



INVESTAVIMO SPRENDIMŲ PRIĖMIMO MODELIŲ LYGINAMOJI ANALIZĖ

Ieva KEKYTĖ¹, Viktorija STASYTYTĖ²

Vilniaus Gedimino technikos universitetas, Vilnius, Lietuva
El. paštas: ¹ieva.kekyte@stud.vgtu.lt; ²viktorija.stasytyte@vgtu.lt

Santrauka. Sparti finansų rinkų plėtra lemia naujus iššūkius tiek investuotojams, tiek investavimo problematiką nagrinėjantiems mokslininkams. Kyla būtinybė sukurti inovatyvius, šiuolaikines finansų rinkų sąlygas atitinkančius investicijų portfelio sudarymo ir valdymo sprendimus. Finansų rinkos sulaukia ypatingo dėmesio, atliekami įvairūs tyrimai, įskaitant įvairių investavimo modelių formavimą, kurie apima finansinės rizikos valdymą ir investavimo sprendimų paramos sistemas. Mokslininkai pripažįsta būtinumą nagrinėti finansines problemas integruotais ir realybę atitinkančiais būdais, grindžiamais sudėtinga kiekybinės analizės technika. Taigi matematinio modeliavimo vaidmuo finansų sektoriuje tampa labai svarbus. Straipsnyje nagrinėjami įvairūs investavimo sprendimų priėmimo modeliai, apimantys prognozavimą, optimizavimą, stochastinius procesus, dirbtinį intelektą ir kt., kurie tampa reikšmingomis priemonėmis priimančios investicinius sprendimus.

Reikšminiai žodžiai: investavimas, sprendimų priėmimo modeliai, akcijų rinka, portfelis, duomenų analizė, prognozavimas.

Įvadas

Finansų rinkos palengvina tarptautinę prekybą, sujungia ir suteikia informacijos apie organizacijų bei ekonomikos ateities perspektyvas, yra ekonomikos augimą skatinanti priemonė (Lin *et al.* 2011). Tačiau šiuolaikinėje finansų rinkoje ir finansų mokslo srityje kyla žiniomis pagrįstų, programiškai aprūpintų sistemų, padedančių investuotojams ir finansų analitikams laiku priimti tinkamus sprendimus, poreikis (Stasytytė 2012). Kai kurie ekonomistai nurodo informacinio efektyvumo trūkumą finansų rinkose, kuris apsunkina kainų nuspėjamumą ir gali sumažinti investuotojų galimybes pelningai prekiauti akcijų rinkose (Lin *et al.* 2011). Duomenų analizė akcijų rinkose jau ilgą laiką išlieka aktuali problema, deja, pati rinka yra sudėtinga ir dinamiška sistema, kurioje duomenys pasižymi dideliu tankumu, yra nestacionarus ir chaotiški (Peters 1994). Finansų rinka yra labai sudėtinga aplinka, ji jautri įvairiems išorės veiksniams, tokiems kaip finansų naujienos, finansinės ataskaitos, vyriausybės politika, ekonomikos aplinka, palūkanų norma, infliacija ir daugelis kitų (Wu *et al.* 2014). Veiksnius, kurie lemia tokį rinkos dinamiškumą, Bao ir Yang (2008) skirsto į dvi grupes: vienas jų galėtų būti kitimas palaipsniui tarp akcijų pirkimo ir pardavimo, kita grupė yra atsitiktiniai veiksniai, tokie kaip skirtingi kasdieniai įvykiai, naujienos ar pasikeitimai, galintys nulemti atskirų akcijų kainų pokyčius. Atsižvelgiant į tai, finansų rinkos sulaukia ypatingo dėmesio, atliekami įvairūs tyrimai, įskaitant įvairių investavimo modelių formavimą, apimančių

finansinės rizikos valdymą (Chen, Du 2009) ir investicinių sprendimų paramos sistemų kūrimą (Chang *et al.* 2009; De Oliveira *et al.* 2013). Taigi pagrindinė mokslinė problema, kuri bus sprendžiama šiame straipsnyje, yra informacijos ir kriterijų trūkumas, pagal kuriuos investuotojas ar rinkos tyrinėtojas rinktųsi investavimo modelį. Kadangi yra daug įvairių modelių bei sprendimų paramos sistemų, kyla sunkumų norint išsirinkti tinkamiausią dinamiškai rinkai ir didelėms duomenų apimtims analizuoti. Modelių palyginimas pagal jų privalumus, trūkumus, taikomus metodus ir rezultatus galėtų būti svarus indėlis sprendžiant įvardytą mokslinę problemą.

Tradicinių inovacijų augimo požiūriu inovacijos finansų srityje padeda gerinti įvairių banko paslaugų kokybę, palengvinti rizikos valdymą, išpildyti rinką ir galiausiai padidinti išteklių paskirstymo efektyvumą (Berger 2003; Houston *et al.* 2010). Lerner ir Tufano (2011) teigia, kad finansinės naujovės teigiamai veikia finansų sektoriaus stiprėjimą, taip pat ir ekonominį augimą. Taigi aukštesnis finansinių inovacijų lygis skatina spartesnę atskirų pramonės sektorių ir visos šalies ekonominį augimą bei suteikia daugiau galimybių didinti plėtros efektyvumą (Beck *et al.* 2016).

Per pastaruosius kelis dešimtmečius finansinių duomenų analizė, padedanti prognozuoti akcijų kainas, prekybos vietas ir investicinius portfelius, tapo labai populiaru mokslinių tyrimų tema (Wu *et al.* 2014). Tačiau portfelio valdymas išlieka viena labiausiai tyrinėjamų temų finansų srityje. Nagrinėjamos problemos dažniausiai yra susijusios

su turto alokacija ir kapitalo paskirstymu portfelyje, kurie sumažintų riziką ir tuo pačiu metu nesuvaržytų tikslo pasiekti norimą gražos lygį (Zhu *et al.* 2011). Šioje naujoje realybėje finansų tyrinėtojai ir praktikai pripažįsta būtinumą nagrinėti finansines problemas integruotais ir realybę atitinkančiais būdais, grindžiamais sudėtinga kiekybinės analizės technika. Taigi matematinio modeliavimo vaidmuo finansuose tampa labai svarbus (Stasytė 2012). Mokslininkai bando sukurti analitinius modelius, kurie tam tikras finansines žinias paverstų rinkos prognozavimo priemone ir padėtų investuotojams siekti norimų tikslų (Wu *et al.* 2014). Siūloma įvairių metodų, kurie apima optimizavimą, stochastinius procesus, sprendimų paramos modelius ir kt., kurie tampa reikšmingomis priemonėmis priimant investicinius sprendimus (Zouponidis, Doumpos 2002). Pastaruoju metu ypač daug dėmesio sulaukia dirbtinis intelektas, kurio naudojimas paskatino daugybės naujų ir įdomesnių modelių atsiradimą, grindžiamą netiesiniais ir nestacionariais metodais. Pagrindiniai iš jų yra įvairūs kompiuteriniai modeliai, tokie kaip neraiškioji logika, dirbtiniai neuronų tinklai, kurie sulaukia nemažai dėmesio dėl gebėjimo susidoroti su neapibrėžtumo ir duomenų chaotiškumo problemomis akcijų rinkose (Vanstone, Tan 2005). Investavimo sprendimų paramos modeliai, skatinantys prekybos akcijų rinkose efektyvumą, yra dar nauja tyrimų sritis, turinti didelį komercinį potencialą (Lin *et al.* 2011). Dėl pirmiau išvardytų priežasčių atliekamas tyrimas, skirtas investavimo sprendimų priėmimo modeliams ir sistemoms palyginti, jų trūkumams ir privalumams išryškinti, yra itin aktualus. Taip pat sprendimų paramos sistemų ir investavimo modelių palyginimas, išskiriant jose taikomus metodus, nėra dažnas mokslinėje literatūroje, todėl pasižymi naujumo elementu ir gali būti įdomus akademinėi bendruomenei bei gali paskatinti naujas mokslines idėjas finansų rinkų tyrimo srityje.

Mokslinio tyrimo objektas – investavimo sprendimų priėmimo modeliai, sprendimų paramos sistemos.

Straipsnio tikslas – išanalizuoti, palyginti ir įvertinti mokslinėje literatūroje siūlomus sprendimų priėmimo kapitalo rinkoje modelius ir juose taikomus metodus.

Tikslui pasiekti iškelti šie uždaviniai:

- išanalizuoti mokslinėje literatūroje siūlomas sprendimų priėmimo kapitalo rinkoje kompleksines priemones;
- apibūdinti siūlomus investavimo sprendimų paramos modelius, pristatant jų veikimo principus ir juose taikomus metodus;
- apibendrinti modelių privalumus ir trūkumus bei galimybes pritaikyti realioje rinkoje.

Sprendžiant numatytus uždavinius buvo taikomi lyginamosios ir sisteminės analizės, apibendrinimo metodai. Tyrimas atliekamas finansų rinkos kontekste, daugiau dėmesio skiriant akcijų rinkos prognozavimo ir portfelio sudarymo šioje rinkoje galimybėms.

Prielaidos investavimo sprendimų priėmimo modeliams kurti

Portfelio pasirinkimas – esminis raktas į investuotojo siekiamą gražą (Pinto *et al.* 2011), jis susijęs su sudėtingais procesais, apimančiais įvairias sprendimo priėmimo situacijas (Lin, Hasieh 2004). Taigi, norint nuspręsti, kurios akcijos turėtų būti įtrauktos į portfelį, reikia įvertinti daug prieštaringų kriterijų. Portfelio efektyvumas, rizikingumas ir patikimumas yra trys esminės savybės, kurių siekia investuotojai, ieškodami galimybių investuoti kapitalo rinkose (Rutkauskas *et al.* 2009). Taip pat vienas iš pagrindinių portfelio formavimo principų išlieka diversifikavimas, kai investuotojai paskirsto savo turimą kapitalą tarp įvairių turto rūšių, siekdami sumažinti riziką ir padidinti laukiamą gražą (Gupta *et al.* 2010; Zhu *et al.* 2011). Ir nors yra atlikta nemažai tyrimų, galinčių padėti sprendimų priėmėjams renkantis portfelį, daugelyje situacijų susiduriama su nepakankamai išsamia informacija, egzistuoja tam tikras neapibrėžtumas, dėl to portfelio pasirinkimas tampa svarbi ir sudėtinga užduotis (Ghasemzadeh, Archer 2000).

Kai kurie ekonomistai nurodo informacinio efektyvumo trūkumą finansų rinkose, kuris apsunkina kainų nuspėjamumą ir gali sumažinti investuotojų galimybes pelningai prekiauti akcijų rinkose (Lin *et al.* 2011). Nepaisant didžiulių mokslininkų pastangų ir taikomų metodų įvairovės, efektyvus akcijų rinkos prognozavimas vis dar išlieka sunkia užduotimi dėl sudėtingų ir laikui einant kintančių priklausomybių tarp akcijų kainos ir ją veikiančių veiksnių (Maknickienė, Maknickas 2012). Dažniausiai investuotojai turi sisteminius metodus, kurie ne tik nustato prekybos galimybes, bet ir yra priemonė, galinti padėti nuosekliai mažinti išlaidas ir klaidų skaičių. Nors įvairios prekybos sistemos egzistuoja, jos dažniausiai skirtos investuoti į vieną akciją ar kitą investavimo priemonę, be to, priklauso nuo pasirinkto modelio parametru, kurie, tikimasi, taip pat gerai suteiks informaciją per visą investavimo laikotarpį, kaip ir testuojant modelį arba atliekant pirmąjį pirkimą.

Kompiuterinės technologijos vis sparčiau integruojasi į finansų sritį, didelės kompiuterių skaičiavimo galimybės sudaro galimybes atlikti sudėtingesnes analizes, apdorojant didesnius duomenų kiekius. Akcijų rinkos prognozavimas turi didelę reikšmę priimant investavimo sprendimus (Guresen *et al.* 2011). Deja, akcijų kainos juda atsitiktinai,

yra susijusios su istoriniais duomenimis, o pati akcijų rinka yra sudėtinga ir netiesiška sistema (Lo, MacKinlay 2011; Manahov, Hudson 2014), kurią sudaro daug skirtingų dalyvių, veikiančių pagal atskirus ekonominius, politinius ir psichologinius veiksnius (Ballings *et al.* 2015), kurie gali padidinti rinkoje esamą neapibrėžtumą, o šis savo ruožtu gali turėti teigiamą arba neigiamą poveikį akcijų kainoms. Todėl labai svarbu siekti prognozavimo stabilumo, kad kuo tiksliau ir laiku būtų galima nustatyti tam tikrą nežinomų duomenų kiekį (Maknickienė, Maknickas 2012). Taigi prognozavimas gali būti sėkmingai įgyvendintas tik taikant priemones ir technikas, galinčias sumažinti neapibrėžtumą, duomenų chaotiškumą ir netiesiškumą (Chang *et al.* 2011). Netiesiškų procesų modeliavimas gali būti svarbus dėl dviejų dalykų: tikroviški modeliai padeda suvokti vidinę netiesiškumo struktūrą ir pagerina tokių procesų numatymą (Maknickienė *et al.* 2011). Analizuojant netiesiškus duomenis, akcijų kainai prognozuoti dažnai taikoma netiesinė regresija ar neuronų tinklai (Enke, Mehdiyev 2013). Taip pat buvo išbūtininti techninės analizės modeliai, kurie įtraukia ekspertų vertinimo sistemas ir kitas informacijos apdorojimo formas (Cervelló-Royo *et al.* 2015). Sprendimų paramos sistemos pripažintos kaip naudingos priemonės, padedančios jų naudotojams planuoti ir priimti sprendimus, be to, gali būti taikomos skirtingose srityse (Klein, Methlie 2009; Martinez *et al.* 2009; Stasytė 2011, 2012). Realiose situacijose sprendimų paramos sistema paprastai interpretuojama kaip kompiuterinė informacinė sistema, skirta sprendimų priėmimo informacijai generuoti ir padedanti vartotojui spręsti problemą (Stasytė 2011, 2012). Ji suteikia informaciją, reikalingą alternatyvoms kurti, analizuoti ir vertinti bei pasirinkti geriausią iš alternatyvų siekiant užsibrėžtų tikslų (French, Turoff 2007; Kaklauskas *et al.* 2007; Power 2008). Taip pat sprendimų paramos sistema gali būti suprantama kaip sistema, surenkanti ir apdorojanti įvairius duomenų ir žinių šaltinius, taip padedanti įgyvendinti sprendimus (Tunčikienė *et al.* 2010).

Vis dėlto sprendimų paramos sistemų taikymas finansų srityje dar nėra iki galo baigtas, sistemos yra nuolatos tobulinamos ir modifikuojamos. Dauguma tokių sistemų paprasčiausiai remiasi daugiakriterio vertinimo metodais (Dymova *et al.* 2009), tačiau yra ir modelių, kuriuose mėginama įtraukti ir pažangesnes prekybos priemones analizuojant istorinius ir esamus duomenis (Atsalakis, Valavanis 2009; Lai *et al.* 2009). Prieš išpopuliarėjant dirbtinių neuronų tinklams, dauguma sprendimų paramos sistemų tyrimų rėmėsi laiko eilučių analize ir, remdamiesi istoriniais duomenimis, prognozuodavo akcijų kainų pokyčius. Finansų srityje plačiai naudojami iš laiko eilučių teorijos susiformavę modeliai, tokie kaip ARIMA, ARCH, GARCH, ir

kt. (Vejdla, Enke 2013). Dabar didžiausias mokslininkų dėmesys koncentruojasi į dirbtinio intelekto naudojimą, jau sukurta nemažai tokių investavimo modelių (Dymova *et al.* 2012). Pirmieji Kuo ir Xue (1998) pasiūlė sprendimų paramos sistemą akcijų rinkai su integruota neraiškiają logika ir neuronų tinklais, kurie buvo išmėginti tiek su kokybiniais, tiek su kiekybiniais duomenimis. Paprastai neuronų tinklas padeda įvertinti vieno kintamojo priklausomybę nuo kitų nepriklausomų kintamųjų, o neraiškūs neuronų tinklas gali padėti inicijuoti sistemos mokymąsi efektyviai reaguoti į rinkos pokyčius tam tikru laiku (Kuo *et al.* 2001). Modelių, integruotų su dirbtinių neuronų tinklu ir neraiškiają logika, mokslinėje literatūroje galima atrasti ir daugiau, pavyzdžiui, Atsalakis ir Valavanis (2009) pasiūlė adaptyvią akcijų rinkos kontrolės sistemą su neraiškiais neuronų tinklais. Hadavandi *et al.* (2010) sukūrė neraiškiają genetinę sistemą (angl. *Genetic Fuzzy Systems*, GFS) ir savitvarkį neuronų tinklą žemėlapi (angl. *Self-Organizing Map*, SOM), kurie sudaro ekspertinę akcijų kainų prognozavimo sistemą. Tsai ir Hsiao (2010) sudarė keletą funkcijų apimančią metodų atrankos sistemą, kuri atrenka geriausiai prognozuoti tinkamus kintamuosius. Techninė analizė, integruota kartu su neuronų tinklais, taip pat gali būti naudojama kainoms prognozuoti (Chavarnakul, Enke 2009). Taigi dirbtinis neuronų tinklas gali būti taikomas akcijų rinkai prognozuoti (Maknickienė, Maknickas 2013a). Toks dirbtiniu intelektu pagrįstų modelių kūrimas sudaro galimybes mokslininkams pritaikyti jau žinomas investavimo strategijas ir tobulinti naujas (Stankevičienė *et al.* 2014). Dauguma autorių siekia sukurti savo modelius, pritaikomus kuo daugiau skirtingų akcijų, nes ne visada modelis, tinkamas vienai akcijai, gali tikti kitai akcijai ar kitokiam turtui.

Nors tarp daugumos ekonomistų yra paplitęs tikėjimas efektyviosios rinkos hipoteze, dauguma kompiuterinio mokymosi šalininkų akcijų rinkos kainas ir pelningumą nagrinėja remdamiesi sudėtingais modeliais, pavyzdžiui, pagerinti prognozavimo metodai gali tiksliau numatyti kainų pasikeitimus rinkoje, padėti investuotojams nustatyti aiškius tikslus ir priimti sprendimus, taip pagerinant portfelio pelningumą (Wu *et al.* 2014). Naujas požiūris į investavimą ir jo metodus yra analitiškai reikšmingas, nes ateitis visada išlieka neapibrėžta, ir mes negalime padaryti išvadų, kurios nebūtų dviprasmiškos (Maknickienė, Maknickas 2013b)

Siūlomi investavimo sprendimų priėmimo modeliai: mokslinės literatūros analizė

Išanalizavus egzistuojančius investavimo sprendimų priėmimo modelius, padedančius investuotojams prekiauti akcijų rinkoje (1 lentelė), pastebėta, kad jie dažniausiai

1 lentelė. Siūdomi investavimo sprendimų priėmimo modeliai (sudaryta autorių)

Table 1. The proposed models for investment decision-making (compiled by the authors)

Modelis	Metodai	Veikimo principas	Rezultatas	Privalumai	Trūkumai
<i>Multi-level and Interactive Stock Market Investment System</i> (MISMIS) (Cho 2010).	Daugiapakopis modeliavimas. Techninė analizė. Fundamentalioji analizė. ARIMA. Dirbtiniai neuronų tinklai (ANN).	Pasirenkamas investavimo laikotarpis. Surenkami istoriniai (2–5 metų) akcijų kainų duomenys ir kiti aktualūs rodikliai (BVP, VKI, nedarbo lygis ir kt.) ir įkeliami į MISMIS sistemą. Sistema transformuoja duomenis ir juos normalizuoja. Naudojantis ARIMA ir neuronų tinklais, parengiama prognozė. Pateikiami apibendrinti rezultatai ir modelis testuojamas.	Akcijų kainos arba indekso prognozė	Gali būti pritaikytas individualaus investuotojo tikslams. Prognozavimo metodų įvairovė, vienu metu galima taikyti kelis skirtingus metodus.	Modeliui taikyti reikia specifinių žinių. Neįvertinami kokybiniai duomenys. Ignoruojama aplinka, kurioje investuojama, neatsižvelgiama į reikšmingus pasikeitimus.
<i>Decision support system for stock investment recommendations using collective wisdom</i> (Gottschilch, Hinz 2014).	<i>Crowd recommendations</i> (minios nuomonė).	Sistema pagal minios vertinimą atrenka akcijas. Akcijos ranguojamos ir pagal gautą sąrašą sudaromas portfelis (pvz., 10 geriausių reitingą turinčių akcijų, 3 geriausios kiekvienoje rinkoje ir pan.). Paskirstomas kapitalas. Portfelio struktūra lyginama su tikslu, atliekamas aktyvų pirkimo / pardavimo veiksmas, siekiant atitikties strategijai.	Portfelio struktūra. Strategijos parinkimas, monitoringas.	Pritaikytas ir nesunkiai prieinamas individualiam investuotojui. Atsižvelgia į investuotojo polinkį rizikuoti.	Egzistuoja neapibrėžtumas. Kuo toliau į ateitį norima prognozuoti, tuo daugiau laikotarpių turi išanalizuoti sistema. Ekspertų nuomonės įtraukimas pagerintų modelio patikimumą.
<i>An adaptive stock index trading decision support system</i> (Chiang et al. 2016).	Dirbtinis neuronų tinklas. Duomenų normalizavimo metodai. DCP.	Parenkami istoriniai akcijų kainų duomenys. Duomenys normalizuojami skaleje nuo 0 iki 1. Pasirenkami potencialūs kintamieji – sistemos (neuronų tinklo) įvestys. Paleidžiamas neuronų tinklas: parenkami metodai, formuojami prognozavimo modeliai, nustatomi komponentų svoriai. Įvedamas sistemos mokymosi algoritmas. Atliekamas sistemos bandymas; Pateikiamas apibendrintas rezultatas. Portfelio rebalansavimas: rezultatas nuo 0,5 iki 1 – kaina kyla, sistema siūlo pirkti; nuo 0 iki 0,5 – kaina krinta, pardavimo signalas.	Akcijos kainos kitimo krypties prognozė.	Sistema automatiškai pritaiko atskiras strategijas kiekvienam portfelyje esančiam aktyvui. Mokymosi algoritmas sumažina paklaidų skaičių. Sumažina netikrų signalų ir transakcijų skaičių, mažesni komisiniai mokesčiai, geresnės pajamos.	Neatsižvelgia į individualaus investuotojo lūkesčius, remiasi tik istoriniais duomenimis. Reikalingos specifinės žinios. Gali neįvertinti smulkesnių svyravimų rinkoje, maži pasikeitimai gali klaidinti sistemą, nustatant ryšius tarp kintamųjų.
<i>Intelligent stock trading system based on improved technical analysis and Echo State Network</i> (Lin et al. 2011).	Patobulinta techninė analizė (slankiųjų vidurkių sistemos, RSI, ROC). Dirbtinis neuronų tinklas. Genetiniai algoritmai.	Akcijų prekybos sistema yra paremta neuronų tinklais ir ESN sistema (angl. <i>Echo State Network</i>). Sistema (neuronų tinklas) išanalizuoja akcijų kainų tendencijas, pateikia uždarymo kainų prognozes ir nurodo pardavimo / laikymo / pirkimo signalus (–1; 0; 1). Rezultatai įkeliami į ESN sistemą įvertinti, ar investuotojui naudinga pirkti ar parduoti akciją, esant tai uždarymo kainai.	Sprendimas pirkti ar parduoti, atsižvelgiant į kainos krypties pasikeitimą.	ESN naudojimas didina prognozės patikimumą ir gerina portfelio pelningumą. Investuotojas gali žinoti, kada kaina bus arčiausiai idealaus pirkimo arba pardavimo taško.	Duomenų chaotiškumas gali veikti sistemos rezultatus. Sistema neįvertina konkrečios kainos, tik trendo apsisukimo taškus ir kitimo kryptį.

Modelis	Metodai	Veikimo principas	Rezultatas	Privalumai	Trūkumai
<i>Autoregressive exogenous (ARX) predictor model</i> (Pinto <i>et al.</i> 2011).	<i>Value-at-Risk</i> (VaR), SIMO / SISO; ARX; Markowitz portfelio modelis.	Modeliai įvertina istorines akcijų kainas ir jų svyravimo riziką.	Pasirinktos akcijos grąžos ir rizikos santykis. Optimalaus portfelio suradimas.	Naudojantis ARX ir Markowitz modelių gali būti formuojamas optimalus portfelis, paskirstyti kapitalą.	Modelis neatsižvelgia į akcijų kainas ir individualaus investuotojo parametrus. Geriausiai veikia naudojamas tik su kitais modeliais.
<i>Fuzzy portfolio selection model</i> (Gupta <i>et al.</i> 2010).	AHP; FMOLP; „silhouette“ koeficientas. W-FMOLP.	Pirmiausia atlieka investuotojų grupės apklausą, sužinomi jų pageidavimai. Toliau klasifikuojami finansiniai turtai, pagal prieš tai gautus kriterijus (rizika, grąža, likvidumas ir stabilumas). Gautų turto klasių svoriai apskaičiuojami naudojant AHP, kurie vėliau naudojami kaip tikslo funkcijų koeficientai FMOLP modelyje, gaunama kapitalo paskirstymo struktūra, kuri lyginama su investuotojų lūkesčiais ir tobulinama, kol gaunamas maksimalus investuotojų pasitenkinimas.	Portfelio struktūra	Atsižvelgia ne tik į grupę investuotojų, bet gali būti naudojama ir individualiai. Struktūrizuojami turtai pagal kategorijas, kurios atitinka skirtingus investuotojų tipus. Interaktyvi sistema.	Portfelio struktūra ne visada gali būti keičiama pagal investuotojo norus, dėl to dar tobulinama. Kaip ir visiems neraiškiosios logikos modeliams, būtina mokymosi sąlyga.
<i>An intelligent stock trading system using comprehensive features</i> (ISTSCF) (Wu <i>et al.</i> 2014).	Sentimentų analizė, techninė analizė, TBSM, SVR.	Informacijos surinkimas iš skirtingų išorės šaltinių (finansinės naujienos, prekybos rinkoje tendencijos ir kt.), suformuojami du indeksai: sentimentų ir techninis. Prognozavimo modelis: mokosi metodų ir taikant SVR gaunamas signalas apie akcijos judėjimo kryptį. Galutiniame etape priimamas sprendimas: pirkti, parduoti arba susilaikyti.	Akcijos kainos judėjimo kryptis. Sprendimas pirkti ar parduoti.	Kokybinių ir kiekybinių duomenų naudojimas kartu padidina prognozės tikslumą. Automatinis sprendimas.	Didelis naujienų srautas gali apsunkinti sentimentų analizės atlikimą atrenkant, kuri informacija yra reikšminga, taip pat atskirti teigiamą ir neigiamą informaciją.
<i>Fuzzy inference systems (FIS)</i> (Rubell, Jessy 2016).	Agentų sistema. Techninė analizė kartu su slankių vidurkių sistemomis (MA, MACD) taip pat RSI, OS ir CO oscilatoriais. Fundamentalioji analizė.	FIS modelį sudaro du etapai. Pirmuoju etapu surenkami įvesties duomenys, fundamentalios analizės metodu atrenkamos įmonės, remiantis technine analize ir akcijų kainomis gaunamas siūlymas: pirkti, parduoti ar susilaikyti. Antruoju etapu įgyvendinamas pasirinktas prekybos veiksmas, kurį atlieka agentų sistema. Prekybos rezultatai kasdien yra įrašomi ir analizuojami.	Investavimo strategija	Sistema labiau remiasi susilaikymo strategija, limituojama prekyba (10 akcijų per įmonę), taip apsaugant investuotojus nuo neracionalių sprendimų.	Sistema pritaikyta prekybai NASDAQ biržoje, galimybė adaptuoti kitose biržose nėra iki galo žinoma. Susilaikymo taisyklė gali ignoruoti reikšmingus rinkos pokyčius.
<i>An intelligent short term stock trading fuzzy system</i> (Chourmouziadis, Chatzoglou 2015).	Neraiškioji logika. Techninė analizė su techniniais indikatoriais MA, MACD, parabolinis SAR ir GANN-HiLo.	Modelis remiasi klasikiniais investavimo sprendimais, kai, remiantis technine analize, naudojant skirtingas kreives, gaunamas sistemos sprendimas: pirkti, parduoti ar susilaikyti. Neraiškioji logika leidžia modeliui taikyti skirtingus rodiklius, duodančius skirtingus signalus ir gauti kiek įmanoma maksimalų efektyvumą bei optimalią portfelio struktūrą.	Investavimo strategija. Kapitalo paskirstymo struktūra.	Naujoviška sistema, įtraukianti retus modelius, pritaikyta prekybai trumposiomis pozicijomis. Gali analizuoti didelį kiekį kiekybinių duomenų, tačiau jų nepervertina ir papildomai reikalauja subjektyvaus vertinimo.	Sistema gali duoti konservatyvų vertinimą: mažesni nuostoliai meškų rinkoje ir mažesnė grąža bulių rinkoje. Prieštaringų modelių taikymas leidžia naudoti sistemą tik atliekant veiksmus su trumpomis pozicijomis. Labai priklauso nuo eksperto nuomonės.

vadunami sprendimų paramos sistemomis, prekybos sistemomis ar prekybos modeliais. Tai priklauso iš dalies nuo autoriaus požiūrio į problemą, modelio veikimo principų, taikomų metodų ir nuo siekiamo tikslo (rezultato).

Atlikus investavimo sprendimų priėmimo modelių analizę (1 lentelė) pastebėta, kad dauguma jų, taikydami patobulintus metodus, siekia nustatyti akcijos kainos prognozę, akcijos kainos judėjimo kryptį, prekybos taškus, geriausią investavimo strategiją, taip pat portfelio struktūrą. Kaip minėta, akcijų rinka yra sudėtinga sistema, apimanti chaotiškus ir nestacionarius duomenis (Evans *et al.* 2013). Dėl to mokslininkai vis dažniau bando sukurti automatinius sprendimo priėmimo modelius, įtraukiančius lanksčius skaičiavimo (angl. *soft computing*) metodus (Geva, Zahavi 2014), tokius kaip dirbtinis neuronų tinklas ir neraiškioji logika, dėl jų sugebėjimo įvertinti netiesinius ir dinamiškus laiko eilučių šablonus (Chang *et al.* 2009; Zbikowski 2015). Be dirbtinio neuronų tinklo, modeliai įtraukia ir kitus metodus, dažniausia tai yra techninė ar fundamentalioji analizė, slankiųjų vidurkių sistemos ir įvairūs techniniai rodikliai, optimizavimo metodai, regresiniai modeliai, genetiniai algoritmai ir kt., kurie pasirenkami priklausomai nuo norimo rezultato.

Vienas iš įdomesnių pastebėjimų, kad investavimo modeliai gali būti statiški ir dinamiški (Lessmann *et al.* 2011), savo atliktoje analizėje atkreipia dėmesį, kad dar nedaug modelių gali būti laikomi dinamiškais. Statiški modeliai analizuoja laiko eilutes, išskirdami į mokymosi ir testavimo etapus, jie dažniausiai naudoja tą patį modelį viso testavimo metu ir jo neatnauja. Priešingai, dinamiški modeliai, tokie kaip „slystančio lango“ (angl. *sliding-window*) arba „kryžminio tinkamumo“ (angl. *cross-validation*) modelio testavimą ir vertinimą atlieka kelis kartus palaipsniui analizuodami mažesnius duomenų kiekius (Lessmann *et al.* 2011). Pagal atliktą analizę galima teigti, kad dauguma modelių, pateikti 1 lentelėje, yra dinamiški, o autoriams akcijų rinkos dinamiškumas ir chaotiškumas yra aktualios problemos. Atsižvelgiant į tai, daugumos pateikti modeliai įtraukia neuronų tinklus kartu su neraiškiosios logikos arba genetinių algoritmų sistemomis, kurie suteikia modeliams galimybę mokytis ir mažinti klaidų tikimybę.

Techninės analizės šalininkai akcentuoja techninių rodiklių galimybę nuspėti vertę, kai oponentai neigia jų vertingumą. Nepaisant to, techniniai rodikliai plačiai naudojami įvairiose kompiuterinėse sistemose ir integruojami su kitais kintamaisiais, pavyzdžiui, kasdienės naujienos finansų rinkose ir pan. (Hsu *et al.* 2016). 1 lentelėje galima matyti, kad analizuojami prognozavimo modeliai gali skirtis pagal savo rezultata: prognozuojama kainos kitimo kryptis (kyla arba krinta), prognozuojamos tikslios akcijų

kainos įvertina investavimo, atsižvelgiant į gautą prognozę, pelningumą. Prognozavimo modeliai taip pat įtraukia diskrečiusius ir tolydžiuosius kintamuosius. Efektyviosios rinkos atveju tokie modeliai, pavyzdžiui, 90 proc. tikslumu galėtų sukurti neįtikėtinai didelį pelningumą (Patel *et al.* 2015). Dalis kompiuterinių akcijų kainų prognozavimo modelių yra statiški, kur prognozes kuria modelis, turintis fiksuotą bandymų skaičių, todėl reikia įtraukti kuo daugiau metodų, kurie padidintų galimybes atpažinti tinkamiausius prognozavimo modelius. Deja, jie neįtraukia naujausių akcijų kainų, kitaip nei dinamiški modeliai, kurie įvertina skirtingos kilmės ir periodų laiko eilutes, ir naudoja naujausius mokymosi šablonus. Be to, statiški modeliai gali pervertinti akcijų kainas, o dinamiški modeliai mažina tokių klaidų tikimybę (Hsu *et al.* 2016).

Prognozės tikslumas, be abejo, priklauso ne tik nuo modelio, bet ir nuo to, kaip ir kokie nepriklausomi kintamieji koreliuoja su tiksliniu kintamuoju. Per pastaruosius kelis dešimtmečius mokslininkai patobulino tradicinius skaitinius prognozavimo modelius (Cheng *et al.* 2010). Nemažai prognozavimo modelių (1 lentelė) yra autoregresiniai, kurie naudoja paprastą autoregresiją (angl. *autoregressive method*, AR), paprastą slankiųjų vidurki (angl. *moving average*, MA), taip pat ARMA, ARCH, GARCH ir ARIMA modelius, kuriuose nepriklausomieji kintamieji atsižvelgia į tikslinio kintamojo praeities reikšmes. Taip pat nemažai modelių naudoja ir techninius rodiklius: tendencijų rodikliai, momentiniai osciliatoriai, diagramų modeliai bei japoniškos žvakės, kiti remiasi paprasčiausiais kainų skirtumais. Informaciniai kintamieji dažniausiai yra įvairios naujienos, politiniai, ekonominiai įvykiai, kurie taip pat atlieka svarbų vaidmenį modeliuojant prognozes ir gali reikšmingai paveikti spėjimo patikimumą. Modelių autoriai pabrėžia finansų rinkos brandos svarbą, taip pat laiko horizontą ir modelių metodologiją, kurie visi turi vienodai didelę reikšmę rinkos nuspėjamumui ir investicijų pelningumo galimybių didinimui.

Dažniausiai investavimo modeliuose taikomi prognozavimo metodai

Finansų rinkai būdingas neapibrėžtumas, susijęs su galimybe numatyti ateitį trumpuoju, vidutiniu ir ilguoju laikotarpiu. Su tuo sutinka dauguma 1 lentelėje pateiktų modelių autorių, dėl to savo modeliuose jie būtinai įtraukia ir prognozavimo posistemį, siekiant kuo labiau sumažinti rinkos neapibrėžtumą. Jie stebi akcijų rinkas, jų pokyčius, siekdami, kad sukurti modeliai kuo labiau atitiktų rinkas, kuriose prekiaujama. Sprendimus dėl pirkimo ar pardavimo jie dažniausiai atlieka dviem etapais: pirma iš sąrašo

pasirenkamos įmonės, atsižvelgiant į jų augimo potencialą ir ekonominius rodiklius, antru žingsniu analizuojamos jų akcijų kainos. Akcijų kainų prognozavimas dėl to yra svarbus veiksnys, formuojant investavimo strategijas ir modelius (De Oliveira *et al.* 2013).

Daug prognozavimo metodų yra sukurtų naudojant kompiuterinius modelius, tokius kaip tiesinė regresija (Clements *et al.* 2009), dirbtinis neuronų tinklas (Kara *et al.* 2011), genetiniai algoritmai (Yang *et al.* 2012) ir daugelis kitų (Guresen *et al.* 2011). Išanalizuotoje literatūroje finansų rinkoms prognozuoti taikomi skirtingi metodai, kuriuos De Oliveira *et al.* (2013) suskirstė į keturias grupes: fundamentalioji analizė, techninė analizė, laiko eilučių prognozavimas taikant tradicinius modelius ir kompiuterizuoti metodai, kuriuos dar įvardija kaip mašininis mokymosi metodus (angl. *Machine Learning Methods*). Jie dažniausiai remiasi dirbtinio intelekto modeliais. Toliau detaliau aptarsime kiekvieną iš metodų grupių.

Akcijų kainai analizuoti dažniausiai naudojamos fundamentalioji, taip pat ir techninė analizė. Abu metodai istoriškai nuolatos konkuravo, kuris iš jų pirmąją prognozuojant akcijų kainas (Power 2008). Tačiau mokslininkai įrodyta, kad reikia pasinaudoti fundamentaliosios ir techninės analizės privalumais kartu, norint pasiekti geresnį rezultatą. Tuo metu, kai techninės analizės specialistai susikoncentruoja į rinkos elgsenos tyrimą, fundamentaliosios analizės specialistai stengiasi nagrinėti visus susijusius veiksnys, veikiančius prekės kainą, kad galėtų nustatyti tikrąją jos vertę (Stasytė 2011).

Fundamentalioji analizė skirta svarbiems ekonominiams, politiniams, socialiniams rodikliams ir jų dinamiškai įvertinti, taip pat įtraukia įmonės kiekybinę ir kokybinę analizę (Lin *et al.* 2011). Toks analizės metodas naudoja statistinius duomenis, prognozes, analizuoja prekių bei paslaugų paklausą ir pasiūlą, taip pat ekonomikos, ir įmonių pagrindus (De Oliveira *et al.* 2013). Ritchie (1996), remdamasis šiais veiksniais, įvertino galimą jų įtaką kapitalo rinkoms ir akcijų vertėms. Šis metodas padeda nustatyti tikėtiną investicijų grąžą atsižvelgiant į finansinę riziką, kuri apima perkamosios galios, palūkanų normos, verslo ir kitas rizikas, atskiras pramonės šakas bei jose veikiančias įmones. Kadangi finansų rinka yra veikiama daugybės veiksnių, tokių kaip politiniai įvykiai, ekonomikos sąlygos, rinkos perspektyvos ir kt., fundamentalioji analizė gali atlikti išsamų ekonomikos tyrimą ir jos poveikį pramonės šakoms, ir įmonėms, įvertinant tvarumu pagrįstas ateities pajamas ir lūkesčius dėl dividendų mokėjimo, taikant įvairius vertinimo metodus (Tucnik 2009). Taigi akcijos vertei nustatyti naudojami tiek kokybiniai, tiek kiekybiniai (finansinės ataskaitos) duomenys. Gauta prognozuojama

reikšmė galėtų būti lyginama su realiąja verte, priimant sprendimą investuoti ar ne. Paprastai fundamentalioji analizė labiau tinka ilgalaikiam prognozavimui ir gali įvertinti bendrą judėjimo tendenciją ateityje (Lin *et al.* 2011).

Realioje rinkoje labai plačiai naudojama techninė analizė, dar vadinama grafikų analize, jos pagrindinė idėja – ieškoti kainos pakilimo viršūnių, dugnų, tendencijų ir rodiklių, kurie leistų apytikriai nustatyti tendencijos pasikeitimo galimybę ir priimti sprendimą pirkti arba parduoti, paremtą techniniais rodikliais, nustatytais analizuojant istorinius duomenis (Bao, Yang 2008). Techninė analizė daro prielaidą, kad investuotojams yra prieinama visa informacija ir ją atspindi akcijos kaina, kuri taip pat turi tendenciją pasikartoti (Cheng *et al.* 2010). Grafikai dažniausiai yra paprasti, taikomi apibrėžti modeliai (kainų kanalai, galva ir pečiai, trikampiai, viršūnės ir dugnai, spragos ir kt.) (Power 2008).

Techninė analizė turi nemažai metodų, populiariausi iš jų yra slankieji vidurkiai ir jų sistemos, lyginamasis jėgos rodiklis (angl. *relative strength indicator*, RSI) ir stochastiniai rodikliai, tačiau ne visi jie tinka visoms akcijoms (Wu *et al.* 2014). Sujungti skirtingus techninės analizės metodus nėra lengva užduotis ir reikalauja priimti sprendimus, remiantis subjektyviais vertinimais (Sevastianov, Dymova 2009). Kai kurie metodai gali duoti skirtingus rezultatus, taip pat priimami sprendimai smarkiai priklauso nuo investuotojo žinių, patirties, tikslų ir požiūrio, kaip jis vertina kainos pokyčius ir tendencijas (Majhi *et al.* 2009).

Lin *et al.* (2011) pasiūlė pažangią akcijų prekybos sistemą, paremtą patobulinta technine analize ir neuronų tinklais. Genetinis algoritmas naudojamas sistemai pagerinti, suteikiant jai galimybę išmokyti parametrus pagal tam tikras prekybos taisykles ir identifikuoti optimalius prekybos taškus, kurie kuo tiksliau atitiktų realias tendencijas. Taip tradicinės prekybos taisyklės veikia kaip ekspertai, siūlantys sprendimą, kuris vėliau importuojamas į dirbtinių neuronų-ESN (angl. *Echi State Network*) sistemą (Jaeger, Haas 2004). ESN pritaikymas, lyginant su kitais modeliais, yra labai paprastas ir nereikia jaudintis dėl konvergencijos, su kuria susiduria tradiciniai neuronų tinklai, ir gali būti naudojamas įvairioms užduotims atlikti: kainos prognozė, krypties prognozė, atsitiktinių įvykių įvertinimas, laiko eilutės prognozė, modeliavimas ir kt. (Jaeger, Haas 2004).

Laiko eilučių prognozavimas tradiciniais metodais grindžiamas tiesinių prognozavimo modelių kūrimu, kurie seka istorinius kainų duomenis (De Oliveira *et al.* 2013). Dažniausiai tai yra regresijos modeliai, tokie kaip paprastoji autoregresija (angl. *autoregressive method*, AR), paprastas slankusis vidurkis (angl. *moving average*, MA), taip pat ARMA, ARCH, GARCH ir ARIMA modeliai.

Analizuojamas kintamasis vertinamas atsižvelgiant į jo praeities reikšmes ir kitus nepriklausomus kintamuosius, kurie gali daryti įtaką jo reikšmėms. Prognozės tikslumas, be abejo, priklauso ne tik nuo modelio, bet ir nuo to, kaip ir kokie nepriklausomi kintamieji koreliuoja su tiksliniu kintamuoju (Cheng *et al.* 2010).

Pažanga tiriant dirbtinį intelektą paskatino įdomių naujų požiūrių į akcijų kainų analizes atsiradimą, remiantis netiesiniais ir nestacionariais modeliais. Kompiuteriniai skaičiavimo metodai, tokie kaip neraiškioji logika, neuronų tinklas, sulaukė didelio dėmesio ir šiuo metu laikomos geriausiomis priemonėmis neapibrėžtumui ir duomenų eilutės chaotiškumui mažinti, nes remiasi netiesiniais ir nestacionariais modeliais (Vanstone, Tan 2005; Maknickienė, Maknickas 2012). Dirbtinis neuronų tinklas yra netiesinis prognozavimo metodas (Kara *et al.* 2011). Modelį įprastai sudaro įvesties, paslėptas sluoksnis arba išsaugota informacija. Vieno sluoksnio neuronai yra visiškai prijungti prie kitų neuronų. Tokie modeliai gali geriau susidoroti su tolygiaisiais duomenimis (Lessmann *et al.* 2011), kurie dažnai pasireiškia prognozuojant laiko eilutes (Hsu *et al.* 2016). Guresen *et al.* (2011) dirbtinio neuronų tinklo privalumais įvardija tai, kad jo nesudaro standartinės formulės ir jis gali lengvai prisitaikyti prie rinkos sąlygų. Pritaikius atitinkamus algoritmus, pavyzdžiui, EVOLINO (Maknickienė, Maknickas 2012), dirbtinis neuronų tinklas įgauna galimybę mokytis ir naudoti daugiau skirtingų metodų kuriant investavimo modelius, kurie geriausiai reprezentuoja esamą rinkos situaciją (Braga *et al.* 2007). Dirbtinis neuronų tinklas gali būti prilyginamas ekspertų vertinimui, o sujungus abu šiuos metodus galima labai pagerinti prognozavimo kokybę ir pelną (Maknickienė *et al.* 2011; Maknickienė, Maknickas 2012). Neraiškioji logika taip pat yra dirbtinio intelekto dalis ir gali būti naudojama netiesiškiems bei chaotiškiems akcijų rinkos duomenims, taikant skirtingus metodus, analizuoti (Russell, Norvig 2014).

Kai kurie modelių autoriai (Gottschilch, Hinz 2014) į prognozavimą siūlo įtraukti minios balsą, kuris be ekspertų įvertinimo taip pat gali padėti nustatyti akcijos vertę arba dirbtiniu intelektu pagrįstus modelius sujungti su Delfi metodu (Maknickienė, Maknickas 2012). Papildomai gali būti naudojama ir sentimentų analizė priimant investavimo sprendimus. Ji dažniausiai apima teksto analizės priemonės ir randa naudingos informacijos įvairiose rinkos naujienose (Wu *et al.* 2014). Tokia tekstinė informacija taip pat gali paveikti investuotojų sprendimus, todėl gali būti laikoma veiksminga priemone, numatant akcijų kainas ir jų tendencijas (Zhou *et al.* 2010). Mokslininkai savo modeliuose stengiasi pritaikyti kuo daugiau metodų, sujungti juos ir, skirtingais būdais analizuodami akcijų kainų judėjimą,

siekti geresnių rezultatų. Prognozavimas yra labai svarbus norint išvystyti veiksmingas strategijas prekybai akcijų rinkoje (De Oliveira *et al.* 2013). Dauguma metodų dėl to kuriami siekiant skirtingų tikslų, turi nevienodas savybes, dėl to rinkdamiesi jų derinį investuotojai turi atsargiai įvertinti, kurie gali būti naudojami kartu, kurie turėtų būti taikomi atskirai. Formavimas naujų ir pažangių investavimo sprendimų priėmimo modelių, kurie tiksliai ir ryžtingai prognozuotų kainas, visada bus nepaprastai svarbus investuotojams ir finansų analitikams (Hafezi *et al.* 2015).

Investavimo sprendimų priėmimo modelių taikymo privalumai ir trūkimai

Dauguma analizuotų investavimo sprendimų priėmimo modelių, pateiktų 1 lentelėje, gali būti plačiai taikomi praktikoje ir atliekant įvairius mokslinius tyrimus, susijusius su finansų rinkose vykstančių procesų modeliavimu ir prognozavimu. Pateikti modeliai apima patobulintus metodus ir gali nustatyti akcijos kainos prognozę, judėjimo kryptį, prekybos vietas, geriausią investavimo strategiją, taip pat portfelio struktūrą. Straipsnyje pateikiama gana išsami ir struktūrizuota investavimo sprendimų priėmimo modelių analizė, apimanti modelių veikimo principus, detalizuojamos jų struktūros bei taikomi metodai. Analizuojami modeliai dažniausiai vadinami sprendimų paramos sistemomis, prekybos sistemomis ar prekybos modeliais ir pan., priklausomai nuo autorių. Kaip minėta, sprendimų paramos sistemos yra pripažintos kaip naudingos priemonės, padedančios jų naudotojams planuoti ir priimti sprendimus, be to, gali būti taikomos skirtingose srityse. Tokias išvadas galima daryti įvertinus pateiktų modelių privalumus:

- Modeliai gali prisitaikyti prie individualių investuotojų, atsižvelgiant į jų lūkesčius ir priimtina rizikos lygį. Kai kurie modeliai gali būti taikomi grupei investuotojų, struktūrizuojant juos ir į portfelį atrenkant turto klases pagal pageidautiną portfelio grąžą, riziką, likvidumą ir tvarumą. Tokie modeliai dažniausiai būna interaktyvūs, nes investuotojas pats gali dalyvauti formuojant portfelį ir savo nuožiūra gali keisti parametrus, nusakančius jo kaip investuotojo savybes.
- Dirbtinių neuronų tinklų, neraiškiosios logikos ar kitų dirbtinio intelekto modelių taikymas prognozuojant akcijų kainas mažina duomenų chaotiškumą bei netikrų signalų skaičių ir leidžia įtraukti daugiau metodų, o tai savo ruožtu didina prognozės tikslumą ir modelio patikimumą. Dirbtinio intelekto modeliai gali analizuoti didelį kiekį

kiekybinių duomenų, tačiau jų nepervertina ir, svarbiausia, gali mokytis.

- Investavimo sprendimų priėmimo modeliai gali prisitaikyti prie skirtingų investavimo priemonių ar net taikyti skirtingas strategijas, kiekvienai portfelio esančiai akcijai.
- Sistemos gali apimti tiek kiekybinius, tiek kokybinius duomenis papildomai įtraukiant tokias analizės technikas, kaip, pavyzdžiui, sentimentų analizė, minios nuomonė, taip padidinant prognozės tikslumą.
- Dažniausiai modeliai duoda automatinius sprendimus, nors kai kuriais atvejais gali tik pateikti siūlymus dėl pirkimo / pardavimo veiksmų, o galutinį sprendimą priima pats investuotojas.
- Suformuojama optimali portfelio struktūra, kuri padeda valdyti finansinę riziką, didina investuotojo grąžą, taip pat užtikrina aukštesnį patikimumo lygį.
- Apsaugo investuotojus nuo neracionalių ir skubotų sprendimų, pateikdamos konservatyvesnę vertinimą ir eliminuodamos mažiau reikšmingus pasikeitimus akcijų rinkose. Padeda efektyviai valdyti ir mažinti operacijų skaičių ir kaštus prekybos platformose.

Tačiau netgi toks investavimo sprendimų priėmimo modelių galimybių atskleidimas ir analitinis procesų aprašymas nėra galutinis, sprendimų paramos modelių taikymas finansų srityje dar nėra iki galo baigtas, sistemos yra nuolat tobulinamos ir modifikuojamos. Straipsnyje analizuoti modeliai susiduria su šiais trūkumais, ribojančiais jų taikymą:

- Reikalingos specifinės žinios, dauguma modelių yra sudėtingi taikyti; pavyzdžiui, norint panaudoti dirbtinį intelektą, gali tekti kreiptis į atitinkamus specialistus, ir ne visi modeliai gali būti prieinami individualiems investuotojams, reikalingos specifinės programos, algoritmų sistemos, kurios dažniausiai yra autoriniai darbai, dėl to sunkiai prieinamos.
- Investavimo sprendimų priėmimo modelius galima supaprastinti atsisakant sudėtingų kompiuterinių metodų, tačiau, taikant paprastesnius metodus, prastėja sistemos efektyvumas, neįvertinami visi kiekybiniai ir kokybiniai duomenys, ignoruojama aplinka, kurioje investuojama, neatsižvelgiant į reikšmingus pokyčius arba priešingai, dėl duomenų ir informacijos chaotiškumo bei dinamiškumo didėja neapibrėžtumas, rinkos pasikeitimai gali būti pervertinti ir gauti klaidingi signalai.
- Kai kurie modeliai vis dar turi ribotas galimybes

adaptuotis skirtingose akcijų rinkose, skirtingoms turto klasėms arba prisitaikyti prie kintančių rinkos sąlygų.

- Būtinybė toliau atlikti tyrimus, vertinant modeliuose taikomų metodų derinius, tinkamumą veikti vienoje sistemoje, nustatyti optimalius jų derinius.

Darbe išanalizuotos priemonės investiciniams sprendimams priimti turi reikalingų bruožų, kurie leistų jas taikyti praktiškai. Patobulinti modeliai pagelbėtų tam tikru sprendimų priėmimo ir valdymo kapitalo rinkoje etapu. Pagerinti prognozavimo metodai gali tiksliau numatyti kainų pokyčius rinkoje, padėti investuotojams nustatyti tikslus ir priimti sprendimus, taip pagerinant portfelio pelningumą (Wu *et al.* 2014).

Išvados

Sparti finansų rinkų plėtra, investicinių priemonių ir paslaugų įvairovės didėjimas – efektyvių investavimo sprendimų sudėtingumo ir naujų investavimo galimybių įrodymas. Tačiau naujos galimybės taip pat iškelia naujus iššūkius, kurie reikalauja vis pažangesnių mokslinių ir praktinių sprendimų. Šiame naujame kontekste išaugo efektyvių finansinių sprendimų priėmimo poreikis ir svarba, o kartu padidėjo ir finansinių sprendimų priėmimo proceso sudėtingumas. Kompiuterinės technologijos vis sparčiau integruojasi į finansų sritį, didelės kompiuterių skaičiavimo galimybės sudaro galimybes atlikti sudėtingesnes analizes apdorojant didesnius kiekius duomenų. Sprendimų paramos sistemos yra pripažintos kaip naudingos priemonės, padedančios jų naudotojams planuoti ir priimti sprendimus, be to, gali būti taikomos skirtingose srityse.

Straipsnyje išanalizuoti devyni investavimo sprendimų priėmimo modeliai. Pastebėta, kad dauguma jų, taikydami patobulintus metodus, siekia nustatyti akcijos kainos prognozę, judėjimo kryptį, prekybos vietas, geriausią investavimo strategiją, taip pat portfelio struktūrą. Atsižvelgiant į tai, kad akcijų rinka yra sudėtinga sistema, apimanti chaotiškus ir nestacionarius duomenis, mokslininkai vis dažniau bando sukurti automatinius sprendimo priėmimo modelius, įtraukiančius kuo daugiau metodų: fundamentaliąją ir techninę analizę, laiko eilučių modelius, slankiųjų vidurkių sistemas, sentimentų analizę, minios balsą, ekspertų vertinimą ir net tokius naujoviškus metodus, kaip dirbtinis neuronų tinklas ir neraiškioji logika, kurie, anot jų, geriausiai sugeba įvertinti netiesinius ir dinamiškus laiko eilučių šablonus.

Priklausomai nuo siekiamo rezultato, mokslininkai savo modeliuose stengiasi pritaikyti kuo daugiau metodų, sujungti juos ir, skirtingais būdais analizuodami akcijų

kainų judėjimą, siekti geresnių rezultatų. Prognozavimas yra labai svarbus norint išvystyti veiksmingas strategijas prekybai akcijų rinkoje. Dauguma metodų kuriami siekiant skirtingų tikslų, turi nevienodas savybes, dėl to, rinkdamiesi jų derinius, investuotojai turi atsargiai įvertinti, kurie gali būti naudojami kartu, kurie turėtų būti taikomi atskirai. Naujų ir pažangių investavimo sprendimų priėmimo modelių, kurie tiksliai ir ryžtingai prognozuotų kainas, formavimas, visada bus nepaprastai svarbus investuotojams ir finansų analitikams, nes tai vis dar yra nauja tyrimų sritis, turinti didelį komercinį potencialą.

Literatūra

- Atsalakis, G. S.; Valavanis, K. P. 2009. Forecasting stock market short-term trends using a neuro-fuzzy based methodology, *Expert Systems with Applications* 36(7): 10696–10707. <https://doi.org/10.1016/j.eswa.2009.02.043>
- Ballings, M.; Poel, D.; Hespels, V. D.; Gryp, N. R. 2015. Evaluating multiple classifiers for stock price direction prediction, *Expert Systems with Applications* 42: 7046–7056. <https://doi.org/10.1016/j.eswa.2015.05.013>
- Bao, D.; Yang, Z. 2008. Intelligent stock trading system by turning point confirming and probabilistic reasoning, *Expert Systems with Applications* 34(1): 620–627. <https://doi.org/10.1016/j.eswa.2006.09.043>
- Beck, T.; Chen, T.; Chen, L.; Song, F. M. 2016. Financial innovation: the bright and the dark sides, *Journal of Banking and Finance* 72: 28–51. <https://doi.org/10.1016/j.jbankfin.2016.06.012>
- Berger, A. N. 2003. The economic effects of technological progress: evidence from the banking industry, *Journal of Money, Credit and Banking* 35: 141–176. <https://doi.org/10.1353/mcb.2003.0009>
- Braga, A. P.; Carvalho, A. P. L.; Ludermir, T. B. 2007. *Artificial Neural Networks: theory and Applications*. 2nd edition, LTC - Technical and Scientific Books, Rio de Janeiro, 280.
- Cervelló-Royo, R.; Guijarro, F.; Michniuk, K. 2015. Stock market trading rule based on pattern recognition and technical analysis: Forecasting the DJIA index with intraday data, *Expert Systems With Applications* 42(14): 5963–5975.
- Chang, P. C.; Fan, C. Y.; Lin, J. L. 2011. Trend discovery in financial time series data using a case based fuzzy decision tree, *Expert Systems with Applications* 38: 6070–6080. <https://doi.org/10.1016/j.eswa.2010.11.006>
- Chang, P. C.; Liu, C. H.; Lin, J. L.; Fan, C. Y.; Ng, C. S. 2009. A neural network with a case based dynamic window for stock trading prediction, *Expert Systems with Applications* 36: 6889–6898. <https://doi.org/10.1016/j.eswa.2008.08.077>
- Chavarnakul, T.; Enke, D. 2009. A hybrid stock trading system for intelligent technical analysis-based equivolume charting, *Neurocomputing* 72(16): 3517–3528.
- Chen, W. S.; Du, Y. K. 2009. Using neural networks and data mining techniques for the financial distress prediction model, *Expert Systems with Applications* 36: 4075–4086. <https://doi.org/10.1016/j.eswa.2008.03.020>
- Cheng, C.-H.; Chen, T.-L.; Wei, L.-Y. 2010. A hybrid model based on rough sets theory and genetic algorithms for stock price forecasting, *Information Sciences* 180: 1610–1629. <https://doi.org/10.1016/j.ins.2010.01.014>
- Chiang, W. Ch.; Enke, D.; Wu, T.; Wang, R. 2016. An adaptive stock index trading decision support system, *Expert Systems With Applications* 96: 195–207. <https://doi.org/10.1016/j.eswa.2016.04.025>
- Cho, V. 2010. MISMS – A comprehensive decision support system for stock market investment, *Knowledge-Based Systems* 23: 626–633.
- Chourmouziadis, K.; Chatzoglou, P. D. 2015. An intelligent short term stock trading fuzzy system for assisting investors in portfolio management, *Expert Systems with Applications* 43: 298–311. <https://doi.org/10.1016/j.eswa.2015.07.063>
- Clements, M. P.; Milas, C.; van Dijk, D. 2009. Forecasting returns and risk in financial markets using linear and nonlinear models, *International Journal of Forecasting* 25: 215–217. <https://doi.org/10.1016/j.ijforecast.2009.01.003>
- De Oliveira, F. A.; Nobre, C. N.; Zarate, L. E. 2013. Applying artificial neural networks to prediction of stock price and improvement of the directional prediction index case study of PETRA4, Petrobras, Brazil, *Expert Systems with Applications* 40(18): 7596–7606. <https://doi.org/10.1016/j.eswa.2013.06.071>
- Dymova, L.; Sevastianov, P.; Bartosiewicz, P. A. 2009. New approach to the rule-base evidential reasoning: stock trading expert system application, *Expert Systems with Applications* 37(8): 5564–5576. <https://doi.org/10.1016/j.eswa.2010.02.056>
- Dymova, L.; Sevastianov, P.; Kaczmarek, K. 2012. A stock trading expert system based on the rule-base evidential reasoning using Level 2 Quotes, *Expert Systems with Applications* 39: 7150–7157. <https://doi.org/10.1016/j.eswa.2012.01.077>
- Enke, D.; Mehdiyev, N. 2013. Stock market prediction using a combination of stepwise regression analysis, differential evolution-based fuzzy clustering, and a fuzzy inference neural network, *Intelligent Automation and Soft Computing* 19(4): 636–648. <https://doi.org/10.1080/10798587.2013.839287>
- 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* 58: 1249–1266. <https://doi.org/10.1016/j.mcm.2013.02.002>
- French, S.; Turoff, M. 2007. Decision support system, *Communications of the ACM* 50(3): 39–40. <https://doi.org/10.1145/1226736.1226762>
- Geva, T.; Zahavi, J. 2014. Empirical evaluation of an automated intraday stock recommendation system incorporating both market data and textual news, *Decision Support Systems* 57: 212–223. <https://doi.org/10.1016/j.dss.2013.09.013>
- Ghasemzadeh, F.; Archer, N. P. 2000. Project portfolio selection through decision support, *Decision Support Systems* 29: 73–88. [https://doi.org/10.1016/S0167-9236\(00\)00065-8](https://doi.org/10.1016/S0167-9236(00)00065-8)
- Gottschilch, J.; Hinz, O. 2014. A decision support system for stock investment recommendations using collective wisdom, *Decision Support Systems* 59: 52–62. <https://doi.org/10.1016/j.dss.2013.10.005>
- Gupta, P.; Inuiguchi, M.; Mehlawat, M. K. 2010. A hybrid approach for constructing suitable and optimal portfolios, *Expert Systems with Applications* 36(5): 5620–5632.

- Guresen, E.; Kayakutlu, G.; Daim, T. U. 2011. Using artificial neural network models in stock market index prediction, *Expert Systems with Applications* 38(8): 10389–10397. <https://doi.org/10.1016/j.eswa.2011.02.068>
- Hadavandi, E.; Shavandi, H.; Ghanbari, A. 2010. Integration of genetic fuzzy systems and artificial neural networks for stock price forecasting, *Knowledge-Based Systems* 23: 800–808. <https://doi.org/10.1016/j.knsys.2010.05.004>
- Hafezi, R.; Shahradi, J.; Hadavandi, E. 2015. A bat-neural network multi-agent system (BNNMAS) for stock price prediction: case study of DAX stock price, *Applied Soft Computing* 29: 196–210. <https://doi.org/10.1016/j.asoc.2014.12.028>
- Houston, J.; Lin, Ch.; Ma, Y. 2010. Creditor rights, information sharing, and bank risk taking, *Journal of Financial Economics* 96(3): 485–512. <https://doi.org/10.1016/j.jfineco.2010.02.008>
- Hsu, M. W.; Lessmann, S.; Sung, M. C.; Ma, T.; Johnson, J. E. V. 2016. Bridging the divide in financial market forecasting: machine learners vs. financial economists, *Expert Systems with Applications* 61: 215–234. <https://doi.org/10.1016/j.eswa.2016.05.033>
- Yang, K.; Wu, M.; Lin, J. 2012. The application of fuzzy neural networks in stock price forecasting based on genetic algorithm discovering fuzzy rules, in *8th international conference on Natural Computation (ICNC)*, 29–31 May, 2012, Chongqing, China, 470–474.
- Jaeger, H.; Haas, H. 2004. Harnessing nonlinearity: predicting chaotic systems and saving energy in wireless communications, *Science* 304(5667): 78–80. <https://doi.org/10.1126/science.1091277>
- Kaklauskas, A.; Zavadskas, E. K.; Trinkūnas, V. 2007. A multiple criteria decision support online system for construction, *Engineering Applications of Artificial Intelligence* 20(2): 163–175. <https://doi.org/10.1016/j.engappai.2006.06.009>
- Kara, Y.; Boyacioglu, M. A.; Baykan, O. K. 2011. Predicting direction of stock price index movement using artificial neural networks and support vector machines: the sample of the Istanbul stock exchange, *Expert Systems with Applications* 38(5): 5311–5319. <https://doi.org/10.1016/j.eswa.2010.10.027>
- Klein, M.; Methlie, L. B. 2009. *Knowledge-based decision support systems with applications in business: a decision support approach*. Wiley, 544.
- Kuo, R. J.; Chen, C.; Hwang, Y. 2001. An intelligent stock trading decision support system through integration of genetic algorithm based fuzzy neural network and artificial neural network, *Fuzzy Sets and Systems* 118: 21–45. [https://doi.org/10.1016/S0165-0114\(98\)00399-6](https://doi.org/10.1016/S0165-0114(98)00399-6)
- Kuo, R. J.; Xue, K. C. 1998. A decision support system for sales forecasting through fuzzy neural networks with asymmetric fuzzy weights, *Decision Support Systems* 24(2): 105–126.
- Lai, R. K.; Fan, C. Y.; Huang, W. H.; Chang, P. C. 2009. Evolving and clustering fuzzy decision tree for financial time series data forecasting, *Expert Systems with Applications* 36(2): 3761–3773. <https://doi.org/10.1016/j.eswa.2008.02.025>
- Lerner, J.; Tufano, P. 2011. The consequences of financial innovation: a counterfactual research agenda, *Annual Review of Financial Economics* 3: 41–85. <https://doi.org/10.1146/annurev.financial.050808.114326>
- Lessmann, S.; Sung, M.; Johnson, J. E. 2011. Towards a methodology for measuring the true degree of efficiency in a speculative market, *Journal of the Operational Research Society* 62: 2120–2132. <https://doi.org/10.1057/jors.2010.192>
- Lin, C. H.; Hasieh, P. J. 2004. A fuzzy decision support system for strategic portfolio management, *Decision Support Systems* 38(3): 383–398.
- Lin, X.; Yang, Z.; Song, Y. 2011. Intelligent stock trading system based on improved technical analysis and Echo State Network, *Expert Systems with Applications* 38: 11347–11354. <https://doi.org/10.1016/j.eswa.2011.03.001>
- Lo, A. W.; MacKinlay, A. C. 2011. *A non-random walk down wall street*. Princeton, New Jersey: Princeton University Press, 448. <https://doi.org/10.1515/9781400829095>
- Majhi, R.; Panda, G.; Sahoo, G. 2009. Development and performance evaluation of FLANN based model for forecasting of stock market, *Expert Systems with Applications* 36: 6800–6808. <https://doi.org/10.1016/j.eswa.2008.08.008>
- Maknickienė, N.; Maknickas, A. 2012. Application of neural network for forecasting of exchange rates and forex trading, in *7th International Scientific Conference "Business and Management 2012"*, 10–11 May, 2012, Vilnius, Lithuania, 122–127.
- Maknickienė, N.; Maknickas, A. 2013a. Financial market prediction system with Evolino neural network and Delphi method, *Journal of Business Economics and Management* 14(2): 403–413. <https://doi.org/10.3846/16111699.2012.729532>
- Maknickienė, N.; Maknickas, A. 2013b. Investigation of prediction capabilities using RNN ensembles, *International Joint Conference on Computational Intelligence* 1: 391–359.
- Maknickienė, N.; Rutkauskas, A. V.; Maknickas, A. 2011. Investigation of financial market prediction by recurrent neural network, *Innovative Infotechnologies for Science, Business and Education* 2(11): 3–8.
- Manahov, V.; Hudson, R. 2014. A note on the relationship between market efficiency and adaptability – new evidence from artificial stock markets, *Expert Systems with Applications* 41: 7436–7454. <https://doi.org/10.1016/j.eswa.2014.06.004>
- Martinez, L.; Ruan, D.; Herrera, F. 2009. Computing with words in decision support systems: an overview on models and applications, *International Journal of Computational Intelligence Systems* 3(4): 382–395. <http://dx.doi.org/10.1080/18756891.2010.9727709>
- Patel, J.; Shah, S.; Thakkar, P.; Kotecha, K. 2015. Predicting stock and stock price index movement using trend deterministic data preparation and machine learning techniques, *Expert Systems with Applications* 42(1): 259–268. <https://doi.org/10.1016/j.eswa.2014.07.040>
- Peters, E. E. 1994. *Fractal market analysis: applying chaos theory to investment and economics*. New York: Willey & Sons, Inc., 336.
- Pinto, D. D. D.; Monteiro, J. G. M. S.; Nakao, E. H. 2011. An approach to portfolio selection using an ARX predictor for securities' risk and return, *Expert Systems with Applications* 38(12): 15009–15013. <https://doi.org/10.1016/j.eswa.2011.05.046>
- Power, D. J. 2008. Understanding data-driven decision support systems, *Information Systems Management* 25(2): 149–154. <https://doi.org/10.1080/10580530801941124>
- Rubell, M. L. G.; Jessy, J. C. 2016. A multiple fuzzy inference systems framework for daily stock trading with application to NASDAQ stock exchange, *Expert Systems with Applications* 44: 13–21. <https://doi.org/10.1016/j.eswa.2015.08.045>
- Ritchie, J. C. 1996. *Fundamental analysis: a back to the basics investment guide to selecting quality stocks*. McGraw-Hill Companies, 395.

- Russell, S.; Norvig, P. 2014. *Artificial intelligence: a modern approach*. Harlow, Essex: Pearson Education Limited, 1152.
- Rutkauskas, A. V.; Stasytytė, V.; Stankevičienė J. 2009. Profit, riskiness and reliability – three-dimensional base for investment decisions management, in *Modeling and Analysis of Safety and Risk in Complex Systems, Proceedings of the Ninth International Scientific School MA SR*, 7–11 July 2009, Saint Petersburg, Russia. SUAI, 105–110.
- Sevastianov, P.; Dymova, L. 2009. Stock screening with use of multiple criteria decision making and optimization, *Omega* 37(3): 659–671. <https://doi.org/10.1016/j.omega.2008.04.002>
- Stankevičienė, J.; Maknickienė, N.; Maknickas, A. 2014. Investigation of exchange market prediction model based on high-low daily data, in *The 8th international scientific conference "Business and Management 2014"*, 15–16 May, 2014, Vilnius, Lithuania, 320–328.
- Stasytytė, V. 2012. Investicijų portfelio sudarymas naudojant sprendimų paramos sistemą, *Verslas: teorija ir praktika* 13(3): 253–263.
- Stasytytė, V. 2011. *Investicijų portfelio sprendimų paramos sistema: daktaro disertacija*. Vilnius. 164 p.
- Tsai, C. F.; Hsiao, Y. C. 2010. Combining multiple feature selection methods for stock prediction: union, intersection, and multi-intersection approaches, *Decision Support Systems* 50: 258–269. <https://doi.org/10.1016/j.dss.2010.08.028>
- Tucnik, P. 2009. Automated futures trading: environment effect on the decision making, in *Proceedings of the ninth WSEAS international conference on applied computer science, World Scientific and Engineering Academy and Society (WSEAS)*, 17–19 October, 2009, Genova, Italy, 74–79.
- Tunčikienė, Ž.; Bivainis, J.; Drejeris, R. 2010. Integrated DSS for strategic planning in public institutions, *Journal of Business Economics and Management* 11(4): 671–688. <https://doi.org/10.3846/jbem.2010.33>
- Vanstone, B.; Tan, C. 2005. Artificial neural networks in financial trading, in M. Khosrow-Pour (Ed.). *Encyclopedia of information science and technology*. Idea Group, 1532–1536. <https://doi.org/10.4018/978-1-59140-553-5.ch031>
- Vejendla, A.; Enke, D. 2013. Performance evaluation of neural networks and GARCH models for forecasting volatility and option strike prices in a bull call spread strategy, *Journal of Economic Policy and Research* 8(2): 1–19.
- Zbikowski, K. 2015. Using volume weighted support vector machines with walk forward testing and feature selection for the purpose of creating stock trading strategy, *Expert Systems with Applications* 42(4): 1797–1805. <https://doi.org/10.1016/j.eswa.2014.10.001>
- Zouponidis, C.; Doumpos, M. 2002. Multicriteria decision aid in financial decision making: methodologies and literature review, *Journal of Multi-Criteria Decision Analysis* 11: 167–186. <http://dx.doi.org/10.1002/mcda.333>
- Zhou, S., et. al. 2010. Crowd modeling and simulation technologies, *ACM Transactions on Modeling and Computer Simulation* 20(4): 1–34.
- 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. <https://doi.org/10.1016/j.eswa.2011.02.075>
- Wu, J-L.; Yu, L-C.; Chang, P-C. 2014. An intelligent stock trading system using comprehensive features, *Applied Soft Computing* 23: 39–50. <https://doi.org/10.1016/j.asoc.2014.06.010>

COMPARATIVE ANALYSIS OF INVESTMENT DECISION MODELS

I. Kekytė, V. Stasytytė

Abstract

Rapid development of financial markets resulted new challenges for both investors and investment issues. This increased demand for innovative, modern investment and portfolio management decisions adequate for market conditions. Financial market receives special attention, creating new models, includes financial risk management and investment decision support systems. Researchers recognize the need to deal with financial problems using models consistent with the reality and based on sophisticated quantitative analysis technique. Thus, role mathematical modeling in finance becomes important. This article deals with various investments decision-making models, which include forecasting, optimization, stochastic processes, artificial intelligence, etc., and become useful tools for investment decisions.

Keywords: investment, decision-making models, stock market, portfolio, data analysis, forecasting.