



## RINKOS SENTIMENTŲ PROGNOZAVIMAS NAUDOJANT DIRBTINĮ INTELEKTĄ

Nijolė MAKNICKIENĖ, Jovita MASĖNAITĖ\*

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

*\*El. paštas [jovita.masenaite@stud.vgtu.lt](mailto:jovita.masenaite@stud.vgtu.lt)*

**Santrauka.** Kiekvienas investuotojas susiduria su efektyvių investicinių sprendimų priėmimo problema. Yra daug metodų, kuriais stengiamasi išanalizuoti finansų rinkoje vykstančių pokyčių priežastis bei remiantis tokia informacija numatyti ateities tendencijas. Vienas iš būdų yra investuotojų sentimentų prognozavimas. Šio straipsnio tyrimo tikslas yra atlikti skirtingų investuotojų sentimentų prognozavimą ir įvertinti prognozavimui naudojamo modelio patikimumą, t. y. siekiama atrasti patikimą sentimentų prognozavimo algoritmą. Tyrimui naudojamas dirbtinio intelekto giliojo mokymosi ilgos trumpalaikės atminties (LSTM) tinklų algoritmas bei grafinis gautų rezultatų vaizdavimas. Atlikus tyrimą buvo pastebėta, kad kiekvienu sentimentų prognozavimo atveju gauta paklaida (RMSE) buvo labai maža, o tai reiškia, kad prognozavimui naudojamas algoritmas yra labai patikimas. Sentimentų prognozavimas kartu su racionaliais prognozavimo metodais gali papildyti prekybos strategiją ar paramos sistemą investuotojui.

**Reikšminiai žodžiai:** investuotojo elgsena, rinkos sentimentai, dirbtinis intelektas, giliojo mokymosi metodas, ilgos trumpalaikės atminties tinklai, prognozavimas.

### Įvadas

Individualūs investuotojai yra vieni pagrindinių finansų rinkos veiksmų, nuo kurių priklauso finansinių priemonių vertės kitimas. Siekiant būti pasiruošus įvairiems rinkos pokyčiams bei juos numatyti yra būtina nagrinėti individualių investuotojų elgseną finansų rinkose. Jeigu didžioji dalis investuotojų nusiteikę optimistiškai, jie skatina finansinių priemonių vertės rinkoje kilimą, jeigu pesimistiškai – kritimą. Todėl yra svarbu stebėti investuotojų priimamus sprendimus ir bandyti išsiaiškinti pagrindines priežastis bei motyvus kodėl konkretūs investiciniai sprendimai yra priimami. Tačiau dauguma investuotojų sprendimus priima remdamiesi savo psichologiniais motyvais, o tokiu būdu priimamus sprendimus yra labai sunku nuspėti. Siekiant kuo tiksliau išsiaiškinti individualių investuotojų elgseną priežastis yra matuojami rinkos sentimentai. Pagal juos investuotojai skirstomi į skirtingas grupes ir bandoma atrasti bendrą jų elgseną siejančių panašumų modelį, kad būtų galima numatyti rinkoje vyraujančias tendencijas. Vienas iš būdų investuotojams priimti efektyvesnius investavimo sprendimus yra rinkos sentimentų prognozavimas, nes žinodami kokie sentimentai vyraus artimiausioje ateityje investuotojai gali bandyti nuspėti ar konkrečios finansinės priemonės vertė kils ar kris ir tuo remdamiesi priimti jiems palankius investicinius sprendimus. Mokslinėje literatūroje vieni tinkamiausių būdų laiko eilutės prognozėms atlikti išskiriami dirbtinio intelekto algoritmai. Dirbtinis intelektas yra naudojamas siekiant atkartoti žmogaus smegenų funkcionalumą, jis susideda iš neuroninių tinklų, kurių pagalba geba pats apsimokyti iš didelio duomenų kiekio ir priimti sprendimus remiantis stebėta informacija. Tačiau moksliniuose darbuose rinkos sentimentų prognozavimui dirbtinio intelekto algoritmai dar nėra pačiai naudojami. Šio straipsnio esmė yra atrasti patikimiausią investuotojų sentimentų prognozavimo algoritmą.

*Tyrimo objektas* – investuotojų sentimentai.

*Tyrimo problema* – kaip atlikti patikimą investuotojų sentimentų prognozavimą.

*Tikslas* – atlikti skirtingų investuotojų sentimentų prognozavimą ir įvertinti prognozavimui naudojamo modelio patikimumą.

*Uždaviniai* tikslui pasiekti:

- išanalizuoti investuotojų elgsenos sampratą mokslinėje literatūroje;
- išanalizuoti investuotojų sentimentų matavimo būdus ir dirbtinio intelekto naudojimo galimybes;
- atlikti investuotojų sentimentų prognozavimą bei naudojamo algoritmo patikimumo įvertinimą.

*Tyrimo metodai:*

- mokslinės literatūros šaltinių analizė;
- giliojo mokymosi LSTM pagrindu prognozavimo algoritmas;
- grafinis duomenų vaizdavimas.

## 1. Investuotojų elgsenos samprata ir klasifikacija

Kiekvieno investuotojo pagrindinė veikla yra pastovus sprendimų priėmimas, nepaisant to, kokios yra investuotojo naudojamos finansinės priemonės. Visi investuotojai norėdami užsiimti investavimo veikla privalo atsakyti į daugybę skirtingų klausimų ir nesvarbu kiek konkretus investuotojas turi patirties, ar jis tik pradedantysis, ar jau pažengęs investavimo srityje. Formuodami savo investicinį portfelį investuotojai turi pasirinkti kokios finansinės priemonės į jų portfelį bus įtrauktos, kokių santykiu bus paskirstytos investicijos, kada ir kokia rizika bus prisiimta, kam paskirti valdyti investicinį portfelį ir kt. (Barber ir Odean, 2013).

Investuotojai sugeba suformuoti efektyvų investicinį portfelį bei parinkti efektyvias investicines priemones. Tai reiškia, kad investuotojai sprendimus priima remdamiesi skaičiavimais ir savo racionalių mąstymu. Tačiau šiems kertiniams tradicinių finansų teorijos nuostatomis prieštarauja jau keliasdešimt metų plėtojama ir nagrinėjama finansų elgsenos teorija. Tai yra mokslas, kuris nagrinėja situacijas esančias rinkoje, kuriose figūruojantys dalyviai demonstruoja savo riboto racionalumo lemiamus veiksmus (Picasso et al., 2019). Finansų elgsenos teorija susiformavo tada, kuomet buvo išsiaiškinta, kad atliekant ekonominių, investicinių sprendimų prognozavimą negalima remtis tik racionalumu. Žmogaus elgsena nėra visuomet paremta tikimybių teorija, matematika ir skaičiavimais, todėl finansų elgsena nagrinėja, kokia yra emocinių veiksnių įtaka daroma rinkos pokyčiams, kadangi investuotojai nėra racionalūs. Bandoma išsiaiškinti kodėl investuotojai elgiasi neracionaliai, kokie yra to motyvai, siekiama suskirstyti investuotojus pagal nuokrypius nuo racionalios elgsenos, kad būtų galima stebėti rinkoje vyraujančias tendencijas ir prognozuoti galimus pakitimus. Tačiau vieno modelio, kaip galima būtų klasifikuoti investuotojus pagal jų elgseną, dar nėra suformuota (Lapanan 2018).

Bikas ir Kavaliauskas (2010) nuokrypius nuo racionalios elgsenos siūlo skirstyti į dvi rūšis: kognityvinius nukrypimus ir pirmumo klaidas. Kognityviniai nukrypimai skirstomi į atskiras sritis:

- Atstovavimas. Sprendimų priėmėjų nuomone, labiau reprezentatyvus rezultatas yra tas, kuris įvyksta neatsižvelgiant į tikimybes;
- Pasitikėjimas. Tendencija, kad investuotojas yra pernelyg užtikrintas atliekant veiksmus, t. y. pervertintas pasitikėjimas savo priimamais sprendimais bei prognozavimo sugebėjimais;
- Stovėjimas/inkaras. Tendencija, kad priimami sprendimai jau yra paveikti investuotojų patirties;
- Tinkamumas. Lengvai prieinama informacija turi didesnę vertę priimant sprendimus;
- Klaida. Spėjimas, kad kokia nors tendencija pakeis savo kryptį.

Pirmumo klaidos skirstomos į tokias sritis:

- Rėminimas. Investuotojai „rėmina“ savo priimamus sprendimus pagal nuokrypius, t. y. grąžą ir nuostolius, nuo subjektyvaus atskaitos taško;
- Nuostolio vengimas. Investuotojas yra jautresnis nuostoliui, o ne pelnui;
- Rizikos ieškojimas nuostoliams padengti. Investuojama saugiai norint apsaugoti savo pelną, tačiau yra daug rizikuojama siekiant padengti nuostolius;
- Subjektyvus tikimybės iškraipymas. Investuotojai remiasi labai subjektyviais sprendimų „svoriais“, kurie pervertina mažą didelio pelno tikimybę ir neįvertina didelės mažo pelno ar didelio nuostolio tikimybės.

Kitokių investuotojų skirstymą pagal nukrypimus nuo racionalios elgsenos pateikia Barber ir Odean (2013). Autoriai investuotojų elgsenos nukrypimus skirsto į dvi rūšis: kognityvinius nukrypimus ir emocinius nukrypimus. Kognityviniai nukrypimai skirstomi į tokias sritis:

- Per didelis pasitikėjimas. Investuotojo pervertintas tikėjimas savo priimamais sprendimais bei gabumais;
- Atstovavimas. Naujai įgyta patirtis yra priskiriama visiškai kitokiam patyrimui negu iš tikrųjų turėtų būti;
- Stovėjimas/inkaras ir prisiderinimas. Prie kažkokios įsivaizduojamos pradinės reikšmės derinami veiksmai;
- Kognityvinis disonansas. Kai naujai gauta informacija prieštarauja investuotojo esamam supratimui;
- Tinkamumas. Remiantis anksčiau įgyta investavimo patirtimi yra apskaičiuojama konkreti tikimybė;
- Priskyrimas. Situacija kai investuotojas prisiskiria sau sėkmingus įvykius bei patirtį;
- Kontrolės iliuzija. Investuotojas mano, kad galutinis rezultatas yra jo rankose ir jis kontroliuoja aplinkybes;
- Konservatizmas. Kai investuotojas nekreipia dėmesio į naują informaciją ir tvirtai laikosi savo nuomonės;

- Neaiškumo vengimas. Situacijose, kuriose pasitaiko dviprasmybių, investuotojai ima dvejoti savo veiksmams;
- Mentalinės sąskaitos. Investuotojo tendencija įvertinti ir koduoti ekonominius rezultatus grupuojant turtą;
- Patvirtinimas. Yra akcentuojamos idėjos, kurios patvirtina investuotojo įsitikinimus, o nuvertinamos tos, kurios prieštarauja;
- Tiriamas numatymas. Kai praėjus konkrečioms įvykiams, investuotojas mano žinojęs, kad taip turėjo būti;
- Naujumas. Kai investuotojas remiasi daugiau nauja informacija, nei senesnėmis ir patikrintomis žiniomis;
- Rėminimas. Tendencija, kad priimami sprendimai pagal tai, kokia situacija tuo konkrečiu metu parodoma.

O emociniai nukrypimai skirstomi į tokias sritis:

- Šelpimas. Investuotojai konkretų turtą vertina labiau, kai jie yra to turto savininkai, t. y. gali juo disponuoti;
- Savikontrolė. Investuotojo elgesio tendencija, kai jis vartoja šiandien rytojaus sąskaita;
- Optimizmas. Pernelyg optimistiškas požiūris trukdo matyti tikrus faktus bei realią situaciją;
- Nuostolio vengimas. Investuotojo jaučiamas didesnis jautrumas nuostolio išvengimui, nei pelno uždirbimui;
- Apgailestavimo vengimas. Kai nesiimama ryžtingų veiksmų, nes manoma, kad jie vis tiek bus netinkami;
- Faktinė padėtis. Kai investuotojas yra iš anksto nuteikiamas pasirinkti tokį sprendimą, kuris patvirtina egzistuojančias sąlygas, o ne alternatyvas, kurios galėtų atnešti pokyčius finansinėje rinkoje.

Kiekviena sritis turi konkrečių investuotojo panašių elgesio bruožų visumą, todėl stebint vieną ar kitą investuotoją ir jo atliekamus veiksmus pagal panašius elgesio bruožus galima jį identifikuoti ir priskirti tam tikrai sričiai, kurios pagalba yra galimybė numatyti ir suprasti kokie jo elgesio motyvai bei kokie galėtų būti investuotojo tolimesni sprendimai. Tačiau tai yra tik keli būdai kaip būtų galima skirstyti investuotojus pagal jų elgesį ir tai nereiškia, kad tik kažkuriuo iš šių klasifikavimo būdų turėtume remtis stebint rinkos tendencijas, nes skirtingose situacijose investuotojai gali elgtis visiškai skirtingai. Šiuolaikinės finansų elgsenos mokslininkai pateikia daug investuotojų tipo nustatymo modelių, kurie padeda identifikuoti investuotojus ir bandyti prognozuoti finansinių rinkų elgseną, o investuotojų elgsenos supratimas gali apsaugoti nuo klaidingų sprendimų priėmimo bei profesionaliau patarti investuotoju (Ryu et al., 2017). Makroekonominiu lygmeniu yra matuojami rinkos sentimentai.

## 2. Rinkos sentimentų reikšmė ir matavimas

Investuotojų sentimentai, tai yra investuotojų elgesio priklausomumas nuo jų psichologijos. Faktiniai investuotojų nukrypimai nuo racionalumu paremto elgesio yra panašaus pobūdžio, o ne atsitiktiniai. Vadinasi tos priimamų sprendimų klaidos, kurias nuolat kartoja dauguma investuotojų, sudaro investuotojo sentimentus (Yang ir Wu, 2019). Nagrinėjant mokslinę literatūrą, pastebėta, kad autoriai skirtingai apibūdina investuotojų sentimentus, pabrėždami vieną ar kitą aspektą. Ben-Rephael et al. (2010) sentimentus apibrėžia iškeldami klausimą, ar investuotojas būdamas tam tikroje situacijoje dėl bet kokio pašalinio veiksnio jaučiasi pernelyg pesimistiškas ar optimistiškas. Autoriai pabrėžia, kad esami investuotojų sentimentai daro įtaką jų požiūriui į ateities įvykius bei priimamus sprendimus, t. y. investuotojai, pasižymintys neigiamais sentimentais, linkę priimti pesimistiškus pasirinkimus, o investuotojai, pasižymintys teigiamais sentimentais – optimistiškus. Bouteska (2019) investuotojų sentimentus apibūdina kaip investuotojų nuotaiką sprendimo priėmimo metu. Tačiau rinkos sentimentai yra platesnė sąvoka, nes ji aprėpia visapusiškai klaidingą suvokimą, kuris gali daryti įtaką neteisingam investicinių priemonių kainų nustatymui. Investuotojų klaidingi įsitikinimai gali susiformuoti tuomet, kai investuotojai klaidingai naudoja teisingą informaciją arba teisingai naudoja klaidingą informaciją (Zhou, 2017).

Individualių investuotojų sentimentai yra naudojami kaip priešingas rodiklis valiutų kursams ar finansiniams indeksų veiksmams atlikti. Sentimentų prognozės investuotojams suteikia papildomos informacijos ir gali lemti geresnius sprendimus finansų rinkose, todėl sudarant informacinį duomenų rinkinį prognozei nustatyti yra būtina matuoti investuotojų sentimentus (Maknickienė ir Vaškevičiūtė, 2017).

Investuotojų sentimentų matavimus galima suskirstyti į tris kategorijas, t. y. tiesioginiai, netiesioginiai ir meta priemonės, remiantis tuo, kaip yra kaupiami duomenys matavimui (He et al., 2019). Tiesioginis sentimentų matavimas yra atliekant investuotojų apklausas, kuriose tiesiogiai klausama kaip žmogus jaučiasi esant dabartinėms ar būsimoms ekonominėms ir akcijų rinkos sąlygoms, o netiesioginis matavimas atspindi ekonominius ir finansinius kintamuosius, galinčius užfiksuoti investuotojų mintis (Beer ir Zouaoui, 2012). Dauguma empirinių tyrimų kaip netiesioginį sentimentų matavimą naudoja rinkos rodiklius. Trečioji kategorija yra tiesioginių ir

netiesioginių sentimentų matavimų derinys, kuris yra sudėtinė viso sentimentų matavimo dalis (Pandey ir Sehgal, 2019).

Šiame darbe yra naudojami AAI (Amerikos individualių investuotojų asociacijos) duomenys (AAI Investor Sentiment Survey, 2019). AAI atlieka individualių investuotojų sentimentų tyrimą, kuris matuoja investuotojų procentinį pasiskirstymą ir rūšiuoja juos į bulių (pozityvią), meškų (negatyvią) arba neutralią kategorijas. Visi AAI nariai yra apklausiami kiekvieną savaitę ir tik vienas kiekvieno nario balsas yra priimamas (Maknickienė et al., 2018).

### 3. Dirbtinio intelekto naudojimas

Dirbtinis intelektas (angl. *Artificial Intelligence, AI*) suteikia idealią galimybę fiksuoti investuotojų sentimentus, nes dirbtinis intelektas gali tiesiogiai įvertinti investuotojų sentimentus be iš anksto nustatytų emocijų duomenų ar pasirinkto specifinio komponento ir tokiu būdu padėti sumažinti prognozavimo šališkumą, kurį sukelia subjektyvus įsikišimas ar įprastos aproksimacijos klaidos. Be to, turėdamas nepriklausomą giliojo mokymosi gebėjimą, dirbtinis intelektas gali tiksliai nurodyti, kokia yra žodžio sentimentalumo reikšmė konkrečioje situacijoje, atsižvelgiant į tai, kad vienas žodis gali atspindėti skirtingą sentimentų laipsnį skirtingų scenarijų atžvilgiu (Ruan et al., 2020). Dirbtinio intelekto pagalba yra siekiama atkartoti žmogaus smegenų funkcionalumą, bandoma atlikti veiksmus, kurios sugeba atlikti pats žmogus, t. y. siekiama sukurti žmogaus smegenų atliekamų intelektinių veiksmų imitaciją (Paschen et al., 2020).

Giliojo mokymosi metodas (angl. *Deep Learning, DL*) yra vienas pažangiausių mašininio mokymosi metodų, jis sulaukė daug dėmesio tyrimų srityje, kadangi jo pagalba galima įveikti priklausomybę nuo rankomis sukurtų funkcijų su kuriomis susiduria tradiciniai mokymosi algoritmai. Giluminis mokymasis arba giluminiai neuroniniai tinklai (angl. *Deep Neural Networks, DNN*) paprastai susideda iš dviejų etapų: mokymo žingsnio, skirto optimizuoti modelio tikslumą, ir išvados fazės, kai modelis naudojamas klasifikavimui ar prognozavimui. Giluminio mokymosi metu sekiausias nervų tinklas gali geriau parodyti sudėtingas aukšto matmens funkcijas ir pritaikyti išgautų duomenų savybes kitose vietose, o jis gali rasti tikrąjį ryšį iš pirminių duomenų (Chen et al., 2019). Šiais laikais giliojo mokymosi metodas naudojamas įvairiose srityse, įskaitant didžiųjų duomenų analizę ir skirtingas programas, tokias kaip modelio atpažinimas, kalbos atpažinimas, kompiuterinis matymas, natūralios kalbos apdorojimas, įsibrovimo aptikimas ir medicininės prognozės (Boulemtafes et al., 2020). Giliojo mokymosi patirtis ypač pagerėja pasitelkiant galingas infrastruktūras, tokias kaip debesys ir mokymosi bendradarbiaujant modelį. Kadangi vartotojo įrenginiai yra riboti išteklių atžvilgiu, išeitis yra resursų reikalaujančių operacijų perkėlimas į išorinę laikmeną su didele galios skaičiavimu ir didele talpa, pavyzdžiui, perkėlimas į debesį (Boulemtafes et al., 2020).

Vienas pažangiausių giliojo mokymosi metodų yra ilgos trumpalaikės atminties (angl. *Long Short-Term Memory, LSTM*) tinklai, kurie skirti sekos mokymosi užduotims, tokioms kaip rašyenos atpažinimas, kalbos atpažinimas arba laiko eilučių prognozavimas (Fischer ir Krauss, 2018). Ilgos trumpalaikės atminties tinklai, tai yra rekurentiniai neuroniniai tinklai galintys išmokyti ilgalaikes priklausomybes. Jie turi „atminties elementus“, kurie gali išlaikyti informaciją neapibrėžtą laiką (Vo et al., 2019).

Atlikus skaičiavimus su MATLAB programa (Matlab..., 2019) naudojant ilgos trumpalaikės atminties metodą gautų prognozių tikslumui įvertinti yra apskaičiuojamas RMSE (angl. *Root Mean Squared Error, RMSE*) paklaidos matas pagal formulę (Šiurkutė ir Jakaitienė, 2009):

$$RMSE = \sqrt{\frac{1}{T} \sum_{t=1}^T (\hat{y}_t - y_t)^2}, \quad (1)$$

kur  $T$  – stebinių skaičius,  $\hat{y}_t$  – prognozuojama reikšmė, o  $y_t$  – stebėta reikšmė, kai  $t = 1, \dots, T$ .

Šio kriterijaus privalumas yra, tas, kad pakėlus kvadratu gautą reikšmę, dideli nuokrypiai yra dar labiau išryškunami. Vadinasi svarbu, kad gauta paklaida būtų kuo mažesnė, siekiant gauti kuo tikslesnę prognozavimo modelį.

### 4. Sentimentų prognozavimas naudojant giliojo mokymosi metodą

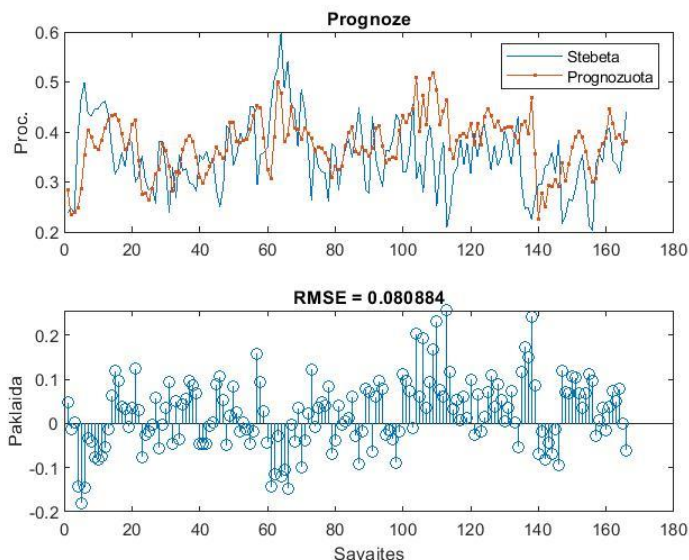
Kaip ir prieš tai buvo minėta, tyrimo metu naudojami AAI sentimentų apklausų istoriniai duomenys. Istorinių duomenų laikotarpis yra nuo 1988 metų sausio 8 dienos iki 2019 metų gruodžio 19 dienos. Kadangi reikšmės buvo fiksuojamos kas savaitę, tai iš viso tyrime buvo naudojami 1666 duomenys. Kiekvienas duomuo suskirstytas į tris kategorijas (bulių, meškų, neutralią) pagal investuotojų sentimentus, išreikštus procentais nuo visų apklausose dalyvavusių individualių investuotojų. Tyrimo metu kiekviena investuotojų kategorija nagrinėjama atskirai.

Investuotojų sentimentai buvo prognozuojami naudojant giliojo mokymosi LSTM metodą su MATLAB programa. 90 % visų duomenų buvo naudojami modelio apmokymui, o paskui vietoje istorinių 10 % paskutinių duomenų buvo atliktos prognozės. Tokiu būdu galima tikrinti ir įsitikinti kiek tiksliai naudojamas neuroninis tinklas

geba prognozuoti, kadangi prognozuotas reikšmės galima palyginti su jau egzistuojančiomis istorinėmis reikšmėmis. Tai atlikus galima prognozuoti ateities reikšmes.

Pirmoji nagrinėjama kategorija yra bulių arba, kitaip tariant, tai yra teigiami investuotojų sentimentai. Tai yra investuotojai, kurie yra suinteresuoti konkrečios finansinės priemonės vertės augimu ir dėl ateities yra nusiteikę pozityviai (Kumari, 2019). Visų pirma buvo atliktas LSTM modelio apmokymas, t. y. modelis atliko istorinių duomenų stebėjimą daug kartų ir ieškojo sąsajų tarp pasikartojančių panašaus pobūdžio kitimų. Apmokytas modelis atliko visos laiko eilutės prognozavimą ir buvo apskaičiuotos paklaidos (RMSE) tam, kad būtų galima įvertinti kiek daug naudojamo modelio prognozių reikšmės yra nutolusios nuo realių reikšmių, t. y. paklaida parodo modelio prognozavimo tikslumą.


1 paveiksle yra pateikti modelio mokymosi ir apskaičiuotų paklaidų grafikai. Teigiami sentimentai išreikšti procentais nuo visų balsavusių individualių investuotojų, o prognozavimo tikslumui vertinti skaičiuojamas RMSE.



1 paveikslas. Teigiamų sentimentų prognozavimo palyginimas su stebėtomis reikšmėmis (sudaryta autorių MATLAB programa)

Pirmame grafike yra atvaizduotos modelio stebėtų ir prognozuotų reikšmių kreivės. Galime matyti, kad prognozuotų reikšmių kreivės forma labai nedaug skiriasi nuo realių reikšmių kreivės. Tuo įsitikinti padeda apskaičiuota bendra visos laiko eilutės paklaida, kuri yra lygi 0,080884. Kuo mažesnė paklaida, tuo tikslesnės yra prognozių reikšmės, todėl galima teigti, kad naudojamas LSTM modelis teigiamų sentimentų prognozavimą atliko labai tiksliai. Toks didelis tikslumas yra dar ir dėl to, kad standartizuotų duomenų pasiskirstymo amplitudė nėra didelė, t. y. visos laiko eilutės didžiausia standartizuota reikmė yra 60 %, o mažiausia 20 %.

2 paveiksle yra pateikti teigiamų sentimentų, išreikštų procentais nuo visų balsavusių individualių investuotojų, istorinių duomenų ir atlikto prognozavimo grafikai.




2 paveikslas. Teigiamų sentimentų istoriniai duomenys bei prognozės naudojant LSTM metodą (sudaryta autorių)

Pagal pateiktus grafikus 2 paveiksle galima atlikti istorinių duomenų bei prognozuotų reikšmių palyginimą. Kaip prieš tai buvo minėta, modelis iš visos turimos laiko eilutės atliko paskutinių 10 % duomenų prognozavimą.

Galima matyti, kad prognozės nuo realių reikšmių nedaug skiriasi. Skirtumas atsiranda dėl modelio prognozavimo paklaidos bei dar ir dėl to, kad modelio mokymuisi naudojami standartizuoti istoriniai duomenys.


Antroji nagrinėjama kategorija yra neutralūs sentimentai. Tai investuotojai, kurie nėra jautrūs nei teigiamiems nei neigiamiems sentimentams ir jie nėra apsisprendę dėl konkrečios finansinės priemonės vertės pokyčio ateityje (García Petit et al., 2019).

3 paveiksle yra pateikti grafikai, kurie vaizduoja modelio mokymąsi bei apskaičiuotas paklaidas. Neutralūs sentimentai išreikšti procentais nuo visų balsavusių individualių investuotojų Pateiktuose grafikuose galima matyti, kaip modelio stebėtų standartizuotų duomenų kreivė skiriasi nuo jo prognozuotų reikšmių kreivės. Skirtumas nėra didelis, bet yra šiek tiek didesnis nei prieš tai nagrinėtu atveju, nes šiuo atveju gauta bendra visų duomenų RMSE paklaida yra didesnė, ji lygi 0,087537. Tačiau toks skirtumas nėra reikšmingas, vadinasi tiek pirmu atveju, tiek antru, atliktas prognozavimas yra labai tikslus.



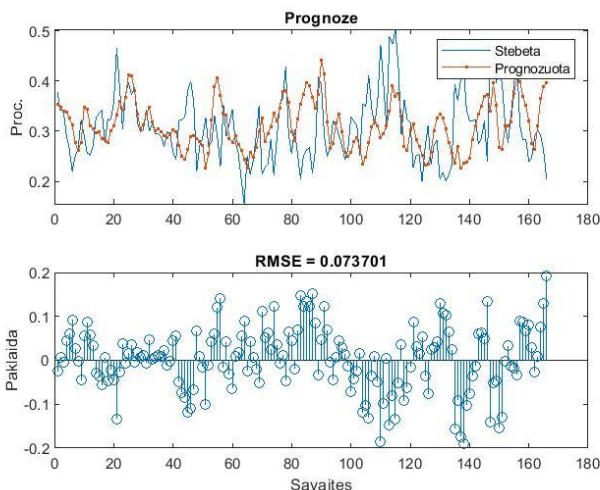
3 paveikslas. Neutralių sentimentų prognozavimo palyginimas su stebėtomis reikšmėmis (sudaryta autorių MATLAB programa)

4 paveiksle pateikti neutralių sentimentų, išreikštų procentais nuo visų balsavusių individualių investuotojų, istorinių duomenų ir prognozės grafikai. Iš pateiktų grafikų galima matyti, kad modelio atliktas prognozavimas yra labai tikslus, kurio reikšmės yra ne tik labai panašios į realiasias, bet bendra kitimo tendencija yra išlaikyta vienoda. Vadinasi tokį modelį galima naudoti ateities reikšmių prognozavimui nebijant, kad bus iškraipyta bendra duomenų tendencija.



4 paveikslas. Neutralių sentimentų istoriniai duomenys bei prognozės naudojant LSTM metodą (sudaryta autorių)


Trečioji nagrinėjama kategorija yra meškų arba, kitaip tariant, tai yra neigiami investuotojų sentimentai. Tai yra investuotojai, kurie yra suinteresuoti konkrečios finansinės priemonės vertės kritimu ir dėl ateities yra nusiteikę negatyviai (Derakhshan ir Beigy, 2019). 5 paveiksle pateikiami modelio mokymosi bei paklaidų grafikai. Neigiami sentimentai išreikšti procentais nuo visų balsavusių individualių investuotojų.



5 paveikslas. Neigiamų sentimentų prognozavimo palyginimas su stebėtomis reikšmėmis (sudaryta autorių MATLAB programa)

Iš 5 paveiksle pateiktų grafikų galima matyti, jog stebėtų duomenų bei prognozuotų duomenų kreivės yra panašios. Taip pat kaip ir prieš tai nagrinėtais atvejais, šiuo atveju paklaida yra labai maža. Lyginant su kitų sentimentų prognozavimo paklaidomis, neigiamų sentimentų prognozavimas yra tiksliausias, nes jo RMSE paklaida yra mažiausia, lygi 0,073701.

6 paveiksle pateikiami neigiamų sentimentų, išreikštų procentais nuo visų balsavusių individualių investuotojų, istorinių duomenų bei prognozės grafikai.



6 paveikslas. Neigiamų sentimentų istoriniai duomenys bei prognozės naudojant LSTM metodą (sudaryta autorių MATLAB)

Pagal 6 paveiksle pateiktus grafikus galima matyti, kad prognozuotos reikšmės yra labai panašios į realias reikšmes. Grafikų skirtumas yra labai nedidelis, be to abiejuose grafikuose yra išlaikyta tokia pati bendra duomenų kitimo tendencija, vadinasi galima teigti, kad toks modelis yra patikimas ir gali būti naudojamas ateities reikšmių prognozavimui.

Apibendrinant visų atliktų sentimentų prognozavimo rezultatus, galima teigti, kad prognozavimui pasirinktas LSTM metodas yra patikimas ir tinkamas naudoti. Visais trimis atvejais paklaidos buvo gautos labai mažos, vadinasi atliktas modelio gebėjimo prognozuoti testas yra rezultatyvus. Tačiau reikia atkreipti dėmesį į tai, kad standartizuotų duomenų visais trimis atvejais amplitudės buvo mažos, vadinasi tai yra vienas iš pagrindinių veiksnių, kodėl prognozavimo paklaidos buvo gautos tokios mažos, nes jeigu duomenų amplitudės būtų žymiai didesnės, tai ir paklaidos būtų didesnės.

Kiekvienas investuotojas yra suinteresuotas konkrečių finansinių priemonių vertės palankiu kitimu, o LSTM metodas puikiai tinka reikšmių prognozavimui investavimo sferoje. Atliktas norimų reikšmių, šiuo atveju investuotojų sentimentų, prognozavimas gali padėti investuotojams priimti racionalius investavimo sprendimus.

## Išvados

Kiekvienas investuotojas prieš atlikdamas investicinius sprendimus nagrinėja turimą informaciją apie dabartinę ir ateities finansinės rinkos situaciją. Tokią informaciją kaupti investuotojai gali pasitelkdami ne tik įvairius finansinius

priemonių vertės kitimo metodus bei technikas, bet ir nagrinėjant rinkos sentimentus bei atliekant jų prognozavimą. Investuotojų sentimentai nurodo kokios nuotaikos vyrauja rinkoje, ar labiau pesimistinės, ar optimistinės. O pagal tai investuotojai gali nuspėti ar finansinių priemonių vertė kris ar kils. Sentimentų prognozavimui atlikti vienas naujausių būdų yra naudojant dirbtinio intelekto algoritmus. Tačiau atlikus mokslinės literatūros analizę buvo pastebėta, kad dirbtinis intelektas dar nėra labai plačiai naudojamas rinkos sentimentų prognozavimui.

Tyrimo metu buvo susipažinta su dirbtinio intelekto naudojimu ir išsiaiškinta, kad laiko eilutės prognozavimui labiausiai tinkamas yra giliojo mokymosi LSTM metodas. Šio metodo algoritmas buvo naudojamas atskirai prognozuojant tris skirtingas investuotojų sentimentų rūšis: teigiamus, neigiamus bei neutralius sentimentus. Kiekvienu atveju buvo gautos labai mažos RMSE paklaidos: 0,07–0,087, o tai reiškia, kad modelio atliktos prognozės yra labai tikslios. Be to, palyginus istorinių duomenų bei atliktų prognozių grafikus, galima pastebėti ir įsitikinti, kad kreivės skiriasi labai nedaug. Vadinasi toks algoritmas yra patikimas ir tinkamas sentimentų ateities reikšmių prognozavimui.

Šiame darbe rinkos sentimentai nebuvo susieti su jokiais finansų rinkos instrumentais ar jų kainomis, nenagrinėta kas daro įtaką pokyčiams: sentimentai keičia finansų rinkos rodiklius ar rinkos pokyčiai lemia sentimentų pokyčius. Prognozuojami sentimentai gali būti susieti su kitais finansų rinkos rodikliais, o nagrinėtas metodas gali būti integruotas į investuotojo prekybos strategiją ar paramos sistemą.

## Literatūra

- AAll Investor Sentiment Survey. (2019). <https://www.aaii.com/sentimentsurvey/>
- Barber, B. M., & Odean, T. (2013). The behavior of individual investors. *Handbook of the Economics of Finance*, 2(Part B), 1533–1570. <https://doi.org/10.1016/B978-0-44-459406-8.00022-6>
- Beer, F., & Zouaoui, M. (2012). Measuring investor sentiment in the stock market. *SSRN Electronic Journal*, 1–30. <https://doi.org/10.2139/ssrn.1939527>
- Ben-Rephael, A., Kandel, S., & Wohl, A. (2012, July). Measuring investor sentiment with mutual fund flows. *Journal of Financial Economics*, 104, 363–382. <https://doi.org/10.1016/j.jfineco.2010.08.018>
- Bikas, E. ir Kavaliauskas, A. (2010). Lietuvos investuotojų elgsena finansų krizės metu. *Business: Theory and Practice*, 11(4), 370–380. <https://doi.org/10.3846/btp.2010.40>
- Boulemtafes, A., Derhab, A., & Challal, Y. (2020). A review of privacy-preserving techniques for deep learning. *Neurocomputing*, 384, 21–45. <https://doi.org/10.1016/j.neucom.2019.11.041>
- Bouteska, A. (2019). The effect of investor sentiment on market reactions to financial earnings restatements: Lessons from the United States. *Journal of Behavioral and Experimental Finance*, 24, 100241. <https://doi.org/10.1016/j.jbef.2019.100241>
- Chen, C., Zhang, P., Liu, Y., & Liu, J. (2019). Financial quantitative investment using convolutional neural network and deep learning technology. *Neurocomputing* (in press). <https://doi.org/10.1016/j.neucom.2019.09.092>
- Derakhshan, A., & Beigy, H. (2019). Sentiment analysis on stock social media for stock price movement prediction. *Engineering Applications of Artificial Intelligence*, 85, 569–578. <https://doi.org/10.1016/j.engappai.2019.07.002>
- Fischer, T., & Krauss, C. (2018). Deep learning with long short-term memory networks for financial market predictions. *European Journal of Operational Research*, 270(2), 654–669. <https://doi.org/10.1016/j.ejor.2017.11.054>
- García Petit, J. J., Vaquero Lafuente, E., & Rúa Vieites, A. (2019). How information technologies shape investor sentiment: A web-based investor sentiment index. *Borsa Istanbul Review*, 19(2), 95–105. <https://doi.org/10.1016/j.bir.2019.01.001>
- He, Z., He, L., & Wen, F. (2019). Risk compensation and market returns: the role of investor sentiment in the stock market. *Emerging Markets Finance and Trade*, 55(3), 704–718. <https://doi.org/10.1080/1540496X.2018.1460724>
- Kumari, J. (2019). Investor sentiment and stock market liquidity: Evidence from an emerging economy. *Journal of Behavioral and Experimental Finance*, 23, 166–180. <https://doi.org/10.1016/j.jbef.2019.07.002>
- Lapanan, N. (2018). The investment behavior of socially responsible individual investors. *Quarterly Review of Economics and Finance*, 70, 214–226. <https://doi.org/10.1016/j.qref.2018.05.014>
- Maknickiene, N., Lapinskaite, I., & Maknickas, A. (2018). Application of ensemble of recurrent neural networks for forecasting of stock market sentiments. *Equilibrium*, 13(1), 7–27. <https://doi.org/10.24136/eq.2018.001>
- Maknickienė, N., & Vaškevičiūtė, A. (2017). Comparison of sentiments data extraction and prediction. *Innovative Infotechnologies for Science, Business and Education*, 1(22), 14–20.
- Matlab deep learning algorithm. (2019). <https://ch.mathworks.com/help/deeplearning/examples/time-series-forecasting-using-deep-learning.html>
- Pandey, P., & Sehgal, S. (2019). Investor sentiment and its role in asset pricing: An empirical study for India. *IIMB Management Review*, 31(2), 127–144. <https://doi.org/10.1016/j.iimb.2019.03.009>
- Paschen, U., Pitt, C., & Kietzmann, J. (2020). Artificial intelligence: Building blocks and an innovation typology. *Business Horizons*, 63(2), 147–155. <https://doi.org/10.1016/j.bushor.2019.10.004>
- 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>
- Ruan, Q., Wang, Z., Zhou, Y., & Lv, D. (2020). A new investor sentiment indicator (ISI) based on artificial intelligence: A powerful return predictor in China. *Economic Modelling*, 88, 47–58. <https://doi.org/10.1016/j.econmod.2019.09.009>



- Ryu, D., Kim, H., & Yang, H. (2017). Investor sentiment, trading behavior and stock returns. *Applied Economics Letters*, 24(12), 826–830. <https://doi.org/10.1080/13504851.2016.1231890>
- Šiurkutė, D. ir Jakaitienė, A. (2009). Infliacijos prognozavimas faktoriniais modeliais. *Lietuvos matematikos rinkinys*, 230–234.
- Vo, N. N. Y., He, X., Liu, S., & Xu, G. (2019). Deep learning for decision making and the optimization of socially responsible investments and portfolio. *Decision Support Systems*, 124, 113097. <https://doi.org/10.1016/j.dss.2019.113097>
- Yang, C., & Wu, H. (2019). Chasing investor sentiment in stock market. *North American Journal of Economics and Finance*, 50, 100975. <https://doi.org/10.1016/j.najef.2019.04.018>
- Zhou, G. (2017). Measuring investor sentiment. *SSRN Electronic Journal*, 1–21. <https://doi.org/10.2139/ssrn.3051414>

## FORECASTING OF MARKET SENTIMENTS USING ARTIFICIAL INTELLIGENCE

Nijolė MAKNICKIENĖ, Jovita MASĖNAITĖ

**Abstract.** Every investor faces the challenge of making efficient investment decisions. There are many methods to analyze the causes of changes in the financial market and to predict future trends based on such information. One way is to predict investors sentiment. This type of study is not extensively studied in the scientific literature, so the purpose of this article research is to perform prediction of different investor sentiment and to evaluate the reliability of the model used for prediction, i.e. reaching to discover a reliable sentiment prediction algorithm. Artificial intelligence deep learning short-term memory (LSTM) network method and graphical representation of the obtained results are used for the research. The study found that the margin of error (RMSE) obtained for each sentiment prediction case was very low, which means that the algorithm used for prediction is very reliable. Investors using this algorithm can help themselves better study market trends, but other financial market research methods should be used in parallel to make investment decisions as efficiently as possible.

**Keywords:** investors behavior, market sentiment, artificial intelligence, deep learning, long-term memory networks, forecasting.