

Economics and management Ekonomika ir vadyba

PARAMOS SISTEMA SPEKULIAVIMUI BIRŽOJE PREKIAUJAMAIŠ FONDAIS

Gediminas TUMAŠEVIČIUS *, Nijolė MAKNICKIENĖ 

Vilniaus Gedimino technikos universitetas, Vilnius, Lietuva

Gauta 2021 m. spalio 31 d.; priimta 2021 m. lapkričio 18 d.

Santrauka. Darbe yra nagrinėjamos spekuliacinio biržoje prekybama fondais, naudojant dirbtinį intelektą, galimybės. Pagrindinis mokslinio tyrimo tikslas – remiantis dirbtinio intelekto bei biržoje prekybama fondų spekuliacinio teoriniais aspektais, sukurti spekuliacinio sprendimų priėmimo paramos sistemą investuotojams, veikiančioms biržoje prekybama fondų rinkoje. Paramos sistema yra kuriama remiantis sustiprintuoju mokymu (angl. *reinforcement learning*), sistemai sudaryti ir detalizuoti buvo taikyti sintezės, konkretizavimo bei apibendrinimo metodai, taip pat, panaudojus susidarytą sistemą bei gavus rezultatus, jiems apdoroti taikyti matematinės-statistinės analizės metodai. Sėkmingai pritaikius pasirinktą metodologiją, sudarant paramos sistemą, buvo gauti teigiami prekybos rezultatai. Sėkmingas tyrimas išplečia giliojo sustiprintojo mokymu taikymo suvokimo ribas bei sudaro pagrindą tolesniam biržoje prekybama fondų paramos sistemos vystymui. Sudaryta paramos sistema sutrumpins sugaištamą laiką tarp prekybos signalo atsiradimo ir investuotojo sprendimo priėmimo, o tai padės sumažinti potencialaus pelno praradimą.

Reikšminiai žodžiai: paramos sistema, biržoje prekybama fondai, spekuliacinimas, dirbtinis intelektas, finansų rinka, sustiprintasis mokymasis, mašininis mokymasis.

Įvadas

Tyrimo aktualumas. Pasaulį kėrciantys socialiniai bei kariniai konfliktai, ekonominiai nesutarimai, ekologinės nelaimės bei humanitarinės katastrofos turi smarkų poveikį finansų sektoriui. Dėl šių įvykių, priklausomai nuo sandorio šalies pusės, įmonės ir valstybės gali susidurti su bankroto rizika arba labai pasipelninti. Paveiktų šalių rezultatai atsispindi finansų rinkose (jeigu įmonės akcijos yra kotiruojamos akcijų biržoje, valstybės yra išleidusios obligacijų, turi savo valiutą ir pan.), tai daro rinkas mažiau stabilias, dinamiškesnes, išauga rizika investuotojams. Be anksčiau paminėtų išorinių rinkoms poveikį darančių veiksnių, yra begalė vidinių veiksnių, kurie gali turėti įtakos finansinių priemonių stabilumui. Viso to rezultatas – didžiausi kiekiai informacijos, kurią turi apdoroti investuotojai, bei išaugęs neapibrėžtumas. Natūralu, kad kuo didesnis kiekis informacijos, tuo daugiau laiko bus užtrunkama analizei ir tuo vėliau bus priimami galutiniai sprendimai. Problema ta, kad kuo ilgiau delsiama priimant sprendimą, tuo daugiau yra prarandama potencialaus pelno. Pasak Martin L. Scholus: „naujos elektroninės prekybos sistemos bei didelės investicijos į technologijas

sufleruoja tai, kad greitis prekyboje tampa vis reikšmingesnis siekiant sėkmės finansų rinkose“. Atlikti mokslininko tyrimai parodė, kad prekybos strategijos sėkmė, kai sandoris yra įvykdomas 0,2 s po intervalo pasikeitimo, yra gerokai žemesnė nei tos strategijos, kurią taikant sandoris įvykdomas iš karto.

Naujausių technologijų pažanga lengvina žmonių gyvenimus moksle, darbuose bei kasdiniuose gyvenimuose, ne išimtis ir finansų sektorius. Integruojamos informacinės technologijos, vis spartėjantis interneto greitis suteikia galimybę pasiekti vis didesnius informacijos kiekius bei vis greičiau juos apdoroti. Modernėjant finansų sektoriui didėja ir konkurencija kapitalo rinkose, o tai pritraukia didesnę mokslininkų, kurie stengiasi sukurti sistemas, palengvinančias bei paspartinančias investavimo procesą, susidomėjimą. Apie sprendimų priėmimo paramos sistemas rašė tokie Lietuvos autoriai, kaip Stasytytė (2011), Maknickas ir Maknickienė (2019), Maknickienė et al. (2020), Maknickienė (2015), Kornilov (2020). Įvairius paramų sistemų aspektus tyrė ir šie užsienio mokslininkai: Huang (2017), Zeebaree ir Aqel (2019), Muhtadin (2015),

*Autorius susirašinėti. El. paštas gediminas.tumasevicius@stud.vilniustech.lt

Rashidi et al. (2018), Ayankoya et al. (2016), Nabipour et al. (2020), Pinto (2014), Li et al. (2019).

Darbo tikslas. Remiantis dirbtinio intelekto bei biržoje prekiaujamų fondų spekuliacinio teoriniais aspektais, sukurti spekuliacinio sprendimų priėmimo paramos sistemą investuotojams, veikiantiems biržoje prekiaujamų fondų rinkoje.

1. Literatūros apžvalga

Remiantis Lietuvos banko viešinama Lietuvos gyventojų investicijų apžvalga (2020 metų), daugiausiai lietuviai yra linkę investuoti į pensijų fondus, gyvybės draudimus ir nekilnojamojį turtą. Į akcijas bei kitus įmonių vertybinius popierius investuoja tik maža dalis. Finansinių ekspertų teigimu, lietuviams koją kiša finansinio raštingumo stoka bei nepasitikėjimas finansinėmis institucijomis (Lietuvos bankas, 2020). Nors ir nekilnojamoji turtas yra gera investavimo priemonė, bėda ta, kad jis reikalauja labai didelio pradinio kapitalo. To išėjis galėtų būti viena iš labiausiai populiarėjančių finansinių priemonių – biržoje prekiaujami fondai.

Yra manoma, kad biržoje prekiaujami fondai (angl. *exchange traded funds (ETFs)*) yra viena svarbiausių 20 metų finansinių inovacijų. Biržoje prekiaujami fondai – tai (kaip ir pavadinimas sufleruoja) investicinis portfelis, kuriuo yra prekiaujama biržose. Šie portfeliai būna sudaryti iš vienos rūšies finansinių priemonių. Didžioji dalis šių fondų yra teisiškai struktūrinami kaip OEIC (angl. *open ended investment company*). Biržoje prekiaujami fondai gali būti suskirstyti į dvi esmines šakas: pasyviai valdomi ir aktyviai valdomi fondai. Didžiąją dalį biržoje prekiaujamų fondų sudaro pasyviai valdomi, tokiais fondais yra stengiamasi sekti kokio nors rinkos indekso ar net kelių indeksų kainos kaitą, be to, ETF fondais gali būti atkartojamos pramonės sektorių, valiutų, žaliavų ir kitų turto klasių kainos (pvz.: Xtrackers STOXX Europe 600 Oil & Gas Swap UCITS ETF IC kartuoja dujų ir naftos kainą, iShares Physical Gold ETC seka aukso kainos pokyčius, SPDR Dow Jones Global Real Estate UCITS ETF atkartoja nekilnojamojo turto sektoriaus kainų judėjimus) (Puelz et al., 2015). Priešingai nei fondai, kurie yra valdomi aktyviai, pasyviai valdomais fondais yra stengiamasi tiksliai sekti tam tikro turto kainos judėjimus ir nėra bandoma aplenkėti rinkos vidurkio. Fondai, kurie yra valdomi aktyviai, siekia gauti didesnę pelną bei patirti mažesnę nuostolį nei rinkos vidurkis. Tokie fondai yra valdomi investuojant lėšas į fondo valdytojo parinktas finansines priemones – tai paprasčiausiai yra standartinis investicinis fondas, kurio vienetais yra prekiaujama biržoje kaip eilinėmis akcijomis (Mazumder, 2014).

Augantis finansinės priemonės populiarumas bei besivystančios ir vis lengviau prieinamos technologijos skatina investuotojus ieškoti būdų, kurie galėtų juos padaryti konkurencingesnius rinkoje, tad vis daugiau investuotojų pereina prie proceso automatizavimo – paramos sistemos sukūrimo. Literatūroje sprendimų priėmimo paramos sistema yra apibūdinama kaip viena sistema, padedanti

išspręsti organizacinius klausimus, sumažinti netikrumą ir pagerinti sprendimų priėmimo procesą. Daugybė mokslininkų yra atlikę sprendimų priėmimo paramos sistemų bei jas naudojančių asmenų tyrimus. Daugeliu atvejų buvo pastebėtas organizacijų veiklos pagerėjimas didinant produktyvumą. Buvo pamatyta, kad dirbtinis intelektas, tinklų kūrimas, debesų kompiuterija ir pan. tradicines gamybos sistemas paverčia intelektinėmis sistemomis. Dauguma šių funkcijų yra būtinybė kuriant organizacinę sistemą, kuri galėtų užtikrinti aukštą produktyvumą, tvarumą bei pranašumą. Ne išimtis yra ir finansų rinkos, prekybos procesų automatizavimas finansų rinkas padarė labiau prieinamas didesniai kiekiui investuotojų. Dinamiškėjančios rinkos bei augantis informacijos kiekis paskatino finansų rinkos dalyvius investuoti į technologijas, kurios suteiktų pranašumą prieš konkurentus.

Didėjantis prieinamų finansinių priemonių kiekis vienu metu ir palengvina, ir apsunkina investavimo procesus. Kaip jau minėta anksčiau, nors ir investuotojas gali pasirinkti finansinę priemonę, kuri tenkina jo investavimo įpročius ar tikslus, augantis informacijos kiekis labai apkrauna priešprekybinę apžvalgą. Esant ribotam laikui, darosi neįmanoma apžvelgti visų galimų finansinių priemonių ir išsirinkti tas, kurios turi didžiausią potencialą dienos prekyboje. Ribotos žmogaus galimybės priverstė institucinius investuotojus ieškoti efektyvesnių problemos sprendimo būdų. Pradėtas naudoti dirbtinis intelektas.

Dirbtinis intelektas – terminas, sugalvotas amerikiečių matematiko John McCarthy 1954 m., jis šią sąvoką aiškina kaip „pažangių mašinų gamybos mokslas ir technologijos“ bei teigia, kad net paprasčiausios mašinos, tokios kaip termostatas, gali turėti įsitikinimus (Locklair, 2018). Atsiradusi tokia sąvoka sukėlė labai daug diskusijų mokslo srityje, per sąvokos egzistavimo laikotarpį šio termino reikšmė buvo vis labiau plečiama. Informatikas, Stanfordo universiteto mokslininkas Nilsas Nilssonas savo darbe *The quest for artificial intelligence: a History of Ideas and Achievements* dirbtinį intelektą įvardina taip: „veikla, skirta mašinai padaryti intelektualias, o intelektas yra savybė, leidžianti subjektui tinkamai ir gerai numatyti savo aplinką“ (Nilsson, 2011). Iš to galima susidaryti įvaizdį, kad dirbtinis intelektas yra žmogaus sudarytas darinys, galintis įvykdyti nurodytas užduotis, atsižvelgiant į aplinką (Naučius, 2018). Tačiau yra susiduriama su problema, kad toks dirbtinio intelekto paaiškinimas nepateikia jokios informacijos apie intelekto lygį, kurį turi subjektas. Kaip teigia studijų grupė straipsnyje *Artificial intelligence and life in 2030*, į tokią plačią sąvokos interpretaciją patektų net paprasčiausias elektroninis skaičiuotuvas, nors modernus dirbtinis intelektas yra daug labiau pažengęs (Stone et al., 2016). Kitokią dirbtinio intelekto interpretaciją pasiūlė Stuart Russell ir Peter Norvig. Šių mokslininkų teigimu, dirbtinis intelektas yra būdas priversti kompiuterį, kompiuterio valdomą robotą ar programinę įrangą mąstyti intelektualiai, panašiai kaip mąsto protingi žmonės. Tai gali būti įgyvendinta tiriant žmogaus elgseną bei mąstyseną ir bandant tai perteikti įrenginiams. Taip pat šie mokslininkai mano, kad pažangus dirbtinis inte-

lektas galėtų pranokti žmogaus galimybes, kartu dirbtiniu intelektu paremti dariniai taptų racionaliomis būtybėmis, kurios gali ne tik logiškai mąstyti, bet ir veikti racionaliai, ieškodamos geriausio situacijos sprendimo būdo, nebūtinai atsižvelgdamos į logiką (Russell & Norvig, 2002).

Taigi, galime daryti išvadą, kad dirbtinis intelektas yra žmogaus sudarytas darinys, kuriuo yra bandoma imituoti žmogaus mąstyseną, elgseną, darinys, kuris sprendimus priima nesekdamas kažkokio suprogramuoto modelio, o atsižvelgdamas į kintamuosius ir nusprenddamas, kokia yra geriausia išeitis. Iš to išeina mintis, kad dirbtinį intelektą galima apibrėžti kaip mašiną, kuri galėtų lengvai imituoti ir vykdyti užduotis, pradedant paprasčiausiomis ir baigiant sudėtingiausiomis. Tačiau pasiekti tokį dalyką yra labai sudėtinga. Šiuo metu dirbtinis intelektas yra skirstomas į tris lygmenis: siaurasis dirbtinis intelektas, bendrasis dirbtinis intelektas ir dirbtinis superintelektas. Antroje darbo dalyje bus pristatyta susidaryta dirbtinio intelekto paramos sistema bei jos veikimo principai.

2. Metodologinė dalis

Kuriant paramos sistemą, vienas iš pirmųjų žingsnių yra programinės kalbos pasirinkimas. Šiam tyrimui buvo pasirinkta „Python“ programinė kalba. Šiuo metu „Python“ yra sparčiausiai auganti programavimo kalba pasaulyje dėl savo patogumo naudoti, greito mokymosi kreivės ir daugybės aukštos kokybės duomenų mokslo ir mašininio mokymosi paketų. „Python“ programinė kalba yra plačiai naudojama kiekybiniam finansams – sprendimams, kurie apdoroja ir analizuoja didelius duomenų rinkinius, didelius finansinius duomenis. Dėl aiškios „Python“ programavimo sintaksės ir draugiškos vartotojui įrankių ekosistemos, ši programavimo kalba yra viena iš geriausių technologijų, leidžiančių valdyti bet kurios finansinės paslaugos kūrimo procesą (Vallat, 2018).

Vienas pirmųjų sukurtos sistemos etapų yra prekybos duomenų gavimas. Duomenims gauti buvo naudojama „pandas“ – „Python“ atvirojo kodo duomenų analizės bei manipuliavimo įrankis, turintis „pandas datareader“ antrinį paketą, kuris suteikia galimybę iš įvairių interneto duomenų šaltinių išgauti finansinius duomenis (tokių kaip „yahoo finance“, „google finance“ ir t. t.). Įrašius pasirinkto biržoje prekiaujamo fondo žymos simbolį, programa iš „yahoo finance“ pasiima 1000 dienų finansinės priemonės kainos istorinius duomenis (rinkos atidarymo, uždarymo, aukščiausią, žemiausią kainas bei prekybos apimtį). 80 % duomenų bus naudojama sistemai „mokinti“ bei likę sistemos efektyvumui testuoti.

Surinktus duomenis programa naudoja finansinių techninės analizės indikatorių reikšmėms skaičiuoti. Pasirinktiems techninės analizės indikatoriams apskaičiuoti buvo naudojami „FinTa“ (*Financial Technical Analysis*) bei „tulip“ (*Financial Technical Analysis Indicator Library*) „Python“ paketai. Naudoti du skirtingi paketai dėl to, kad ne visus indikatorių apima viena ar kita biblioteka. Moksliniuose šaltiniuose yra akcentuojamos keturios esminės techninės analizės indikatorių šakos: tendencijų,

nepastovumo, prekybos apimties ir impulso (dar vadinami momento indikatoriais) (Peachavanish, 2016). Šiame tiriamajame darbe bus naudojami keturi skirtingi indikatoriai, siekiant išvengti multikolinearumo problemos, buvo pasirinkta naudoti indikatorių iš kiekvienos šakos. Analizei naudoti indikatoriai:

Santykinio stiprumo rodiklis (RSI). Tai techninėje analizėje naudojamas momentinis (impulso) indikatorius. Naudojant šį indikatorių yra įvertinamas naujausių kainų pokyčių dydis tam, kad būtų galima nustatyti, ar turtas yra perpirktas, ar perparduotas. *RSI* yra atvaizduojamas kaip osciliatorius (linijinė diagrama, judanti tarp dviejų kraštutinumų), kurio reikšmės svyruoja nuo 0 iki 100 (Badruzaman, 2019). Santykinio stiprumo rodiklis apskaičiuojamas dviem etapais. Pirmame etape yra taikoma (1) formulė:

$$RSI_1 = 100 - \frac{100}{1 + \frac{\text{Vidutinis pajamingumas}}{\text{Vidutinis nuostolis}}} \quad (1)$$

Pradinei *RSI* vertei apskaičiuoti įprastai yra naudojamas 14 periodų laikotarpis. Atlikus pirmojo etapo skaičiavimus, kitas etapas yra duomenų išlyginimas. Tam yra taikoma (2) formulė:

$$RSI_2 = 100 - \left[\frac{100}{1 + \frac{(BP \cdot (\text{periodų skaičius} - 1)) \cdot EP}{(BN \cdot (\text{periodų skaičius} - 1)) \cdot EN}} \right], \quad (2)$$

čia *BP* – buvęs vidutinis pajamingumas; *BN* – buvęs vidutinis nuostolis; *EP* – esamas pajamingumas; *EN* – esamas nuostolis.

Įprastai manoma, kad pirkimo signalas atsiranda tuomet, kai *RSI* reikšmė perkopia 30 ribą, o pardavimo signalas, kai *RSI* leisdamasis kerta 70 reikšmę.

Klinger'io apimties osciliatorius (KVO). Apimties indikatoriumi yra matuojamos pinigų srautų tendencijos, paremtos apimtimi. Kaip ir dauguma kitų osciliatorių, taip ir *Klinger'io apimties osciliatorius* yra paremtas dviejų skirtingo periodo eksponentinių slankiųjų vidurkių (*EMA*) skirtumu (dažniausiai yra naudojami 34 ir 55 periodų *EMA*). Kai 34 periodų *EMA* reikšmė tampa žemesnė už 55 periodų *EMA*, tuomet *KVO* indikatorius leidžiasi, priešingu atveju – kyla (*Klinger*, 1997).

Klinger'io apimties osciliatorius grafikuose yra dažniausiai vaizduojamas su 13 periodų slankiuoju vidurkiu (priklausomai nuo investuotojo įpročių ši reikšmė gali būti keičiama). Jeigu šis slankusis vidurkis susikerta su *KVO*, kai indikatorius yra augimo procese, tas taškas yra interpretuojamas kaip ilgos pozicijos užsiėmimo signalas. Priešingu atveju – atvirkščiai.

Vidutinis krypties indeksas (ADX). Indikatorius yra naudojamas kainos tendencijų stiprumui nustatyti. Signalas trumpai arba ilgai pozicijai užimti atsiranda tuomet, kai *ADX* grafikas kerta 25 ribą (grafiko reikšmės svyruoja nuo 0 iki 100), tačiau dėl to, kad šis indikatorius yra

atsiliekančias, spekuliantai yra pradėję naudoti 20 ribą. Indikatoriaus 60 ribos kirtimas yra interpretuojamas kaip stiprios tendencijos griuvimo pradžia ir vienas iš signalų uždaryti poziciją (Gurrib, 2018).

Vidutiniam krypties indeksui apskaičiuoti yra taikoma (3) formulė:

$$ADX = MA \left(\frac{(+DI) - (-DI)}{(+DI) + (-DI)} \right) \cdot 100, \quad (3)$$

čia $+DI$ – teigiamas krypties judėjimo indeksas; $-DI$ – neigiamas krypties judėjimo indeksas; MA – slankusis vidurkis.

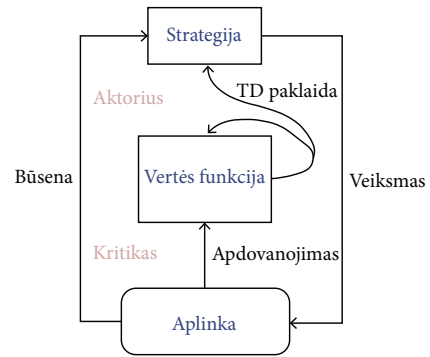
Vidutinio tikrojo diapazono indikatorius (ATR). Tai yra indikatorius, kuriuo yra matuojamas rinkos nepastovumas, išskaidant visą pasirinkto laikotarpio turto kainos diapazoną. Kylanti ATR reikšmė rodo didėjančią rinkos nepastovumą, žema indikatoriaus reikšmė reiškia, kad rinka yra pasyvi. ATR nėra kryptingas, todėl auganti ATR reikšmė gali rodyti pardavimo ar pirkimo spaudimą. Aukštos ATR vertės paprastai atsiranda dėl staigaus kainos kilimo ar nuosmukio (Soleymani & Paquet, 2021).

Vidutinio tikrojo diapazono indikatoriumi apskaičiuoti yra taikoma (4) formulė:

$$ATR = \left(\frac{1}{n} \right) \sum_{(i=1)}^{(n)} TR_i, \quad (4)$$

čia TR – konkretus tikrasis diapazonas; n – naudojamas laikotarpis.

Programai mokytis buvo naudota „Stable Baselines“ biblioteka (tai yra gerokai pagerinta „OpenAI Baselines“ atšaka, kuriai būdinga unifikauta algoritmų struktūra bei plati dokumentacija). Biblioteka suteikia galimybę naudotis šiais algoritmais: A2C, ACER, ACKTR, DDPG, DQN, GAIL, HER, PPO, TRPO, SAC. Kuriant paramos sistemą spekuliacijai biržoje prekiaujamais fondais nuspręsta naudoti A2C (*Advantage Actor Critic*) algoritmą. A2C yra sustiprintojo mokymosi algoritmas, kuris susideda iš dviejų tinklų (aktoriaus bei kritiko), kurie kartu sprendžia tam tikrą problemą (Li, 2017; Li et al., 2020). Aukštu lygiu funkcija „Advantage“ apskaičiuoja agento TD (laiko skirtumo, angl. *temporal difference*) paklaidą arba numatomą klaidą. Aktorių tinklas kiekvienu laiko žingsniu pasirenka tam tikrą veiksmą, o kritikų tinklas įvertina nurodytos įvesties būsenos kokybę arba Q reikšmę (veiksmaus vertinimas priklauso ne tik nuo to, kiek veiksmas yra geras, bet ir atsižvelgiama į tai, kiek jis gali būti geresnis). Kai kritikų tinklas sužino, kurie žingsniai yra geresni ar blogesni, aktorius šią informaciją panaudoja mokydamas agentą ieškoti gerų būsenų ir vengti blogų būsenų (Mnih et al., 2016). A2C architektūra yra pavaizduota 1 paveiksle. „Advantage“ funkcija nurodo, ar būsena geresnė, ar blogesnė, nei tikėtasi. Jei veiksmas yra geresnis, nei tikėtasi (pranašumas yra didesnis nei 0), norime paskatinti aktorių atlikti daugiau tų veiksmų. Jei veiksmas yra blogesnis, nei tikėtasi (pranašumas yra mažesnis nei 0), norime paskatinti aktorių imtis priešingų veiksmų (Li et al., 2018). Jei veiksmas atliekamas tiksliai taip, kaip tikėtasi (pranašumas lygus 0), aktorius iš to veiksmo nieko neišmoksta.



1 paveikslas. A2C algoritmo architektūra
Figure 1. A2C algorithm architecture

A2C naudoja to paties agento kopijas, kad atnaujintų gradientus su skirtingais duomenų pavyzdžiais. Kiekvienas agentas dirba savarankiškai, kad sąveikautų su ta pačia aplinka. Kiekvienoje iteracijoje po to, kai visi agentai baigia skaičiuoti savo gradientus, A2C naudoja koordinatorių, kad vidutinis visų agentų gradientas būtų perduotas visuotiniam tinklui, jog pasaulinis tinklas galėtų atnaujinti aktoriaus ir kritiko tinklą. Visuotinio tinklo buvimas padidina mokymo duomenų įvairovę (Yang et al., 2020). Sinchronizuotas gradiento atnaujinimas yra ekonomiškėsnis, greitesnis ir geriau veikia esant dideliems partijų dydžiams.

Objektyvi A2C funkcija yra aprašoma:

$$\nabla J_{\theta}(\theta) = E \left[\sum_{t=1}^T \nabla_{\theta} \log \pi_{\theta}(a_t | S_t) A(S_t, a_t) \right], \quad (5)$$

čia $\pi_{\theta}(a_t | S_t)$ – strategijos tinklas (tinklas, kuris išmoksta duoti tam tikrą rezultatą, pateikdamas tam tikrą įvestį), $A(S_t, a_t)$ – „Advantage“ funkcija, kuri gali būti aprašyta taip:

$$A(S_t, a_t) = Q(S_t, a_t) - V(S_t). \quad (6)$$

Be to, A2C algoritmas buvo naudojamas su LSTM (*Long Short-Term Memory*) sluoksniu. LSTM architektūra yra tam tikra pasikartojančio neuroninio tinklo (RNN) rūšis, skirta panaikinti tradicinio RNN silpną mokantis ilgalaikių priklausomybių (Bengio (1994) parodė, kad tradicinis RNN vargiai gali atsiminti sekas, kurių ilgis viršija 10) (Kuutti et al., 2019). LSTM padeda išsaugoti klaidą, kurią galima pakartoti per laiką, ir sluoksnius. Išlaikydami pastovesnę klaidą, sluoksniai leidžia pasikartojantiems tinklams toliau mokytis per daugelį laiko žingsnių (daugiau nei 1000), taip atveriamas kanalas, leidžiantis susieti priežastis ir pasekmes nuotoliniu būdu. Tai yra vienas iš pagrindinių mašininio mokymosi ir dirbtinio intelekto iššūkių, nes algoritmai dažnai susiduria su aplinkomis, kuriose atlygio signalai yra reti ir atidėliojami (Kratzert et al., 2018). Vėliau programa pradeda mokymosi procesą sukurtoje mokymosi aplinkoje. Mokymosi aplinkai sukurti yra naudojamas „Gym“ – aplinkų / problemų rinkinys, skirtas išbandyti ir kurti sustiprintojo mokymosi algoritmus. Programai mokinti yra skirta 1 000 000 laiko žingsnių. Kaip jau minėta anksčiau, programai mokytis yra


naudojama 80 % duomenų, paimtų iš „Yahoo finance“. Po mokymosi proceso yra išbandoma gauta sistema naudojant likusius 20 % duomenų bei pateikiami gauti rezultatai.

3. Simuliacijos rezultatai


Sukurtoje testavimo aplinkoje buvo simuliuojama prekyba naudojant sudarytą modelį. Sistemai išbandyti pasirinkta naudoti svertinio biržoje prekiaujamo fondo – „ProShares UltraPro QQQ“ duomenis. Prieš testavimą algoritminis mokymasis buvo sustabdytas programai atlikus 909 500 laiko žingsnių, čia paaiškintos variacijos reikšmė siekė 0,11 (viso modelio dispersijos dalis, kuri paaiškinama veiksniais, kurie iš tikrųjų yra, o ne dėl klaidų dispersijos, ši reikšmė gali svyruoti nuo neigiamos iki 1), vertės pradimas buvo lygus $2,49e-10$ (kuo ši reikšmė yra žemesnė, tuo modelis yra tikslesnis). Išbandyto modelio rezultatai yra matomi 2 paveiksle.

2 pav. žali taškai žymi vietas, kuriose sudaryta sistema užimtų ilgas pozicijas, raudoni taškai žymi vietas, kur sistema užimtų trumpas pozicijas. Matome, kad laikotarpiams, kai vykdavo esminiai kainos pokyčiai, sistema užimdavo pelningas prekybos pozicijas. Pastebime, kad bendras atlygis siekė 46,805, o prekybos galutinis pelnas siektų 1,6581, tai reiškia, kad per testuojamąjį laikotarpį sudarytas modelis pradinę turto vertę padidintų 65,81 % (per šį laikotarpį „ProShares UltraPro QQQ“ kaina pakilo 51,37 %, o tai rodo, kad sudarytas modelis aplenkė rinką 14,44 %). Nors sudarytas modelis atrodo veiksmingas, paaiškintos variacijos reikšmė yra labai žema – 0,11, o tai reiškia, kad gautas modelis yra nepatikimas (Merenda (1997, p. 158) teigė, kad, remiantis „tikrųjų“ veiksnių ir komponentų skaičiumi, [dispersijos dalis] turėtų būti bent 0,50).

Siekiant patobulinti sudarytą prekybos modelį ir gauti aukštesnę variacijos reikšmę, iš sistemos buvo nuspręsta pašalinti ATR indikatorių (kadangi šis gali kilti arba kristi nepriklausomai nuo to, ar kaina auga ar krenta) bei buvo sumažintas KVO indikatorius periodų kiekis (bandant sumažinti indikatorius atsilikimą). Atlikus šiuos pakeitimus programa buvo iš naujo paleista mokytis. Algoritminis mokymasis buvo sustabdytas programai atlikus 884 000 laiko žingsnių. Šį kartą paaiškintos variacijos reikšmė buvo maksimali ir siekė vienetą, vertės pradimas buvo aukštesnis nei pirmojo bandymo metu ir buvo



2 paveikslas. „ProShares UltraPro QQQ“ kainos grafikas su gautais rezultatais (1 periodas = 1 diena)
Figure 2. “ProShares UltraPro QQQ” price chart with results (1 period = 1 day)



3 paveikslas. „ProShares UltraPro QQQ“ kainos grafikas su gautais rezultatais (pašalinus ATR indikatorių bei sumažinus KVO indikatorius periodų skaičių) (1 periodas = 1 diena)
Figure 3. “ProShares UltraPro QQQ” price graph with the obtained results (removing the ATR indicator and reducing the number of KVO indicator periods) (1 period = 1 day)

lygus 0,000359. Antrojo bandymo rezultatai yra matomi 3 paveiksle.

3 pav. matome, kad, pakartojus bandymą su tam tikrais pakeitimais, trumpos bei ilgos pozicijos užėmimas tapo tolygesnis. Bendras atlygis šį kartą buvo beveik 3 kartus didesnis ir siekė 122,21 (tai reiškia, kad sustiprinto mokymosi agentas geriau atliko savo darbą maksimizuojant bendrą atlygį), o prekybos galutinis pelnas buvo lygus 2,1339. Taigi, matome, kad modelio aplinkos pakeitimai pagerino susidarytos sistemos efektyvumą, be to, yra matomas sudarytos sistemos potencialas prekyboje biržoje prekiaujamais fondais. Siekiant tikslingiau įvertinti susidarytą sistemą, reiktų atlikti daugiau bandymų su skirtingais ETF.

Išvados ir siūlymai

Atliktas darbas leido suformuoti toliau pateiktas išvadas.

Išnagrinėjus biržoje prekiaujamus fondus, buvo išaiškinta, kad ETF yra biržoje prekiaujamas investicinis portfelis, sudarytas iš tos pačios rūšies vertybinių popierių. Šiais fondais dažniausiai yra bandoma atkartoti kokio nors indekso, žaliavos ar valiutos kainos judėjimus. Dėl savo išskirtinių savybių (likvidumo, gyvų kainų pokyčių, dažnai viešinamos informacijos ar skaidrumo) šie fondai labiau primena akcijas nei tradicinius investicinius fondus. Likvidumas, didelis rūšių kiekis bei prieinama kaina daro šiuos fondus patrauklius spekuliantams.

Atlikus literatūros analizę buvo nustatyta, kad dirbtinis intelektas yra žmogaus sudarytas darinys, kuriuo yra bandoma imituoti žmogaus mąstyseną, elgseną, darinys, kuris sprendimus priima nesekdamas kažkokio suprogramuoto modelio, o atsižvelgdamas į kintamuosius ir nusprenddamas, kokia yra geriausia išeitis. Iš to išeina mintis, kad žmogaus intelektą galima apibrėžti kaip mašinos lengvai imituojamą dalyką ir galintį vykdyti užduotis, pradedant paprasčiausiomis ir baigiant sudėtingiausiomis. Tačiau pasiekti tokį dalyką yra labai sudėtinga.

Sistema buvo sudaryta naudojant „Python“ programavimo kalbą. Programa buvo treniruojama remiantis 4 indikatoriais: ATR, ADX, KVO bei RSI. Sukurta programa yra paremta A2C (*Advantage Actor Critik*) algoritmu su LSTM (*Long Short-Term Memory*) sluoksniu.

Atlikus modelio efektyvumo testavimą su pirminiais indikatoriais bei pasirinktimis buvo gautas teigiamas rezultatas. Programa per tiriamąjį laikotarpį sugeneruotų 65,81 % pelno, o tai reiškia, kad tą patį laikotarpį programa aplenkė rinką 14,44 %. Nors ir buvo gautas teigiamas pelno rezultatas, modelio paaiškintos variacijos reikšmė buvo labai žema ir tai sufleruoja, kad modelis yra nepatikimas. Dėl šios priežasties buvo atliktas pakartotinis bandymas atlikus tam tikrus aplinkos pakeitimus (pašalinus ATR indikatorių bei sumažinus KVO indikatoriaus reikšmes). Antras bandymas sugeneravo geresnius rezultatus, modelio paaiškintos variacijos reikšmė buvo maksimali (1), o prekybos galutinis pelnas buvo lygus 2,1339. Taigi, matome, kad modelio aplinkos pakeitimai pagerino sudarytos sistemos efektyvumą, be to, yra matomas sudarytos sistemos potencialas prekyboje biržoje prekiaujamais fondais. Siekiant tiksliau įvertinti sudarytą sistemą, reiktų atlikti daugiau bandymų su skirtingais ETF.

Literatūra

- Ayankoya, K., Calitz, A. P., & Greyling, J. H. (2016). *A framework for grain commodities trading decision support for South African maize farmers* [Conference presentation]. 10th International Business Conference 2016, Club Mykonos, Langebaan, South Africa.
- Badruzaman, J. (2019). Analysis relative strength index and earning per share on stock price. *Asian Journal of Economics, Business and Accounting*, 12(4), 1–9. <https://doi.org/10.9734/ajeba/2019/v12i430157>
- Gurrib, I. (2018). Performance of the Average Directional Index as a market timing tool for the most actively traded USD based currency pairs. *Banks and Bank Systems*, 13(3), 58–70. [https://doi.org/10.21511/bbs.13\(3\).2018.06](https://doi.org/10.21511/bbs.13(3).2018.06)
- Huang, S.-C. (2017). *A big data analysis system for financial trading* [Conference presentation]. World Conference on Business and Management 2017, Bali, Indonesia.
- Yang, H., Liu, X. Y., Zhong, S., & Walid, A. (2020). Deep reinforcement learning for automated stock trading: An ensemble strategy. In *Proceedings of the First ACM International Conference on AI in Finance* (pp. 1–8), New York. <https://doi.org/10.1145/3383455.3422540>
- Klinger, S. J. (1997). Identifying trends with volume analysis. *Technical Analysis of Stocks and Commodities Magazine*, 15, 68–70.
- Kornilov, S. (2020). *Assessing organizational efficiency under macroeconomic uncertainty in decision support systems: Ensemble methods in machine learning with two-stage nonparametric efficiency models* [Doctoral dissertation, Mykolas Romeris University]. https://repository.mruni.eu/bitstream/handle/007/16539/Disertacija_Kornilov.pdf?sequence=1&isAllowed=y
- Kratzert, F., Klotz, D., Brenner, C., Schulz, K., & Herrnegger, M. (2018). Rainfall–runoff modelling using long short-term memory (LSTM) networks. *Hydrology and Earth System Sciences*, 22(11), 6005–6022. <https://doi.org/10.5194/hess-22-6005-2018>
- Kuutti, S., Bowden, R., Joshi, H., de Temple, R., & Fallah, S. (2019, October 27–30). End-to-end reinforcement learning for autonomous longitudinal control using advantage actor critic with temporal context. In *2019 IEEE Intelligent Transportation Systems Conference (ITSC)* (pp. 2456–2462). IEEE. <https://doi.org/10.1109/ITSC.2019.8917387>
- Li, R., Wang, C., Zhao, Z., Guo, R., & Zhang, H. (2020). The LSTM-based advantage actor-critic learning for resource management in network slicing with user mobility. *IEEE Communications Letters*, 24(9), 2005–2009. <https://doi.org/10.1109/LCOMM.2020.3001227>
- Li, S., Bing, S., & Yang, S. (2018). Distributional advantage actor-critic. *arXiv:1806.06914*.
- Li, Y. (2017). Deep reinforcement learning: An overview. *arXiv:1701.07274*.
- Li, Y., Zheng, W., & Zheng, Z. (2019). Deep robust reinforcement learning for practical algorithmic trading. *IEEE Access*, 7, 108014–108022. <https://doi.org/10.1109/ACCESS.2019.2932789>
- Lietuvos bankas. (2020). *Lietuvos gyventojų investavimo įpročiai: vyrauja pensijų fondai ir nekilnojamasis turtas*. <https://www.lb.lt/lt/naujienos/lietuvos-gyventoju-investavimo-iprociai-vyrauja-pensiju-fondai-ir-nekilnojamasis-turtas>
- Locklair, V. A. (2018). Giant thinking... minds? The problem of strong artificial intelligence. *Concordia Technical Journal*, 1(1).
- Maknickas, A., & Maknickienė, N. (2019). Support system for trading in exchange market by distributional forecasting model. *Informatica*, 30(1), 73–90. <https://doi.org/10.15388/Informatica.2019.198>
- Maknickienė, N. (2015). *Paramos sistema investuotojui valiutų rinkoje* [Daktaro disertacija, Vilniaus Gedimino technikos universitetas]. Technika. <https://doi.org/10.20334/2310-M>
- Maknickienė, N., Maknickas, A., & Martinkutė-Kaulienė, R. (2020). Trading support method based on computational intelligence for speculators in the options market. *Journal of International Studies*, 13(3), 231–247. <https://doi.org/10.14254/2071-8330.2020/13-3/15>
- Mazumder, I. (2014). Investing in exchange traded funds. *Applied Finance Letters*, 3(2), 16–23. <https://doi.org/10.24135/afl.v3i2.23>
- Merenda, P. F. (1997). A guide to the proper use of factor analysis in the conduct and reporting of research: Pitfalls to avoid. *Measurement and Evaluation in Counseling and Development*, 30(3), 156–164. <https://doi.org/10.1080/07481756.1997.12068936>
- Mnih, V., Badia, A. P., Mirza, M., Graves, A., Lillicrap, T., Harley, T., Silver, D., & Kavukcuoglu, K. (2016, June). Asynchronous methods for deep reinforcement learning. In *International Conference on Machine Learning* (pp. 1928–1937). PMLR.
- Muhtadin, F. (2015). *Decision support system for stock trading using fuzzy logic and genetic algorithm*. https://informatika.stei.itb.ac.id/~rinaldi.munir/TA/Makalah_TA_Fadhil_Muhtadin.pdf
- Naučius, M. (2018). Should fully autonomous artificial intelligence systems be granted legal capacity? *Law Review*, 17(1), 113–132. <https://doi.org/10.7220/2029-4239.17.6>
- Nilsson, N. J. (2011). *The quest for artificial intelligence: A history of ideas and achievements*. Cambridge University Press.
- Peachavanish, R. (2016, March 16–18). Stock selection and trading based on cluster analysis of trend and momentum indicators. In *Proceedings of the International MultiConference of Engineers and Computer Scientists* (pp. 1–5), Hong Kong.
- Pinto, M. A. F. (2014). *Design and implementation of an algorithmic trading system for the Sifox application*. <https://core.ac.uk/download/pdf/302971773.pdf>
- Puelz, D., Carvalho, C. M., & Hahn, P. R. (2015). Optimal ETF selection for passive investing. *arXiv:1510.03385*.
- Rashidi, M., Ghodrati, M., Samali, B., & Mohammadi, M. (2018). Decision support systems. In *Management of information systems*. IntechOpen. <https://doi.org/10.5772/intechopen.79390>

- Russell, S. J., & Norvig, P. (2002). *Artificial intelligence: A modern approach* (2nd ed.). Prentice Hall.
- Soleymani, F., & Paquet, E. (2021). Deep graph convolutional reinforcement learning for financial portfolio management - DeepPocket. *arXiv:2105.08664*.
<https://doi.org/10.1016/j.eswa.2021.115127>
- Stasytytė, V. (2011). *Investicijų portfelio sprendimų paramos sistema* [Daktaro disertacija, Vilniaus Gedimino technikos universitetas]. Technika.
- Stone, P., Brooks, R., Brynjolfsson, E., Calo, R., Etzioni, O., Hager, G., Hirschberg, J., Kalyanakrishnan, S., Kamar, E., Kraus, S., Leyton-Brown, K., Parkes, D., Press, W., Saxe-nian, A. L., Shah, J., Tambe, M., & Teller, A. (2016). *Artificial intelligence and life in 2030: The one hundred year study on artificial intelligence* (Report of the 2015-2016 Study Panel). Stanford University.
- Vallat, R. (2018). Pingouin: Statistics in Python. *Journal of Open Source Software*, 3(31), 1026.
<https://doi.org/10.21105/joss.01026>
- Zeebaree, M., & Aqel, M. (2019). A comparison study between intelligent decision support systems and decision support systems. *The ISC International Journal of Information Security*, 11(3), 187–194.

SUPPORT SYSTEM FOR SPECULATION BY EXCHANGE TRADES FUNDS

G. Tumaševičius, N. Maknickienė

Abstract

The paper examines the possibilities of speculating in exchange-traded funds by using artificial intelligence. The main goal of the research is to create a support system for speculative decision-making for investors operating in exchange-traded funds market. The research will be based on the theoretical aspects of artificial intelligence and speculation of exchange-traded funds. The support system is developed on the basis of reinforcement learning, the methods of synthesis, concretization and generalization were used to create and detail the system, as well as the methods of mathematical-statistical analysis were used to process them. Successful application of the chosen methodology in the design of the support system has resulted in positive trade results. Successful research broadens the boundaries for usage of deep reinforcement learning, and provides a basis for further development of the support system for exchange-traded funds. The support system put in place will shorten the time between the occurrence of a trading signal and the decision of the investor, which will help to reduce the loss of potential profits.

Keywords: support system, exchange traded funds, speculation, artificial intelligence, financial market, reinforcement learning, machine learning.