos indeksai – OMXV, OMXR, OMXT, OMXB. Kadangi Baltijos biržoje sandoriai atskiromis akcijomis vyksta ne kasdien, Evolino rekurentinis neuroninis tinklas neįvykusį sandorį prilygina jo nulinei kainai, taigi prognozavimas tampa absurdišku. Baltijos akcijų indeksų kitimas nėra chaotiškas, lengvai prognozuojamas tiek su, tiek be dirbtinio intelekto sistemos, pelningas tik ilgalaikėje investavimo strategijoje. Todėl didesnis dėmesys skiriamas pasaulinėms finansinėms priemonėms.

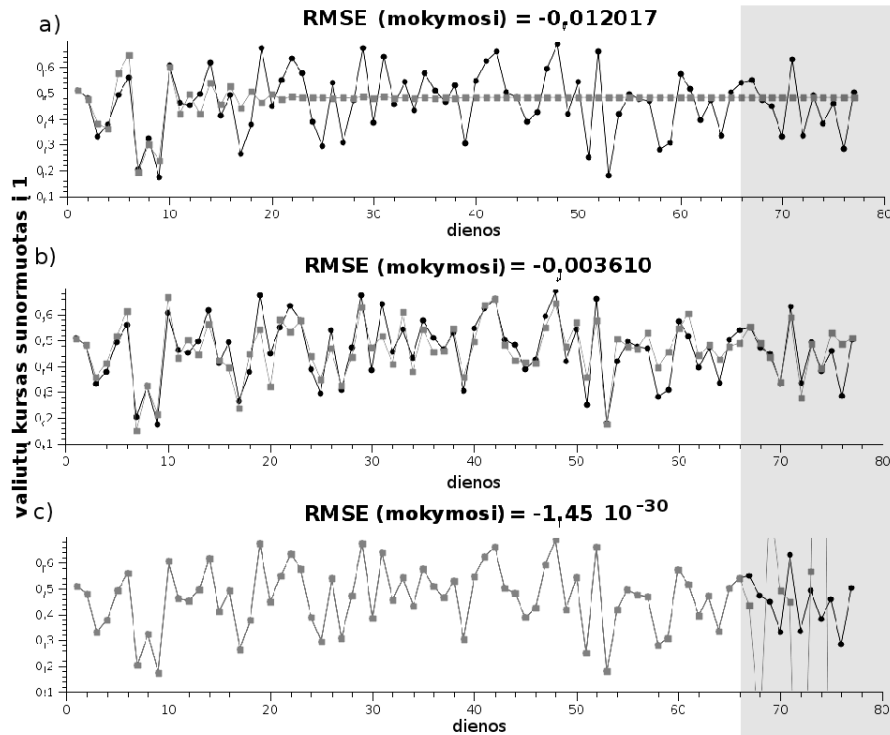
Visuose dirbtinio intelekto sistemų taikymo uždaviniuose labai svarbi dalis yra įvesčių parinkimas. Evolino algoritmas buvo pakeistas, kad galėtų naudoti dvi įvestis – vieną, atitinkančią prognozuojamą finansinį rodiklį, kitą – parenkamą kaip „mokytojas“.

Evolino rekurentinio neuroninio tinklo taikytojai gali pasirinkti svarbiausius vidinius parametrus:

- iteracijų (pakartojimų) skaičių, nusakanti, kiek kartų neuroninis tinklas kartoja mokymosi procesą;
- neuronų kiekį, nusakanti, kiek neuronų naudojama užduočiai atlikti;
- istorinių duomenų įvestyse kiekį, nusakanti, kokia duomenų apimtis reikalinga tikslui pasiekti.

Intuityvus spėjimas, kad visi šie parametrai turi būti maksimalūs, nepasiteisino, todėl buvo atliktas skaitinis eksperimentinis tyrimas, kurio metu buvo siekiama rasti geriausias Evolino rekurentinio neuroninio tinklo būsenas finansinių rinkų priemonių prognozavimui. Nuoseklaus tyrimo metu, keičiant iteracijų skaičių, neuronų skaičių ir istorinių duomenų kiekį buvo tirtas Evolino rekurentinio neuroninio tinklo gebėjimas atkartoti istorinius duomenis ir prognozuoti naujus, nežinomus 3 proceso taškus. Didinant iteracijų skaičių, mokymosi ir prognozavimo tikslumas iš pradžių sparčiai didėja, bet, pasiekęs tam tikrą lygį (150 iteracijų), nebesikeičia, todėl daugiau didinti kartojimų skaičių, o kartu ir prognozavimo trukmę, nebėra prasmės. Neuronų skaičiaus ir istorinių duomenų apimties kitimas yra akivaizdžiai priklausomi tarpusavyje ir egzistuoja toks jų atitikimas, kad prognozavimas yra tiksliausias. Atliekant tyrimą, pasitvirtino žmonių elgsenai būdingas dėsnis, kad produktyvus mąstymas tiesiogiai nepriklauso nuo reproduktyvaus mąstymo (Rimkutė 2007), geresnis neuroninio tinklo mokymasis negarantuoja geresnio prognozavimo. Pastebėtas trijų tipų prognozės Evolino rekurentiniu neuroniniu tinklu elgsys: silpnas mokymasis ir neprognozavimas, geras mokymasis ir geras prognozavimas, puikus mokymasis, bet blogas prognozavimas. Tai pavaizduota 3.1 paveiksle. Prieš pradėdant naudoti įrankį, būtina jo parametrus suderinti taip, kad rezultatai būtų gero mokymosi ir gero prognozavimo srityje. Dažniausiai tai daroma stebint grafinį atvaizdavimą ir prognozuojamą paklaidą – jei mokymasis nepakankamas, padidiname neuronų skaičių, duomenų vektorių arba abu šiuos parametrus, jei mokymasis idealus, bet neprognozuoja – mažiname neuronų skaičių arba duomenų vektorių, kol prognozė ir mokymasis susibalsuoja. Tokiu būdu pasirinkti šie parametrų rinkiniai: iteracijų skaičius 180, neuronų kiekis intervale [56; 72], istorinių duomenų įvestyse kiekis intervale [80; 150].

Atsižvelgdami į žmogaus mokymosi ir patirties ypatumus, darome prielaidą, kad įvestys turi būti susiję su išvestimis. Kadangi pasirinkome prognozuoti valiutų kursus (EUR/JPY; EUR/CHF; EUR/USD; USD/JPY), tai tinklo mokymui istorinius dviejų metų prognozuojamo valiutų kurso duomenis imame kaip duomenų bazę, kuri geriausiai atspindi prognozuojamo valiutų kurso kitimą




**3.1 pav.** Trijų tipų prognozės elgesys: a) silpnas mokymasis ir neprognozavimas; b) geras mokymasis ir geras prognozavimas; c) puikus mokymasis, bet blogas prognozavimas

**Fig. 3.1** Three types of behaviour: a) weak learning and no forecasting; b) good learning and good forecasting; c) excellent learning, but no forecasting

laike. Šveicarijos mokslininkų sukurtas Evolino rekurentinis neuroninis tinklas (Wierstra *et al.* 2005, Schmidhuber *et al.* 2005) pritaikomas dviems įvestims ir, išbandžius keletą įvairių variantų, antroje įvestyje pasirenkami naudoti fondų biržos elementų (XAUUSD; XAGUSD; QM; GM) kainų dviejų metų istoriniai duomenys. Iš šių duomenų formuojamas reikiamas duomenų rinkinys įvestims.

Dirbtinio intelekto įvesčių parinkimui svarbu įvertinti įvesčių tarpusavio ryšį – arba įvestys turi būti labai artimos, priklausomos viena nuo kitos, arba priešingai – kuo labiau skirtis. Šiam ryšiui nustatyti naudojome ortogonalumo lygtis (2.12). Apskaičiuodami  $\varepsilon$ , turime matavimo skalę įvesčių tarpusavio ryšiui nustatyti. Algoritmas paima paskutinius žinomus prognozuojamo duomenų vektorius  $n$  valiutų kursus ir jiems parenka tokį pat kiekį  $n$  duo-

menų iš „mokytojo“ duomenų vektoriaus (3.2 pav.) taip, kad jų  $\varepsilon$  būtų mažiausiai. Atliktuose bandymuose finansų rinkos įvairioms investicijoms buvo gauti  $\varepsilon \in [0,000000001; 0,001]$ .



**3.2 pav.** Ortogonalinių įvesčių parinkimas iš prognozuojamo ir „mokytojo“ duomenų vektorių


**Fig. 3.2** Selection of orthogonal inputs from forecasting and "teaching" data vectors

Atliktas statistinis tyrimas, pasirenkant galimus geriausius ortogonalumus  $[1e - 9; 1e - 6]$  ir grupes su didesnėmis  $\varepsilon$  reikšmėmis  $[1e - 4; 9,99e - 4]$  ir  $[1e - 4; 9,99e - 3]$ , parodė, kad Evolino neuroninis tinklas tiksliau prognozuoja, kai investicijose yra labiausiai ortogonalūs duomenys, kokius tik pavyksta rasti (pav. 3.3).

Siekiant prognozuoti valiutų kursą Evolino rekurentiniu neuroniniu tinklu, reikia suderinti parametrus – iteracijų skaičius turi būti ne mažesnis nei 150, neuronų skaičius 52–64, duomenų kiekis 90–150. Iš „mokytojų“ pasirenkamas tas, kurio galimas geriausias ortogonalumo įvertis  $\varepsilon$  yra mažiausias –  $[1e - 9; 1e - 6]$ .

Finansų rinkų priemonių prognozavimui naudojant vieną Evolino rekurentinį neuroninį tinklą, įgyta patirtis leido sukurti ne tik prognozavimo modelį, bet ir patikimą paramos sistemą investuotojui.

Mokslininkai, naudojantys neuroninių tinklų ansamblius (Zhou *et al.* 2002, Tsakonas, Dounias 2005, Nguyen, Chan 2004, Siwek *et al.* 2009), teigia, kad ansamblio prognozė yra tikslesnė ir patikimesnė, nei vieno neuroninio tinklo. Todėl prognozavimo modeliui pasirinkome ansamblio iš  $N$  Evolino rekurentinių neuroninių tinklų architektūrą. Prognozavimo modelio sudėtingumą ir neuroninių tinklų skaičių lėmė techninės galimybės, todėl buvo nagrinėti ir testuoti du skirtingi prognozavimo modeliai: modelis, kai neuroninių tinklų skaičius  $N$  mažas, ir modelis, kai neuroninių tinklų skaičius didelis. Skaičiaus  $N$  dydžio pagrindimas pateikiamas kiekvienu atveju atskirai.



**3.3 pav.** Statistiniai koreliacijos koeficientų skirstiniai: a) tarpusavyje mažiausiai ortogonalioms  $[1e - 4 - 9,9e - 4]$  įvestims; b) tarpusavyje maksimaliai ortogonalioms  $[1e - 9 - 9,9e - 5]$  įvestims

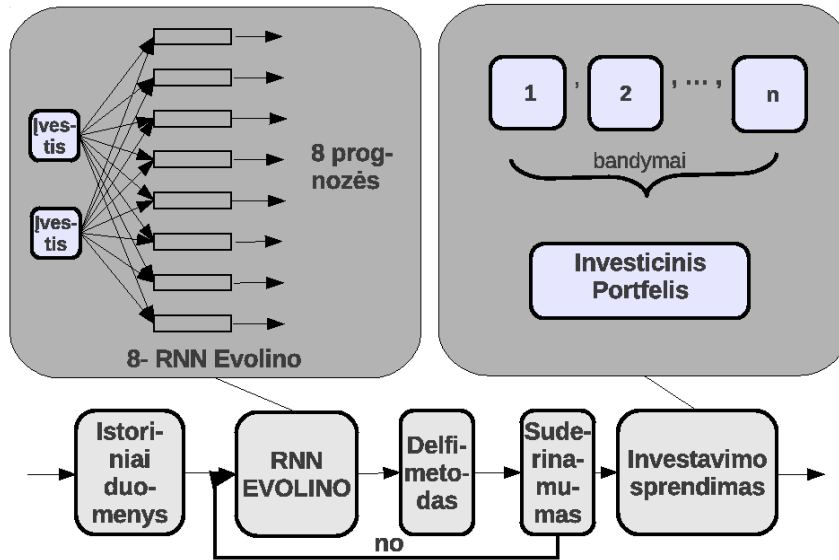
**Fig. 3.3** Distributions of statistical correlation coefficients: a) less orthogonal  $[1e - 4 - 9,9e - 4]$  inputs b) maximally orthogonal  $[1e - 9 - 9,9e - 5]$  inputs

### 3.1.2. Prognozavimo modelis, kai Evolino rekurentinių neuroninių tinklų skaičius ansamblyje yra mažas

Šis modelis yra paprastas naudoti, jam pakanka paprasto personalinio kompiuterio resursų. Prognozavimo modelį sudaro trys pagrindinės dalys: įvesčių paruošimas, Evolino rekurentinių neuroninių tinklų ansamblis, ekspertinė vertinimo sistema.



Evolino rekurentinių neuroninių tinklų skaičių  $N$  lemia ekspertinių metodų reikalavimas  $n \geq 7$ . Prognozavimo modelio schema pavaizduota 3.4 paveiksle.



3.4 pav. Prognozavimo modelio schema kai Evolino rekurentinių neuroninių tinklų skaičius  $N = 8$ , mažas

Fig. 3.4 Scheme of forecasting model, when number of recurrent neural networks is  $N = 8$ , small

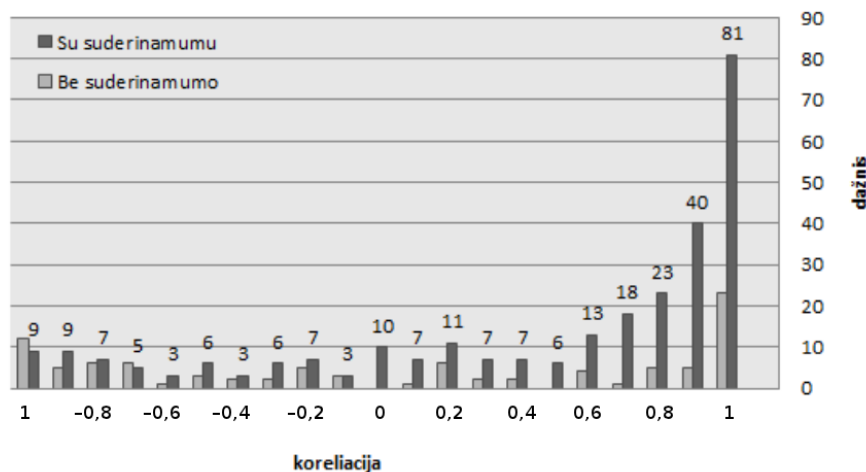
Įvesčių parinkimas. Įvestyse naudojamos skaitinės 2 metų istorinių duomenų reikšmės: vienoje įvestyje – norimo prognozuoti valiutų kurso istorinių duomenų skaitinės reikšmės, o kitoje – „apmokymui“ pasirinkto rinkos dalyvio istorinių duomenų skaitinės reikšmės. Šiame etape prognozavimui pasirinkti 5 valiutų kursai: EUR/USD (euro ir JAV dolerio santykis), EUR/JPY (euro ir Japonijos jenos santykis), USD/JPY (JAV dolerio ir Japonijos jenos santykis), EUR/CHF (euro ir Suomijos franko santykis). Pastarojo kitimui „prisirišus“ prie euro, imtas naudoti GBP/USD (Jungtinės karalystės svarų sterlingų ir JAV dolerio santykis). „Apmokymui“ pasirinktos metalų kainos: aukso (XAUUSD) ir sidabro (XAGUSD) kainų JAV doleriais istoriniai dviejų metų duomenys. Taip pat naudoti naftos (QM) ir dujų (QG) kainų JAV doleriais istoriniai dviejų metų duomenys. Atsižvelgdamas į aprašytą duomenų tarpusavio ortogonalumo įtaką prognozavimo tikslumui, algoritmas naujausiems prognozuojamo valiū-

tų kurso duomenų 80–140 taškams parenka po 8 atitinkamo dydžio mažiausio tarpusavio ortogonalumo intervalus su kiekvienu „apmokymui“ pasirinktu rinkos dalyviu. Sprendimo priėmėjas, analizuodamas gautus rezultatus, pasirenka „mokytoją“ iš keturių rinkos dalyvių. Mažiausias gaunamas ortogonalumas paprastai svyruoja intervale  $[e - 9; 9,9e - 5]$ . Dažniausiai buvo pasirinkti XAU-USD ir QM istoriniai duomenys. Šio etapo pabaigoje turime 8 poras duomenų rinkinių, kurie gali būti naudojami kaip įvestys sekančiame etape.

Dirbtinio intelekto sistemą sudaro 8 vienu metu prognozuojantys Evolino rekurentiniai neuroniniai tinklai, jų veikimo principas aprašytas teorinėje dalyje. Įvestyse kiekvienas iš jų gauna prognozuojamo valiutų kurso  $N$  paskutinius žinomus duomenis ir parinktus ortogonaliausius kito rinkos dalyvio istorinius duomenis iš 2 metų laikotarpio. Visi Evolino rekurentiniai neuroniniai tinklai gauna skirtingus įvesties duomenis, o išvestyse visi pateikia prognozuojamą vertę sekančiai arba kitai pasirinktai dienai. Šio etapo gale turime 8 to paties valiutų kurso prognozes tai pačiai dienai.

Ekspertiniai vertinimo metodai naudojami specialistų nuomonių, prognozių įvertinimui, mūsų modelyje naudojami dirbtinio intelekto sistemų, t. y. Evolino rekurentiniais neuroniniais tinklais gautų prognozių įvertinimui. Stebint atskirai visų 8 prognozių atvaizdavimus, galima pastebėti, kad iš jų viena ar kelios pasitaiko visiškai nelogiškos, neretai net išeinančios už skalės ribų. Likusi prognozių dalis – išsibarsčiusi netoli tikrosios tikrinamos vertės. Todėl, pritaikius Delfi metodą, išdėsčius visas prognozuojamas vertes didėjimo kryptimi, apskaičiavus kvartilius, galima teigti, kad prognozuojama vertė bus tarp 1 ir 3 kvartilės. Mediana šiuo atveju yra arčiau tikrosios vertės nei vidurkis, kuriam didelę įtaką daro labiau nukrypusios vertės. Stebint bendrą grafinę prognozę, išskirtą intervalą tarp kvartilių, galima pastebėti kad RNN prognozių sklaida yra labai įvairi, todėl skaičiuojamas suderinamumas pagal 2.14 formulę ir, jei jis yra intervale  $[0; 0,025]$ , prognozė laikoma patikima, jei ne – antrasis etapas kartojamas iš naujo (kartais paimamas kitas „mokytojas“, jei geriausi ortogonalumai yra artimi). Šio etapo pabaigoje mes turime prognozuojamą pasirinkto valiutų kurso reikšmę. Visų trijų etapų atlikimo trukmė personaliniu kompiuteriu užtrukdavo apie 45 minutes.

Modelio prognozavimo patikimumą ir tikslumą nustatysime atlikdami statistinį tyrimą, palygindami koreliaciją tarp prognozuojamos vertės ir tikros vertės ateityje. Tyrimui imti 2 metų istoriniai duomenys, 2011/10/01–2012/05/31 laikotarpiu, kiekvieną valiutų biržos prekybos dieną duomenis papildant naujais duomenimis. Naudota kasdien keturių valiutų kursų duomenys: EUR/USD, EUR/JPY, USD/JPY, EUR/CHF. Algoritmo pagalba randamos ortogonaliausios įvestys iš 4 pasirinktų (XAU/USD; XAG/USD; QM; QG). Įvairūs valiutų



**3.5 pav.** Koreliacijos koeficientų skirstiniai – su tinkamu suderinamumu intervale  $[0; 0,024]$ , be nuomonių suderinamumo arba intervale  $[0,025; 1]$

**Fig. 3.5** Distributions of correlation coefficients – with compatibility in range  $[0; 0,024]$ , without compatibility or in range  $[0,025; 1]$

kursai ir skirtingos „apmokymo“ įvestys garantuoja atsitiktinį duomenų pobūdį. Kokią įtaką prognozavimo tikslumui daro suderinamumo skaičiavimas, ištirsime palygindami koreliacijos koeficientų histogramas, kurių suderinamumas yra intervale  $[0; 0,024]$  ir intervale  $[0,025; 1]$  (pav 3.5).

Tyrimas parodo, jog kai nuomonių suderinamumas yra intervale  $[0; 0,024]$ , koreliacijos koeficientas 29 % lygus 1, o tai rodo tikslų prognozavimą, 62 % yra intervale  $[0,6; 1]$  ir tai rodo labai gerą prognozavimą, 76 % yra intervale  $[0; 1]$  – tai rodo teisingą valiutų kurso pokyčio kryptį. Kai Evolino rekurentinių neuroninių tinklų prognozių suderinamumas yra intervale  $[0,025; 1]$  (tai nusako labai didelę prognozių sklaidą), atitinkamai koreliacijos koeficientas yra 25 % lygus 1, 39% yra intervale  $[0; 0,024]$ , 51 % yra intervale  $[0,024; 1]$ . Esant Evolino rekurentinių neuroninių tinklų prognozių suderinamumui, artimesniam 0, modelio prognozės tikslumas ir patikimumas yra didesnis.

### 3.1.3. Prognozavimo modelis, kai Evolino rekurentinių neuroninių tinklų skaičius ansamblyje yra didelis

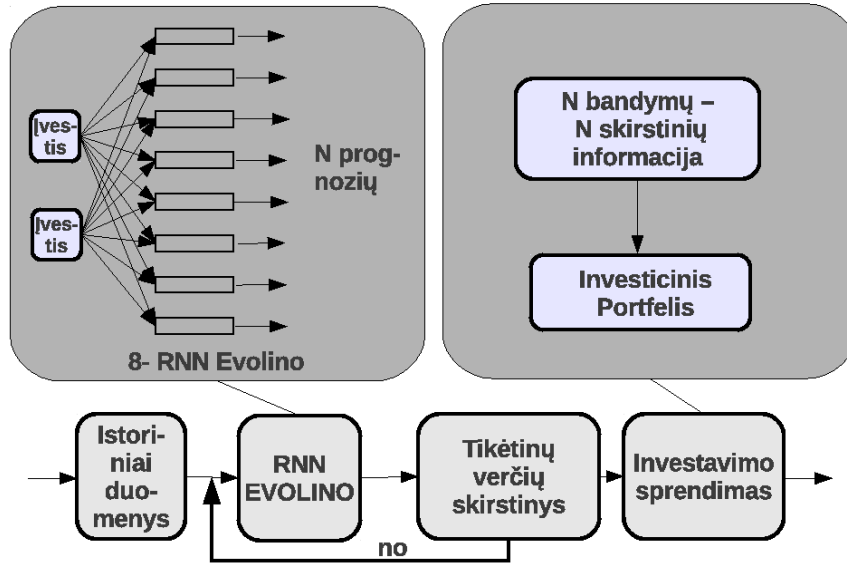
Pirmajame modelyje padidinus Evolino rekurentinių neuroninių tinklų skaičių tiek, kad gautume prognozių skirstinį, gautume kokybiškai naują prognozės

išraišką. Tačiau su turimais resursais tai gali užtrukti labai ilgai – viena prognozė gaunama per 45 minutes. Todėl būtina šį procesą spartinti. Kiekvienas Evolino rekurentinis neuroninis tinklas gali skaičiuoti prognozes atskirai tuo pat metu, tam tikslui šie procesai buvo lygiagretizuoti. Tam naudota mpi4py Dalcin (2012/12/01). Kiekvieno rekurentinio neuroninio tinklo prognozavimo ciklas padalinamas į lygius intervalus ir kiekvienas intervalas skaičiuojamas atskirame procesoriaus mazge. Kadangi sąsaja tarp mpi jungčių nebereikalinga, gaunamas toks, artimas 1, procesų lygiagretizavimo efektyvumas (Fox *et al.* 1989, Kumar *et al.* 1994):

$$S = \frac{1}{P} \frac{T_{seq}}{T(P)}, \quad (3.1)$$

čia  $P$  – procesorių skaičius,  $T(P)$  yra lygiagretaus algoritmo veikimo laikotarpis,  $T_{seq}$  yra nuoseklaus algoritmo veikimo laikotarpis. Pagreitėjimas buvo pasiektas naudojant šešių mazgų Intel(R) Xeon(R) CPU E5645 @ 2.40 GHz procesorių, pasinaudojant www.time4vps.eu debesų paslauga. 300 Evolino rekurentinių neuroninių tinklų ansamblio skaičiavimai atliekami per 612 valandų. Prognozavimo modelio schema pavaizduota 3.6 pav. Pirmoji modelio dalis – *įvesčių parinkimas* – yra tokia pat, kaip pirmame prognozavimo modelyje.

Antroji dalis – *Evolino RNN ansamblis*. Evolino rekurentinių neuroninių tinklų prognozavimui galima pasirinkti  $N$ . Kai  $N > 60$ , gaunamas tam tikros formos prognozių skirstinys, turintis visus skirstiniams būdingus parametrus: vidurkį, medianą, modą, asimetriją, smailumą ir kt. *Investavimo sprendimas* priimamas atsižvelgiant į skirstinio formą ir parametrus. Eksperimentiškai nustatyta kaip kinta prognozavimo tikslumas, lyginant skirstinio medianą su tikrąja valiutų kurso verte, kintant Evolino rekurentinių neuroninių tinklų skaičiui  $N$  nuo 60 iki 300. Prognozavimo tikslumo matu pasirinktas MAPE (2.16 formulė). Testavimui atlikti stebėjimai 2013/01/20–2013/03/15 (3.7 pav.). Gautos prognozavimo tikslumo vertės yra intervale 94–99,6%. Prognozavimo tikslumas ir stabilumas priklauso nuo skaičiaus  $N$ , tačiau didesniai  $N$  reikia daugiau laiko skaičiavimas. Evolino rekurentinių neuroninių tinklų skaičiui  $N$  esant intervale [1; 100], stebimas aukštas tikslumas, bet mažas stabilumas. Skirstinio forma nėra pakankamai aiški ir parametrai nėra pakankamai informatyvūs. Kai  $N$  yra intervale [100; 200], prognozė yra tiksli ir stabili, nereikalauja labai daug laiko ir resursų, prognozių skirstinys yra pakankamai informatyvus. Kai  $N$  yra intervale [200; 300], prognozavimo rezultatas yra puikus investavimui, bet reikalauja pernelyg daug laiko skaičiavimams, jei norime sudaryti investicinį portfelį – investavimo sprendimas finansų rinkoje gali būti priimtas per vėlai.

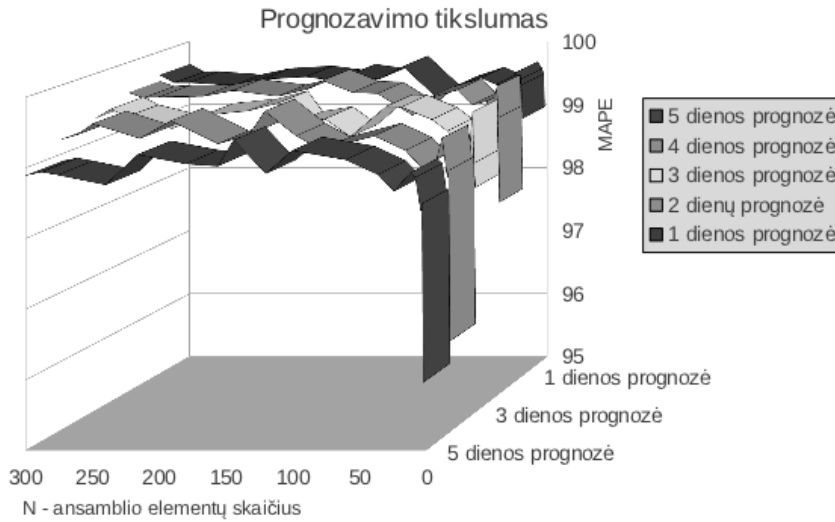


3.6 pav. Prognozavimo modelio schema, kai Evolino rekurentinių neuroninių tinklų skaičius  $N$  yra didelis

Fig. 3.6 Scheme of forecasting model, when number of recurrent neural networks  $N$  is large

1–2 dienų prognozės yra tikslios ir stabilios, o 3, 4 ir 5 dienų į ateitį prognozių tikslumas išauga tik Evolino rekurentinių neuroninių tinklų ansambliui pasiekus 64 elementus. Ateities prognozavimo ir numatymo paklaidos dydis didėja laikui bėgant, nes neapibrėžtis didėja priklausomai nuo prognozuojamo laikotarpio. Kuo daugiau elementų ansamblyje, tuo daugiau laiko trunka skaičiavimai. 200 elementų ansambliui suskaičiuoti keturias prognozes trunka apie 10 valandų. Atlikti 3 bandymai su 1008 Evolino rekurentinių neuroninių tinklų ansambliu 100 % prognozavimo nepasiekė, o laiko tokiems skaičiavimams reikia žymiai daugiau – 3,5 paros. Be to, kartais skaičiavimai nutrūksta, nes jie vykdomi ne personaliniame kompiuteryje, o naudojant 8 papildomus procesorius.

Siekiant optimizuoti investavimo sprendimo priėmimą, tyrimui pasirinkome 176 Evolino rekurentinių neuroninių tinklų (skaičius turi dalintis iš 8, nes naudojame 8 procesorius) prognozavimo įrankį. Jo tikslumas yra pakankamas, skirstinio forma informatyvi, o skaičiavimo laikas nesiekia 10 valandų. Todėl per parą galima suskaičiuoti 8 valiutų kursų prognozes. Investavimo sprendimo priėmimas finansų rinkose visada susijęs su neapibrėžtimi, todėl skirsti-



**3.7 pav.** Prognozavimo tikslumo priklausomybė nuo Evolino rekurentinių neuroninių tinklų skaičiaus, prognozuojant 1–5 dienas į ateitį

**Fig. 3.7** Dependence of forecasting accuracy from number of recurrent neural networks, for 1–5 days ahead

nys prognozuojant yra stochastiškai informatyvesnis, nei pavienės prognozės ar prognozavimo intervalas.

### 3.2. Sprendimo priėmimas rizikos ir neapibrėžties sąlygomis

Suderintas ir parengtas darbui dirbtinės intelekto sistemos įrankis yra patikimas informacijos šaltinis investuotojui. Vienas Evolino rekurentinis neuroninis tinklas pateikia vienetinę prognozę – vieną tašką vienam būsimam įvykiui ateityje. Mažas Evolino rekurentinių neuroninių tinklų ansamblis pateikia keletą atskirų prognozių vienam būsimam įvykiui ateityje. Šioms prognozėms pritaikius ekspertinius vertinimo metodus gaunamos patikimesnės prognozės. Didelis Evolino rekurentinių neuroninių tinklų ansamblis pateikia stochastiškai informatyvų skirstinį, kuris investuotojui pateikia pilnesnį investicinių galimybių rinkinį.

Sukurti prognozavimo modeliai investuotojui suteikia plačias pasirinkimo galimybes – galima rinktis prognozuojamus finansinius įrankius, jų „mokytojus“, siaurinti ar platinti suderinamumo intervalą, sudaryti didesnius ar įvairesnius investicinius portfelius, keisti investavimo trukmę. Pasirinkimą didžia dalimi lemia techninės galimybės – skaičiavimo greitis ir atminties resursai. Visi tyrimai atlikti naudojant personalinį kompiuterį, lygiagrečių skaičiavimą siekiant, kad sprendimo priėmimas būtų priimtas per protingą laikotarpį.

Toliau bus nagrinėjamos investicinio portfelio sudarymo ir optimizavimo galimybės, naudojant jau suderintus prognozavimo modelius, eksperimentiškai vertinamas investicinių portfelių efektyvumas, aprašomi testavimai realioje rinkoje. Į prognozavimo modelį integravus moderniosios portfelio teorijos dėsningumus, gauta patikima paramos sistema investuotojui valiutų rinkoje.

### 3.2.1. Investicijų portfelio optimizavimas naudojant prognozavimo modelį su mažu Evolino rekurentinių neuroninių tinklų skaičiumi

Investiciniam portfeliui sudaryti eksperimentiškai naudojame keturis valiutų kursus (EUR/USD, EUR/JPY, USD/JPY arba GBP/USD), kiekvieną Forex rinkos prekybos dieną gaunami nauji duomenys ir prognozavimo modelio pagalba gaunamos keturios prognozės ( $L_1, L_2, L_3, L_4$ ) pasirinktam 3 dienų laikotarpiui į ateitį. Taip pat naudojamos atitinkamos paskutinės žinomos rinkos uždarymo kainos ( $A_1, A_2, A_3, A_4$ ). Taigi planuojamas instrumento pelningumas yra  $ER_i = L_i - M_i$ . Taikydami 2.23 ir 2.24 formules, bandomė sudaryti efektyvius dvimačius portfelius (pelningumas-rizika), siekiant gauti didžiausią pelną duotam rizikos lygiui. Tyrimui naudoti 3 skirtingi investiciniai portfeliai.

1. Konservatyvus portfelis sudaromas dalinant investavimui pasirinktą sumą visoms keturioms valiutų operacijoms po lygiai – jei prognozuojamas valiutų kurso kilimas – perkame, jei kritimas – parduodame, jei prognozės suderinamumo net ir kartojant prognozavimą nepavyksta gauti – laukiame. Gavus naujus duomenis, pakoreguojame duomenis, papildome investicijų krepšelį uždirbtomis lėšomis ir vėl daliname po lygiai visiems valiutų kursams.

2. Nuosaikųjį imitacinį portfelį sudarome atsižvelgdami į prognozuojamo pelno dydį. Turimą investicijoms sumą daliname atitinkamai gaunamam procentiniam prognozuojamam pelnui  $W_i = \frac{ER_i}{ER_p} W$ .

3. Agresyvus portfelis sudaromas visą investuojamą sumą investuojant į vieną, žadančią didžiausią prieaugį valiutą  $\max(L_1 - A_1, L_2 - A_2, L_3 - A_3, L_4 - A_4) = \max(ER_i)$ .

Eksperto rezultatai atvaizduoti grafiškai 3.8 paveiksle. Trys skirtingi bandymai investuoti atspindi investuotojo galimybes, pasirenkant investavimo strategiją, tikintis atitinkamo pelningumo. Agresyvaus investavimo strategija visais trim bandymais yra pelningiausia – siekia 35–45 %, nuosaikaus siekia 28–32 %. Konservatyvaus investavimo strategija visais trim atvejais yra mažiausiai pelninga 14–16 %, bet kartu šios kreivės beveik neturi kritimo periodų, taigi yra mažiausiai rizikingos.

Sprendimo priėmimas, žinant skaitines prognozes  $L_1 - A_1$ ,  $L_s - A_2$ ,  $L_3 - A_3$ ,  $L_4 - A_4$ , apsaugo investuotoją nuo sprendimų, kuriuos lemia asmeninės, psichologinės, emocinės ar informacinės priežastys. Sprendimas priimamas remiantis matematine logika, o pasitikėjimas paramos sistema gali būti įgyjamas mokomojoje rinkoje. Svarbiu pasiklovimo prognoze rodikliu tampa įverčių suderinamumo intervalas. Jei kartojant prognozes nepavyksta gauti tinkamo suderinamumo, prognozė nestabili ir nepatikima, tuomet geriau sprendimą priimti skirtumui  $L_i - A_i$  priskiriant 0.

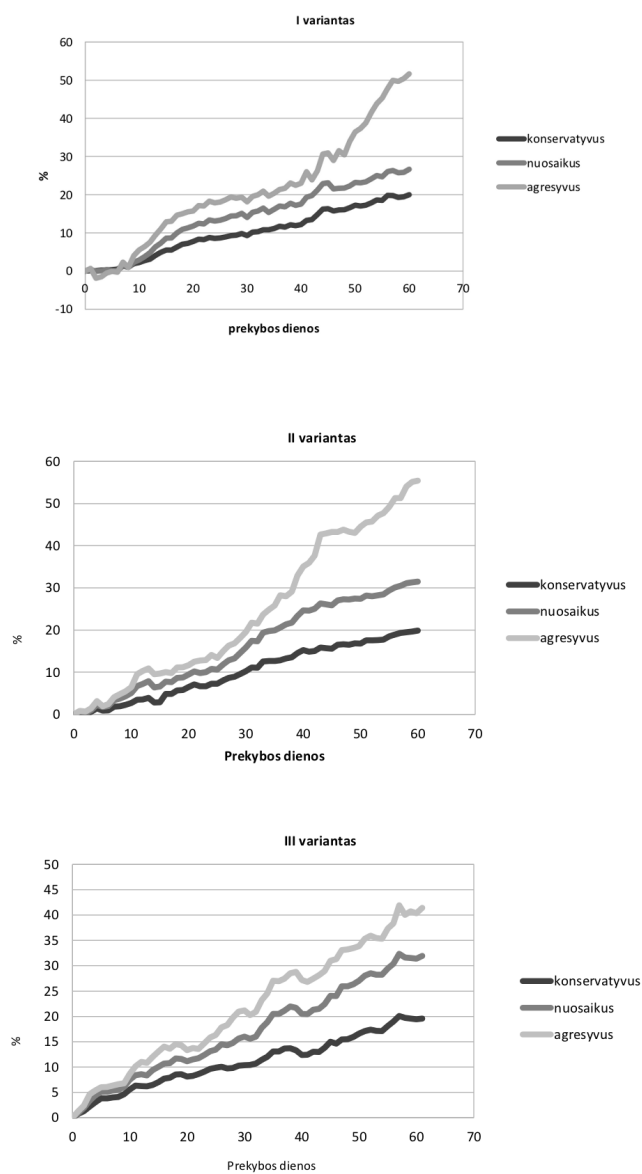
Kiekvienas investavimas neišvengiamai susijęs su rizika prarasti investicijas. Palygindami trijų investavimo strategijų – konservatyvios, nuosaikios ir agresyvos – trijų bandymų vidutinių standartinių nuokrypių slankiuosius vidurkius gauname, kad rizikingiausias yra agresyvus investicinis portfelis, mažiau rizikingas nuosaikus ir mažiausiai rizikingas konservatyvus investicinis portfelis.

Standartinis nuokrypis matuoja investicinių pasiūlymų rezultatų nepastovumą, t. y. rizikingumo lygmenį. Kuo didesnis standartinis nuokrypis, tuo platesniu diapazonu gali svyruoti laukiamas rezultatas, tuo rizikingesnis investicinis pasiūlymas, ir atvirkščiai. Standartinis nuokrypis parodo laukiamos investicijos grynosios dabartinės vertės sklaidos diapazoną. Konservatyvaus investicinio portfelio eksperimentinis standartinio nuokrypio slankusis vidurkis yra intervale  $[0,22; 0,77]$ , nuosaikaus intervale –  $[0,35; 0,80]$ , o agresyvaus – intervale  $[0,54; 1,60]$ .

Apskaičiuojame Sharpe indeksų slankiuosius vidurkius kiekvienai investavimo strategijai ir valiutų rinkos nuosavų svyravimų Sharpe indeksų slankiuosius vidurkius pagal 2.30 formulę. Gautieji Sharpe indeksai agresyviai (0,84), nuosaikiai (0,79) ir konservatyviai (0,74) strategijoms rodo aukštą portfelių efektyvumą, lyginant su saugia investicija.

Lyginant investavimo strategijų Sharpe indeksų slankiųjų vidurkių skirstinius su to pačio laikotarpio valiutų kursų svyravimų Sharpe indeksų skirstiniais, pastebime, kad prognozavimo modelio skirstiniai turi didesnę dešiniąją asimetriją 0,81 < 2,08 konservatyviai, 2,26 nuosaikiai ir 2,51 agresyviai strategijoms negu pasirinktų keturių valiutų kursų nuosavųjų svyravimų Sharpe





3.8 pav. Procentinis pelningumas trims skirtingoms investavimo strategijoms

Fig. 3.8 Percentage profitability for three investment strategies

**3.1 lentelė.** Portfelio veiksnio parametrai trims investavimo strategijoms

Portfelis	Pelningumas %	Rizikingumas	Sharpe indeksas		ASSR	Sortino indeksas
	vidurkis	$\sigma$	vidurkis	skew	vidurkis	vidurkis
Konservatyvi	0,31	0,38	0,74	2,08	0,92	1,13
Nuosaiki	0,45	0,53	0,79	2,26	1,01	1,28
Agresyvi	0,70	0,81	0,84	2,51	1,07	1,22
Valiutų rinkos	0,31	0,72	0,41	0,79	0,45	0,55

indeksų skirstinys. Investuotojui tai reiškia, kad investuoti paramos sistemos pagalba yra naudingiau, nei investuojant į pasirinktą saugią investiciją su 3 % pelningumu per metus. Teigiamas valiutų rinkos Sharpe indeksas gali būti nulemptas ekonominio augimo ar kitų valiutų rinką veikiančių išorinių sąlygų.

Pritaikyta Sharpe rodiklio asimetrija (ASSR) įvertina portfelio gražos skirstinio asimetriją. Dešinioji asimetrija nusako tikėtiną pelningumo padidėjimą.

Sortino rodiklis labiau atspindi investuotojo lūkesčius – jis atsižvelgia tik į neigiamus standartinius nuokrypius. Agresyvaus portfelio Sortino indekso vidurkis yra 1,22, nuosaikaus – 1,8, o konservatyvaus – 1,13. Visi Sortino indeksai yra labai aukšti, tai leidžia teigti, kad paramos investuotojui sistema turi žemą nuostolių riziką.

3 investavimo strategijų veiksnio įvertinimo parametrai pateikti 3.1 lentelėje.

Tyrimo rezultatai, pateikti 3.1 lentelėje, rodo, kad rinkos savas pelningumas atitinka konservatyviąją strategiją, bet jis žymiai mažesnis negu nuosaikiosios ir agresyvosios strategijos pelningumai. Rinkos savasis rizikingumas adekvatus agresyvosios rinkos rizikingumui, bet jis didesnis negu konservatyvosios ir nuosaikiosios strategijų rizikingumai. Rinkos Sharpe indeksas yra žemesnis negu prognozavimo modelio strategijų pagalba pasiekiamas indeksas. Kiti atitinkami rinkos parametrai, tokie kaip skirstinio asimetrija, ASSR indeksas ir Sortino indeksas, yra žymiai mažesni negu prognozavimo modelio pagalba gauto prognozavimo ir investavimo pagal sukurtas tris strategijas parametrai.

Investicinio portfelio veiksnio parametrai nusako prognozavimo modelio veiklos galimybes, leidžia tiksliau pasirinkti parametrus ir investavimo strategiją, bet negali suteikti pakankamai informacijos apie rinkos kitimą ateityje. Parametrai gali suteikti informacijos apie investavimo rizikingumą, tikėtiną pelningumą, o tai gali būti naudojama prognozavimo modelio kūrimo ir derinimo etape.

Investicinio portfelio veiklos indikatoriai gali suteikti investuotojui daugiau informacijos pasirenkant investavimo strategiją ir sudarant investicinius portfelius.

### 3.2.2. Investicijų portfelio optimizavimas naudojant prognozavimo modelį su dideliu Evolino rekurentinių neuroninių tinklų skaičiumi

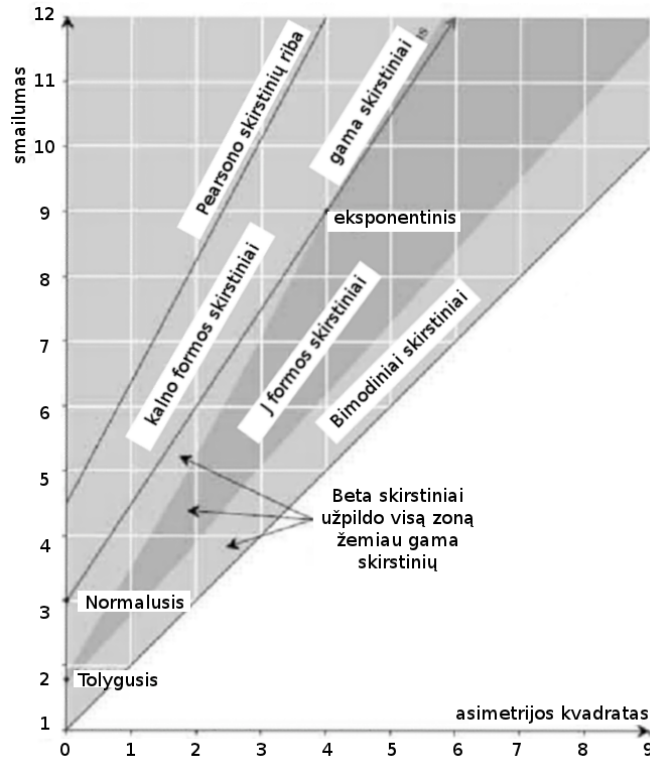
Naudojant modelį su dideliu Evolino rekurentinių neuroninių tinklų skaičiumi, gaunamas tikimybių skirstinys, prognozių histograma. Siekiant nustatyti, koks tai skirstinys, pasinaudosime skirstinio formos apibūdinimo schema (angl. *Sharpe Characterization Plane*) (3.9 pav.).

Nuo 2013-06-28 iki 2013-07-28 dienos kasdien prognozuojant EUR/USD, EUR/JPY, USD/JPY, GBP/USD, NZD/CAD, GBP/AUD, USD/CHF ir gautiems skirstiniams apskaičiuojant asimetrijos kvadratą (2.31 formulė) ir smailumą (2.32 formulė), gauname tokį smailumų išsibarstymą (3.9 paveikslas).

Palyginus 3.9 ir 3.10 grafikus, nustatome, kad skirstiniai yra multimodiniai. Atsižvelgiant į 95 % patikimumo statistinius vertinimus (Wheeler 2013), prognozavimas galimas, kai smailumas yra intervale  $[1; 3,2]$ , o asimetrijos kvadratas  $[0; 2]$ . 3.10 paveiksle matyti, kad į šią zoną patenka nemaža dalis – 60,4% – visų prognozių. Investuotojui pakanka atspėti tik rinkos instrumento kitimo kryptį, todėl prognozavimo įrankio tikslumas yra pakankamas sėkmingai prekybai valiutų rinkoje.

Prognozavimo metu gautų histogramų pavyzdžiai pateikti 3.11 paveiksle. Mažas išsibarstymas ir viena išskirtinai didelė moda (3.11 pav. a) rodo aiškia prognozuojamą valiutų kurso kitimo kryptį ir mažą riziką. Didelis išsibarstymas ir vienos aiškos prognozės nebuvimas (3.11 pav. b) atspindi valiutų kurso kitimo krypties nestabilumą ir neapibrėžtumą. 3.11 paveikslo c dalyje pateiktas multimodinės histogramos pavyzdys taip pat išpėja apie rinkos būsenos neapibrėžtumą. Didesnė skirstinio asimetrija (3.11 pav. d) leidžia tikėtis didesnio pokyčio tam tikra kryptimi.

Naudojant prognozių skirstinių pateikiamą informaciją, galima pradėti investuoti imitacinėje rinkoje, sudaryti investicinius portfelius, pasirinkti ar su-



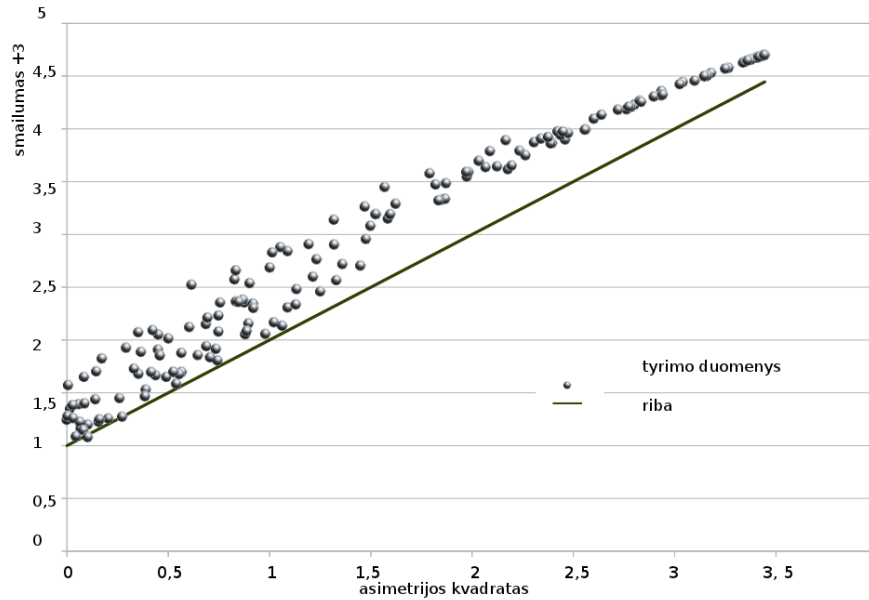
3.9 pav. Skirstinio formos apibūdinimo schema (Wheeler 2013)

Fig. 3.9 Sharpe Characterization Plane (Wheeler 2013)

kurti investavimo strategijas. Valiutų rinkos kitimo greitis ir prognozių skaičiavimo greitis leidžia spekuliuoti valiutų rinkoje su dieniniais ar 2–5 dienų laikotarpio valiutų kursų pokyčiais.

3.12 paveiksle pateikti skirstiniai gauti 1008 Evolino rekurentinių neuroninių tinklų ansambliu. Skirstinių forma aiški, išnykęs multimodiškumas, juos paprasta naudoti prognozėms. Prognozių tikslumas nepadidėjo, MAPE yra intervale [99,299; 99,9999], o skaičiavimo laikas išaugo iki 3,4 paros. Taigi, prekiaujant dieniniais duomenimis, prognozė gaunama per vėlai.

**Portfelio ortogonalumo įtaka investavimui.** Investiciniams portfeliams sudaryti buvo naudojami septynių valiutų kursų istoriniai duomenys: EUR/JPY; EUR/USD; USD/JPY; GBP/USD; GBP/AUD; NZD/CAD; USD/CHF. Atsižvelgiant į portfelio ortogonalumo sąlygą (2.25 formulė), apskaičiuojame koreliacijos koeficientus  $r_{ij}$  kiekvienos valiutų kursų poros istoriniams duomenims (3.2 lentelė).




3.10 pav. Skirstinio formos apibūdinimo schema, testuojant modelį realioje rinkoje

Fig. 3.10 Sharpe characterization plane by testing model in real market

3.2 lentelė. Valiutų kursų koreliacijos koeficientai

Valiutų kursas	EUR/JPY	EUR/USD	USD/JPY	GBP/USD	GBP/AUD	NZD/CAD	USD/CHF
EUR/JPY	1	-0,188	0,786	-0,51	0,145	0,361	0,313
EUR/USD	-0,188	1	-0,756	0,808	0,244	-0,151	-0,964
USD/JPY	0,786	-0,756	1	-0,849	-0,059	0,337	0,815
GBP/USD	-0,51	0,808	-0,849	1	0,007	-0,346	-0,82
GBP/AUD	0,145	-0,059	0,007		1	-0,403	-0,307
NZD/CAD	0,361	-0,151	0,337	-0,346	-0,403	1	0,224
USD/CHF	0,313	-0,964	0,815	-0,82	-0,307	0,224	1

Atsižvelgiant į koreliacijos koeficientus, sudarome du investicinius portfelius. Vienas jų, remiantis tik istoriniais duomenimis, yra mažiausiai ortogonalus, t. y. su didžiausiais koreliacijos koeficientais intervale  $[0,7; 0,99]$ . Jį sudaro EUR/JPY, EUR/USD, USD/JPY ir GBP/USD. Antrasis portfelis yra labiau ortogonalus, jo koreliacijos koeficientai yra intervale  $[0,1; 0,5]$ . Šiame portfelyje yra GBP/AUD, NZD/CAD, USD/CHF ir EUR/JPY. Ortogonalumo sąlygoje yra dar du kintamieji –  $\sigma_i$  ir  $\sigma_j$ . Jie gaunami iš prognozių skirstinio ir yra ne




**3.11 pav.** Skirstinių, gautų 176 Evolino neuroninių tinklų ansamblio sistema, pavyzdžiai a) USD/JPY 2013-07-02; b) EUR/JPY 2013-07-03; c) EUR/USD 2013-06-06; d) EUR/USD 2013-06-19

**Fig. 3.11** Examples of distributions by ensemble from 178 Evolino recurrent neural networks a) USD/JPY 02-07-2013; b) EUR/JPY 03-07-2013; c) EUR/USD 06-06-2013; d) EUR/USD 19-06-2013

istorinių duomenų, o prognozės, kuri gaunama remiantis istoriniais duomenimis, rezultatas. Stebėjimų metu matoma, kad, kai  $\sigma$  viršija 20 %, prognozė yra labai išsibarsčiusi, netiksli ir todėl nepatikima. Investuotojas gali tiesiog neinvestuoti į tokią valiutų porą arba, atsižvelgdamas į riziką, atlikti operacijas rizikuodamas mažesne pinigų suma. Atliktame eksperimente, siekiant įvertinti portfelių ortogonalumo įtaką investavimo pelningumui, investuojama suma buvo dalinama visoms valiutų poroms po lygiai. Laikomasi sąlygos, kad  $\sigma$  neturi viršyti 20 %.

**Optimizuotas portfelis** sudaromas dalijant investavimui skirtas lėšas ne po lygiai kiekvienam investavimo instrumentui, o suteikiant tam tikrus svorius. Sviurių pasirinkimą lemia prognozuojamas pelningumas, rizikingumas ir patikimumas. Efektyviam sviurių  $W_i$  paskirstymui naudojamos 2,6–2,8 lygtys, sąlyga  $\sum W_i = 1$  ir ortogonalumo sąlyga  $\min \sum_{ij} r_{ij} \sigma_i \sigma_j$ .



**3.12 pav.** Skirstiniai, gauti 1008 Evolino rekurentinių neuroninių tinklų ansamblio sistema: a)USD/JPY; b)EUR/JPY; c) EUR/USD; d) EUR/USD 2013-09-02 dieną

**Fig. 3.12** Distributions obtained by 1008 Evolino recurrent neural networks

**Investicijų portfelių veiksnio įvertinimas.** Visų trijų portfelių veiksnio parametrai, gauti imant prekybos realioje rinkoje „Oanda“ duomenis, pateikti 3.3 lentelėje.


**3.3 lentelė.** Portfelių veiksnio parametrai prekybos realioje rinkoje duomenims

Portfelis	MAPE	Pelnin-gumas	Rizikin-gumas	Sharpe indeksas	Sortino indeksas
Mažiau ortogonalus	0,9981	0,89	0,017	-1,23	-4,48
Labiau ortogonalus	0,99999	5,44	0,037	0,66	107,51
Ortogonalus optimizuotas	0,99999	16,66	0,067	2,03	nėra neigiamų

Portfelių efektyvumo parametrai skaičiuojami dieniniams duomenims. Jie rodo, kad efektyviausias yra ortogonalus optimizuotas portfelis, jis per prekybos laikotarpį neturėjo nė vieno praradimo, o pelningumas net 16,6 %, Sharpe indeksas siekia 2,03. Kiek mažiau efektyvus yra ortogonalus neoptimizuotas portfelis, jo pelningumas 5,44 %, Sharpe indeksas 0,66, o Sortino indeksas 107,51 toks aukštas, nes įvyko tik trys praradimai per prekybos laikotarpį. Prasčiau neortogonalus ir neoptimalus portfelio rodikliai – 0,89 %, –1,23, –4,48 – atitinkamai, gauti dėl praradimų su EUR/JPY ir USD/JPY.

### 3.2.3. Paramos sistemos testavimas realioje rinkoje

Ištyrus prognozavimo modelius ir sukūrus paramos investuotojui sistemą, galima paramos sistemą apibandyti realioje rinkoje. Pasirinkti EUR/JPY, EUR/USD, USD/JPY ir GBP/USD valiutų kursai, kasdien suskaičiuojamos jų prognozės ir atsižvelgiant į jas – investuojama. 3.13 paveiksle matome Methatrader Alpari pateiktą pirmųjų bandymų prognozuoti grafiką. Matomas akivaizdus skirtumas prognozuojant pirmuoju (pilka sritis) ir antruoju modeliais (balta sritis). Čia investavimui skirta suma dalinama po lygiai, neatsižvelgiant į prognozuojamą pelningumą ar rizikingumą, nenaudojant apsauginių elementų – „sustabdyti praradimus“ (angl. *“stop loss”*) ar pasiektas pelnas (angl. *“take profit”*). Fiksuojamasis momentas – rinkos uždarymo kaina. Pagrindinės praradimų priežastys yra psichologinės: godumas, viltis, neryžtingumas, patirties stoka.




**3.13 pav.** Pirmieji žingsniai realioje rinkoje 2013/01/04–2013/10/01 laikotarpiu: prognozuojant mažą modeliu, su 8 Evolino RNN, vėliau dideliu modeliu su 176 Evolino RNN (šaltinis: Methatrader Alpari ataskaita už laikotarpį).

**Fig. 3.13** First steps in real market during the 04-01-2013–01-10-2013 period: first using small forecasting model with 8 Evolino, after by large forecasting model with 176 Evolino RNN (source: Methatrader Alpari report)

3.14 paveiksle pateikta visų metų prekybos realioje rinkoje, taikant tą patį dalijimo po lygiai principą, ataskaita. Visi šiame tyrime naudoti valiutų kursai



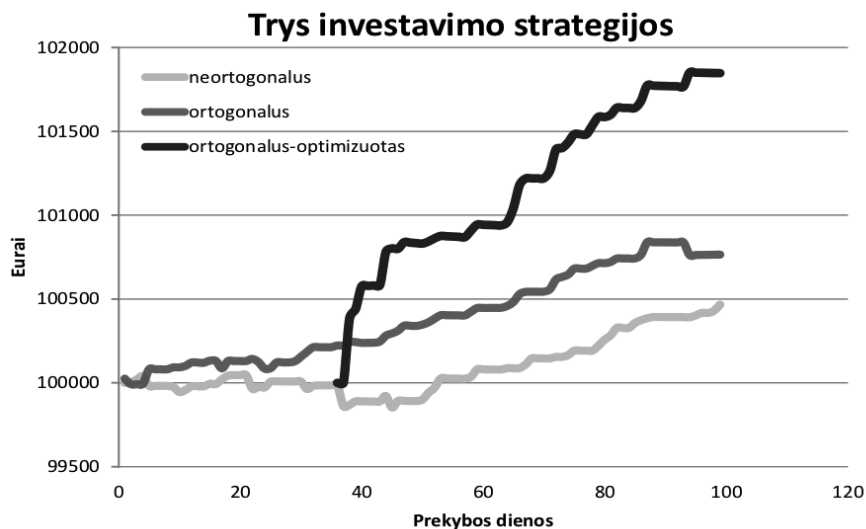
susiję vienas su kitu, jų koreliacijos koeficientai yra intervale  $[0,7; 0,99]$  – tai mažiausiai ortogonalus portfelis.



**3.14 pav.** Prekyba realioje rinkoje 2013-01-04–2014-01-04 laikotarpiu: prognozuojant modeliu su mažu RNN skaičiumi, vėliau modeliu su dideliu RNN skaičiumi (šaltinis: Methatrader Alpari ataskaita už laikotarpį).

**Fig. 3.14** Trading in real market during the 04-01-2013–04-01-2014 period: first using small forecasting model with 8 Evolino, after by large forecasting model with 176 Evolino RNN (source: Methatrader Alpari report)

Atsižvelgiant į teorinius trijų portfelių – neortogonalus, ortogonalus ir ortogonalus optimizuoto – palyginimus, imitacinėje rinkoje „Oanda“ testuoti trys atitinkami portfeliai. Jų rezultatai pateikti 3.15 paveiksle.



**3.15 pav.** Trijų investicinių portfelių testavimas imitacinėje rinkoje 2013/01/04-2013/10/04 laikotarpiu

**Fig. 3.15** Testing of three investment portfolios in demo market during the 04-01-2013–04-10-2013 period

Trys skirtingi investiciniai portfeliai atspindi pasirinktas strategijas. Šimtas dienų prekyboje yra pernelyg mažas laikotarpis, tačiau jau matyti, kad mažiausiai sėkmingas yra mažiausiai ortogonalus portfelis. Tiriamuoju laikotarpiu informacinės priemonės nagrinėjo Japonijos vyriausybės manipuliavimus su Japonijos jenos kursais. Akivaizdūs bandymai pakelti krintančią jenos vertę atspindi istoriniuose duomenyse. Tiriamasis prognozavimo modelis pirmąją manipuliavimo dieną neteisingai prognozavo EUR/JPY ir USD/JPY kursų kryptis, dėl to patirti nuostoliai. Vėliau dirbtinio intelekto sistema išmoko atpažinti manipuliavimus ir pateikdavo prognozes su milžinišku standartiniu nuokrypiu, o dar vėliau prognozių skirstinys tapo bimodinis su dviem beveik lygiomis modomis. Ortogonaliam portfeliui šios manipuliacijos turėjo žymiai mažesnę įtaką, nes jo sudėtyje yra tik vienas valiutų kursas susijęs su Japonijos jena – EUR/JPY. Optimizuotas portfelis yra sėkmingiausias, jis dėl techninių naujų galimybių pradėtas vėliau, jau po pirmųjų Japonijos vyriausybės manipuliacijų. Be to, optimizavimas yra labai sėkmingas.


#### 3.2.4. Investicinio portfelio optimizavimas atsižvelgiant į skirstinių kompoziciją

Prekybos valiutų rinkoje algoritmas, naudojant uždarymo duomenis, yra gana paprastas: jei tikėtinų verčių skirstinio moda yra didesnė nei uždarymo kaina, reikia *pirkti*, priešingu atveju – *parduoti*. Tačiau kiekvieno investuotojo svajonė yra pirkti, kai kaina yra žemiausia, ir parduoti tada, kai kaina yra aukščiausia.

Pasirinkus maksimalias ir minimalias dienas dviejų metų vertes, prognozuojant aprašytuoju modeliu, gaunami du tikėtinų verčių skirstiniai sekančiais dienai (3.16 pav.).

Šie skirstiniai suteikia papildomų pasirinkimo galimybių investuotojams – galima pasirinkti skirtingus tikėtinus dienos pokyčius, atsižvelgiant į juos atitinkančias tikimybes. Taip pat papildomos informacijos sprendimo priėmimui suteikia skirstinių forma ir parametrai (asimetrija, smailumas, standartinis nuokrypis). Sprendimą *pirkti* ar *parduoti* lemia valiutų kurso vertė einamuoju momentu prognozuojamų verčių skirstinių atžvilgiu.

Keturių valiutų kursų prognozių skaičiavimas Evolino RNN ansambliu užtrunka apie 6 valandas 25 minutes. Siekiant gauti maksimalių ir minimalių tikėtinų verčių skirstinius, skaičiuojama dukart per dieną. Investicinis portfelis iš tų pačių keturių valiutų kursų (GBPAUD, NZDCAD, EURJPY ir USDCHF) sudaromas pertvarkant 2.23–2.24 lygtis į sekančią lygčių sistemą:



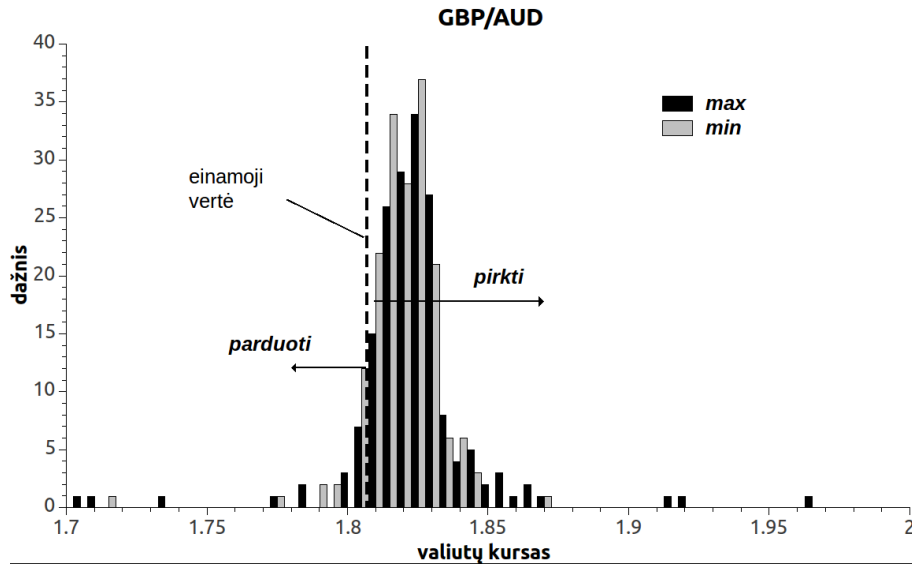
**3.6 pav.** Dviejų skirstinių kompozicija  
**Fig. 3.16** Composition of two distributions

$$\begin{cases} \max & \sum_{i=1}^n p_{pi} W_i \\ \min & \sum_{i=1}^n p_{li} W_i, \end{cases} \quad (3.2)$$

čia  $p_{pi}$  yra prognozuojamo sprendimo sėkmės tikimybė, o  $p_{li}$  – prognozuojamo sprendimo nesėkmės tikimybė.

Tikimybių skaičiavimo metodiką iliustruoja 2014-08-11 dieną gauti prognozių skirstiniai (3.17–3.20 pav.).

Minimalių GBP/AUD tikėtinų verčių skirstinio (3.17 pav. pilkas stulpelis) standartinis nuokrypis yra 0,0096, asimetrija – 1,5668, smailumas – 0,9777, pagrindinė moda – 1,825. Maksimalių tikėtinų verčių skirstinio (3.17 pav. juodas stulpelis) standartinis nuokrypis lygus 0,0405, asimetrija – 0,7538, smailumas – 1,1435, pagrindinė moda – 1,825. Einamojo momento vertė (uždarymo vertė 2014-08-08) yra 1,8071, ji yra į kairę nuo minimalios ir maksimalios modų. Sprendimas turi būti *pirkti*. Maksimaliųjų verčių skirstinio ribojama sritis į dešinę nuo einamojo momento vertės yra didesnė nei į kairę. Sėkmės tikimybė



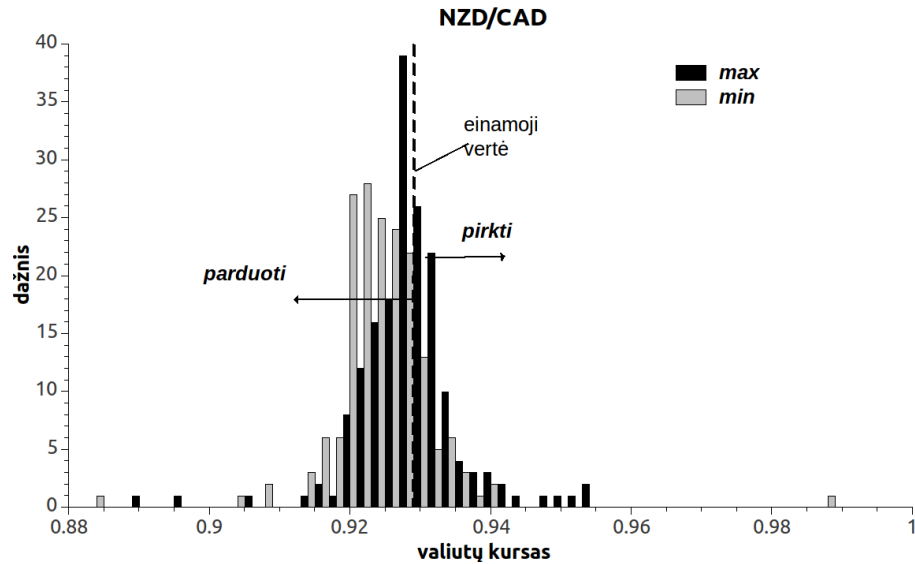
**3.17 pav.** Maksimalių ir minimalių tikėtinų verčių skirstiniai GBP/AUD valiutų kursui 2014-08-11

**Fig. 3.17** Maximal and minimal distributions for GBP/AUD exchange rate in 11-08-2014

nusprendus *pirkti* yra didesnė nei *parduoti*. Sprendimas *parduoti* yra rizikingas.

Minimalių NZD/CAD tikėtinų verčių skirstinio (3.18 pav. pilkas stulpelis) standartinis nuokrypis yra 0,0178, asimetrija – 1,811, smailumas – 1,5975, pagrindinė moda – 0,922. Maksimalių tikėtinų verčių skirstinio (3.18 pav. juodas stulpelis) standartinis nuokrypis yra 0,0052, asimetrija – 0,0504, smailumas – 1,8618, pagrindinė moda – 0,928. Einamojo momento vertė (uždarymo vertė 2014-08-08) yra 0,9277, ji yra į dešinę nuo minimaliosios ir maksimaliosios modos. Sėkmės tikimybė nusprendus *pirkti* yra mažesnė nei *parduoti*. Sprendimas *pirkti* yra rizikingas.

Minimalių EUR/JPY tikėtinų verčių skirstinio (3.19 pav. pilkas stulpelis) standartinis nuokrypis yra 2,846, asimetrija – 1,3108, smailumas – 0,47, pagrindinė moda – 135,50. Maksimalių tikėtinų verčių skirstinio (3.19 juodas stulpelis) standartinis nuokrypis yra 3,5238, asimetrija – 0,4359, smailumas – 1,6244, pagrindinė moda – 136,00. Einamojo momento vertė (uždarymo vertė 2014-08-08) yra 136,79900, ji yra į dešinę nuo minimalios ir maksimalios modos. Sprendimas turi būti *parduoti*. Sritis, kurią riboja minimalaus tikėtinų verčių skirstinio dalis į kairę nuo einamosios vertės, yra didesnė nei į dešinę.



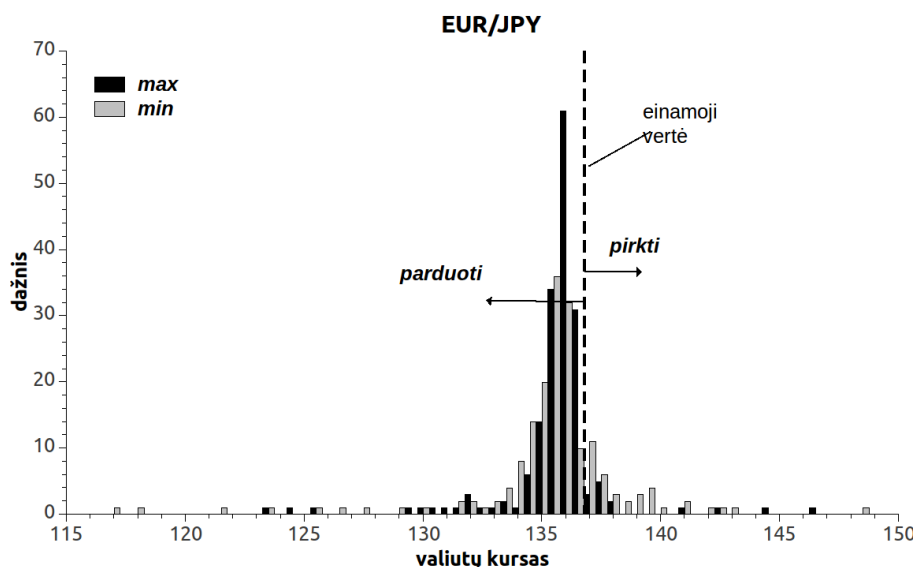
**3.18 pav.** Maksimalių ir minimalių tikėtinų verčių skirstiniai NZD/CAD valiutų kursui 2014-08-11

**Fig. 3.18** Maximal and minimal distributions for NZD/CAD exchange rate in 11-08-2014

Taigi tikimybė, kad valiutų kursas kris, yra didesnė, negu kad tikimybė, kad EUR/JPY augs.

Minimalių USD/CHF tikėtinų verčių skirstinio (3.20 pav. pilkas stulpelis) standartinis nuokrypis yra 0,002994909, asimetrija – 1,385249, smailumas – 0,6202291, pagrindinė moda – 0,902000. Maksimalių tikėtinų verčių skirstinio (3.20 pav. juodas stulpelis) standartinis nuokrypis yra 0,02830611, asimetrija – 0,9365431, smailumas – 1,219776, pagrindinė moda – 0,908000. Einamojo momento vertė (uždarymo vertė 2014-08-08) yra 0,90514. Ji yra tarp minimalios ir maksimalios modos. Minimaliųjų verčių skirstinio sritis į kairę nuo einamosios vertės yra apytiksliai lygi maksimaliųjų verčių skirstinio ribojamai sričiai į dešinę nuo einamosios vertės. Taigi tikimybė, kad valiutų kurso vertė kris, yra apytiksliai lygi tikimybei, kad USD/CHF kils. Šios dienos (2014-08-11) atveju, keturių valiutų portfelis sudaromas taikant 3.2 lygčių sistemą ir dalinamas tokiomis dalimis: GBP/AUD – 0,38, NZD/CAD – 0,17, EUR/JPY – 0,43, USD/CHF – 0,10. Dienos pelningumas yra 7,14 %.

Naudojant šį dviejų skirstinių metodą dvylika savaičių, kasdien iš keturių valiutų kursų sudaromi du portfeliai: vienas optimizuotas pagal 3.2 formulę, o kitas lėšas – dalinant po lygiai visiems keturiems valiutų kursams. Taip pat



**3.19 pav.** Maksimalių ir minimalių tikėtinų verčių skirstiniai EUR/JPY valiutų kursui 2014-08-11

**Fig. 3.19** Maximal and minimal distributions for EUR/JPY exchange rate in 11-08-2014

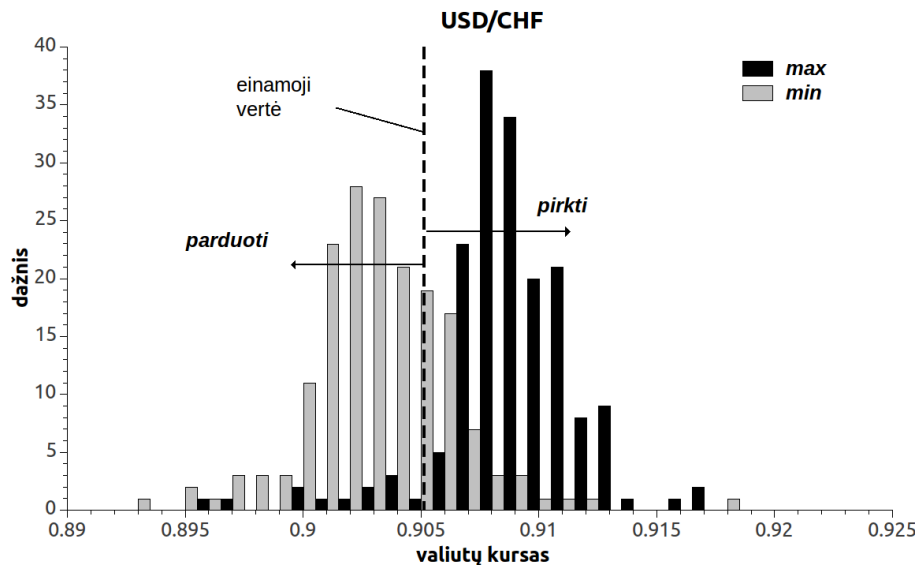
palyginimui imami du analogiški portfeliai, naudojantys vieną skirstinį, gautą iš uždarymo duomenų. Palyginimo rezultatai pateikti 3.4 lentelėje.

**3.4 lentelė.** Portfelių efektyvumo palyginimas

rodiklis	ekstremalių verčių		uždarymo verčių	
	optimalus	1/N	optimalus	1/N
pelningumas	0,17	0,15	0,10	0,09
Sharpe rodiklis	1,76	1,65	0,99	0,91
MAPE (pagal modą)	0,0044	0,0044	0,0079	0,0079

Sharpe rodiklio skaičiavimams imta nerizikingos investicijos norma (angl. *risk free rate*), kurią atitinka 13 savaičių išdo vekselių (angl. *treasury bill*) vertė lygi 0,01 (www.finance.yahoo.com, 2014-09-01). Mūsų tyrime abiejų ekstremalius duomenis naudojančių portfelių Sharpe rodiklis yra didesnis, nei uždarymo istorinius duomenis naudojantys portfeliai.

MAPE ir kiti prognozavimo tikslumo nustatymo metodai skirti taškinėms prognozėms. Tikėtinų verčių skirstiniams vienas taškas, net jei tai ir pagrindinė moda, negali tiksliai atspindėti prognozavimo tikslumo ir patikimumo. Du skirstinius prognozavimui naudojanti metodika atsižvelgia į dvi modas ir jų iš-



**3.20 pav.** Maksimalių ir minimalių tikėtinų verčių skirstiniai USD/CHF valiutų kursui 2014-08-11 (sudaryta autorės).

**Fig. 3.20** Maximal and minimal distributions for USD/CHF exchange rate in 11-08-2014

sidėstymą einamojo momento kainos atžvilgiu. MAPE skaičiavimui naudota ta moda, kuri lemia sprendimo priėmimą. Apskaičiuotas tikslumas, naudojant du skirstinius, yra beveik dukart tikslesnis nei vieno skirstinio.

Buvo prekiaujama realiu laiku, be validacijos periodo. Investiciniai portfeliai, sudaryti naudojant ekstremalias (maksimalias ir minimalias) reikšmes, yra pelningesni, efektyvesni ir tikslesni, nei portfeliai, sudaryti naudojant tik uždarymo duomenis.

Prekyba realioje rinkoje, taikant patikimą dirbtinio intelekto sistemą, yra pelninga, įtraukianti emociniu sėkmės pojūčiu, tačiau reikalauja daug kruopštaus darbo ir užima nemažai laiko.

### 3.3. Trečiojo skyriaus išvados

Siekiant sukurti paramos sistemą investuotojui valiutų rinkoje būtina kruopščiai suderinti visus paramos sistemos veikimo etapus:

1. Chaotinis procesas turi atmintį – tai, kas vyko praityje, daro įtaką veiksams ateityje. Todėl prognozavimui naudojami prognozuojamo

valiutų kurso istoriniai duomenys ir artimiausi ortogonaliems išteklių kainų istoriniai duomenys, kasdien juos papildant naujais duomenimis.

2. Dirbtinio intelekto algoritmai turi būti kruopščiai parengti valiutų rinkos prognozavimui:
  - 2.1. Evolino RNN sėkmingai pritaikytas ne tik autorių testuotam Maclay-Glass procesui, kalbos atpažinimui, bet ir chaotinių valiutų kursų svyravimų prognozavimui.
  - 2.2. Prieš pradėdant naudoti Evolino RNN, būtina jo parametrus – iteracijų skaičių, neuronų skaičių ir istorinių duomenų apimtį – suderinti taip, kad rezultatai būtų tinkamo mokymosi ir gero prognozavimo srityje.
  - 2.3. Labai svarbus įvesčių tarpusavio ryšys. Parinkus įvestis su mažiausiu galimu ortogonalumo įverčiu  $1e - 4 < \varepsilon$ , prognozavimo patikimumas ir tikslumas padidėja.
  - 2.4. Keletas Evolino RNN, prognozuojantys vienu metu, suteikia daugiau patikimos informacijos apie ateitį, negu atskira prognozė.
3. Sukurtas prognozavimo modelis, naudojantis 8 Evolino RNN ir jų prognozėms taikantis ekspertinius metodus – nuomonių suderinamumo skaičiavimą ir Delfi metodą, paprastai taikomus ekspertų nuomonių įvertinimui. Šio modelio taikymas finansų rinkų prognozavimui investuotojui suteikia papildomų galimybių:
  - 3.1. Tyrimas rodo, kad prognozavimo modelio patikimumas tiksliai prognozuoti valiutų kurso vertę yra 29 % (koreliacijos koeficientas lygus 1), tiksliai prognozuoja 62 % (koreliacijos koeficientas yra intervale  $[0,6; 1]$ ), o teisingą valiutų kurso pokyčio kryptį prognozuoja 76 % (koreliacijos koeficientas yra intervale  $[0; 1]$ ).
  - 3.2. Prognozavimo modelis atveria plačias pasirinkimo galimybes investuotojui – galima rinktis prognozuojamus finansinius įrankius, jų „mokytojus“, siaurinti ar platinti suderinamumo intervalą, sudaryti didesnius ar įvairesnius investicinius portfelius, keisti investavimo trukmę, rizikingumo laipsnį.
  - 3.3. Testuojant paramos sistemą investuotojui, tiriamuoju istoriniu laikotarpiu pelningumas siekia 35–45 % pasirinkus agresyvią investavimo strategiją, 28–32 % – nuosaikią ir 14–16 % – konservatyvią.



- 3.4. Laukiamos investicijos, naudojant paramos investuotojui sistemą, grynosios dabartinės vertės sklaidos diapazonas skirtingo rizikavimo strategijoms neviršija 1,6 %.
  - 3.5. Gautieji Sharpe indeksai  $[0,74; 2,51]$  reiškia, kad investuoti paramos sistemos pagalba yra naudingiau negu į pasirinktą saugią investiciją su 3 % pelningumu per metus.
  - 3.6. Aukšti Sortino indeksai leidžia teigti, kad paramos investuotojui sistema turi žemą nuostolių riziką.
  - 3.7. Investicinio portfelio veiksnio parametrai nusako prognozavimo modelio veiklos galimybes, leidžia tiksliau pasirinkti parametrus ir investavimo strategiją, bet negali suteikti pakankamai informacijos apie rinkos kitimą ateityje. Parametrai gali suteikti informacijos apie investavimo rizikingumą, tikėtiną pelningumą, ir tai gali būti naudojama prognozavimo modelio kūrimo ir derinimo etape.
  - 3.8. Slankiųjų pelningumo vidurkių ir Sharpe indeksų skirstiniai, jų asimetrija ir ASSR indeksas geriausiai atspindi modelio prognozavimo rezultatus. Grafiškų analizė atskleidžia, kad stebimas skirstinių poslinkis į teigiamą pusę atspindi investavimo strategijos galimybes.
  - 3.9. Pelningumo ir Sharpe indekso slankiųjų vidurkių skirstinių asimetrija į dešinę ir ASSR indekso maksimizavimas atitinka tikėtiną investicinės grąžos maksimizavimą.
4. Sukurtas prognozavimo modelis, naudojantis 100–300 Evolino RNN ir jų prognozes, sudaro tikėtinų verčių skirstinį. Šio modelio taikymas finansų rinkų prognozavimui leidžia tvirtinti, kad:
    - 4.1. Ansamblis, kurį sudaro didelis Evolino RNN skaičius, suteikia daugiau patikimos informacijos apie ateitį, negu atskira prognozė ar prognozuojamas intervalas.

- 4.2. Nustatyta skirstinio forma – multimodinis skirstinys. Tiksliausia prognozė gaunama, kai skirstinio smailumas yra intervale  $[1; 3,2]$ , o asimetrijos kvadratas  $[0; 2]$ .
5. Į prognozavimo modelius integruojant moderniąją portfelio teoriją, gaunama paramos sistema investuotojui valiutų rinkoje. Investicinio portfelio formavimo principai suteikia paramos sistemai stabilumo, patikimumo ir efektyvumo:
  - 5.1 Labai svarbi yra investicinio portfelio ortogonalumo sąlyga. Parinkus valiutų kursus su mažiausiu galimu ortogonalumo įverčiu  $\varepsilon$ , portfelio pelningumas padidėja 6 kartus.
  - 5.2 Tikėtinų verčių intervalas investicinio portfelio optimizavimui leidžia naudoti dvimačio portfelio lygtis, atsižvelgiant į rizikingumą ir pelningumą pasirinkti priimtina investavimo strategiją.
  - 5.3 Tikėtinų verčių skirstinio parametrus taikant adekvataus trimačio portfelio lygtims, investicinio portfelio optimizavimo uždavinys tapo paprastu kvadratinio optimizavimo uždaviniu.
6. Sukurta paramos sistema investuotojui leidžia sprendimo priėmimui naudoti skirstinių kompoziciją. Portfelis, sudarytas naudojant maksimalių ir minimalių tikėtinų verčių skirstinius, yra 60–70 % pelningesnis, 80 % efektyvesnis ir 79 % tikslesnis nei naudojant uždarymo duomenis.





---

## Bendrosios išvados

1. Nagrinėjant paramos sistemų investuotojams finansų rinkose galimybes nustatyta, kad pilna arba ideali informacija visiems rinkos dalyviams yra nepasiekiamo, todėl visiškai efektyvi rinka egzistuoti negali. Tačiau asimptotiškas artėjimas prie pilnos informacijos daro efektyviosios rinkos hipotezę viena svarbiausių socialiniuose moksluose.
2. Sinergijos efektas tarp skirtingų mokslo šakų (ekonomikos, matematikos, psichologijos, biologijos), naujausių technologinių atradimų (internetinių atsiskaitymų, dirbtinio intelekto) ir investuotojų patirties, sudaro prielaidas gauti efektyvų, kokybiškai naują, socialiai harmoningą, inovatyvų prognozavimo įrankį.
3. Finansų rinkų prognozavimui tikslingai pritaikius dirbtinio intelekto algoritmus ir į juos integravus moderniąją portfelio teoriją, sukurta patikima ir efektyvi sprendimų finansų rinkose priėmimo paramos sistema, gebanti įvertinti istorinius duomenis, naudojanti inovatyvius algoritmus. Investavimo įrankis suteikia papildomos informacijos investuotojams, tokiu būdu jie įgauna pranašumų prieš kitus rinkos dalyvius:
  - 3.1. Paramos sistemos investuotojui prognozavimo įrankio prognozė yra multimodinis skirstinys, kurio forma ir parametrai suteikia investuotojui informacijos apie valiutų rinkos pokyčius ateityje.

- 3.2. Maksimalių ir minimalių tikėtinų verčių skirstinių kompozicija įvertina dieninių valiutų kursų svyravimų ribas, prognozuoja valiutų kurso kitimo krypties virsmą.
  - 3.3. Dirbtinio intelekto algoritmai gali būti sėkmingai taikomi valiutų rinkų prognozavimui, juos tinkamai suderinus. Nuosekliai keičiant vidinius rekurentinių neuroninių tinklų parametrus, randamas toks neuronų skaičiaus, iteracijų skaičiaus ir istorinių duomenų kiekis, kad sistema veiktų gero mokymosi ir gero prognozavimo srityje.
  - 3.4. Labai svarbus įvesčių tarpusavio ryšys. Parinkus įvestis su mažiausiu galimu ortogonalumo įverčiu ( $1e - 4 < \epsilon$ ), prognozavimo patikimumas ir tikslumas padidėja 6 kartus.
  - 3.5. Dirbtinio intelekto algoritmų architektūra lemia prognozavimo rezultatų informatyvumą. Mažiausiai informatyvi yra taškinė prognozė, gaunama vienu Evolino rekurentiniu tinklu. Mažas Evolino rekurentinių neuroninių tinklų ansamblis (8 elementų), taikant ekspertinius metodus, pateikia tikslesnį ir patikimesnį tikėtinų verčių intervalą. Prognozavimo tikslumas siekia 62–76 %. Didelio Evolino rekurentinių neuroninių tinklų ansamblio (120–1008 elementų) prognozė – stochastiškai informatyvus skirstinys ir prognozavimo tikslumas, lygus 92–96%.
4. Turint patikimą prognozavimo įrankį, investuojamų lėšų paskirstymo sprendimas priimamas įvertinant tikėtiną grąžą, esant tam tikram rizikos lygiui su tam tikra tikimybe. Į modelį integruojant investicinio portfelio optimizavimo lygtis ir pritaikius portfelio ortogonalumo principą, investavimo sprendimai rizikos ir neapibrėžties sąlygomis tampa efektyvesni.
    - 4.1. Tikėtinų verčių intervalas investicinio portfelio optimizavimui leidžia naudoti dvimačio portfelio lygtis, atsižvelgiant į rizikingumą ir pelningumą, pasirinkti priimtina investavimo strategiją. Skirtin-go rizikingumo strategijų efektyvumas, išreikštas Sharpe indeksu yra 0,31–0,7, o Sortino indeksu – 1,13–1,28.
    - 4.2. Tikėtinų verčių skirstinio parametrus taikant adekvataus trimačio portfelio lygtims, investicinio portfelio optimizavimo uždavinys tampa paprastu kvadratinio optimizavimo uždaviniu. Ortogonalaus ir ortogonalaus optimizuoto portfelio efektyvumas, išreikštas Sharpe indeksu, yra 0,66–2,03, Sortino indeksu – apie 107,51.

5. Paramos sistemos investuotojui valiutų rinkoje patikrinimas imitacinėje rinkoje realiu laiku patvirtino teorines modelių patikimumo ir tikslumo prielaidas, teorinius moderniosios portfelio teorijos principus.



---

## Literatūra ir šaltiniai

AbuHamad, M., Mohd, M., Salim, J., 2013. Event-driven business intelligence approach for real-time integration of technical and fundamental analysis in forex market. *Journal of Computer Science* 9 (4), 488.

Agrawal, S., Jindal, M., Pillai, G., March 17 - 19 2010. Momentum analysis based stock market prediction using adaptive neuro fuzzy inference system. In: *Proceedings of the International MultiConference of Engineers and Computer Scientists, IMECS 2010*. Vol. I. pp. 526–531.

Akerlof, G. A., 1970. The market for "lemons": Quality uncertainty and the market mechanism. *The quarterly journal of economics*, 488–500.

Albin, P., Foley, D. K., June 1992. Decentralized, dispersed exchange without an auctioneer : A simulation study. *Journal of Economic Behavior & Organization* 18 (1), 27–51.

Amari, S., 1960. Topological and information-theoretical foundations of diakoptics and codiakoptics. Ph.D. thesis, Master's dissertation submitted to the University of Tokyo.

Anderson, J. C., Frankle, A. W., 1980. Voluntary social reporting: an iso-beta portfolio analysis. *Accounting Review*, 467–479.

Ang, K., Quek, C., Sep. 2006. Stock trading using rspop: a novel rough set-based neuro-fuzzy approach. *IEEE Trans Neural Netw.* 17 (5), 1301–1316.

Anghelache, G., Trifan, A., 2013. Forecasting the investors behavior on the capital market in romania: Trading strategies based on technical analysis versus artificial intelligence techniques. *International Journal of Business and Social Research* 3 (2), 114–121.

Asadi, S., Hadavandi, E., Mehmanpazir, F., Nakhostin, M., 2012. Hybridization of evolutionary levenberg–marquardt neural networks and data pre-processing for stock market prediction. *Knowledge-Based Systems* 35, 245–258.

Asgharian, H., 2011. A conditional asset-pricing model with the optimal orthogonal portfolio. *Journal of Banking & Finance* 35 (5), 1027–1040.

Axelrod, R., 1997. The dissemination of culture a model with local convergence and global polarization. *Journal of conflict resolution* 41 (2), 203–226.

Axtell, R., Epstein, J., Young, H., 2001. The emergence of classes in a multi-agent bargaining model. in Durlauf, Young eds, 191–212.

Bae, K., Han, D., Sohn, H., 2012. Importance of access to finance in reducing income inequality and poverty level. *International Review of Public Administration* 17 (1), 55–77.

Baillie, R. T., Lippens, R. E., McMahon, P. C., 1983. Testing rational expectations and efficiency in the foreign exchange market. *Econometrica: Journal of the Econometric Society*, 553–563.

Beck, T., Demirguc-Kunt, A., Laeven, L., Levine, R., December 2004a. Finance, firm size, and growth. Working Paper 10983, National Bureau of Economic Research.

Beck, T., Demirguc-Kunt, A., Levine, R., December 2004b. Finance, inequality, and poverty: Cross-country evidence. Working Paper 10979, National Bureau of Economic Research.

Bernardo, D., Hagrass, H., Tsang, E., 2012. An interval type-2 fuzzy logic based system for model generation and summarization of arbitrage opportunities in stock markets. In: *Computational Intelligence (UKCI)*, 2012 12th UK Workshop on. IEEE, pp. 1–7.



- Bhattacharyya, R., Kar, S., Majumder, D. D., 2011. Fuzzy mean–variance–skewness portfolio selection models by interval analysis. *Computers & Mathematics with Applications* 61 (1), 126–137.
- Black, F., 1974. International capital market equilibrium with investment barriers. *Journal of Financial Economics* 1 (4), 337–352.
- Bodas-Sagi, D., Fernández-Blanco, P., Hidalgo, J., Soltero-Domingo, F., 2013. A parallel evolutionary algorithm for technical market indicators optimization. *Natural Computing*, 1–13.
- Bollen, J., Mao, H., Zeng, X., 2011. Twitter mood predicts the stock market. *Journal of Computational Science* 2 (1), 1–8.
- Briggs, A. H., Weinstein, M. C., Fenwick, E. A., Karnon, J., Sculpher, M. J., Paltiel, A. D., 2012. Model parameter estimation and uncertainty: a report of the ispor-smdm modeling good research practices task force-6. *Value in Health* 15 (6), 835–842.
- Cederman, L., 1997. Emergent actors in world politics: how states and nations develop and dissolve. Princeton University Press.
- Chakravarty, S., P.Dash, 2012. A pso based integrated functional link net and interval type-2 fuzzy logic system for predicting stock market indices. *Applied Soft Computing* 12 (2), 931–941.
- Chang, P., Fan, C., 2008. A hybrid system integrating a wavelet and tsf fuzzy rules for stock price forecasting. *IEEE Transactions on Systems, Man, and Cybernetics, Part C*, 802–815.
- Chang, P. C., Wang, Y. W., 2006. Fuzzy delphi and back-propagation model for sales forecasting in pcb industry. *Expert Syst. Appl.* 30 (4), 715–726.
- Chen, F., Gou, C., Guo, X., Gao, J., 2008. Prediction of stock markets by the evolutionary mix-game model. *Physica A: Statistical Mechanics and its Applications* 387 (14), 3594–3604.
- Choudhry, R., Garg, K., 2008. A hybrid machine learning system for stock market forecasting. *World Academy of Science, Engineering and Technology* 39, 315–318.
- Cooper, I., 1996. Arithmetic versus geometric mean estimators: Setting discount rates for capital budgeting. *European Financial Management* 2 (2), 157–167.

- Cortes, C., Vapnik, V., 1995. Support-vector networks. *Machine learning* 20 (3), 273–297.
- Cura, T., 2009. Particle swarm optimization approach to portfolio optimization. *Nonlinear Analysis: Real World Applications* 10 (4), 2396–2406.
- da Silva, R., Bazzan, A., Baraviera, A., Dahmen, S., 2005. Emerging collective behavior in a simple artificial financial market. In: *Proceedings of the fourth international joint conference on Autonomous agents and multiagent systems*. ACM, pp. 313–319.
- Dalcin, L., 2012/12/01. <https://code.google.com/p/mpi4py/>.
- Dalkey, N. C., 1969. The delphi method. Tech. Rep. RM-5888-PR, RAND Corporation.
- Damodaran, A., 2012. Investment philosophies: Successful strategies and the investors who made them work. Vol. 665. John Wiley & Sons.
- Dorigo, M., Gambardella, L. M., 1997. Ant colony system: A cooperative learning approach to the traveling salesman problem. *Evolutionary Computation, IEEE Transactions on* 1 (1), 53–66.
- Dorigo, M., Maniezzo, V., Colorni, A., 1996. Ant system: optimization by a colony of cooperating agents. *Systems, Man, and Cybernetics, Part B: Cybernetics, IEEE Transactions on* 26 (1), 29–41.
- Duru, O., 2010. A fuzzy integrated logical forecasting model for dry bulk shipping index forecasting: An improved fuzzy time series approach. *Expert Systems with Applications* 37 (7), 5372–5380.
- Dzielinski, M., 2012. Measuring economic uncertainty and its impact on the stock market. *Finance Research Letters* 9 (3), 167–175.
- Edmans, A., 2011. Does the stock market fully value intangibles? employee satisfaction and equity prices. *Journal of Financial Economics* 101 (3), 621–640.
- Guresen, E., Kayakutlu, G., Daim, T., 2011. Using artificial neural network models in stock market index prediction. *Expert Systems with Applications* 38 (8), 10389–10397.
- Einav, L., Levin, J. D., 2013. The data revolution and economic analysis. Tech. rep., National Bureau of Economic Research.

- Escobar, A., Moreno, J., Múnera, S., 2013. A technical analysis indicator based on fuzzy logic. *Electronic Notes in Theoretical Computer Science* 292, 27–37.
- Estrada, J., 2009. Geometric mean maximization: an overlooked portfolio approach? Available at SSRN 1421232.
- Etzioni, O., Weld, D., 1995. Intelligent agents on the internet: Fact, fiction, and forecast. *IEEE expert* 10 (4), 44–49.
- Evans, C., Pappas, K., Xhafa, F., 2013. Utilizing artificial neural networks and genetic algorithms to build an algo-trading model for intra-day foreign exchange speculation. *Mathematical and Computer Modelling*.
- Fama, E. F., 1970. Efficient capital markets: A review of theory and empirical work\*. *The Journal of Finance* 25 (2), 383–417.
- Fox, G., Johnson, M., Lyzenga, G., Otto, S., Salmon, J., Walker, D., White, R. L., 1989. Solving problems on concurrent processors vol. 1: General techniques and regular problems. *Computers in Physics* 3 (1), 83–84.
- Franklin, S., Greasser, A., 1996. Is it an agent, or just a program?: A taxonomy for autonomous agents. In: *Proceedings of the Third International Workshop on Agent Theories, Architectures, and Languages*, Springer-Verlag.
- Gabrielsson, P., König, R., Johansson, U., 2013. Evolving hierarchical temporal memory-based trading models. In: *Applications of Evolutionary Computation*. Springer, pp. 213–222.
- Gau, Y.-F., Wu, Z.-X., 2014. Order choices under information asymmetry in foreign exchange markets. *Journal of International Financial Markets, Institutions and Money* 30, 106–118.
- Ghoul, S. E., Guedhami, O., Kwok, C. C., Mishra, D. R., 2011. Does corporate social responsibility affect the cost of capital? *Journal of Banking & Finance* 35 (9), 2388–2406.
- Giebel, S., Rainer, M., 2013. Neural network calibrated stochastic processes: forecasting financial assets. *Central European Journal of Operations Research*, 1–17.
- Gilchrist, S., Sim, J. W., Zakrajšek, E., 2014. Uncertainty, financial frictions, and investment dynamics. Tech. rep., *National Bureau of Economic Research*.

- Gödel, K., 1992. On Formally Undecidable Propositions of Principia Mathematica and Related Systems. Dork.
- Goldberg, D. E., Holland, J. H., 1988. Genetic algorithms and machine learning. *Machine learning* 3 (2), 95–99.
- Golmakani, H. R., Fazel, M., 2011. Constrained portfolio selection using particle swarm optimization. *Expert Systems with Applications* 38 (7), 8327–8335.
- Grover, L., 1996. A fast quantum mechanical algorithm for database search. In: *Proceedings of the twenty-eighth annual ACM symposium on Theory of computing*. ACM, pp. 212–219.
- Guo, H. W. X., Yang, F., 2012. Thermal power financial environment risk forecast model by combined stock multi-indicators basis on rbf neural network. *AASRI Procedia* 1, 519–524.
- Hanafizadeh, P., Mirzazadeh, M., 2011. Visualizing market segmentation using self-organizing maps and fuzzy delphi method—adsl market of a telecommunication company. *Expert Systems with Applications* 38 (1), 198–205.
- Harvey, C. R., Siddique, A., 2000. Conditional skewness in asset pricing tests. *The Journal of Finance* 55 (3), 1263–1295.
- Hatcher, L., O’Rourke, N., 2014. A step-by-step approach to using SAS for factor analysis and structural equation modeling. Sas Institute.
- Haven, E., Liu, X., Shen, L., 2012. De-noising option prices with the wavelet method. *European Journal of Operational Research* 222 (1), 104–112.
- Homann, A., Jager, W., Eije, J. V., 2007. Social simulation of stock markets: Taking it to the next level. *Journal of Artificial Societies and Social Simulation* 10 (2), 7.
- Hsieh, T., Hsiao, H., Yeh, W. C., 2011. Forecasting stock markets using wavelet transforms and recurrent neural networks: An integrated system based on artificial bee colony algorithm. *Applied soft computing* 11 (2), 2510–2525.
- Hsu, Y., Lee, C., Kreng, V., 2010. The application of fuzzy delphi method and fuzzy ahp in lubricant regenerative technology selection. *Expert Systems with Applications* 37 (1), 419–425.
- Huberman, B., Glance, N., 1993. Evolutionary games and computer simulations. *Proceedings of the National Academy of Sciences* 90 (16), 7716–7718.

- Hussan, M., Nath, B., Kirley, M., 2007. Fussion model hmm, ann and ga for stock market forecasting. *Experts Systems With Applications* 33, 171–180.
- Hutter, M., 2001. General loss bounds for universal sequence prediction. arXiv preprint cs/0101019.
- Hutter, M., 2003. Optimality of universal bayesian prediction for general loss and alphabet. *Journal of Machine Learning Research* 4, 971–997.
- Hutter, M., 2007. On universal prediction and bayesian confirmation. *Theoretical Computer Science* 384 (1), 33–48.
- Hutter, M., 2012a. Can intelligence explode? *Journal of Consciousness Studies* 19 (1-2), 143–166.
- Hutter, M., 2012b. One Decade of Universal Artificial Intelligence. Atlantis Press.
- Hutter, M., Zaalon, M., 2005. Distribution of mutual information from complete and incomplete data. *Computational Statistics & Data Analysis* 48 (3), 633–657.
- Indro, D. C., Lee, W. Y., 1997. Biases in arithmetic and geometric averages as estimates of long-run expected returns and risk premia. *Financial Management*, 81–90.
- Jean, W. H., 1984. The harmonic mean and other necessary conditions for stochastic dominance. *The Journal of Finance* 39 (2), 527–534.
- Jeanneney, S. G., Kpodar, K., 2011. Financial development and poverty reduction: Can there be a benefit without a cost? *The Journal of Development Studies* 47 (1), 143–163.
- Jobson, J. D., Korkie, B., 1982. Potential performance and tests of portfolio eciency. *Journal of Financial Economics* 10 (4), 433–466.
- Johnson, N., Lamper, D., Jeeries, P., Hart, M., Howison, S., 2001. Application of multi-agent games to the prediction of financial time series. *Physica A: Statistical Mechanics and its Applications* 299 (1), 222–227.
- Jorion, P., 1986. Bayes-stein estimation for portfolio analysis. *Journal of Financial and Quantitative Analysis* 21 (3), 279–292.

Kaboudan, M., Conover, M., 2013. A three-step combined genetic programming and neural networks method of forecasting the s&p/case-shiller home price index. *International Journal of Computational Intelligence and Applications* 12 (01).

Kancerevičius, G., 2009. Finansai ir investicijos. Vol. 3 leidimas. Smaltija.

Kendall, G., Su, Y., 2005. A particle swarm optimisation approach in the construction of optimal risky portfolios. In: *Artificial Intelligence and Applications*. ACTA Press.

Khashei, M., Bijari, M., 2012. Exchange rate forecasting better with hybrid artificial neural networks models. *Journal of Mathematical and Computational Science* 1 (1).

Khashei, M., Rafiei, F., Bijari, M., 2013. Hybrid fuzzy auto-regressive integrated moving average (farimah) model for forecasting the foreign exchange markets. *International Journal of Computational Intelligence Systems* 6 (5), 954–968.

Kim, K., Han, I., 2000. Genetic algorithms approach to feature discretization in artificial neural networks for the prediction of stock price index. *Expert Systems With Applications* 19 (2), 125–132.

Kimoto, T., Asakawa, K., Yoda, M., Takeoka, M., Jun 17–21 1990. Stock market prediction system with modular neural networks. In: *International Joint Conference, San Diego, CA, USA*. Vol. 1. pp. 1–6.

Knight, F. H., 2012. Risk, uncertainty and profit. Courier Dover Publications.

Koekebakker, S., Zakamouline, V., 2007. Generalized sharpe ratios and portfolio performance evaluation. Faculty of Economics and Social Sciences, University of Agder, Norway.

Kohonen, T., 1988. An introduction to neural computing. *Neural networks* 1 (1), 3–16.

Kronholm, K., Schweizer, J., 2003. Snow stability variation on small slopes. *Cold Regions Science and Technology* 37 (3), 453–465.

Kulkarni, A. S., 1996. Application of neural networks to stock market prediction. Tech. rep., [www.machine-learning.martinsewell.com](http://www.machine-learning.martinsewell.com).

- Kumar, V., Grama, A., Gupta, A., Karypis, G., 1994. Introduction to parallel computing: design and analysis of algorithms. Benjamin/Cummings Publishing Company Redwood City, CA.
- Kuo, R., Lee, L., Lee, C., 14-17 Oct. 1996. Integration of artificial neural networks and fuzzy delphi for stock market forecasting. In: Systems, Man, and Cybernetics, 1996., *IEEE International Conference on*. Vol. 2. pp. 1073–1078.
- Latane, H. A., 1959. Criteria for choice among risky ventures. *The Journal of Political Economy* 67 (2), 144–155.
- Law, S. H., Singh, N., 2014. Does too much finance harm economic growth? *Journal of Banking & Finance* 41, 36–44.
- LeBaron, B., 2002. Building the santa fe artificial stock market. *Physica A*.
- Legg, S., Hutter, M., 2007. Universal intelligence: A definition of machine intelligence. *Minds & Machines* 17 (4), 391–444.
- Lim, K.-P., Brooks, R., 2011. The evolution of stock market efficiency over time: a survey of the empirical literature. *Journal of Economic Surveys* 25 (1), 69–108.
- Makridou, G., Atsalakis, G., Zopounidis, C., Andriosopoulos, K., 2013. Gold price forecasting with a neuro-fuzzy-based inference system. *International Journal of Financial Engineering and Risk Management* 1 (1), 35–54.
- Maridziuk, J., Jaruszewicz, M., 2007. Neuroevolutionary approach to stock market prediction. In: IJCNN 2007, *International Joint Conference on* 12-17 Aug. 2007. pp. 2515–2520.
- Markowitz, H., 1952. Portfolio selection. *The journal of finance* 7 (1), 77–91.
- Markowitz, H., 2012. Mean-variance approximations to the geometric mean. *Annals of Financial Economics* 7 (01).
- Marwala, T., 2013. Multi-agent approaches to economic modeling: Game theory, ensembles, evolution and the stock market. In: *Economic Modeling Using Artificial Intelligence Methods*. Springer, pp. 195–213.
- Mathieu, P., Brandouy, O., 2010. A generic architecture for realistic simulations of complex financial dynamics. In: Demazeau, Y., Dignum, F., Corchado, J., Pérez, J. (Eds.), *Advances in Practical Applications of Agents and Multiagent Systems*. Vol. 70 of *Advances in Intelligent and Soft Computing*.

- Springer Berlin / Heidelberg, pp. 185–197, 10.1007/978-3-642-12384-9\_23.
- McCarthy, J., Lifschitz, V., 1991/1950. Artificial intelligence and mathematical theory of computation: papers in honor of John McCarthy. Academic Press.
- McCulloch, W., Pitts, W., 1943. A logical calculus of the ideas imminent in nervous activity. *Bulletin of Mathematical Biophysics* 5, 115–33.
- McKay, M. D., 1995. Evaluating prediction uncertainty. Tech. rep., Nuclear Regulatory Commission, Washington, DC (United States). Div. of Systems Technology.
- Melnikas, B., Samulevičius, J., 2010. Institutional interaction and activation of scientific and technological progress: The case of lithuanian. In: *6th International scientific conference "Business and Management"2010*. Vilniaus Gedimino technikos universitetas.
- Merhav, N., Feder, M., 1998. Universal prediction. *IEEE Transactions on Information Theory* 44 (6), 2124–2147.
- Miller, J., 1996. The coevolution of automata in the repeated prisoner’s dilemma. *Journal of Economic Behavior & Organization* 29 (1), 87–112.
- Minsky, M., 1963. Steps toward artificial intelligence. *Computers and thought* 406, 450.
- Missiakoulis, S., Vasiliou, D., Eriotis, N., 2007. A requiem for the use of the geometric mean in evaluating portfolio performance. *Applied Financial Economics Letters* 3 (6), 403–408.
- Missiakoulis, S., Vasiliou, D., Eriotis, N., 2010. Arithmetic mean: A bellwether for unbiased forecasting of portfolio performance. *Managerial Finance* 36 (11), 958–968.
- Missiakoulis, S., Vasiliou, D., Eriotis, N., 2012. Forecasting performance with the harmonic mean: Long-term investment horizons in shanghai stock exchange. *Review of Applied Economics* 8 (1).
- Mohapatra, P., Das, S., 2013. Stock market prediction using bio-inspired computing: A survey. *International Journal of Engineering Science*.
- Mundell, R., 1973. A plan for a european currency. *The economics of common currencies*, 143–172.



- Mundell, R., 2000. Currency areas, volatility and intervention. *Journal of Policy Modeling* 22 (3), 281–299.
- Mundell, R., 2003a. Does asia need a common currency? In: *Exchange Rate Regimes and Macroeconomic Stability*. Springer, pp. 61–75.
- Mundell, R., 2003b. Prospects for an asian currency area. *Journal of Asian economics* 14 (1), 1–10.
- Mundell, R., 2012. The case for a world currency. *Journal of Policy Modeling* 34 (4), 568–578.
- Mundell, R. A., 1961. A theory of optimum currency areas. *The American Economic Review*, 657–665.
- Nagelocd, K., Rasmussenaf, S., 1994. Trac at the edge of chaos. In: *Artificial Life IV: Proceedings of the Fourth International Workshop on the Synthesis and Simulation of Living Systems*. Vol. 4. MIT Press, p. 222.
- Neri, F., 2011. Learning and predicting financial time series by combining natural computation and agent simulation. *Applications of Evolutionary Computation*, 111–119.
- Newell, A., 1982. The knowledge level. *Artificial intelligence* 18 (1), 87–127.
- Nguyen, H., Chan, C., 2004. Multiple neural networks for a long term time series forecast. *Neural Computing & Applications* 13 (1), 90–98.
- Ohlhorst, F. J., 2012. Big data analytics: turning big data into big money. John Wiley & Sons.
- Onur, E., 2008. The role of asymmetric information among investors in the foreign exchange market. *International Journal of Finance & Economics* 13 (4), 368–385.
- Patel, P., Marwala, T., 2006. Forecasting closing price indices using neural networks. In: *Systems, Man and Cybernetics, 2006. SMC’06. IEEE International Conference on*. Vol. 3. pp. 2351–2356.
- Peat, M., et al., 2013. Big data in finance. *InFinance: The Magazine for Fiansia Members* 127 (1), 1834–4232.
- Pierro, M. D., Mosevich, J., 2011. Eects of skewness and kurtosis on portfolio rankings. *Quantitative Finance* 11 (10), 1449–1453.

- Plikynas, D., 2008. Multiagent based global enterprise resource planning: Conceptual view. *Wseas Transactions on Business And Economics* 5 (6).
- Pontines, V., Rajan, R. S., 2011. Foreign exchange market intervention and reserve accumulation in emerging asia: Is there evidence of fear of appreciation? *Economics Letters* 111 (3), 252–255.
- Preble, J., 1983. Public sector use of the delphi technique. *Technological Forecasting and Social Change* 23 (1), 75–88.
- Prietula, M., Carley, K., Gasser, L., 1998. Simulating organizations: Computational models of institutions and groups. Vol. 1. The MIT Press.
- Qiang, Y., Bing, L., Yijun, L., 2005. Amnestic neural network for classification: application on stock trend prediction. In: *Services Systems and Services Management, 2005. Proceedings of ICSSSM '05. 2005 International Conference on 13-15 June 2005*. Vol. 2. pp. 1031–1034.
- Quek, C., Guo, Z., Maskell, D. L., 2011. A novel fuzzy associative memory architecture for stock market prediction and trading. *International Journal of Fuzzy System Applications* 1 (1), 61–78.
- Ramanauskas, T., Rutkauskas, A., 2009. Empirical version of an artificial stock market model. *Monetary Studies* 1, 5–26.
- Raposo, R., Cruz, A. O., Mendes, S., *et al.*, 2005. Using frames and multi-agents for stock market prediction based on fundamentalist analysis with fuzzy neural networks. In: *Proceeding AIC'05 Proceedings of the 5th WSEAS International Conference on Applied Informatics and Communications*. Vol. 3. Stevens Point, Wisconsin, USA, pp. 2892–2897.
- Rashid, T., 2009. A heterogeneous ensemble network using machine learning techniques. *International Journal of Computer Science and Network Security* 9 (8), 335–339.
- Rechenberg, I., 1973. Evolution strategy: Optimization of technical systems by means of biological evolution. Fromman-Holzboog, Stuttgart 104.
- Rimkutė, E., 2007. Mąstymas ir kalba. Vilnius University press.
- Majhii R., Panda, G., G.Sahoo, 2009. Development and performance evaluation of flann based model for forecasting of stock markets. *Expert Systems with Applications* 36 (3), 6800–6808.

- Roll, R., 1980. Orthogonal portfolios. *Journal of Financial and Quantitative Analysis* 15 (05), 1005–1023.
- Roll, R., 1983. On computing mean returns and the small firm premium. *Journal of Financial Economics* 12 (3), 371–386.
- Rousseau, P. L., Wachtel, P., 2011. What is happening to the impact of financial deepening on economic growth? *Economic Inquiry* 49 (1), 276–288.
- Rutkauskas, A., 2000. Formation of adequate investment portfolio for stochasticity of profit possibilities. *Property management* 4 (2), 100–115.
- Rutkauskas, A., 2001. Financial analysis problems under presence of uncertainty. *Property management* 5 (1), 45–62.
- Rutkauskas, A., 2006. Adekvačiojo investavimo portfelio anatomija ir sprendimai panaudojant imitacines technologijas. *Ekonomika* 75, 52–76.
- Rutkauskas, A., May 2008. From two-dimensional profit-risk to three-dimensional profit-reliability-risk in financial markets. In: *Marketing and Management Sciences*. Imperial College Press, pp. 508–511.
- Rutkauskas, A., Ramanauskas, T., 2009. Building an artificial stock market populated by reinforcement-learning agents. *Journal of Business Economics and Management* 4, 329–341.
- Saeedi, A., Chahardeh, Z., 2013. The effects of uncertainty of available information on investors’ behaviors on herding formation. *Management Science Letters* 3 (7), 1983–1988.
- Santiago, R. D., Estrada, J., 2011. Geometric mean maximization: Expected, observed, and simulated performance. *Observed, and Simulated Performance* (July 27, 2011).
- Sarno, L., Taylor, M. P., 2001. Official intervention in the foreign exchange market: is it effective and, if so, how does it work? *Journal of Economic Literature*, 839–868.
- Schmidhuber, J., 2002. The speed prior: a new simplicity measure yielding near-optimal computable predictions. In: *Computational Learning Theory*. Springer, pp. 216–228.
- Schmidhuber, J., Gagliolo, M., Wierstra, D., Gomez, F., Apr. 2006. Evolution for recurrent support vector machines. isbn 2-930307-06-4. *ESANN’2006 proceedings - European Symposium on Artificial Neural Networks*, 593–598.

Schmidhuber, J., Wierstra, D., Gomez, F., 2005. Evolution: Hybrid neuroevolution / optimal linear search for sequence learning. proceedings of the 19th international joint conference on artificial intelligence,. *Proceedings of the 19th International Joint Conference on Artificial Intelligence*, 466–477.

Schmidt, A., 1996. A modular neural network architecture with additional generalization abilities for high dimensional input vectors. Ph.D. thesis, Manchester Metropolitan University.

Schumpeter, J. A., 1934. The theory of economic development: An inquiry into profits, capital, credit, interest, and the business cycle. Vol. 55. Transaction Publishers.

Searle, J., September 1980. Minds, brains, and programs. *Behavioral and Brain Sciences* 3 (3), 417–424.

Sephton, P. S., Larsen, H. K., 1991. Tests of exchange market efficiency: fragile evidence from cointegration tests. *Journal of International Money and Finance* 10 (4), 561–570.

Sewell, M., 2011. History of the efficient market hypothesis. RN 11 (04), 04.

Sharpe, W., 1994. The sharpe ratio. *The Journal of Portfolio Management* 21 (1), 49–58.

Shen, W., Guo, X., Wu, C., Wu, D., 2011. Forecasting stock indices using radial basis function neural networks optimized by artificial fish swarm algorithm. *Knowledge-Based Systems* 24 (3), 378–385.

Shiller, R. J., February 1980. Do stock prices move too much to be justified by subsequent changes in dividends? Working Paper 456, National Bureau of Economic Research.

Shoham, Y., 1997. An overview of agent-oriented programming. Software agents 4.

Singh, M., Huhns, M., 1999. Multiagent systems for workflow. *International Journal of Intelligent Systems in Accounting, Finance & Management* 8 (2), 105–117.

Situngkir, H., Surya, Y., 2004. Agent-based model construction in financial economic system. arXiv preprint nlin/0403041.

- Siwek, K., Osowski, S., Szupiluk, R., 2009. Ensemble neural network approach for accurate load forecasting in a power system. *International Journal of Applied Mathematics and Computer Science* 19 (2), 303–315.
- Solomono, R., Feb 1960. A preliminary report on a general theory of inductive inference. Tech. Rep. V-131, Zator Co. and Air Force Office of Scientific Research, Cambridge, Mass.
- Sortino, F. A., Price, L. N., 1994. Performance measurement in a downside risk framework. *The Journal of Investing* 3 (3), 59–64.
- Spence, A. M., Michael, A., 1974. Market signaling: Informational transfer in hiring and related screening processes. Harvard University Press Cambridge, MA.
- Spence, M., 1973. Job market signaling. *The quarterly journal of Economics*, 355–374.
- Spence, M., 1976. Informational aspects of market structure: An introduction. *The Quarterly Journal of Economics*, 591–597.
- Stiglitz, J. E., 1984. Theories of wage rigidity.
- Stiglitz, J. E., Weiss, A., 1981. Credit rationing in markets with imperfect information. *The American economic review*, 393–410.
- Strauss, H., Zeigler, L., 1975. Delphi, political philosophy and the future. *Futures* 7 (3), 184–196.
- Streltchenko, O., Yesha, Y., Finin, T., 2005. Multi-agent simulation of financial markets. *Formal Modelling in Electronic Commerce*, 393–419.
- Szeto, K., Fong, L., 2000. How adaptive agents in stock market perform in the presence of random news: A genetic algorithm approach. In: Intelligent Data Engineering and Automated Learning—IDEAL 2000. *Data Mining, Financial Engineering, and Intelligent Agents*. Springer, pp. 505–510.
- Tesfatsion, L., Judd, L., 2006. Handbook of Computational Economics: Agent-Based Computational Economics. Elsevier, 2006.
- Todd, G. P., 2000. Mean-variance analysis in portfolio choice and capital markets. Vol. 66. John Wiley & Sons Incorporated.
- Tome, J., Carvalho, J., 2005. Market index prediction using fuzzy boolean nets hybrid intelligent systems. In: *HIS '05, Fifth International Conference on 6-9 Nov. 2005*. Vol. 5. INESC-ID, Lisboa, Portugal.

Topa, G., 2001. Social interactions, local spillovers and unemployment. *The Review of Economic Studies* 68 (2), 261–295.

Tsakonas, A., Dounias, G., Sep 2005. An architecture-altering and training methodology for neural logic networks: Application in the banking sector. In: Madani, K. (Ed.), *Proceedings of the 1st International Workshop on Artificial Neural Networks and Intelligent Information Processing, ANNIIP 2005. NSTICC Press, Barcelona, Spain*, pp. 82–93, in conjunction with ICINCO 2005.

Turing, A. M., 1936. On computable numbers, with an application to the entscheidungsproblem. *Proceedings of the London mathematical society* 42 (2), 230–265.

Turing, A. M., 1950. Computing machinery and intelligence. *Mind* 59 (236), 433–460.

Vapnik, V., 2000. The nature of statistical learning theory. *Springer*.

Š. Raudys, Zliobaite, I., 2006. The multi-agent system for prediction of financial time series. In: *Artificial Intelligence and Soft Computing – ICAISC 2006*. Vol. 4029. Springer Berlin / Heidelberg, pp. 653–662, 10.1007/11785231\_68.

Walker, A., Selfe, J., 1996. The delphi method: a useful tool for the allied health researcher. *International Journal of Therapy and Rehabilitation* 3 (12), 677–681.

Wang, J., Leu, J., Jun 3–6 1996. Stock market trend prediction using arima-based neural networks. In: *IEEE International Conference on Neural Networks*, Washington DC, USA. Vol. 44. pp. 2160–2165.

Wang, P., 2014. Is the distribution of financial returns symmetric?—empirical evidence from the international exchange market. *Empirical Evidence from the International Exchange Market* (March 9, 2014).

Weide, J. H. V., Peterson, D. W., Maier, S. F., 1977. A strategy which maximizes the geometric mean return on portfolio investments. *Management Science* 23 (10), 1117–1123.

Werbos, P. J., 1982. Applications of advances in nonlinear sensitivity analysis. In: *System modeling and optimization*. Springer, pp. 762–770.

- Wheeler, D. J., 2013. Problems with skewness and kurtosis, part two, <http://www.qualitydigest.com/inside/quality-insider-article/problems-skewness-and-kurtosis-part-two.html> (2013/08/08).
- Wierstra, D., Gomez, F., Schmidhuber, J., 2005. Modelling systems with internal state using evoluno. *Conference on genetic and evolutionary computation GECCO*, 1795–1802.
- Windle, P., *et al.*, 2004. Delphi technique: assessing component needs. *Journal of perianesthesia nursing: ocial journal of the American Society of PeriAnesthesia Nurses/American Society of PeriAnesthesia Nurses* 19 (1), 46.
- Wong, A., Zhou, X., 2014. Development of financial market and economic growth: Review of hong kong, china, japan, the united states and the united kingdom. *International Journal of Economics and Finance* 3 (2), p111.
- Xia, Y., Liu, B., Wang, S., Lai, K. K., 2000. A model for portfolio selection with order of expected returns. *Computers & Operations Research* 27 (5), 409–422.
- Xu, F., Chen, W., Yang, L., 2007. Improved particle swarm optimization for realistic portfolio selection. In: Software Engineering, Artificial Intelligence, Networking, and Parallel/Distributed Computing, 2007. *SNPD 2007. Eighth ACIS International Conference on*. Vol. 1. IEEE, pp. 185–190.
- Yamashita, T., Hirasawa, K., Hu, J., 2005. Application of multi-branch neural networks to stock market prediction. In: *Neural Networks, 2005. IJCNN'05. Proceedings. 2005 IEEE International Joint Conference on*. Vol. 4. IEEE, pp. 2544–2548.
- Ye, B. M. K., Wang, S., Wang, H., 2008. Ontology based multi-agent system for financial systemic risk management. In: *Education Technology and Training, International Workshop on Geoscience and Remote Sensing*. Vol. 2. pp. 609–612.
- Zadeh, L. A., 1965. Fuzzy sets. *Information and control* 8 (3), 338–353.
- Zakamouline, V., Koekebakker, S., 2009. Portfolio performance evaluation with generalized sharpe ratios: Beyond the mean and variance. *Journal of Banking & Finance* 33 (7), 1242–1254.
- Zhang, G., 2012. Optimal geometric mean returns of stocks and their options. *International Journal of Stochastic Analysis* 2012.
- Zhang, L., Sun, Y., 2013. Evolved neural network based intelligent trading

system for stock market. In: *Advances in Swarm Intelligence*. Springer, pp. 478–488.

Zhou, Z.-H., Wu, J., Tang, W., 2002. Ensembling neural networks: many could be better than all. *Artificial intelligence* 137 (1), 239–263.

Zhu, H., Wang, Y., Wang, K., Chen, Y., 2011. Particle swarm optimization (pso) for the constrained portfolio optimization problem. *Expert Systems with Applications* 38 (8), 10161–10169.



---

## Autorės mokslinių publikacijų disertacijos tema sąrašas

### Recenzuojamuose mokslo žurnaluose

Rutkauskas, A.V.; Stasytytė, V.; Maknickienė, N. 2014. Government debt as the integral portfolio of assets and liabilities generated by debt, *Journal of Business Economics and Management. Vilnius: Technika* 15(1): 22–44. ISSN 1611-1699. (ISI Web of Science)

Maknickienė, N.; Maknickas, A. 2013. Financial market prediction system with Evolino neural network and delphi method, *Journal of Business Economics and Management. Vilnius: Technika* 14(2): 403–413. ISSN 1611-1699. (ISI Web of Science)

Rutkauskas, A. V.; Levickaitė, R.; Maknickienė, N. 2014. Creative Economy: Search for Universally Sustainable Development Possibilities in the Context of Lithuanian Creative and Cultural Industries, *Asian Journal of Business and Management (AJBM). Jakarta: Asian Online Journals* 2(4): 246–257. ISSN 2321-2802.

Maknickienė, N.; Rutkauskas, A.V.; Maknickas, A. 2011. Investigation of finance market prediction by recurrent neural network, *Innovative Technologies for Science, Business and Education* 2(11): 3–8. ISSN 2029-1035.

### Kituose mokslo leidiniuose

Stankevičienė, J.; Maknickienė, N.; Maknickas, A. 2014. Investigation of exchange market prediction model based on high-low daily data, in *The 8th Internationale Scientific Conference Business and Management 2014*, 320–327. ISSN 2029-4441.

Maknickienė, N. 2014. Selection of orthogonal investment portfolio using evolino RNN trading model, in *Procedia – Social and Behavioral Sciences. The 2-dn International Scientific conference „Contemporary Issues in Business, Management and Education 2013”*. Amsterdam: Elsevier Science Ltd., vol. 110, 1158–1165.

Maknickienė, N.; Maknickas, A. 2013a. Investigation of Prediction Capabilities using RNN Ensembles, in *Proceedings of Conference 5th International Joint Conference on Computational Intelligence*, 391–395.

Maknickienė, N.; Maknickas, A. 2012. Application of neural network for forecasting of exchange rates and forex trading, in *The 7th Internationale Saentific Conference Buisnes and Managemesnt 2012*, 122–127. ISSN 2029-4441. (Thomson ISI Proceedings)

Maknickas, A.; Maknickienė, N. 2012. Influence of data orthogonality: on the accuracy and stability of financial market predictions, in *Proceedings of Conference IJCCI 2012: 4th International Joint Conference on Computational Intelligence, Barcelona, Spain, 5–7 October, 2012*, 616–619.

Maknickienė, N. 2012. Evaluation of the portfolio performance indicators, using Evolino RNN trading model, in *Proceedings of Conference Contemporary issues in business, management and education’2012*, 158–169.

Rutkauskas, A.V.; Stasytytė, V.; Maknickienė, N. 2011. Entrepreneurship portfolio construction and management, in *Proceedings of the Annual International Conference on inovation and Enterpreneuship*, 57–62. ISBN 978981089-4931.

Rutkauskas, A. V.; Maknickienė, N.; Maknickas, A. 2010. Modeling of history and prediction of finance market time serias using evolino, in *The 6th International Scientific Conference Business and Management 2010*, 170–175. ISSN 2029-4441. (Thomson ISI Proceedings)

---

## Summary in English

### Introduction

#### Problem formulation

The ability to predict the economic process produces better solutions for both the state and the company, or on a personal level, reduces the level of uncertainty. All financial market modelling and forecasting processes involve uncertainties and are constantly changing. Uncertainty leads to economic and financial policy changes, different growth rates of productivity change, war, acts of terrorism, climate change, natural disasters and has many other results. Economic uncertainty is inevitable, and all economic operators need to adapt to it. There is always a certain possibility of unknown risk, which was not foreseen, and probabilistic forecasts of economic expression need to be used. Currency market forecasting is a stochastic process, so it can only be a heuristic approach to obtaining the best result, which best reflects distributions of the possibilities. Such tasks are often dealt with using decision support systems. The support system for investors is created through the latest scientific and technological achievements in various fields. One of these is the artificial intelligence algorithms connecting mathematics, computer science, biology, psychology sciences. A properly designed, tested and optimised prediction model using artificial intelligence algorithms can be a reliable, profitable and moderately risky support system for investors. Prediction result of model can be not only a point, but stochastically informative distribution of expected values too. The integration of modern portfolio theory to forecasting model allows optimum profit and risk assessment. A support system for investor

can be successfully applied not only to personal speculation on the currency market, but also to the activities of investment funds and the management of public finances.

## **Relevance of the thesis**

Public finance management, investment funds and individual investors require reliable forecasting, and a modelling system of financial processes enabling better investment decisions, and reducing the level of uncertainty. Effective financial market theory is unable to explain all the chaotic market behaviour patterns, or to take into account the information asymmetry. The rapid development of new technological advances are penetrating the financial markets. The internet, and the development of information systems, have meant that financial market participants can quickly and effectively make decisions on currency and stock markets, monitor and analyse the results in real time. This dissertation therefore aims to deepen understanding of the functioning of the foreign exchange market, the key factors and states. The dissertation uses ensemble of algorithms for evolutionary recurrent neural networks, with different historical data, and allows a stochastically informative distribution of expected values, reflecting the behaviour of exchange rates in the future. Modern portfolio theory integrated with a forecasting tool allows forecasting of the financial market, and getting to know the essential characteristics of the financial market, which allows increased efficiency in the foreign exchange market and creates preconditions for a more rational allocation of limited resources in the world.

## **Object of research**

The support system for investors in the currency market based on artificial intelligence algorithms.

## **Aim of the thesis**

To create an investment decision-making support system targeting investors in the currency market by adapting artificial intelligence algorithms and modern portfolio theory.

## **Objectives of the thesis**

The following objectives have been set to achieve the aim of the thesis:

1. To analyse of the scientific literature about aspects of the financial markets in the global economy and artificial intelligence forecasting algorithms. Determining the synergy between the different branches of science, the latest technological breakthroughs and possibilities of modern portfolio theory with the purpose of obtaining an efficient, high-quality new, socially harmonious, and innovative forecasting tool.

2. To develop of the foreign exchange market forecasting model on the basis of universal artificial intelligence theory, universal predictions and opportunities of modern portfolio theory.
3. To integrate modern portfolio theory into the forecasting model with the purpose of obtaining an effective support system for investors in the currency market.
4. To substantiate empirically the effectiveness and reliability of the support system when investing in the currency market in real time, to verify modern portfolio theory.

## Research methodology

The scientific sources, including an analysis of theoretical and experimental studies, have been analyzed, synthesized and summarised in order to achieve the objectives of the thesis. Analytical and numerical methods for experiments have been used in this work, involving historical and real-time exchange market data. Economic forecasting methods have been used to shape the evolutionary neural network ensemble. Expert evaluation methods were customised for output of the artificial intelligence algorithms: the Delphi method and an assessment of the compatibility of the group rating. Methods of distribution analysis was applied to the output of big Evolino recurrent networks ensemble. Stochastic optimisation, visualisation and analysis methods were used to analyse possibilities for the investment portfolio.

## Scientific innovation of the thesis

1. An investment decision-making support system targeting investors in the currency market by adapting artificial intelligence algorithms and modern portfolio theory has been proposed.
2. The exchange market has been analysed as a chaotic process which is influenced by market resource elements. A selection of historical exchange rates and prices of resources were made in order to get closer to the maximum data orthogonality which improves forecasting statistical results and reduces time required for recurrent neural network learning.
3. Evolutionary recurrent neural network algorithms, combined into an ensemble with different historical data (8–1008 elements), can now receive quality forecasting, and assessment of opportunities for market expectations.
4. The result of the forecasting model is a stochastically informative distribution of expected values, reflecting the behaviour of the exchange rates forecast for the future. The composition of distributions opens opportunities for more efficient trading in the real market.

5. Investment portfolio optimisation and orthogonality principles incorporated in the forecasting model enables use of the Evolino recurrent neural network model in an environment characterised by high uncertainty as a reliable support system for the investor.

## Practical value of research findings

The support system for the investor in the currency market presented in the thesis, reliably reflects the behaviour of the foreign exchange market in the future, and assesses the profitability of the investor financial expectations, risks and reliability. Information obtained from the support system gives the investor the advantage in making investment decisions compared to the uninformed market players. The support system for the investor in the currency market, through an investment fund, the management of public finances, and the reinvestment of cash, can therefore solve social, cultural and other vital public problems.

## Statements to be defended

1. An effective support system for investors can be created by the application of artificial intelligence algorithms for forecasting the financial markets and integrating them with modern portfolio theory.
2. Distributions of expected values and their composition give further information to the investor and best reflect the future changes of the foreign exchange market.
3. Artificial intelligence algorithms can be successfully applied to financial market forecasting by aligning internal system parameters, selecting the proper input and by selecting the architecture of the artificial intelligence systems.
4. Investment decisions under uncertainty and risk become more effective if the investment portfolio optimisation equations are integrated into the model and the portfolio orthogonality principle is applied.
5. Testing the support system for investors in a real market is the best way to evaluate the investment tool and investment strategy, and gives further information about market participants.

## Approval of research findings

Four articles have been published on the dissertation topic: two in IS Web of Science journals (Rutkauskas *et al*(2014), Maknickienė, Maknickas (2013)), and two in other reviewed journals (Maknickienė *et al*(2011), Rutkauskas *et al*(2014)). Nine papers were presented at international conferences: two as conference materials in *ISI Proceedings*, Maknickienė, Maknickas *et al*(2012), Rutkauskas *et al*(2010)), seven were reviewed at

international conference proceedings (Stankevičienė *et al*(2014), (Maknickienė(2014), Maknickienė, Maknickas(2013), Maknickas, Maknickienė(2012), Maknickienė(2012), Rutkauskas *et al*(2011)).

The thesis consists of three chapters, beginning with the introduction. The first chapter analyses the financial market, including features, processes analysis, management and regulatory aspects of the global economy, and financial market forecasting using artificial intelligence algorithms. The second section is devoted to artificial intelligence, forecasting, expert methods and examination of the theoretical framework for investment, a detailed description of the operation principle of Evolino RNN, the choice of principles for the neural network ensemble architecture. The third section presents the stages of preparation for the artificial intelligence algorithms for productive work, the experimental evaluation of support systems for investor reliability, profitability and risk, and the experimental evaluation of investment portfolio optimisation strategies. This section also provides the results of testing the support system for investors in the real market and investment portfolio optimisation according to the composition of distributions. At the end of the thesis there is a general conclusions.

## Structure of the thesis

Volume of work is 145 pages, that contain: 49 formulas, 52 pictures and 4 tables. The thesis was based on 222 other literary sources.

## 1. Opportunities study of investment in financial markets

The abundance and reliability limitations of forecasting tools form a dual approach to economic forecasting: a sceptical thought that forecasting is not possible because of the uncertainty, or believed that the prediction models can reduce the level of uncertainty and to allow for better decisions. Financial market forecasting models are based on effective market theory, and the rationality of investors, and are essentially based on a certain state of equilibrium. In reality, the achievement of such a perfect state is not possible. For this reason, financial market forecasters sought other intelligent algorithms, which are based not only on mathematical logic, but on the variety of the patterns of behaviour formed by the nature. Financial market forecasting and modelling require a profound understanding of the functioning and the key factors of the finance market.

Nobel Prize winner Eugene Fama is regarded as the father of effective market hypothesis ((Fama 1970)). Historical analysis of a number of effective market hypothesis researchers Baillie *et al.* (1983), Sephton, Larsen (1991), Lim, Brooks (2011), Sewell (2011) leads to the conclusion that complete or perfect information for all market participants is unavailable, and therefore a fully efficient market can not exist. However, asymptotic approaches to the full information confirms price trends and ma-

kes effective market hypothesis of the main hypothesis of the social sciences. The main regularities of financial theory, which must be taken into account in research into financial processes, are uncertainty, the cyclical nature of economic processes, information variability and symmetry.

Well developed, smooth-functioning financial markets can play an important role in contributing to economic health and efficiency. The relationship between financial and economic growth was defined for the first time in 1911 by Joseph Schumpeter (Schumpeter (1934)).

Financial markets help to effectively target savings and investment in the economy with aim of growth of capital accumulation and production of goods and services. A harmony of well-developed financial markets and institutions, as well as a set of various financial products and instruments, meets the needs of borrowers and lenders and thus serves the entire economy. Disproportionate attempts to foster economic growth have side effects, however. The relationship between the frequency of financial crises and intensity of attempts to influence economic growth has been observed (Rousseau, Wachtel (2011)). Another problem for the global economy, which can be solved through financial market development, is the growing inequality and increasing poverty of the world's population (Beck *et al.* (2004a), Jeanneney, Kpodar (2011), Bae *et al.* (2012)).

The aim of achieving not only financial return but also social well-being through investment is obtained through socially responsible investing, which allows investors to positively express their values, even if they have to sacrifice diversification or short-term efficiency in their investment portfolio. However, in the long run this idea successfully competes with not socially responsible investment (Ghoul *et al.* (2011)).

Influential market players, such as governments or national banks, may affect the financial markets through control, regulation and interventions. Easier ways to participate in financial market activity include investment and speculation.

Large amounts of historical data, and an abundance of multimedia information about making the right choice and a need for reliability, and technological advancement, formed the background to the emergence of decision support systems for investors. Interactions between research and the knowledge economy, technological development and investor practices are certainly complex phenomena that require a sound scientific knowledge and effective technological solutions.

All methods are based on historical data, and statistical analysis can not accurately calculate the values of the financial market in the future. There is not a single law, formula or theorem that ensures stock, currency or capital market tool calculation. There are a lot of successful people, however, who have been trading in the stock exchanges for a long time. Heuristic market forecasting tools allow us to create a range of investor support systems. Artificial intelligence systems are also now being applied as financial market forecasting tools.

Investor in its decision to invest in a set of instruments has certain expectations that the market or other financial instruments in the future will behave according to certain rules. Investment success is therefore a reliable forecasting tool for selection and asset allocation.



A large part of forecasts is based on averages: arithmetic, geometric, harmonic and many weighted hybrids. Another important prediction method is the Sharpe index maximisation method. It is also based on the assumption that the behaviour of financial market instruments in the future will be the same as in the past. The wavelet noise reduction method is also used to obtain more reliable forecasts and lower investment risk profiles.

Artificial intelligence systems are among the most promising forecasting tools. Neural networks, genetic algorithms, fuzzy systems, expert systems or various hybrid tools are used for forecasting the financial markets. Artificial intelligence algorithms are prepared for productive work by selecting appropriate input, by aligning their parameters, grouping and combining multiple systems or modules as long as the prediction accuracy of the financial instruments are sufficient.

Having sufficiently reliable forecasts of expected returns naturally brings a need for the efficient allocation of resources invested in different financial instruments. Asset allocation is the decision process regarding the distribution of invested assets among different asset classes for investment purposes. Managing and investing their assets generally used a financial instrument – diversification. Anderson, Frankle (1980), Jorion (1986) examines the problem of portfolio diversification, and experimentally determines how many tools are needed for a safe investment portfolio. An effective portfolio is described as a portfolio with the highest return for a given level of risk, based on the maximisation of the expected return.

Pierro, Mosevich (2011) proposed a portfolio selection approach, and the use of portfolio returns using past distribution parameters: mean, standard deviation, Sharpe index, asymmetry and kurtosis. The portfolio which has the lowest risk for a given profitability is based on risk minimisation. One of the most popular of risk mitigation techniques is an orthogonal portfolio Roll (1980).

Rutkauskas (2000) offered adequate investment portfolio, which combines profitability, risks and reliability. Financial analysis under uncertainty from the usual two-dimensional (profitability-risk) is transformed to become three-dimensional (profitability-risk-reliability). An investment strategy is a set of investment solutions, which allows the investor to obtain the best balance of profitability, risk and reliability. For this purpose, a variety of optimisation algorithms are used. With the emergence of artificial intelligence algorithms, they also started to apply to optimisation of the investment portfolio.

Chaotic variations of financial instruments involve memory. What has happened in the past influences the future. The first step of the investment portfolio contains a certain pattern of change from the past. In the second step the invested funds are allocated to investment instruments, taking into account the finding in the first steps. Investment decisions shall be taken under uncertainty, giving priority to more expected predicted events, which are described by distribution.

## 2. Theoretical background of decision-making under uncertainty

Artificial intelligence can be defined as a science that creates computer algorithms that simulate intelligent processes that are typical in people.

One of the pioneers of artificial intelligence was Alan Turing (1950). He defined the rules, well known as the Turing test, which describe the relationship between humans and computers in order to recognise algorithms being artificial intelligence:

1. The opportunity to create a sufficient connection with a computer system in any human language.
2. Are able to recognize the knowledge before and after a test.
3. Automatically adapt to using the available knowledge and make new conclusions from this knowledge.
4. A learning process that has to adapt to new circumstances.

In practice, artificial intelligence systems can do everything a person is able to do. Scientists today are trying to develop these cognitive processes (Hutter (2012b)):

A summary is essentially an inductive conclusion. Induction is the process of concluding, in view of the general rules or models of observation or finding patterns in historical or other data. This is an essential feature of the intellect;

Prognosis is related to the future of an explanation based on the past observed data (Solomono (1960), Legg, Hutter (2007)).

Authentication is associated with the classification process. A certain character or class of items is to be selected from data.

Association. Two elements or events are linked if there is a relationship between them. A set of observations can be grouped into different categories.

Reasoning is undoubtedly the most prominent feature of human intelligence. Deductive reasoning or logic is not expressed as part of the architecture of artificial intelligence. The most common artificial intelligence is to perform logical decisions only where uncertainty is very low, or the probability is approximately 0 or 1.

Problem solving can be defined as a purposeful, reasoned, approach to achieving a certain goal.

Planning the ability to optimise future events, s certain location in time or space, is found in maximisation and minimisation functions, and it meets a certain set of rules.

Creativity is the ability to generate innovative ideas and implement them in reality. Creative people are often more successful than those without these properties. Creativity is the ability to solve optimisation problems where no one else could.

News. Artificial intelligence protects all operating history and has a strong ability to remember and use the stored knowledge.

Activity. Artificial intelligence can affect the environment that responds to the agent. Decisions can have long-term consequences, and artificial intelligence developers should take them into account.

Learning is a knowledge optimisation problem. There are many different forms of learning, such as with a teacher, without a teacher, semi-reinforced, copying, associative, and many others. Learning is one of the main features of artificial intelligence.

Knowing oneself is an important characteristic of high intelligence. It is important to recognise and identify the cause of your thoughts, especially when dealing with other forms of intelligence.

Consciousness is perhaps the most mysterious feature of the human mind, it is not surprising that there is too little data about its existence and the use of artificial intelligence systems.

This work examines only one characteristic of artificial intelligence – prediction, which is very important in order to provide financial market trends. By forecasting we mean the ability to correctly guess a certain amount of unknown data in time with some precision. The predicted dataset is compared with a set of known data to evaluate the correlation between them.

Suppose it is known that  $p$  is an element of some set of distributions  $P$ . Choose a fixed weight  $w_q$  for each  $q$  in  $P$  such that the  $w_q$  adds up to 1 (for simplicity, suppose  $P$  is countable). Then construct the Bayesmix  $M(x) = \sum_q w_q q(x)$ , and predict  $M$  instead of the optimal but unknown  $p$ . (Merhav, Feder (1998), Hutter (2003)): Let  $LM(n)$  and  $Lp(n)$  be the total expected unit losses of the  $M$  predictor and the  $p$  predictor, respectively, for the first  $n$  events. Then  $LM(n) - Lp(n)$  is at most of the order of  $\sqrt{Lp(n)}$ . That is,  $M$  is not much worse than  $p$ , and in general, no other predictor can do better than that. In particular, if  $p$  is deterministic, then the  $M$  predictor won't make any more errors.

If  $P$  contains all recursively computable distributions, then  $M$  becomes the celebrated enumerable universal prior. The aim of this paper is to construct a model that can make predictions with a small enough difference  $M(t) - p(t)$  for some fixed time  $t$ .

Authors (Schmidhuber *et al.* 2005) in 2005 introduced a new class of learning algorithms for supervised recurrent neural networks. Evolino stands for EVolution of recurrent systems with Optimal LINear Output. Evolino uses evolution to discover good recurrent neural network hidden node weights, while using methods such as linear regression or quadratic programming to compute the optimal linear mappings from the hidden state to the output. In some cases, quadratic programming is used to maximise the margin. Evolino-based Long Short-Term Memory (LSTM) can solve tasks that Echo State nets cannot.

The Evolino recurrent neural network forms an LSTM network with  $N = 4n$  memory cells, where  $N$  is the total number of neurons and  $n$  is the number of memory cells. The genetic evolution algorithm is applied to each quartet of memory cells separately. The cell has an internal state  $S$ , together with a forget gate ( $G_F$ ) that determines how much the state is attenuated at each time step. The input gate ( $G_I$ ) controls access to the cell through the external inputs that are summed into the  $\Sigma$  unit, and the output gate ( $G_O$ ) controls when and how much the cell fires. The dark nodes represent the multiplication function and the linear regression Moore-Penrose pseudo-inverse method is used to compute the output (light blue circle). A detailed

description of the Evolino RNN algorithm can be found in (Schmidhuber *et al.* 2005), (Schmidhuber *et al.* 2006). It is important to calibrate the internal Evolino recurrent neural network parameters for productive work. One Evolino RNN provides a forecast with some accuracy. More Evolino recurrent neural networks can be combined into ensembles. Ensembles were used by a number of scientists: Zhou *et al.* (2002), Tsakonas, Dounias (2005), Nguyen, Chan (2004), Siwek *et al.* (2009). All of these authors used 2–12 networks in ensemble and they argued that the ensemble forecast is more accurate and reliable than a single neural network. A difference emerges in how many elements are used in the ensemble. The quantity of ensemble elements is limited by the available memory and time resources. When the amount of RNN in the ensemble  $< 60$ , the forecast is a point or interval, and when the amount of RNN is  $> 60$ , it is possible to obtain a distribution of the expected values. Investment decisions depend on the shape and parameters of distribution.

The simplest way to define the portfolio is to indicate its composition, or to identify the amount or part of some type of investment that is included in the portfolio. Markovitzo (Markowitz (1952)), Bleck (Black (1974)) proposed the two dimensional portfolio optimisation model. Efficient two-dimensional portfolio (profitability-risk) is defined as a portfolio, which has the lowest risk for a given profitability and maximum return for a given level of risk:

$$\begin{cases} \max & ER_p \\ \min & \sigma^2; \end{cases} \quad (3.3)$$

where

$$ER_p = \sum_{i=1}^n W_i (ER_{di} - Me_i); \quad (3.4)$$

$$\sigma^2 = \sum_{i=1}^n W_i^2 \sigma_i^2 + 2 \sum_{i=1}^n \sum_{i=j}^n W_i W_j r_{ij} \sigma_i \sigma_j, \quad (3.5)$$

where  $ER_p$  is expected return of investment portfolio;  $ER_i$  “expected return of portfolio tool  $i$ ”;  $W_i$  is investment on tool  $i$ ;  $W_j$  is investment on tool  $j$ ;  $r_{ij}$  is correlation coefficient between tools  $i$  and  $j$ ;  $\sigma_i$  is standard deviation of tool  $i$ ;  $\sigma_j$  is standard deviation of tool  $j$ .

Optimisation under uncertainty is a decision-making framework to deal with model parameters (mean, expected utility, risk measure, etc.) that are unknown or stochastic. Data uncertainty is random and can be explained by probability distribution. Authors (Rutkauskas (2000), Rutkauskas (2006)) use a three-dimensional adequate portfolio, which has reliability as a third dimension.

$$\begin{cases} \max & ER_p \\ \min & \sigma^2. \\ \max & P_p \end{cases}$$

Uncertainty is described through a probability function  $P_p$ . It provides good solutions in practice, but it suffers from the curse of dimensionality.

The portfolio optimisation equation supplemented by the orthogonality condition, was first proposed by Roll (1980):

$$\left| \sum_{ij} r_{ij} \sigma_i \sigma_j \right| = 0. \quad (3.6)$$

This condition allows the investor to create a portfolio of investment tools that are least interrelated. Modern portfolio theory integrated in support system for investors makes investment decisions under uncertainty and risk more efficient.

### 3. Support system for investors in the currency market

A very important part of the application of artificial intelligence systems is input selection and customisation. The Evolino algorithm has been modified to use two inputs – one corresponding to forecast the exchange rate, the next selected as the "teacher" (gold price in USD, silver price in USD, oil price in USD and gas price in USD).

In the forecasting process by Evolino RNN, researchers can choose the most important internal parameters:

1. Number of iterations, describing how many times the neural network learning process needs repeating.
2. Number of neurons, describing how many neurons are needed to complete a task.
3. Quantity of historical data for input, describing how much data is needed to achieve the objective.

An intuitive guess that all of these parameters must be maximum failed. Numerical experimental study was performed to find the best Evolino RNN states for forecasting financial market instruments. During extensive research, changing the number of iterations, the number of neurons and historical data has been studied to determine the Evolino RNN ability to replicate historical data and predict three new and unknown points. By increasing the number of iterations, learning and prediction accuracy increases rapidly at first, but a certain level (150 iterations) is constant and further increases the number of repetitions, and thus the prediction time is no longer meaningful. The investigation revealed that better learning of the neural network does not guarantee better prediction. The study observed three types behaviour in forecasts by Evolino RNN: weak learning and not forecast; good learning and good forecasting; great learning but bad forecasting. Before using the tool, its parameters must be adjusted so that the results are in a good learning and good forecasting state. In most cases this is done by observing the graphical representation and the predicted error.

Through observation of RNN learning for financial market indexes DJIA, Nasdaq and gold price in USD, it was found that the result is highly dependent on the choice of the input and output ranges. Study of the standard deviation's dependence on learned RNN on orthogonality in selected ranges obtained much better results with higher data

orthogonality. Statistical research, selected most orthogonal inputs ( $[1e - 9; 1e - 6]$ ), and less orthogonal ( $[1e - 4; 9.99e - 4]$ ) and ( $[1e - 4; 9.99e - 3]$ ). Investigation revealed that the Evolino RNN accurately predicted when the input received most orthogonal data (pav. 3.3).

One Evolino RNN is harmonised for forecasting, our experience led to the creation of a forecasting model that uses an ensemble of 8 Evolino RNN. Prediction was investigated with the Python programme using the following steps:

**Data step.** Getting historical financial markets data from Meta Trader-Alpari. For prediction we chose EUR/USD (Euro and American Dollar), EUR/JPY (Euro and Japanese Yen), USD/JPY (American Dollar and Japanese Yen), EUR/CHF (Euro and Swiss Franc) exchange rates and their historical data for the first input, and for the second input, two years historical data for XAUUSD, XAGUSD, QM, and QG. At the end of this step we had a basis of historical data.

**Input step.** The Python script calculates the ranges of orthogonality of the last 80–140 points of the exchange rate historical data chosen for prediction, and an adequate interval from the two years historical data of XAUUSD, XAGUSD, QM, and QG. A value closer to zero indicates higher orthogonality of the input base pairs. The eight pairs of data intervals with the best orthogonality were used for the input to the Evolino recurrent neural network.

**Prediction step.** Eight Evolino recurrent neural networks made predictions for a selected point in the future. At the end of this step, we had eight different predictions for one point of time in the future.

**Consensus step.** The resulting eight predictions are arranged in ascending order, and then the median, quartiles, and compatibility are calculated. If the compatibility is within the range  $[0; 0.024]$ , the prediction is right. If not, then step 3 is repeated, sometimes with another ‘teacher’ if the orthogonality is similar. At the end of this step, we have one most probable prediction for the chosen exchange rate.

**Investment step.** Repeating steps 1–4 for the other exchange rates gives us a set of exchange rate forecasts to build an investment portfolio. The first portfolio is made from the four exchange rates (EUR/USD, EUR/JPY, USD/JPY, EUR/CHF), and the investment amount is divided equally at every step of investing. The second portfolio is made from the same four exchange rates but the amount invested is divided by the projected percentage gain. The third choice of investment portfolio consists of the exchange rate whose projected growth rate is the highest. Having several different exchange rate forecasts allows the investor to choose different investment portfolios and to reduce the investment risk, thus increasing its reliability. Three investment portfolios were tested: conservative, moderate and aggressive. Conservative portfolio was made from the four exchange rates (EUR/USD, EUR/JPY, USD/JPY, EUR/CHF) with the investment amount divided equally at every step of investing (3 days in our research). The investor, with four predictions from the model, chooses one from the three operations *buy* – if the exchange rate will increase, *sell* – if the exchange rate will decrease, and *keep* – if the prediction has some doubt, such as very high variation. Every operation with exchange rates has a damage equal to 0.02 from the operation.

Moderate portfolio is made from the same four exchange rates. The investor, having four predictions from the model, in order to maximise profits, divides the initial investment amount by the projected percentage gain.

Aggressive portfolio is made from the same exchange rates but the entire amount is invested in only one exchange rate, that with the biggest predicted profit.

The credibility of the model forecast, building investment portfolios by the projected gain, increases the profitability of the investment from 12%–15% to 20%–25% and 27%–35% in 40 trading days with different degrees of risk. The standard deviation describes the portfolio risk and the Sharpe ratio indicates the expected differential return per unit of risk associated with the differential return. The risk free rate was put at 3% per year. After selecting three different levels of risk for the investment portfolios, all portfolios had a good positive Sharpe index and the aggressive portfolio had a very good Sharpe index (greater than 1). Using only one exchange rate (EUR/USD and USD/JPY) resulted in a standard deviation of 0,61–0,62, and a Sharpe ratio of 0,73. Investing, knowing the prediction of the recurrent neural network ‘team’, becomes more reliable and more profitable. The increased reliability of the model gives the decision maker big investment opportunities and freedom of choice.

The model developed, based on the Evolino recurrent neural network and on expert methods, is simple to use and is a good tool for the investor. The reliability of this model, measured by the correlation coefficient, is high enough for profitable trading in the finance market. The credibility of the model’s forecast increases the profitability of the investment.

The model allows the investor to make different investment portfolios, based on the choice of different investment strategies with different levels of risk.

This model has great potential for various investment portfolios and investment strategy choices. It can be easily adapted for trading other financial indicators or stocks.

Second prediction model uses big number of Evolino RNN. For calculation of many ensembles, software and hardware acceleration were employed. Every predicting neural network from the ensemble could be calculated separately, so calculations could be made in parallel.

The first two steps – *Data step* and *Input step* – remain the same as in the first model. This is followed by other steps:

Prediction step. We can choose  $n$  neural network forecasting. Neural networks can mean a number of hours required for a decision, therefore, it is necessary to select the optimum number of ensembles. When  $n > 60$ , the forecast assumes the shape of the distribution. At the end of this step, we have a distribution with all parameters – mean, median, mode, skewness, kurtosis and etc. Decisions about trading are made through a composed portfolio of exchange rates by analysing the distribution parameters.



The test of the accuracy of models was investigated by MAPE (Mean Absolute Percentage Error)s:

$$P_{ea} = 100 - \frac{100}{N} \sum_i \frac{|Y_i - \hat{Y}_i|}{Y_i} \quad (3.7)$$

where  $N$  – number of observations in the test set,  $Y_i$  – actual output and  $\hat{Y}_i$  – forecasted output. Test from 5 observations was made in 20/01/2012–15/03/2012. The accuracy of predictions obtained in the interval was 94-99,6% forecasting becomes more stable when there are more networks. This investigation shows that in some cases more is not always better – with many predictions EVOLINO RNN requires more time and resources for calculating processes. An interval of number of EVOLINO RNN [1; 100] has high accuracy, but is not stable. The distribution of predictions has no form or clear shape and parameters are not informative. An interval [100; 200] is accurate and stable, so it does not require too much time and resources. Distribution of predictions is sufficiently informative. An interval of n [200; 300] is good for investigation, but requires too much calculation time – the investment decision in finance market so could be too late. Forecasts that are 1 and 2 points ahead are accurate and stable, and stability is only reached for forecasts 3, 4 and 5 points ahead when the ensemble consists of over 64 RNN. In time series forecasting, the magnitude of the forecasting error increases over time, since the uncertainty increases with the horizon of the forecast.

Neural network architecture is very important in the forecasting process. The single neural network system provides a point forecast where accuracy is very unstable. Ensembles from eight neural networks provide more accurate forecasting points in the expected range. When the number of neural networks exceeds 120 a multimodal distribution of predictions is obtained, it opens up new opportunities for investment portfolios. More is not always better, however. The ensemble for prediction requires more calculating time and resources. Stable and not faster growing prediction accuracy, is achieved by increasing the number of RNN in an ensemble, when  $n > 120$ , allows optimisation of the investment decision-making process. Those ensembles make it possible to expect prediction accuracy of up to 5 days into the future. Decisions to invest in the financial markets are always taken under uncertainty, and therefore, distributions are more informative and more reliable than the scatter projections. The application of distributions of probabilities in the investment portfolio needs further investigation.

When the number of Evolino RNN  $> 120$ , forecasting assumes the shape of the distribution. Distributions are not normal, they are multimodal. The tight distribution predicts the clear direction of currency price changes. Scattered distribution shows high risk, and its standard deviation is high. Multimodal distribution warns about several forces operating in the financial market. Skewed distribution shows the different probabilities of markets changing directions. Investor decisions in all cases depend on the last known value position in respect of mode of distribution.



Potential distributions best reflect the investment opportunities in conditions of uncertainty. Modelling, using an ensemble of Evolino RNN, is a reliable forecasting tool that is useful for investors in the currency market. Its prediction is stochastically informative potential distribution, which is helpful for portfolio selection. The shape and parameters of distribution influence decision making in currency markets.

The aspiration of every speculator is to buy at minimal value and to sell at maximal. Some changes were therefore made in the model, and forecasting obtained from high and low daily historical data. The result of the prediction is two distributions of expected returns – high and low. Speculators can use different probabilities for trading decisions. 68 % probability bounds can be used for finding take profit value, 95 % probability bounds can be used for finding stop loss value.

Testing this method with two distributions shows that prediction reflects the expected exchange rate dynamics. Two distributions are more stochastically informative for decision making in the Forex market than one.

High and low expected value distributions provide sufficient information about the direction of exchange rates changes, risks and reliability of investment. Accordingly, the area defined by the distribution reflects the probability of a decision. If conditions of forecasting are equal, trading using two distributions of the expected returns of the lowest and highest values are almost twice as effective than trading using closing data and one distribution of expected returns.

Testing the support system for investors in the currency market confirmed the theoretical assumptions of forecasting model reliability and accuracy, the principles of modern portfolio theory.

## General conclusions





1. Examining the possibilities of support systems for investors in the financial markets showed that complete or perfect information for all market participants is not available, and therefore a fully efficient market can not exist. However, the asymptotic approach to the full information confirms price trends and makes the effective market hypothesis one of the most important in the social sciences.
2. Developing support systems for investors involved monitoring synergies between the different branches of science (economics, mathematics, psychology, biology), the latest technological breakthroughs (online payments, artificial intelligence) and investor experience for the purpose of obtaining an efficient, high-quality new, socially harmonious, innovative forecasting tool.
3. The principles of investment portfolio selection define modern portfolio theory. Using three-dimensional evaluation of efficient portfolio, and portfolio orthogonality condition, adequate portfolio equations becomes very informative and allow for productive investment. Reliable and efficient support system for solutions in the financial markets, is capable of properly assessing historical data, using innovative algorithms. The support system for investors

was created using a targeted application of artificial intelligence algorithms to financial market forecasting and by integrating them into modern portfolio theory. This investment tool provides additional information for investors, so they obtain a competitive advantage over other market players:

- 3.1 The forecast of support systems for investors in the currency market is a multimodal distribution of expected values, the shape and parameters of which provide the investor with sufficient information about changes in the foreign exchange market in the future. The composition of distributions of the maximum and minimum expected values assesses the daily exchange rate fluctuation limits, and predicts the direction of change in the exchange rate conversion.
  - 3.2 Artificial intelligence algorithms can be successfully applied to forecasting currency markets, as they are properly aligned. Consistently changing internal RNN parameters involve finding numbers of neurons, iterations and the number of historical data points that the system operates in the area of good learning and good prognosis;
  - 3.3 After selecting the input with the lowest possible estimate of orthogonality ( $1e-4 < varepsilon$ ), forecasting accuracy and reliability increases;
  - 3.4 Architecture of artificial intelligence algorithms, determines the informativeness of forecasting results. One Evolino RNN provides a least informative point forecast. A small Evolino recurrent neural network ensemble (8 items), with expert techniques, provides a more accurate and reliable range of expected values. The forecasting accuracy of this ensemble is 62–76%. A big Evolino recurrent neural network ensemble (120–1008 elements) forecast provides a stochastically informative distribution and its forecasting accuracy is 92–96%;
4. Decisions about the allocation of invested funds with a reliable forecasting tool shall be taken when assessing the expected return for a given level of risk with a certain probability. The integration of equations in investment portfolio optimisation in the forecasting model and application of the portfolio orthogonality principle determines that investment decisions under conditions of uncertainty and risk become more efficient.
    - 4.1 The range of expected values allows the use of two-dimensional portfolio equations for investment portfolio optimisation, taking into account the risks and profitability, so as to choose the appropriate investment strategy. The effectiveness of different risk strategies expressed in the Sharpe index is 0,31 to 0,7 and in the Sortino index is 1,13 to 1,28.
    - 4.2 When parameters of distributions of expected values are applied to adequate three-dimensional portfolio equations, the investment portfolio optimisation problem becomes a simple square optimisation task. Efficiency

of orthogonal and orthogonal-optimised portfolios expressed in Sharpe index is from 0.66 to 2.03, and in the Sortino index is 107.51.

5. Testing the support system for investors in the currency market in a simulated market in real time confirmed the theoretical assumptions of the system’s reliability and accuracy and the theoretical principles of modern portfolio theory.



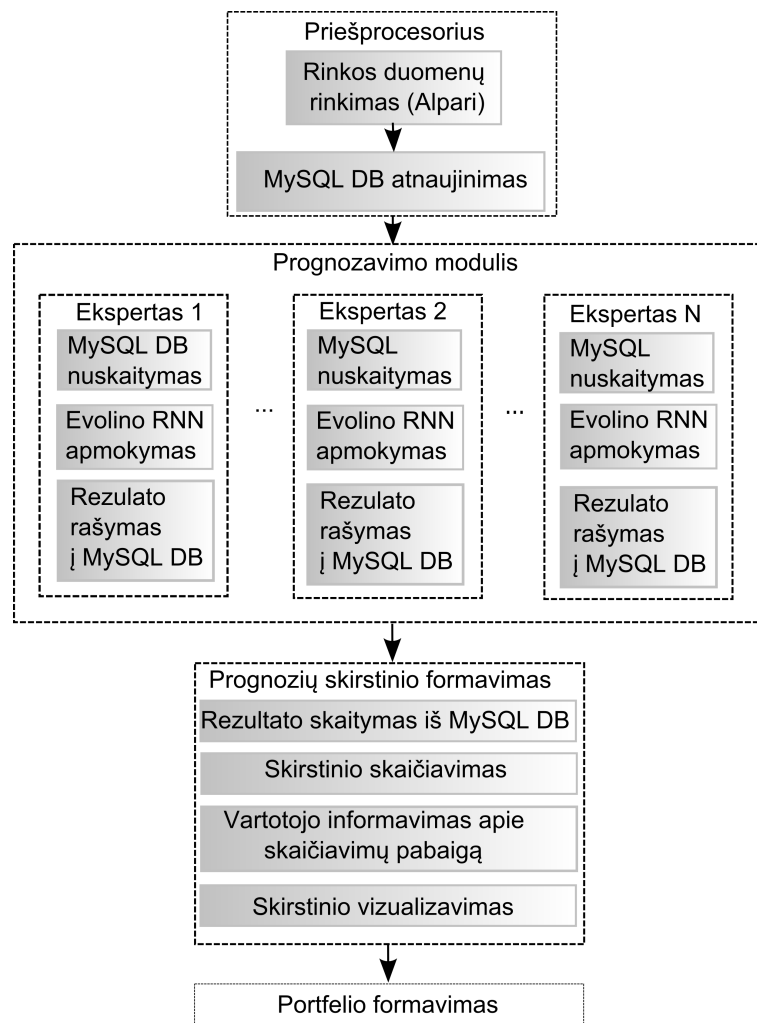
---

## Priedai<sup>1</sup>

- A priedas.** Paramos sistemos investuotojams schema
- B priedas.** Bendraautorių sutikimai teikti publikacijų medžiagą disertacijoje
- C priedas.** Autoriaus mokslinių publikacijų disertacijos tema kopijos

---

<sup>1</sup>Priedai pateikiami pridėtoje kompaktinėje plokštelėje



Nijolė MAKNICKIENĖ

PARAMOS SISTEMA INVESTUOTOJUI  
VALIUTŲ RINKOJE

Daktaro disertacija  
Socialiniai mokslai, Ekonomika (04S)

THE SUPPORT SYSTEM FOR THE INVESTOR  
IN CURRENCY MARKET

Doctoral Dissertation  
Social Sciences, Economics (04S)

2015 03 26. 13,0 sp. l. Tiražas 20 egz.  
Vilniaus Gedimino technikos universiteto leidykla „Technika“,  
Saulėtekio al. 11, LT-10223 Vilnius, <http://leidykla.vgtu.lt>  
Spausdino UAB „Ciklonas“,  
J. Jasinskio g. 15, 01111 Vilnius