



INVESTAVIMO AKCIJŲ RINKOJE NAUDOJANT GILIOJO MOKYMOŠI MODELIOUS TYRIMAS

Nijolė MAKNIČKIENĖ, Amanda URBONAVIČIŪTĖ*

*Vilniaus Gedimino technikos universitetas, Verslo vadybos fakultetas,
Finansų inžinerijos katedra, Saulėtekio al. 11, LT-10223, Vilnius, Lietuva*

**El. paštas amanda.urbonaviciute@stud.vgtu.lt*

Santrauka. Kiekvienas investuotojas ieško geriausio sprendimo, taktikos ir metodo, kuris padėtų pelningai nustatyti akcijų kainų judėjimo kryptis. Tačiau investuotojai susiduria su sunkumais nuspėjant akcijų kitimo kryptis. Dažnai pasirinktas ir naudojamas metodas nėra tikslus prognozavimo įrankis, todėl investuotojų dėmesys krypta į giliojo mokymosi metodus, kurie tampa paramos sistema investuotojui. Straipsnio tikslas yra palyginti giliojo mokymosi ir techninės analizės metodo prognozes bei akcijų kainų krypties nuspėjamumo paklaidas. Ištyrus penkių pasirinktų akcijų kainų prognozes gautas giliojo mokymosi metodo prognozavimo pranašumas lyginant su slankiojo vidurkio metodu. Šio darbo rezultatai išlieka svarbūs ir aktualūs, nes tyrimai susiję su giliojo mokymosi metodo panaudojimu investavime atskleidžia galimybes investuotojui ar spekuliantui.

Reikšminiai žodžiai: akcijų rinka, prognozavimas, investavimas, gilusis mokymasis, techninė analizė, akcijų kaina, paramos sistema.

Įvadas

Finansų rinkose įvyko daug svarbių pokyčių, kurie pakeitė investuotojų elgesį, rinkas bei jų prognozavimo modelius, kaip finansinės krizės, ekonominiai ir politiniai pokyčiai, globalizacija bei vis besikeičiančių finansinių technologijų spartumas. Todėl finansų rinkoje vykstantys procesai tampa labai aktualūs finansų pasaulyje besisukantiems investuotojams, ekonomistams ir netgi mokslininkams. Finansų rinkose siekiama surasti ir pritaikyti tokį metodą, kuris padėtų nustatyti tikslesnes investavimo prognozes bei akcijų kainas.

Esami prognozavimo metodai nėra pakankamai tikslūs, sunku nuspėti akcijų rinkos kainas ir jų kitimo kryptį. Todėl kyla problema, kaip surasti ir pritaikyti metodą, kuris rodytų tiksliausių kainų kitimo kryptį bei prognozes. Šiuo metu investavime yra plačiai taikomi techninės analizės metodai. Techninėje analizėje yra nagrinėjami istoriniai akcijų kainų duomenys, pagal kuriuos spėjama ateities akcijų kaina. Procesą palengvina naudojami prognozavimo indikatoriniai, kaip: slankiojo vidurkio indikatorius ir jo atmainos. Besikeičiančiame finansų pasaulyje vis ieškoma naujų būdų bei inovatyvių technologijų, kurias būtų galima pritaikyti tokioje srityje, kaip – investavimas. Didelio susidomėjimo sulaukia dirbtinio intelekto, giliojo mokymosi (angl. *deep learning*) metodų pritaikymas ir investavime. Investavimo srityje dirbtinio intelekto tyrimai tampa labai perspektyvūs.

Tyrimo objektas – akcijų rinka.

Tyrimo tikslas – palyginti giliojo mokymosi algoritmo akcijų kainų prognozes su techninės analizės indikatoriaus prognozėmis.

Uždaviniai tikslui pasiekti:

1. Išnagrinėti mokslinę literatūrą apie akcijų rinkos prognozavimo metodus;
2. Prognozuoti pasirinktų įmonių akcijų kainas naudojant techninės analizės metodą remiantis pasirinktais indikatoriais;
3. Nustatyti pasirinktų įmonių akcijų kainų kitimą pritaikant giliojo mokymosi metodą;
4. Išnagrinėjus techninės analizės metodus, nustatyti, kuris metodas parodė tiksliausių akcijos kainą pasirinktose įmonėse bei palyginti techninės analizės ir giliojo mokymosi metodų akcijų kitimo kryptis.

Tyrimo metodai. Išsikeltam tikslui pasiekti ir uždaviniams įvykdyti taikomi atliktos analizės interpretavimo vertinimas, t. y. surinktos informacijos palyginimas, susisteminimas, interpretavimas. Akcijų kainų prognozavimui techninės analizės būdu bei giliojo mokymosi metodu naudojami Yahoo Finance (2019) internetinio tinklapio duomenys. Nustatant tiksliausių akcijų kainų prognozavimo metodą naudojama statistinė bei grafinė gautų duomenų lyginamoji analizė.

1. Investavimo akcijų rinkose metodų naudojimas: mokslinės literatūros analizė

Sparčiai besikeičiantys finansiniai procesai skatina ieškoti naujų būdų kaip padidinti turimas pajamas. Didelio susidomėjimo sulaukia finansų rinkų aktyvumas bei jų likvidumas. Finansų rinka suprantama kaip lėšų ar finansinių priemonių judėjimas ten, kur būtų galimas efektyvesnis jų panaudojimas tolimesniems finansiniams veiksams, kaip kapitalo didinimui ar investavimui (Pekarskienė ir Pridotkienė, 2010). Finansiniai procesai susiję su rizikomis, kurių dažniausiai suvaldyti neįmanoma, nes rizika priklauso nuo aplinkos pasikeitimų, kurie vyksta itin sparčiai. Finansų rinką įtakoja tokie pokyčiai kaip: ekonominiai ir politiniai veiksniai, kurie gali apsukti rinkas kita kryptimi (Bikas ir Kavaliauskas, 2010), todėl yra labai naudinga turėti savą supratimą, kad būtų galima pasirinkti atitinkamą sprendimą, net ir asmeniškai.

Akcijų rinka yra viena iš svarbiausių finansų rinkų, pagal kurią galima matyti esamą ir net nuspėti būsimą ekonominę situaciją. Pavyzdžiui, jei ekonomika auga, tai ir akcijų rodikliai palankūs, jei akcijos krenta, tai reiškia, kad ekonomika ims lėtėti (Cibulskienė ir Marcišauskienė, 2013). Glaudus akcijų ir ekonomikos pasikeitimų ryšys matomas vykstant didžiausioms finansų krizėms, kaip *Pirmoji pasaulio krizė*, *Pasaulio krizė*, *Tarpautinė finansų krizė*, *Didžioji depresija*, *2008 metų globali krizė kt.* Finansų krizės labai paliečia ir finansų rinkas, kadangi prekiaujama vertybiniais popieriais (akcijomis), kuriuose slypi dideli kiekiai pinigų (Mockaitienė ir Žmiejauskaitė, 2009). Akcijų rinka laikoma viena iš rizikingiausių, bet tuo pačiu galinčių atnešti didelę investicinę grąžą. Dėl to įmonės, norėdamos pritraukti reikalingą kapitalą iš potencialių investuotojų renkasi akcijų rinką. Akcijos suteikia galimybę paskirstyti lėšas tarp skirtingų subjektų, tokiu būdu valstybės ar įmonės gali papildyti savo biudžetą lėšomis, taip pat investuotojai gali investuoti į laisvas lėšas tikėdamiesi pelno ateityje (Cibulskienė ir Marcišauskienė, 2013). Kiekvienas dalyvis į rinką ateina su nustatyta, pradine akcijos kaina. Akcijų kaina yra nuolatos kintanti, kadangi akcijų rinka yra labai aktyvi ir veikianti visą laiką, dėl to per trumpą laiką kaina gali labai greitai išaugti nuo neigiamos iki aukštos. Gera ekonominė situacija, augančios bendrovės, geri finansiniai rodikliai skatina rinkos dalyvius investuoti į akcijas (Boreika ir Pilinkus, 2009). Tikroji akcijų vertė turėtų atspindėti visą informaciją, kuri yra svarbi tos akcijos veikimui ir dėl tos priežasties turėtų būti mažai įtakojama kitų sprendimų. Tai skatina kurti naujas, individualias schemas suprantant investavimo techniką bei taikyti individualius veiksmus asmeniškai, taip akcijų rinkose išlaikant balansą. Mokslininkų teigimu, tai priklauso nuo esamos pasiūlos ir paklausos, ekonominių, politinių pasikeitimų, bet kartais sunku nuspėti ateitį pažiūrėjus į dabarties akcijos kainas, todėl didelis investuotojų dėmesys krypsta į akcijų indeksus, kadangi akcijų indeksai parodo akcijų rinkos situaciją ir vystymąsi bei kitimo tendencijas (Cibulskienė ir Marcišauskienė, 2013). Autoriaus teigimu, remiantis efektyvios rinkos hipoteze, buvusios akcijų kainų grąžos neturėtų daryti jokios įtakos esamoms ir būsimoms akcijų kainų grąžoms, nors ir mokslinėje literatūroje gausu sėkmingų investavimų istorijų, kurie remėsi akcijų praeities duomenimis (Gang et al., 2019). Vis dėlto akcijų indeksai yra skirti kiekybiniais būdais įvertinti akcijų rinkų pokyčius. Remiantis akcijų indeksu pokyčiais, analizuojant akcijų indeksų istoriją, galima palyginti ir apskaičiuoti kitimo priežastis, tendencijas. Tiriant praeities ir dabarties akcijų kainų kitimus galima nuspėti ateities premialiaris vertybinių popierių kainas, jų kilimo galimybes bei akcijos pirkimo ar pardavimo laikotarpį, kuris atneštų didžiausią investicinę grąžą (Lileikienė ir Dervinienė, 2010). Investuojant į akcijas, nei vienas investuotojas nėra apsaugotas nuo gresiančios rizikos neuždirbti pelno arba prarasti visą kapitalą, kadangi didelę grąžą visada lydi didelė rizika.

Investavimas akcijų rinkose pritraukia vis daugiau naujų finansų rinkų žaidėjų. Svarbiausiu klausimu ir iššūkiu išlieka, kaip nustatyti akcijų rinkų kainų prognozes, kadangi akcijų kainų pokyčiai vis dar laikomi sunkiai apibrėžiami ir nepastovūs. Pagrindinės ir tradicinės akcijų kainų analizės metodu laikoma techninė analizė (angl. *technical analysis*). Dažnai investuotojai pasirenka šį būdą akcijų kainoms analizuoti. Svarbia užduotimi ir tikslu tampa išsiaiškinti, kokia gali būti galutinė investavimo grąža (Kekytė ir Stasytė, 2017). Techninės analizės analitikai tiki, kad dėl akcijos kainų chronologiško judėjimo judės panašia tendencija. Dėl to, analitikas norėdamas prognozuoti akcijų kainų pokyčius, tiria tik istorinius kainų pokyčius nagrinėdamas diagramas, modelius ir daugybę rodiklių gautų iš atvirų, aukštų, žemų uždarymo kainų bei jų apimčių (Metghalchi et al., 2011). Taigi, techninės analizės metodu siekiama nustatyti akcijų kainų judėjimo tendencijas, jos pasikeitimo priežastis palyginant su ankstesniais etapais ir judėti tos linkmės pusėn. Techninės analizės pagrindinis tikslas yra ieškoti aukščiausių bei žemiausių akcijos kainų taškų, kurie padėtų tolimesnei analizei tarp akcijų kainų istorinių duomenų. Akcijų kainų svyravimai yra pasikartojantys, todėl techninės analizės grafikų naudojimas padeda investuotojui nuspręsti, kada laikas pirkti, o kada reikia parduoti nenukenčiant finansškai (Kekytė ir Stasytė, 2017). Taip pat laikui bėgant buvo pastebėta techninės analizės modelio tobulėjimas. Kaip jau minėta anksčiau, šis metodas naudojamas akcijų istorinės raidos analizei. Šiandien, pastarųjų metų technologija leidžia naudoti realaus laiko duomenis nuspėjant akcijų kainas. Investuotojai, vadovaujantis akcijų prekybos taisyklėmis, kuri paremta technine analize, naudojami informacija pagrįsta indikatoriais, diagramų modeliais, kurie apima ekonometrinius, statistinius ir netgi dirbtinio intelekto modelius. Visa tai leidžia įveikti akcijų rinką, kuri prieštarauja esamos rinkos hipotezei (Cervelló-Royo et al., 2015). Taip pat techninės analizės tyrėjai mano, kad šiuo būdu galima išsamiai paaiškinti rinkos pokyčius, kurių pagrįsta strategija yra pagrįsta akcijų kaina ir joje apskaičiuotais matematiniais rodikliais, kaip – slenkantis vidurkis – tendencijų nuspėjamumo matas, kuris parodo akcijų kainų laiko eilučių atliktą analizę (Picasso et al., 2019). Slenkančio vidurkio indikatorius tikslas yra nustatyti kainų pokyčių tendencijas. Šis indikatorius parodo

pirkimo ir pirkimo signalus, remiantis dviem slenkančiais akcijų kainų vidurkiais. Pavyzdžiui, akcijų kainų pirkimo signalas pasirodo tada, kai esama akcijų kaina yra aukščiau negu slenkančio vidurkio indikatorius, o pardavimo – atvirkščiai, kai antrasis rodiklis pakyla aukščiau nei pirmasis (Sobreiro et al., 2016). O akcijų kainų vidurkį remiantis slenkančio vidurkio indikatoriumi apskaičiuojama pagal formulę:

$$MA(q)_t = \frac{1}{q} \times \sum_{i=t-q+1}^t p_i, \quad (1)$$

čia: P – kaina laiko momentu i , o $MA(q)$ – slenkančio vidurkio vertė momentu t , apskaičiuota per paskutinius q periodus.

Kiekvienos kainos svoris lygus $\frac{1}{q}$ (paprastai apibrėžiamas vidurkiu). Visa slenkančiojo vidurkio indikatorius esmė yra vadovautis pagrindine taisykle „pirkti, kai kaina kerta slenkančio vidurkio rodiklį iš apačios, o parduoti – kai kaina kerta slenkančio vidurkio indikatorius rodiklį iš viršaus“ (Kresta ir Franek, 2015). Tačiau techninės analizės naudojime pastebima ir trūkumų. Duomenų analize pagrįstos prognozės labai priklauso nuo subjektyvaus veiksnio. Tai reiškia, kad gauta informacija analizės metu, gali būti interpretuojama skirtingai. Techninės analizės naudojimas tampa vis mažiau populiarus, kadangi juo naudojantis labai didelei daliai aktyvių investuotojų ir didėjant procesų apimčiai, vien tik techninės analizės naudojimas nėra pats tiksliausias akcijų kainų nustatymo įrankis dėl visuotinio populiarumo, metodų neapibrėžtumo (Nedzveckas ir Dapkus, 2013). Norint sumažinti riziką investavime, būtina pasinaudoti visais metodais, kurie padėtų ją eliminuoti. Tačiau nėra paprasta tikslingai pritaikyti vieną iš metodų konkrečiai akcijų kainos analizei.

Pasauliui keičiantis ir tobulėjant, naujų technologijų atsiradimas ir jų naudingas pritaikymas įvairioms sritims sparčiai skatina domėtis tokiais technologijomis, kaip dirbtinis intelektas (angl. *artificial intelligence*). Kadangi, ši technologija, daugeliui asocijuojasi su tam tikrų procesų palengvinimu, pritaikomumu kasdieniniams ir rutininiais darbams, ši sritis laikoma labai perspektyvia. Dirbtinis intelektas jau stipriai pakeitė pramonės ir finansų pasaulį. Šiandieną visuomenė dirbtinį intelektą laiko ne vien tik technologija, kuri galbūt iš dalies galėtų pagerinti procesų vykdymą, dirbtinis intelektas tampa būtinybe, be kurios neįsivaizduojamas našesnis ir produktyvesnis darbas, verslų kūrimas, tobulėjimas (Amilevičius, 2017). Dirbtinis intelektas apibrėžiamas, kaip sistema, kuri gali pati apsimokyti, savarankiškai prisitaikyti prie naujų pokyčių ar mokymosi. Todėl didelis dėmesys skiriamas giliajam mokymuisi, kadangi teigiama, kad:

- Intelektuali sistema turėtų sugebėti spręsti problemas ir situacijas, kurios skiriasi nuo numatytų jos kūrėjų;
- Intelektinė sistema turėtų gebėti apibendrinti ir įsisavinti įgytas žinias, kad jas galėtų taikyti ir kitokioms problemoms negu buvo apmokyta pirmiausiai.

Akivaizdu, kad bet kuri dirbtinio intelekto programinės įrangos sistema dėl išvardintų savybių yra laikoma stipria pretendente turėti bendrą žmogaus intelektą (Goertzel, 2014). Gilusis mokymasis suprantamas, kaip tam tikros sistemos savarankiškas gebėjimas pagal turimą, įdiegtą informaciją, taikyti naujus metodus modeliui treniruoti ir tada naudojant apmokytą modelį prognozėms sudaryti iš naujų duomenų (Heaton et al., 2016). Giluminio mokymosi sistemos gali būti lengvai pritaikomos prie daugelio problemų, tiek teorinių ir praktinių, kaip: programų patobulinimas, našumo optimizavimas, didelių duomenų apdorojimas, čia dirbtinis intelektas tampa plačiai naudojamas ir finansų srityje. Pavyzdžiui, investavimo srityje dirbtinį intelektą taiko nustatant sukčiavimo atvejus bei analizuojant finansų rinkų pokyčius bei tendencijas (Amilevičius, 2017). Tačiau pastebima, kad dirbtinio intelekto mokymosi programų taikymas investavime nėra pakankamai ištyrinėta sritis, kuri būtų taikoma investavime, todėl tai apsunkina investuotojams kainų rinkų nuspėjamumą, akcijų kilimo bei kritimo prognozes bei galimybę prekiaujant akcijomis užsidirbti. O vis didėjant akcijų kainų nustatymo sudėtingumui ir tikslumui, investuotojai ieško būdų, kaip pereiti nuo įprastų jau naudojamų akcijų kainų nustatymo metodų prie patobulintų strategijų, kurios padidintų investavimo pelną bei pačios rinkos prognozavimą (Naranjo ir Santos, 2019). Kadangi, investavimas finansų rinkose yra labai rizikinga sritis, kurią veikia daugelis ekonominių, politinių ar psichologinių veiksnių, mokslininkai ieško būdų, kaip palengvinti prekybą atliekant tyrimus bei kuriant investavimo modelius (Kekytė ir Stasytė, 2017). Nauji modeliai ir dirbtinio intelekto taikymas finansų rinkose padėtų ją su efektyvinti, sumažinant klaidų skaičių investuojant, įvertinti akcijų kainos pokyčių tendencijas, tačiau vis dar neaišku, kokią tikrąją vertę ekonomikai galėtų duoti dirbtinio intelekto naudojimas investavime. Jei sukurtos intelektualios sistemos veiktų tik investuotojo akcijų kainų prognozavimo naudai be rizikos, tai sukeltų neefektyvių lėšų pasiskirstymą tarp investuotojų bei akcijų prekiautojų. Prognozuojant akcijų kainas ar pačias finansų rinkas tai tampa didžiausiu iššūkiu dirbtinio intelekto kūrėjams ir visai mokslininkų bendruomenei dėl dirbtinio intelekto galimybių pritaikymu investuojant. Taigi, apžvelgus naujausią literatūrą ir dirbtinio intelekto mokymosi metodus, nustatyta, kad neuroniniai tinklai yra viena iš dominuojančių metodų akcijų rinkos kainų prognozavime (Al-Radaideh et al., 2013).

Vienas iš dirbtinio intelekto modelių, kuris gali būti taikomas investavime vadinamas – neuroniniai tinklai (angl. *neural networks*). Tai tinklai, kurie geba apdoroti duomenis naudojantis dirbtiniu intelektu, kuris sukurtas

remiantis žmogaus neuroninių tinklų struktūra ir pagal nervų sistemos veikimo principą. Neuroninių tinklų veikimas pagrįstas neuronais, kurie apdoroja gautą informaciją. Signalai yra perduodami ryšių jungtimis. Jungtys turi atitinkamą svorį, kuris keliaujant signalais, priklausomai nuo informacijos gali padvigubėti, kitaip sakant, apsimokyti ir pritaikyti tam tikram sprendimui naują informaciją. Išvestinis signalas gaunamas naudojant jutimo vienetus, kurie sudaro įvesties sluoksnį, o įvesties signalas aktyvinamas į pagrindinį neuronų tinklą (Sureshkumar ir Elango, 2012). Taigi, tokiu būdu vyksta giluminis mokymasis, todėl neuroninių tinklų pritaikomumas labai platus. Ankstesni tyrimai parodė, kad dirbtiniai neuroniniai tinklai yra tinkami naudoti modelio atpažinimui, duomenų klasifikavimui užduotims ir netiesioginiam, adaptyviam mokymuisi, todėl plačiai taikoma analizuojant įvairius finansų srities duomenis. Dėl šių savybių, neurotinių tinklų metodas laikomas vienu svarbiausių sričių taikant akcijų kainų prognozavimui investavime. Rinkos žaidėjų elgesio modelio nustatymas ir akcijų kainų numatymas yra nauja neuroninių tinklų taikymo sritis. Daugelis kompanijų jau taiko neuroninius tinklus, kurie padėtų pagerinti akcijų kainų prognozavimą analizuojant akcijų rinką (Sureshkumar ir Elango, 2012). Kadangi, neuroniniai tinklai veikia pagal koncepciją „mokykis pagal pavyzdį“. Pavyzdžiui, dabartiniai akcijų kainų nuosmukiai ir pakilimai yra labai susiję su istoriniais praeities įvykiais, kurie įtakoja akcijų kainų pokyčius. Neuroniniai tinklai galėtų modeliuoti tokius laikinus akcijų rinkų pokyčius, sukuriant giliojo mokymosi grįžtamąjį ryšį (Vaisla et al., 2010). Dirbtinio intelekto nauji ar vis dar kuriami modeliai kaip neuroniniai tinklai tampa vis svarbesni finansų rinkose. Dirbtinio intelekto programos galėtų palengvinti tam tikrus procesus, jo pritaikomumu, patobulinti kasdieninius finansinius procesus padėtų lengviau nuspėti bei suprasti akcijų kainų pokyčius, kitimo priežastis bei aplinkybes. Suvaldyti ir suprasti tokį didelį duomenų kiekį, globalų investuotojų srautą tampa vis sunkiau.

2. Akcijų rinkos kainų krypties nustatymas naudojant techninę analizę ir giliojo mokymosi metodus


Šiame darbe pasirinktos penkių įmonių akcijų kainos bus prognozuojamos naudojant paprastąjį slankųjį vidurkį ir giliojo mokymosi Matlab algoritmą laiko eilučių prognozavimui (Matlab algoritmas, 2019). Gautų rezultatų palyginimas ir analizė leis atskleisti galimybes ir rizikas investuotojui.

Norint išanalizuoti tiksliausią akcijų kainų kryptį, daugelis investuotojų taiko techninėje analizėje naudojamus indikatorius, kurie padeda nustatyti tikslesnius nuosmukius, kilimus bei pačią akcijų kainų prognozuojamą kryptį. Remiantis autorių, kaip Angelės Lileikienės, Mindaugo Butko (Lileikienė ir Dervinienė, 2010), (Ginevičius ir Podvezko, 2008) ir kt. nagrinėjama literatūra tyrimui atlikti, pasirenkamas populiarus tarp investuotojų techninės analizės indikatorius, kaip slenkančio vidurkio indikatorius (angl. *moving average*).

Atliekant tyrimą, atsitiktiniu būdu pasirenkamos penkios bendrovės, kurios leidžia akcijas ir yra populiariausių sąraše:


1. APPLE – prekybos simbolis – APPL
2. TESLA – prekybos simbolis – TSLA
3. AMAZON – prekybos simbolis – AMZN
4. GOOGLE – prekybos simbolis – GOOG
5. NEFLIX – prekybos simbolis – NFLX

Tyrimui atlikti, pradiniai duomenys buvo gaunami iš internetinio portalo *YAHOO FINANCE* sudarant ir analizuojant grafikus bei juose pateikiamą informaciją pasinaudojant slenkančio vidurkio indikatoriumi dviejų metų laikotarpyje bei analizuojant trijų dienų akcijų kainų pokyčius, kurio metu buvo gauti tokie grafikai:




1 paveikslas. APPLE bendrovės akcijų kainų kitimas naudojant techninės analizės metodą (šaltinis: sudaryta darbo autorių remiantis www.finance.yahoo.com [2019.10.16] duomenimis)

1 paveiksle naudojant statistinių duomenų analizę grafiškai matoma, kad slenkančio vidurkio linija yra žemiau negu istorinių duomenų susiformavus linija, tai rodo kaina kils, patikrinus kitos dienos pateiktą uždarymo kainą, uždarymo kaina kilo.



2 paveikslas. AMAZON bendrovės akcijų kainų kitimas naudojant techninės analizės metodą (šaltinis: sudaryta darbo autorių remiantis www.finance.yahoo.com [2019.10.16] duomenimis)

2 paveiksle matyti tolygus uždarymo kainos ir slenkančio vidurkio kitimas. Slenkančio vidurkio prognozė linija baigiasi ties uždarymo kainos linijos, t. y. nematomas aiškus kainos kritimas ar kilimas, tačiau stebint pačią prognozuojamą kryptį matomas kritimas. Nustatyta uždarymo kaina taip pat rodo mažėjimą.



3 paveikslas. GOOGLE bendrovės akcijų kainų kitimas naudojant techninės analizės metodą (šaltinis: sudaryta darbo autorių remiantis www.finance.yahoo.com [2019.10.16] duomenimis)

3 paveiksle matoma, kad uždarymo kainos linija ir slenkančio vidurkio linija yra susikirtimo taške. Kadangi slenkančio vidurkio indikatorius rodo kritimo kryptį galima teigti, kad uždarymo kaina kris, tačiau prognozė netiksli, aiškiai neparodo. Kaina gali kristi arba kilti. Remiantis Yahoo finance duomenimis, akcijų kaina krito.

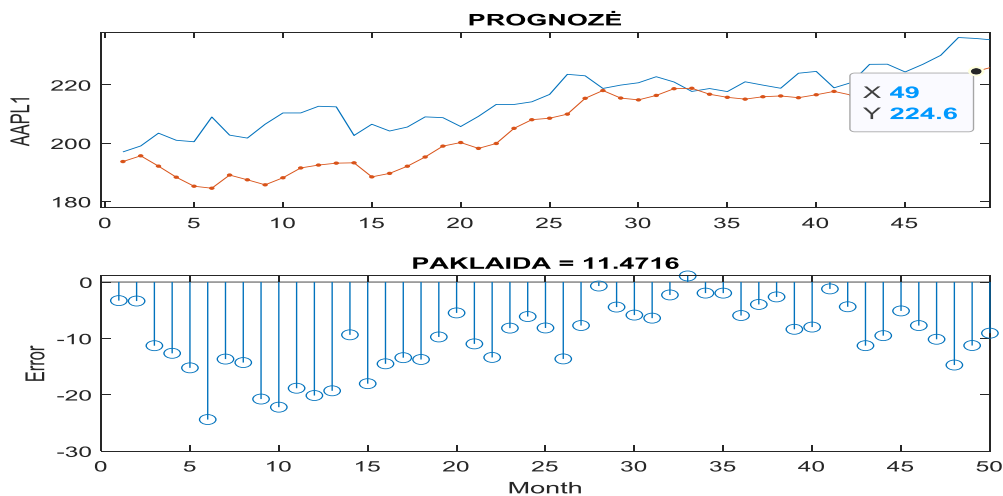
Patikrinus ir kitų likusių bendrovių (NFLX, TSLA) akcijų uždarymo kainų prognozes, slenkančio vidurkio indikatorius prognozės linija buvo taip pat žemiau uždarymo kainos linijos – kainos kilimas. Prognozė buvo teisinga. Taigi techninės analizės slenkančio vidurkio indikatorius visose bendrovėse rodė teisingą kryptį, tačiau kaip teorinėje dalyje pateiktoje taisyklėje, kad jei slenkančio vidurkio linija bus aukščiau – kaina kris, ir atvirkščiai, buvo matomi netikslumai GOOG ir AMZN bendrovėse.

Taip pat prognozuojant akcijų kainų kilimus, nuosmukius, laiką kada geriausia pirkti akcijas, o kada parduoti vis daugiau yra naudojama dirbtinio intelekto atmainomis. Viena iš jų – MATLAB giliojo mokymosi programa, kuri tampa kaip paramos sistema investuotojui. Svarbią reikšmę giliojo mokymosi metodo naudojime daro paklaida (angl. RMSE). Tai vienas iš veiksmingiausių rodiklių, kuris matuoja skirtumus tarp stebimų verčių ir numatytų verčių (Wang et al., 2020), taip pat rodo vidutinį numatomos vertės įvertinimo paklaidos dydį, kuris apskaičiuojamas (Maqsood et al., 2020):

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (prognozė(t) - istoriniai\ duomenys(t))^2}{n}} \quad (2)$$

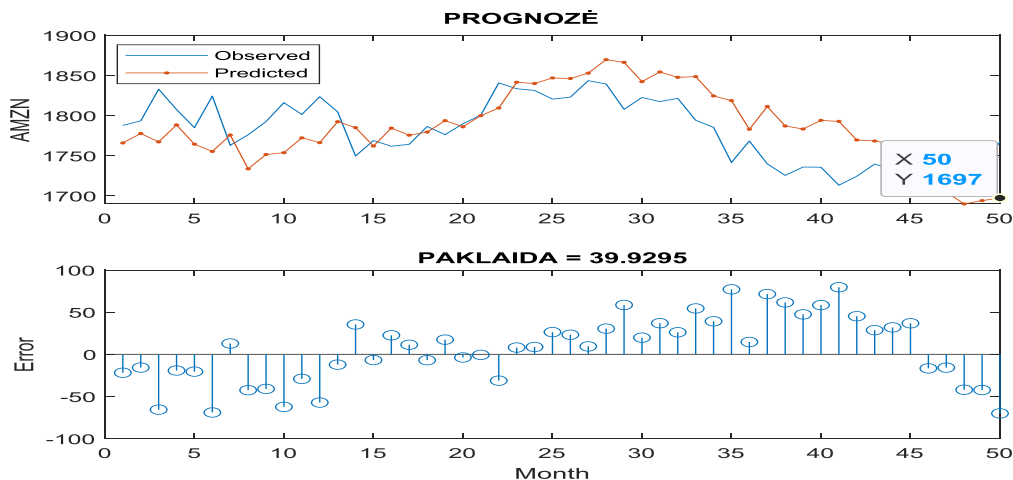
Taigi, paklaida parodo skirtumą tarp nagrinėjamų istorinių akcijų kainų duomenų ir kokia turėjo būti prognozuojama vertė. Todėl galima lengvai patikrinti klydimą. Šio darbo pagrindiniu tikslu lieka išsiaiškinti, ar

giliojo mokymosi programų modeliai gali nuspėti akcijų keitimosi kryptį. Kaip ir techninėje analizėje, nagrinėjant 2 metų periodo, trijų dienų akcijų grafikų kitimą buvo analizuojami grafikai techninėje analizėje naudojamus jau pirmoje dalyje nagrinėtus indikatorius bei pasirinktas bendroves.




4 paveikslas. Apple bendrovės akcijų kitimo prognozė taikant giliojo mokymosi metodą (šaltinis: sudaryta darbo autorių remiantis www.finance.yahoo.com [2019.10.16] duomenimis)

4 paveiksle matoma AAPL giliojo mokymosi suformuotą grafiką. Grafiko pabaigoje prognozuojama akcijų kaina laikosi arčiau istorinių duomenų. Todėl paklaida mažėja. Paskutiniame grafiko taške, prognozės linija matoma žemiau negu suformuota pagal istorinius akcijų kainų duomenis. Tai rodo, kad akcijų kaina kils. Pačios prognozės kryptis taip pat kyla ir paklaida matoma ganėtinai žema, paklaida (angl. RMSE) – 11,47.



5 paveikslas. Amazon bendrovės akcijų kitimo prognozė taikant giliojo mokymosi metodą (šaltinis: sudaryta darbo autorių remiantis www.finance.yahoo.com [2019.10.16] duomenimis)

5 paveiksle matoma giliojo mokymosi būdu sudaryta AMAZON akcijų kainų kitimo prognozė. Pagal dviejų metų laikotarpį surinktus AMAZON akcijų kitimo duomenis, giliojo mokymosi programa, remiantis tik pateiktais duomenimis be apsimokymo, būtų nuspėjusi AMAZON akcijų kainų augimą, tačiau įvykus giliajam mokymuisi šiame atvejyje prognozavimo linija yra stipriai žemiau negu tyrinėjami akcijų duomenis. Taip aiškiai matoma, kad akcijų kaina tikrai turėtų kristi.



6 paveikslas. Google bendrovės akcijų kitimo prognozė taikant giliojo mokymosi metodą (šaltinis: sudaryta darbo autorių remiantis www.finance.yahoo.com [2019.10.16] duomenimis)

6 paveiksle matoma GOOG akcijų kainų krypties prognozė. Matomas netolygus akcijų kainų judėjimas. Iš paveikslo matyti trys staigūs pasikartojantys kritimai. Galutiniame taške pastebimas susikirtimo taškas, kryptis išlieka neutrali, nei leidžiasi nei kyla. Paklaida – 33,99.

3. Investavimo akcijų rinkose modelių pritaikomumo ir tikslumo vertinimas

Antrajame skyriuje buvo analizuoti akcijų kainų judėjimo kryptys naudojant tradicinius metodus, kaip: techninės analizės metodas ir patobulintus, kaip giliojo mokymosi metodas. Atliktas praktinis tyrimas akcijų kainų prognozės nuspėjamumui, kurio metu buvo siekiama išsiaiškinti tinkamiausio metodo panaudojimą investuojant. Todėl trečiajame skyriuje, pasirinkus penkias skirtingas bendroves (Apple, Amazon, Google, Netflix ir Tesla) buvo analizuoti antroje dalyje gautų akcijų kainų grafikai ir jų kitimas.

1 lentelė. Suminė nagrinėjamų metodų lentelė (šaltinis: sudaryta darbo autorių remiantis antroje dalyje nagrinėtais grafikai)

Bendrovės	MATLAB	MA
APPL	+	+
AMZN	+/-	+/-
GOOG	+/-	+/-
NFLX	+	-
TSLA	+	+

Nagrinėjant penkių pasirinktų bendrovių akcijų kitimo grafikus bei jų kryptį, pagal sudarytą 1 lentelę matoma, kad giliojo mokymosi metodas akcijų kitimo kryptį suprognozavo geriau, nors ir nežymiai. Giliojo mokymosi metodu ir techninės analizės sudarytuose grafikuose akcijų judėjimo išdėstymas matomas labai panašiai. Pagal grafiką tiksliai nurodė Apple, Netflix ir Tesla įmou akcijų judėjimo kryptį. Tuo tarpu naudojantis techninės analizės metodo slenkančio vidurkio indikatoriumi tiksliai pavyko nustatyti tik Tesla ir Apple akcijų kitimą.

2 lentelė. Giliojo mokymosi ir techninės analizės apskaičiuotos paklaidos (šaltinis: sudaryta darbo autorių remiantis antroje dalyje nagrinėtais grafikai)

	MATLAB	MA
APPL	11.47 (RMSE)	16.55 (RMSE)
AMZN	39.9 (RMSE)	60.41 (RMSE)
GOOG	33.9 (RMSE)	32.13 (RMSE)
NFLX	6.41 (RMSE)	16.55 (RMSE)
TSLA	9.43 (RMSE)	17.79 (RMSE)

Pagal pateiktą 2 lentelę matoma, kad naudojantis giliojo mokymosi metodo programa Matlab akcijų prognozavimo paklaida buvo visur mažesnė negu prognozuojant technine analize, išskyrus tik Google bendrovę, kur paklaida mažesnė naudojant slenkančio vidurkio indikatorių.

Išvados

Investuotojui stebinčiam akcijų kainų kitimą svarbiausia yra kryptis, kadangi, jei labiausiai naudojami techninės analizės indikatoriai parodys apytiksliai akcijų kainas, kurios viena nuo kitos skirsis nežymiai, tai investuojant didelės reikšmės neturės. Todėl investuotojai didžiausią dėmesį skiria prognozavimo metodų tobulinimui. Analizuojant akcijų kainų prognozes grafiškai, matoma, kad prognozė naudojant gilųjį mokymąsi buvo tikslesnė už prognozę naudojantis slankiojo vidurkio metodu apie 20 procentų. Todėl giliojo mokymosi metodas gali tapti puikia paramos sistema investuotojui, kuri patikslina ir nukreipia tinkama linkme tradiciniu būdu gautas akcijų kainų prognozes. Naudojant techninės analizės indikatorių ir giliojo mokymosi programas kartu, gali būti pasiekiamas tikslesnis prognozavimas, kadangi išsiskyrus kryptį ar nesutapus prognozuojamoms akcijų kainoms galima atlikti dar gilesnę analizę, analizuojant skirtingus rodokus duomenis. Tyrimas atliktas labai trumpą laiką ir apsiribojo vienu techninės analizės indikatoriumi. Investavimo strategijos naudojant gilųjį mokymąsi sukūrimas, testavimas ir tyrimas gali būti tolesnė mokslinė kryptis.

Literatūra

- Al-Radaideh, Q., Assaf, A., & Alnagi, E. (2013). Predicting stock prices using data mining techniques. In *The International Arab Conference on Information Technology*, 1–8. <http://www.acit2k.org/ACIT/2013Proceedings/163.pdf>
- Amilevičius, D. (2017). Dirbtinis intelektas ir besiformuojančių technologijų etika. *Naujas židinys-Aidai*, (4), 19–24. <https://hdl.handle.net/20.500.12259/35657>
- Bikas, E., & Kavaliauskas, A. (2010). Lithuanian investors' behaviour during financial crisis. *Business: Theory and Practice*, 11(4), 370–380. <https://doi.org/10.3846/btp.2010.40>
- Boreika, P. ir Pilinkus, D. (2009). Makroekonominė rodiklių ir akcijų kainų tarpusavio ryšys Baltijos šalyse [Relations between macroeconomic indices and stock prices in the Baltic countries]. *Ekonomika ir vadyba*, 14, 692–699. <http://search.ebscohost.com/login.aspx?direct=true&db=bth&AN=41976539&site=ehost-live&scope=site>
- 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. <https://doi.org/10.1016/j.eswa.2015.03.017>
- Cibulskienė, D. ir Marčišauskienė, J. (2013). Baltijos šalių makroekonominė rodiklių ir akcijų rinkos kainų tarpusavio ryšio vertinimas. *Ekonomika ir vadyba: aktualijos ir perspektyvos*, 1(29), 51–61.
- Gang, J., Qian, Z., & Xu, T. (2019, August). Investment horizons, cash flow news, and the profitability of momentum and reversal strategies in the Chinese stock market. *Economic Modelling*, 83, 364–371. <https://doi.org/10.1016/j.econmod.2019.08.021>
- Ginevičius, R. ir Podvezko, V. (2008). Daugiakriterinio vertinimo būdų suderinamumas. *Verslas: teorija ir praktika*, 9(1), 73–80. <https://doi.org/10.3846/1648-0627.2008.9.73-80>
- Goertzel, B. (2014). Artificial general intelligence: Concept, state of the art, and future prospects. *Journal of Artificial General Intelligence*, 5(1), 1–48. <https://doi.org/10.2478/jagi-2014-0001>
- Heaton, J. B., Polson, N. G., & Witte, J. H. (2016). *Deep learning in finance*. <http://arxiv.org/abs/1602.06561>
- Yahoo Finance. (2019). <https://finance.yahoo.com/>
- Kekytė, I. ir Stasytytė, V. (2017). Investavimo sprendimų priėmimo modelių lyginamoji analizė. *Mokslas – Lietuvos Ateitis*, 9(2), 197–208. <https://doi.org/10.3846/mla.2017.1023>
- Kresta, A., & Franek, J. (2015). Analysis of moving average rules applicability in Czech stock market. *Procedia Economics and Finance*, 30(1965), 364–371. [https://doi.org/10.1016/S2212-5671\(15\)01303-9](https://doi.org/10.1016/S2212-5671(15)01303-9)
- Lileikienė, A. ir Dervinienė, A. (2010). Akcijų portfelio formavimas ir valdymas fundamentalios ir techninės analizės pagrindu. *Vadyba*, 1(17), 15–24.
- Maqsood, H., Mehmood, I., Maqsood, M., Yasir, M., Afzal, S., Aakil, F., Selim, M. M., & Muhammad, K. (2020). A local and global event sentiment based efficient stock exchange forecasting using deep learning. *International Journal of Information Management*, 50, 432–451. <https://doi.org/10.1016/j.ijinfomgt.2019.07.011>
- Matlab algoritmas. (2019). <https://ch.mathworks.com/help/deeplearning/examples/time-series-forecasting-using-deep-learning.html>
- Metghalchi, M., Chang, Y.-H., & Garza-Gomez, X. (2011). Technical analysis of the taiwanese stock market. *International Journal of Economics and Finance*, 4(1), 90–102. <https://doi.org/10.5539/ijef.v4n1p90>
- Mockaitienė, S. ir Žmiejauskaitė, K. (2009). Finansų rinkų krizės priežastys ir pasekmės Pabaltijo šalių akcijų rinkai. *Ekonomikos ir vadybos aktualijos*, 178–188.
- Naranjo, R., & Santos, M. (2019). A fuzzy decision system for money investment in stock markets based on fuzzy candlesticks pattern recognition. *Expert Systems with Applications*, 133, 34–48. <https://doi.org/10.1016/j.eswa.2019.05.012>

- Nedzveckas, J. ir Dapkus, R. (2013). Valiutų kursų analizei ir prognozavimui naudojamų metodų testavimas. *Vadyba*, 22(1), 121–126.
- Pekarskienė, I. ir Pridotkienė, J. (2010). Vertybinių popierių rinkos vaidmuo ekonomikoje [Significance of stock market to an economy]. *Ekonomika ir vadyba*, 177–184.
<http://search.ebscohost.com/login.aspx?direct=true&db=bth&AN=53172863&site=ehost-live&scope=site>
- Picasso, A., Merello, S., Ma, Y., Oneto, L., & Cambria, E. (2019). Technical analysis and sentiment embeddings for market trend prediction. *Expert Systems with Applications*, 135, 60–70. <https://doi.org/10.1016/j.eswa.2019.06.014>
- Sobreiro, V. A., Cruz Cacique da Costa, T. R., Farias Nazário, R. T., Lima e Silva, J., Moreira, E. A., Lima Filho, M. C., Kimura, H., & Arismendi Zambrano, J. C. (2016). The profitability of moving average trading rules in BRICS and emerging stock markets. *North American Journal of Economics and Finance*, 38, 86–101.
<https://doi.org/10.1016/j.najef.2016.08.003>
- Sureshkumar, K. K., & Elango, N. M. (2012). Performance analysis of stock price prediction using artificial neural networks. *Global Journal of Computer Science and Technology*, 12(1).
- Vaisla, K., Bhatt, K. A., & Kumar, S. (2010). Stock market forecasting using artificial neural network and statistical technique: A comparison report. *International Journal of Computer and Network Security*, 2(8), 50–55.
- Wang, W., Li, W., Zhang, N., & Liu, K. (2020). Portfolio formation with preselection using deep learning from long-term financial data. *Expert Systems with Applications*, 143, 113042. <https://doi.org/10.1016/j.eswa.2019.113042>

INVESTIGATION OF INVESTMENT IN STOCK MARKET USING DEEP LEARNING MODELS

Nijolė MAKNICKIENĖ, Amanda URBONAVIČIŪTĖ

Abstract. Investing becomes an integral part of the financial world. As one market gamer encourages the launch or continuation of existing activities, the other players in the market are earning their shares. Therefore, each investor looks for the best solution, tactics and a method that will help to profitably determine the direction of the movement of shares. However, investors face difficulties in predicting stock variation forecasts. Often the chosen and used method is not an accurate forecasting tool, so investors focus on deep learning methods that become a support system for the investor. The article examines the comparison of the forecasts for the schedules received in deep learning and technical analysis methods, and the uncertainty about the predictability of share prices. The results of this work remain relevant and relevant, as studies relate to the use of a deep learning approach in investment, which is heavily analysed and investigated by researchers, and is still attempting to understand the success of its utilisation by investing.

Keywords: investing, deep-learning, technical analysis, share price, stock market, prediction, support system.