



## SKAITMENINIŲ VALIUTŲ KAINŲ PROGNOZAVIMAS NAUDOJANT GILIOJO MOKYMOŠI ALGORITMĄ

Nijolė MAKNIČKIENĖ, Kristina MIŠKINYTĖ\*

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

*\*El. paštas [kristina.miskinyte@stud.vgtu.lt](mailto:kristina.miskinyte@stud.vgtu.lt)*

**Santrauka.** Kriptovaliutos vis dar yra finansų rinkos naujovė ir iki galo neištirta finansinis instrumentas. Tai išlaiko kriptovaliutas įdomia ir aktualia tema, tiek mokslininkams, tiek reguliacinėms institucijoms bei investuotojams. Kriptovaliutų rinka yra auganti, nestabili ir nuolat besikeičianti, kas suteikia jai aukštą riziką ir plačias galimybes. Finansinis išmanymas ir toliaregiškas prognozavimas, nepasimetant pinigų vertės, rizikos ir nenuspėjamumo chaose yra ypač svarbus šiandieninėje ekonomikoje. Sudėtingas kriptovaliutų rinkos pobūdis reikalauja plataus profilio duomenų kiekio, kuriam apdoroti taikomi įvairūs metodai, tokie kaip statistinė, techninė, sentimentų, sprendimų bei kita analizė. Ankstesni tyrimai kriptovaliutų kainas numatė dviem būdais: empirine analize ir mašinių mokymosi algoritmų analize. Šiame straipsnyje testuojamas giliojo mokymosi algoritmo taikymo galimybės kriptovaliutų kainų prognozavime. Taikant ilgalaikės trumpalaikės atminties tinklo (angl. *long short-term network*, toliau LSTM) algoritmą, prognozuojamas trumpalaikis kriptovaliutų kainų kitimas bei įvertinamas sugeneruotų duomenų tikslumas. Rezultatai parodė, kad giliojo mokymosi algoritmas kainas prognozuoja su maža paklaida ir tiksliai nuspėję kainos pokyčio tendenciją, kas leidžia teigti, kad giliojo mokymosi algoritmas yra efektyvi rizikos mažinimo priemonė finansų rinkoje.

**Reikšminiai žodžiai:** dirbtinis intelektas, gilusis mokymasis, LSTM, prognozavimas, kriptovaliutos, kriptovaliutų rinka.

### Įvadas

Finansų rinkoje yra svarbus ne tik finansinis išmanymas bet ir toliaregiškas prognozavimas, nepasimetant pinigų vertės, rizikos ir nenuspėjamumo chaose. Kriptovaliutos nėra naujiena tiek finansų rinkai, tiek jos dalyviams. Aktyvų investavimą ir susidomėjimą šiuo finansiniu produktu iššaukė 2017 m. įvykęs kirpto-bumas. Tuometinė kriptovaliutų rinkos kapitalizacija sausio mėnesį siekė 17,000 mln. JAV dolerių, o jau birželį buvo pašokusi iki 90,000 mln. JAV dolerių. Jau 2018 gegužę tik dviejų didžiausių kriptovaliutų (Bitcoin ir Ethereum) bendra rinkos vertė [coinmarketcap.com](http://coinmarketcap.com) (2019) duomenimis siekė 160,9 milijardų JAV dolerių. Kapitalizacijos dydis ir kitimas yra vertės rodiklis suinteresuotam vartotojui ar investuotojui. Jis yra gaunama padauginus esamų rinkoje žetonų skaičių iš tuometinės jų kainos, taip išreiškiant investicijos dydį. Investavimo rizikos mažinimui vis dažniau pasitelkiamas dirbtinis intelektas, kuris automatizuoja ne tik fizinį bet ir protinį darbą, šiuo atveju – strateginį sprendimų priėmimą išanalizuojant tūkstančius duomenų sekundžių greičiu. Atlikta literatūros analizė parodė, kad yra tik keli moksliniai darbai, skirti analizuoti kriptovaliutų kainų prognozavimą taikant giliojo mokymosi algoritmus. Mokslinių tyrimų stoka skatina analizuoti šią tyrimo sritį giliau. Būtent todėl straipsnio tikslas – pritaikant giliojo mokymosi algoritmą nustatyto trumpalaikį kriptovaliutų kainos kitimą. Straipsnyje nagrinėjamas dirbtinis intelektas ir jo panaudojimas kriptovaliutų kainų prognozavimui, apžvelgti dažniausiai taikomi algoritmai bei palyginti trumpalaikių prognozuojamų kainų rezultatai su realiais duomenimis.

### 1. Dirbtinio intelekto taikymo kriptovaliutų rinkoje apžvalga


Pirmoje straipsnio dalyje apžvelgiamas dirbtinis intelektas, jo svarba ir taikymas kriptovaliutų rinkoje. Pagrindinis dėmesys skiriamas giliojo mokymosi algoritmo pritaikymo galimybės kriptovaliutų kainų prognozavimui bei rezultatų tikslumo nagrinėjimui.

Kriptovaliutos nėra nei naujas produktas, nei faktiniai pinigai, tai visiškai skaitmeninė vertės perdavimo priemonė, kurios naudojimo ir ateities galimybių aspektai yra vis dar tiriami ir teisiškai apibrėžiami. Kriptovaliutų pradžia laikomi 2009 metai, kai buvo pristatyta Bitcoin kriptovaliuta. Nepaisant to, intensyvus susidomėjimas ir

naudojimas investiciniu pobūdžiu yra ganėtinai naujas reiškinys, kuris stokoja detalių tyrimų tiek ties kriptovaliutų rinkos kainų kitimu, tiek investavimu ir prognozavimu. Kriptovaliutų apibrėžimas yra dažnai tapatinamas su elektroninių pinigų sąvoka, kas teisiškai neatitinka elektroninių pinigų ir elektroninių pinigų įstaigų XIII-1094 įstatymo apibrėžtų būtinų sąlyga, tokių kaip plataus priimtumo ar leidėjui privalomo išpirkimo. Lietuvos Bankas (2017) kriptovaliutas apibūdina kaip nereguliuojamus skaitmeninius pinigus, kurių išleidimo į apyvartą negarantuoja centrinis bankas. Virtualūs pinigai arba kriptovaliuta literatūroje apibūdinama kaip elektroniniu būdu išleidžiama valiuta, kurios pakeitimas į realios vertės pinigus nėra garantuotas valstybės. Dauguma mokslininkų kriptovaliutas apibūdina kaip virtualų turtą, kurio paskirtis yra būti mainų priemone ar terpe. Tam sukurti naudojama sudėtinga kriptografijos technologija, kuri užtikrina finansinių operacijų srauto saugumą ir papildomų kriptovaliutų generavimą (Schueffel, 2017; Chohan, 2018). Andrianto (2017) apibūdina kriptovaliutas kaip sparčiai besiplečiančią mokėjimo sistemą, priklausančią nuo skaitmeninės blokų grandinės sistemos. Dourado ir Brito (2014) įvardina virtualias valiutas kaip sistemą, kuri naudoja kriptografiją, kad užtikrintų saugų skaitmeninių žetonų pardavimą ar keitimąsi decentralizuotu būdu. Tad bendrai tariant, kriptovaliuta tai – mokėjimų tarpės sistema, naudojami kriptografijos technologiją, kad sukurtų virtualaus turto vertę.

Baur et al. (2018) kriptovaliutas apibrėžia, kaip investavimo priemonę. Mokslininkai teigia, kad virtualios valiutos nėra tik mokėjimų sistema, tačiau ir ypač sparčiai populiarėjanti investavimo priemonė. Kriptovaliutų rinka yra auganti, nestabili ir nuolat besikeičianti, kas paverčia ją ypač rizikinga. Augantis susidomėjimas investavimo srityje išbalansuoja kriptovaliutų kainas, sukeldamos vertės nepastovumą, kas atbaido potencialius valiutos naudotojus. Taip pat nevertėtų užmiršti ir rizikos dėl didelės kriptovaliutų koncentracijos vienoje vietoje, ko pasėkoje galimas dirbtinis kainos sukėlimas. Paprasčiausias pavyzdys būtų sutartinis sandoris tarp dviejų santykinai didelį kiekį kriptovaliutų turinčių šalių, kur dirbtinai atliekant pirkimo ir pardavimo sandorius, skatinamas dirbtinis kainos augimas. Stabili pusiausvyra tarp investuotojų ir vartotojų yra ypač svarbi, siekiant išlaikyti kriptovaliutų, kaip mainų priemonės, matavimo mato ir kaupimo būdo sėkmę (Platanakis ir Urquhart, 2019).

Rinkos pokyčio krypties prognozavimas yra sudėtingas ir tuo pat įdomus mokslininkams, siekiantiems pagerinti jau egzistuojančius prognozavimo modelius. Kiekvieno investuotojo tikslas, renkantis investavimo strategiją, remiantis modeliais, medija ir naujausia informacija, ekonomikos prognozėmis ir panašiai, yra atlikti sprendimus, kurie sumažintų riziką ir padidintų pelną. Kriptovaliutos ypač pasižymi savo kainų nepastovumu, ką virtualios valiutos ypač aiškiai įrodė 2017–2018 metais (1 paveikslas). Kainos kintamumas rodo, kiek yra rizikingas turto laikymas tam tikru metu ar laikotarpius. Kuo didesnis kainos pokyčio procentas, tuo didesnė tikimybė, kad vertė gali arba smarkiai pakilti arba taip pačiai nukristi. Tai sudaro ganėtinai didelę riziką, tačiau tuo pat metu padidina šansus patirti didelį pelną per trumpą laiko tarpą. Theblockcrypto.com (2019) atlikta kainų kitimo analizė parodė, kad 2009 birželį Bitcoin buvo pati nestabiliausia valiuta - kainos pokytis siekė 102 %. Nepaisant to, Bitcoin išliko pelningiausia kriptovaliuta, kurios vertė netgi pakilo 30 %. „Ltecoin“ kainų svyravimas siekė 98 %, „XRP“ – 82 %. Bitcoin kainos augimas sukėlė rinkos dalyviams vilčių, kad tai numatoma rinkos augimo kryptis. Dėl to dauguma investuotojų koncentruojasi į kriptovaliutų rinkos augimo galimybes. Coinmarketcap.com duomenimis, dabartinėje rinkoje yra 2,895 kriptovaliutos, kurių kapitalizacija, paklausa ir cirkuliavimas rinkoje yra skirtingas. Atsižvelgiant į tai, kad investavimo rizika yra didelė, ypač aktualus ir svarbus yra tikslingas rinkos prognozavimas.



1 paveikslas. Bendra kriptovaliutų rinkos kapitalizacija (JAV doleriais) 2013–2019 metais (coingecko.com, 2019)

Nors klasikinis sprendimų priėmimo požiūris yra grindžiamas laiko patikrintomis sprendimų priėmimo taisyklėmis, šiuolaikinis sprendimų palaikymas daugiausia grindžiamas statistiniais įrodymais, kurie gaunami analizuojant patikimus duomenis (Feuerriegel ir Fehrer, 2016). Šį duomenų pagrįstumu palaikomą sprendimų priėmimo būdą paskatino suvokimas, kad žmonės ir jų kompiuteriai generuoja daug ir įvairių duomenų, kuriuos yra įmanoma analizuoti. Šis atotrūkis ir bandymas fiksuoti ir naudoti pusiau struktūruotų ir nestrukūruotų duomenų vadinamas „Big Data“ – didžiųjų duomenų era. Terminas apima nuolat didėjančių duomenų kieki ir sparčiai besivystančios kompiuterinės technikos tobulinimą, kad sprendimų priėmimas būtų grindžiamas sudėtingų duomenų analize (Power, 2014). Tikslingam, greitam ir efektyviam gaunamos informacijos analizavimui pasitelkiami algoritmai. Mašininio mokymosi procese, sudarytam algoritmui duodamas duomenų rinkinys, kurio pagrindu atliekamos prognozės ar sprendimai (Mahdaviaf ir Ghorbani, 2019). Gilusis mokymasis yra mašininio mokymosi atšaka, kuriame mokymasis yra sudarytas iš neuronų sluoksnių, kurių kiekvienas pateikia mokymosi proceso algoritmą. Neuronų sluoksniai leidžia palaipsniui išgauti savybes, būdingas kiekvienam lygiui iš pateiktų tyrimo duomenų. Giliojo mokymosi algoritmas sudaro struktūrą, kuri veikia atgaline seka, kurios metu kiekviename sluoksnyje gauti parametrai yra pritaikomi prieš tai gautiems parametrams, tam, kad būtų sudaryta visus sluoksnius atspindinti veiksmų struktūra (Zhong et al., 2018; Aldweesh et al., 2019).

Kaip ir akcijų rinkos prognozavime, taip ir kriptovaliutų rinkoje, kyla klausimas – ar yra įmanoma nuspėti kriptovaliutų elgesį, kai šis yra toks dinamiškas, kas iš esmės prieštarauja Efektyvios rinkos hipotezei, pagal kurią kainų kitimas yra atsitiktinis (Sun et al., 2020). Ankstesni tyrimai virtualių valiutų kainas numatė dviem būdais: empirine analize ir mašinių mokymosi algoritmų analize. Šiame straipsnyje apžvelgiama giliojo mokymosi algoritmų metodų taikymas literatūroje, kriptovaliutų kainų prognozavimui.

Sun et al. (2020) atliko kainų prognozavimą taikydami tris skirtingus metodus: „LightGBM“, SVM („Support Vector Machines“) ir RF („Random Forests“). Tyrimui buvo naudojamos 42 kriptovaliutos, pasirinktos pagal aktyvumą. Gauti rezultatai parodė, kad modeliai geriausiai veikia naudojant dviejų savaičių prognozavimo laikotarpį. Atlikus tą patį tyrimą pasirinkus 10 stipriausių valiutų, prognozavimas buvo šiek tiek tikslesnis. To pasėkoje autoriai priėjo išvada, kad prognozavimo tikslumas koreliuoja su kriptovaliutų stiprumu ir prognozavimo laikotarpiu. Lyginant tris modelius, LightGBM parodė geresnius rezultatus lyginant su likusiais dviem.

Lahmiri ir Bekiros (2019) kriptovaliutų kainų prognozavimui pasirinko siauresnę imtį – tris pačias aktyviausias kriptovaliutas – Bitcoin, Digital Cash ir Ripple. Taikant giliojo mokymosi algoritmus. Šiuo tikslu buvo pasirinkti du algoritmai – LSTM ir apibendrintas regresinis tinklas (angl. *generalized regression neural networks*, toliau GRNN). Autoriai taip pat šiek tiek patobulino LTSM modelį, pertaikydami jam „kontroliuojančius vartus“, kurių galutinis tikslas – filtruoti informaciją, kuri yra reikšminga, ir galiausiai taptų prognoze. Tyrimo rezultatai parodė, kad LSTM giliojo mokymosi sistema, geriau sugebėjo išmokyti trijų pasirinktų valiutų kitimo dinamiką ir pateikti tikslesnei prognozes, lyginant su GRNN. Autoriai taip pat pabrėžė, kad giliojo mokymosi sistemos sugeba įsisavinti tiek trumpalaikę tiek ilgalaikę informaciją tuo pat metu, kas suteikia pranašumo siekiant atskleisti kitimo seką.

Madan et al. (2015) taip pat taikė giliojo mokymosi algoritmus Bitcoin kainų prognozavimui. Bendrai duomenų kitimo tendencija aptikti, taikytas atraminųjų vektorių klasifikatoriaus (SVM) algoritmas. Tyrimo rezultatai buvo teigiami – autorių algoritmas 98,7 % tikslumu numatė Bitcoin dienos kainas, ir 50–55 % aukšto dažnio kainas. Bitcoin kainą taip pat prognozavo ir Chen et al. (2020). Autoriai naudojo tiek statistinius metodus tiek mašininio mokymosi metodus. Dienos kainos prognozavime, statistiniai metodai pasiekė 66 % tikslumą, kur giliojo mokymosi algoritmų rezultatai pasiekė 65 % tikslumą. Tačiau lyginant su aukšto dažnio kainų prognozavimu, mokymosi modelių rezultatai pasiekusi 67,2 % tikslumą, kai statistinio prognozavimo tikslumo vidurkis siekė – 53 %. Rebane et al. (2018), Torres ir Qiu (2018) savo darbuose, taip pat lygino giliojo mokymosi prognozavimo rezultatus su laiko eilučių analizės modelio rezultatais. Abu darbai patvirtino, kad algoritmo pateiktos prognozės yra tikslesnės negu laiko eilučių statistinio prognozavimo metodo.

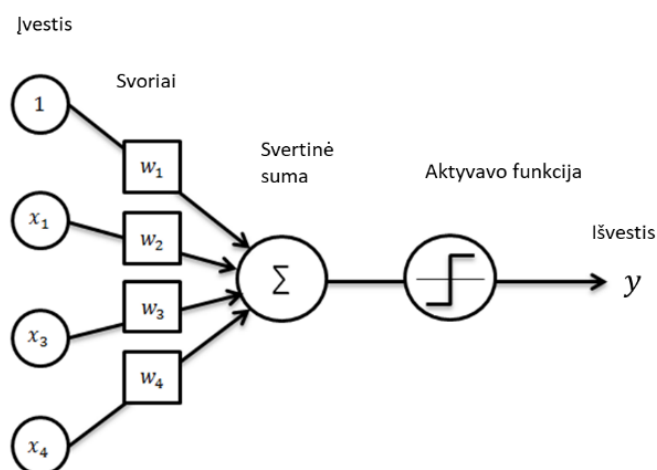
Kim et al. (2016) kriptovaliutų kainos vertinimui naudojo virtualių valiutų svetainių naudotojų išreiškiamus komentarus taikant sentimentų analizę, kaip veikiančią jų kainos svyravimo ir naudojimo faktorių. Mokslininkai pritaikė šį paprastą, tačiau efektyvų būdą trijų populiariausių kriptovaliutų kainų ir operacijų prognozavimui. Autoriams pavyko pasiekti 79,57 % prognozavimo tikslumą taikant Granger priežastingumo modelį. Tyrimas parodė, kad tiek kainų kitimas, tiek operacijų apimtis yra stipriai susiję su teigiamomis temomis, komentarais bei atsakymais. Mai et al. (2018) atliko tyrimą apie Bitcoin kainos kitimo ir socialinių tinklų sąsają. Šis tyrimas parodė, kad socialiniuose tinklai sudaryti iš 95 % pasyvių naudotojų, kas palieka 5 % aktyvių vartotojų, kurie paskelbia didžiąją dalį komentarų ir diskusijų, veikiančių kriptovaliutų kainų svyravimus. Tyrimo rezultatai leido priėti išvadą, kad sentimentų analizė yra svarbus ir efektyvus kriptovaliutų kainų prognozavimo būdas.

Apžvelgus šiuos ir panašius empirinius tyrimus, pastebėta, kad tyrimui naudojant dažną kainos kitimą, giliojo mokymosi algoritmų rezultatai yra tikslesni. Kai kurie mokslininkų darbai parodė, kad taikant statistinius metodus prognozavimui, galimi netgi tikslesni rezultatai. Žinoma, rezultatų gavimui yra ypač svarbus duomenų dažnumo pasirinkimas, dėl ypač greitai kintančios kriptovaliutų kainos bei prognozavimo laikotarpio pasirinkimas. Nepaisant to, galima pabrėžti, kad dirbant su dideliu kiekiu duomenų, dirbtinis intelektas yra pranašesnis, mat duomenys apdorojami su mažesniu žmogiškųjų klaidų faktoriu.

## 2. Giliojo mokymosi algoritmai kriptovaliutų prognozavime


Kaip jau minėta, gilusis mokymasis yra mašininio mokymosi atšaka. Šis algoritmas buvo sukurtas remiantis žmogaus biologine smegenų struktūra ir jos neuroninio tinklo funkcijomis. Neuronų tinklas yra programavimo sistema, sudaryta iš sujungtų neuronų, kuriais yra perduodami signalai. Ši sistema leidžia kompiuteriui mokytis iš stebėjimo duomenų, taip palaipsniui tobulindama veiksmų atlikimą signalų perdavimo metu (Talo et al., 2019). Vieno neurono signalo išvestis (angl. *output*) veikia kaip kito neurono įvestis (angl. *input*). Algoritmo veikimo principas yra daugkartiniu informacijos apdorojimu, kas suteikia gilesnį ir naudingesnį mokymąsi. Neuronų tinklai dažniausiai yra sudaryti iš sluoksnių, kurių kiekvieną sudaro daugybė neuronų. Tokia struktūra leidžia kompiuteriui rinkti apdorotus duomenis, kurie moko, kaip turėtų būti pakeisti vidiniai parametrai, kad būtų atvaizduotas kiekvieno sluoksnio rezultatas. Rezultatai ar atpažinti pasikartojantys veiksmai yra skaitiniai ir išreikšti vektoriuose, kurie vartotojui pateikiami kaip vaizdai, tekstas, laiko eilutės ir pan. (Zhong et al., 2018).

Sluoksniai yra surišti mazgais (sinapsėmis), kuriuose vyksta skaičiavimai. Mazgas derina duomenų įvestį su koeficientų arba svorių rinkiniu, kurie tą įvestį arba sustiprina, arba sumažina, taip priskirdami įvesties reikšmę užduočiai, kurią bando išmokyti algoritmas. Sinapsių ir neuronų sandaugų suma sudaro aktyvavimo funkciją, kuri apriboja neurono išvesties amplitudę. Naudojant aktyvavimo funkciją yra nustatoma, ar ir koku mastu išvesties signalas toliau turėtų būti siunčiamas per tinklą. Jei signalas praeina, neuronas tampa „aktyvuotas“ (Selman, 2012; MahdaviFar ir Ghorbani, 2019). 2 paveikslas vaizduoja neurono tinklo veiklos struktūrą.




2 paveikslas. Neuronų tinklo veiklos struktūra (Love, 2007)

Visų pirma yra sudedamos neuronų reikšmės, kurios buvo prieš tai prijungtuose stulpeliuose. Paveiksle vaizduojami keturi signalai ( $X_1, X_2, X_3, X_4$ ), taigi turime keturis neuronus besijungiančius prie vieno. Kiekvienas signalas yra sudauginamas iš atitinkamo svorio ( $w_1, w_2, w_3, w_4$ ). Kiekviena neuronų jungtis turi savo svorius reikšmes, kurios yra vienintelės kintančios mokymosi proceso metu. Trečiu žingsniu yra gaunama sandaugų suma. Suma keliauja į aktyvacijos funkciją, kuri dažniausiai yra pakeičiama į reikšmę nuo 0 iki 1. Tam dažniausiai naudojama Sigmoido funkcija, dar vadinama logistine funkcija (3 paveikslas). Gauta reikšmė, siunčiama toliau, kaip signalas kitam neuronui (Selman, 2012; MahdaviFar ir Ghorbani, 2019). Pagrindinė neuronų tinklo užduotis yra sugeneruoti išvesties rezultata kiekvienam signalui. Iš pradžių algoritmas bando nustatyti ir suderinti teisingų atsakymų skaičių, taip kartais tiesiog atspėjant atsakymus. Spėjimai lyginami su realiai duomenimis, pagal ką keičiami parametrai, kol gaunamas rezultatas, taptų panašesnis į pateiktus „tikruosius“ duomenis. Taigi, kol algoritmas „mokosi“ jis tūkstančius kartų spėlioja, lygina, priskiria svorius ir vėl lygina rezultatus, kol spėlionės nustoja tikslėti arba tikslumas tampa per mažas tolesniam tikslinimui (Tang et al., 2018).



3 paveikslas. Sigmoido funkcija (Chang et al., 2012)

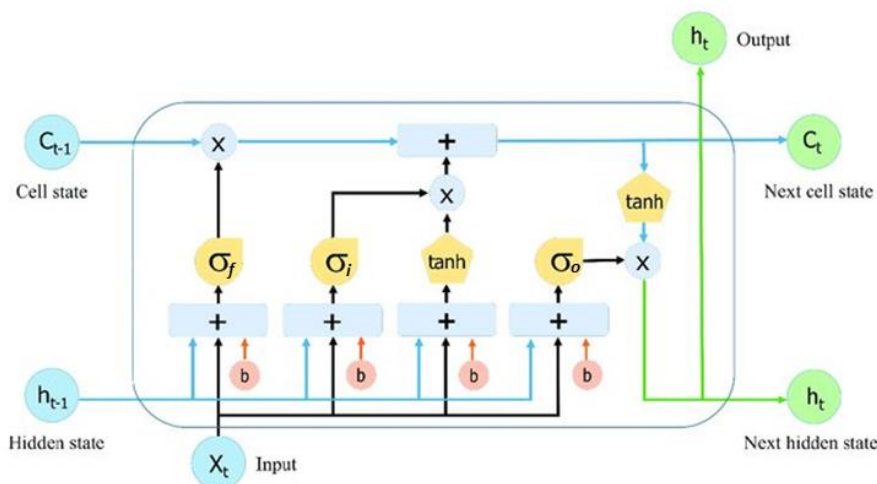
Pagrindinis giliojo mokymosi skiriasis bruožas nuo kitų mašininio mokymosi metodų yra, tai, kad giliojo mokymosi algoritmas klasifikuoja ir mokosi daugiau pagal sutapimus ir tam tikrus aptinkamus duomenų bruožus, negu specifinių užduočių algoritmus. Tai yra naudinga kriptovaliutų prognozavimui, kai pateikus didelį duomenų kiekį, algoritmas surenka panašius kainų pokyčius. Taip pat algoritmo klasifikatoriai mokosi su įvairiu duomenų kiekiu, kurio rezultato tikslumas gerėja didėjant duomenų kiekiui (4 paveikslas) (Tang et al., 2018).



4 paveikslas. Duomenų kiekio įtaka dirbtinio intelekto metodų rezultatų tikslumui (Tang et al., 2018)

Ilgalaikės trumpalaikės atminties tinklas (LSTM) yra besikartojančių neuronų tinklo (angl. *recurrent neural network*, toliau RNN) algoritmo tęsinys (Hochreiter ir Schmidhuber, 1997). RNN algoritmas geba aptikti stebimų duomenų sekas ir jas tiksliai suklasifikuoti pagal koreliacijos stiprumą. Siekiant pašalinti RNN algoritmo netikslumus besimokant iš laiko-eilučių duomenų, buvo sukurta patobulinta jo versija, kuri geba apdoroti ir mokytis iš ilgesnių laiko eilučių – LSTM (Nakisa et al., 2018). Būtent dėl šios priežasties LSTM yra tinkamas metodas kriptovaliutų kainų prognozavimui. Straipsnio tikslui pasiekti bus taikomas sekos eilės mokymosi regresinis modelis (angl. *sequence-to-sequence learning*). Šiame ilgalaikės trumpalaikės atminties modelio mokymo būde gauti atsakymai yra mokymosi seka, kurios reikšmės keičiasi per vieną periodą. To pasėkoje, kiekvienos įvesties laiko žingsnyje, LSTM tinklas mokosi numatyti kito laiko žingsnio reikšmę.

Taikant šį prognozavimo metodą, LSTM algoritmas mokosi prognozuoti. Tam kad būtų vykdomi žemiau pateikti modelio mokymosi žingsniai (5 paveikslas) taikomas algoritmo kodas:



5 paveikslas. Ilgalaikės trumpalaikės atminties neuronų tinklo struktūra (Le et al., 2019)

LSTM tinklas yra sudarytas iš atminties bloků, kurie vadinami ląstelėmis (angl. *cells*). Duomenų srauto judėjimą sudaro būsenų perdavimas iš vienos ląstelės į kitą: ląstelės būsenos ( $C_{t-1}$ ), kuri siunčia paskutinio LSTM vieneto atminties informaciją ir paslėptos būsenos ( $h_{t-1}$ ) – paskutinė LSTM vieneto išvestis. Paslėptoji būseną veikia, kaip neuronų tinklo atmintis – saugo informaciją iš apdorotų duomenų prieš tai. Ši būseną gaunama sudarant vektorių iš esamos ir buvusių įvesčių, taip saugant informaciją apie ne tik esamą bet ir visas buvusias įvestis. Vektorius toliau

keliauja per aktyvacijos funkciją ( $\sigma$ ), kurios gautas rezultatas yra nauja paslėpta būseną ( $h_t$ ), kuri toliau keliauja link naujos įvesties ( $X_t$ ) (Le et al., 2019).

Duomenys iš ląstelės gali būti pašalinti arba pridėti per sigmoido vartus, kartais dar vadinamus reguliatoriais (angl. *sigmoid gate*). Vartai yra sudaryti iš svorių. LSTM dažniausiai turi tris vartus: įvesties ( $\sigma_i$ ), išvesties ( $\sigma_o$ ) ir pamiršimo ( $\sigma_f$ ). Jų paskirtis yra skirstyti ir reguliuoti duomenų srautus. Išvesties vartai atskiria, kuri informacija turėtų būti palikta, o kuri išmesta. Čia, jei iš sigmoido funkcijos gauta reikšmė yra arti 0, vadinasi, turi būti pamiršta, jei, kuo arčiau 1 – išsaugota. Įvesties vartai skirti ląstelės būsenos atnaujinimui. Čia pirmiausia paskutinė paslėpta būseną ir nauja įvesties suma yra paverčiami į reikšmę, nuo 0 iki 1, naudojant sigmoido funkciją. Suma neuroniniais tinklais keliauja ir į tanh funkciją, kur priskiriama reikšmė nuo -1 iki 1, tam kad tinklas būtų sureguliuotas. Abiejų funkcijų išskirtys yra sudauginamos ir keliauja į sigmoido funkciją, kur vėl yra sprendžiama ar rezultatas turėtų būti atsimintas ar pamirštas. Apdorota informacija keliauja link prieš tai buvusios ląstelės būsenos ( $C_{t-1}$ ), kurios reikšmė yra sudauginama su pamiršimo vartų išvestimi. Gauta sandauga yra susumuojama su įvesties ir tanh funkcijų sandauga. Ši išvestis keliauja toliau, kaip atnaujinta ląstelės funkcija –  $C_t$  (Tran et al., 2018).

Išvesties vartai skirti paslėptos ląstelės būsenos atnaujinimui. Tam prieš tai esanti paslėpta ląstelės būsenos reikšmė siunčiama į sigmoido funkciją, kartu su nauja įvestimi. Tuomet gauta reikšmė sudauginama su reikšme gauta siunčiant atnaujintą ląstelę ( $C_t$ ) į tanh funkciją. Sandauga yra nauja paslėpta išvestis ( $h_t$ ). Apibendrinant, vartai mokosi, kuriuos duomenis reikia palikti, kuriuos išmokti ir saugoti. Tokiu būdu informacija perduodama ilgoje sekų grandinėje (Tran et al., 2018).

Tyrimo praktinėje dalyje ilgalaikės trumpalaikės atminties modelio algoritmas mokomas prognozuoti kriptovaliutos kainą. Tyrimui buvo pasirinktos penkios kriptovaliutos, pagal jų kapitalizaciją rinkoje, remiantis naujausiais coinmarketcap.com duomenimis: Bitcoin, XRP, Bitcoin Cash, Litecoin, Binance Coin. Algoritmo mokymui yra pasirinktas kasdieninis uždarymo kainos kitimas periodui nuo 2017 m. sausio 1 iki 2019 m. spalio 31. Duomenys surinkti iš finance.yahoo.com atviros prieigos svetainės. Žemiau pateikti, duomenų prognozavimo žingsniai:

- Algoritmas mokosi nuspėti reikšmes naudojant prieš tai buvusių laiko eilutės reikšmę iš eilės pagal seką, taip paslenkant kiekvieną buvusią vertę per vieną laiko žingsnį. Mokymuisi bus testuojama ir mokomasi iš 90 % pateiktų duomenų, likusius 10 % prognozuojant ir vertinant nuokrypį nuo gautų reikšmių ir realių duomenų.
- Kad algoritmo mokymasis būtų tikslesnis ir neiškryptų, duomenys standartizuojami, taip kad vidurkio ir vieneto dispersija būtų lygi nuliui. Duomenų prognozavimui bus naudojami tokie patys parametrai, kaip ir treniruočių duomenims.
- Domenų prognozavimui algoritmas mokomas su kiekviena nauja įvestimi numatyti būsimą reikšmę. Taigi algoritmas mokysis iš numatytų reikšmių sekos principu.
- Numatytos reikšmės lyginamos su mokymosi duomenimis skaičiuojant kvadratų vidurkio kvadratinės šaknies nuokrypį (angl. *root mean square error*, toliau RMSE).
- Naudojant realius duomenis, LSTM tinklas bus atnaujintas, tam kad prognozuojant sekančią laiko žingsnio reikšmę, būtų naudojami realūs duomenys, vietoj prieš tai išprognozuoto.
- Vertinamas prognozavimo tikslumas, skaičiuojant kvadratų vidurkio kvadratinės šaknies nuokrypius ir vidutinę absoliutinę procentinę paklaidą su atnaujintais duomenimis.

### 3. Giliojo mokymosi algoritmo taikymo kriptovaliutų kainų prognozavimui tyrimas

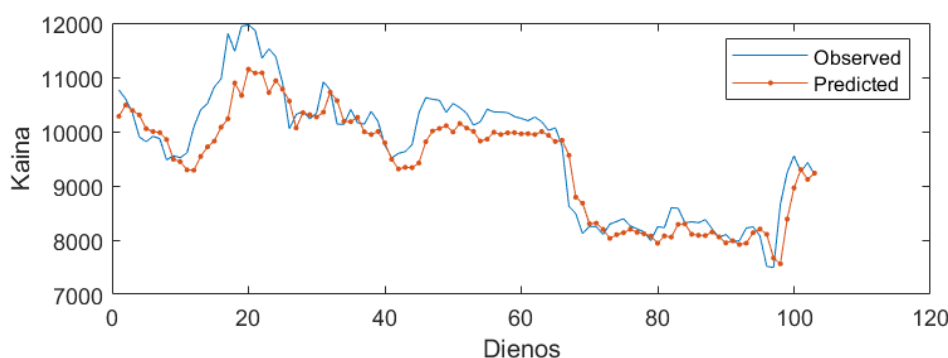
Tyrimas atliekamas naudojant Matlab programinę terpę, kuri yra skirta įvairiems matematiniais veiksmais atlikti, vienos iš jų – operacijos matricomis. Ši programa pasirinkta dėl savo neuroninių tinklų funkcijų rinkinio, kuris skirtas neuroninių tinklų kūrimui. Tyrimo metu visiems duomenims naudojami vienodi parametrai. Kad duomenys mokymosi proceso metu neiškryptų ir būtų tinkami neuronų tinklo formavimui, nustatomi nulinio vidurkio ir vieneto dispersijos standartizavimo reikšmės. Kadangi duomenų kiekis didelis, nustatoma, kad LSTM sluoksnis turės 200 paslėptųjų jungčių. Prognozavimas vyks sekos principu, tam algoritme nurodama, kad mokymasis vyktų iš išvesties, t. y. su kiekvieną įvestimi, LSTM numatys sekantį žingsnį, jo atsakymas bus naudojamas kito žingsnio numatymui ir t. t. dėl ko mokymasis neturi galutinės mokymosi įvesties. Tam, kad prognozavimas būtų tikslus, duomenų atnaujinimui nurodoma 300 epochų. Šios epochos reprezentuoja, kiek kartų visi mokymo vektoriai bus naudojami svorių atnaujinimui. Šiame etape 90 % testuojamų duomenų yra naudojami mokymuisi prieš svorių atnaujinimą.

Lentelė 1 pateikia testuojamų kriptovaliutų atnaujinto neuronų tinklo prognozavimo kvadratų vidurkio kvadratinės šaknies nuokrypį prognozuotam laikotarpiui ir vidutinę absoliutinę procentinę paklaidą (angl. *mean absolute percentage error*, toliau MAPE) pirmą prognozės savaitę. Čia MAPE reprezentuoja prognozavimo tikslumą – paklaidos dydį procentais nuo tikrųjų reikšmių, RMSE parodo nuokrypių sklaidą, tad kuo didesnis RMSE, tuo didesnis prognozių nuokrypiai nuo realių reikšmių.

1 lentelė. Prognozavimo su atnaujintai duomenimis nuokrypiai (sudaryta autorių)

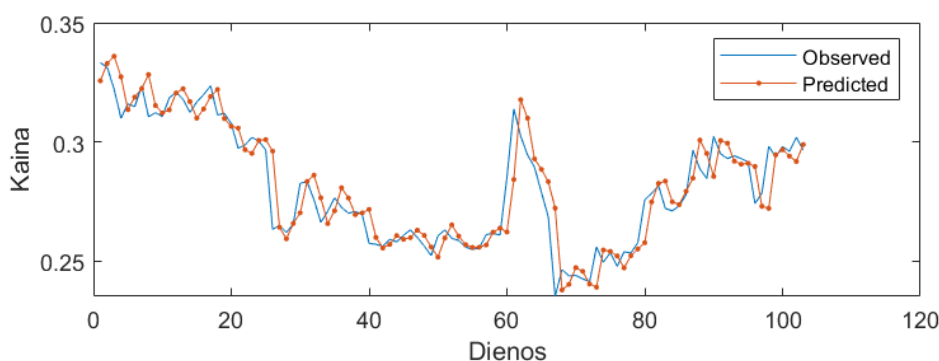
	Bitcoin	XRP	Bitcoin Cash	Litecoin	Binance Coin
RMSE	459,68	0,0097	13,11	2,9338	1,96
MAPE	0,813 %	0,027 %	0,033 %	0,024 %	0,027 %

Iš 1 lentelės matome, kad didžiausias tiek RMSE tiek MAPE nuokrypis yra Bitcoin kriptovaliutos duomenims. Tai galimai yra dėl to, kad tai pati nepastoviausia kriptovaliuta, turinti didžiausią kapitalizaciją ir investuotojų susidomėjimą, kas lemia akivaizdžią RMSE reikšmės atotrūkį, nuo likusių rezultatų. Kadangi Bitcoin kainos pokyčiai taip pat jautresni tiek ekonomikos svyravimams, tiek socialinėse erdvėse vyraujantiems vartotojų lūkesčiams, algoritmui yra sunkiau mokytis ir tiksliau prognozuoti kainos pokyčius, ko pasėkoje nuokrypis yra didžiausias. Tačiau žvelgiant į 6 paveikslą, matome, kad kainos kitimo tendencija atitinka realius duomenis. Iš prognozės grafiko, pastebima, kad modelio prognozės pateikė žemesnes, negu realias kainas.




6 paveikslas. LSTM prognozės su atnaujintai duomenimis Bitcoin kriptovaliutai (sudaryta autorių)

Žvelgiant į tiksliausias prognozes, čia galima išskirti dvi kriptovaliutas – Ripple (XRP), turintį mažiausią RMSE ir Litecoin, su mažiausiu MAPE. 7 paveikslas vaizduoja XRP kriptovaliutos prognozes su atnaujintais duomenimis. Visų pirma pastebima, kad kainos kitimo tendencija yra tarsi pasislinkusi per vieną laiko žingsnį. Taip pat iš paklaidos sklaidos matome, kad ji yra tolygiai pasiskirsčiusi, vadinasi prognozuojama kaina buvo svyruojanti – tiek didesnė, tiek mažesnė negu realūs duomenys. Stebina, tai, kad modelis išprognozavo ganėtinai staigų kainos šuolį ir kritimą 60–70 dienomis, tiek visą kainos kitimo tendenciją. Tam įtakos gali turėti žemesnė kriptovaliutos kaina, ko pasėkoje gaunama mažesnė paklaidos sklaida.




7 paveikslas. LSTM prognozės su atnaujintai duomenimis XRP kriptovaliutai (sudaryta autorių)

Žvelgiant į Litecoin prognozių rezultatus 8 paveiksle, taip pat yra matomas tikslus realių duomenų atkartojimas, tiek ties kainos dydžiu, tiek pačia kainos kitimo tendencija. Besimokydamas iš Litecoin duomenų, algoritmas tiksliau išpranašavo, kainos dydžius, negu XRP kriptovaliutai, tai pastebima ne vien tik iš MAPE geresnio rezultato, bet ir iš to, kad prognozuojama linija yra šiek tiek labiau „užlipus“ ant stebimų duomenų.



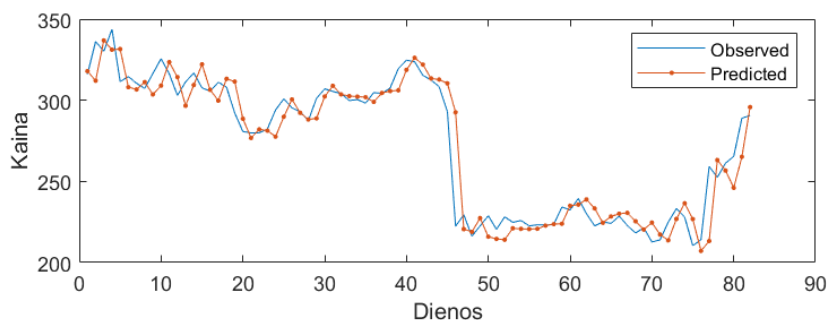
8 paveikslas. LSTM prognozės su atnaujintai duomenimis Litecoin kriptovaliutai (sudaryta autorių)

Iš 1 lentelės matome, kad Binance Coin turi mažiausią RMSE nuokrypį po XRP kriptovaliutos bei tik 0,003 % didesnį MAPE nuo mažiausio rezultato. Tačiau iš 9 paveikslas matome, kad prognozuojamų duomenų atotrūkis pastebimai didesnis ir beveik visą prognozuojamą laikotarpį laikosi aukščiau realių kainų, lyginant su kitomis prognozėmis.



9 paveikslas. LSTM prognozės su atnaujintai duomenimis Binance Coin kriptovaliutai (sudaryta autorių)

10 paveiksle vaizduojama antra pagal nuokrypį netikslingiausiai išprognozuotos kriptovaliutos – Bitcoin Cash – vertės raida. Prognozės atrodo netgi tikslesnė už Litecoin, tačiau RMSE yra didesnis. Tam įtakos turi kainų skirtumai, mat lyginant pagal MAPE santykinį nuokrypį, Bitcoin Cash rezultatai yra tik 0,03 %.



10 paveikslas. LSTM prognozės su atnaujintai duomenimis Bitcoin Cash kriptovaliutai (sudaryta autorių)

Apibendrinant galima teigti, kad LSTM modelis tiksliai atvaizduoja kainos kitimo tendenciją. Pastebima, kad mažesnės kainos kriptovaliutų prognozės yra tikslesnės ir su mažesne paklaida. LSTM modelis visoms penkioms kriptovaliutoms prognozavo realius duomenis atitinkančias kainų kitimo tendencijas. Nors giliojo mokymosi algoritmas neatkartoja tiksliai būsimų kainų prognozių, nuokrypis yra sąlyginai mažas – neperkopia 0,8 % didžiausią kapitalizaciją turinčiomis kriptovaliutomis. Tokie rezultatai leidžia prognozuoti, kad dirbtinio intelekto technologijos bus sparčiai integruojamos į finansų rinką, taip plečiant finansinių paslaugų šaką elektroninėje erdvėje tiek privatiems asmenims, tiek įmonėms. Kriptovaliutų perdavimo ir vertės kitimo stebėjimo bei investavimo raliu laiku poreikis stimuliuoja paklausą ir galimybes fintech produktams, kurie leistų vartotojui saugiai, greitai ir patogiai dalyvauti kriptovaliutų rinkoje bei integruoti kriptografijos bei giliojo mokymosi technologijas į verslo modelius.



## Išvados

Dauguma mokslininkų kriptovaliutas apibūdina kaip virtualų turtą, kurio paskirtis yra būti mainų priemone ar terpe, kur reguliacinės įstaigos kriptovaliutas mato, kaip nereguliuojamą virtualią vertės išraišką, kuri gali būti naudojama, kaip pinigų alternatyva bei investavimo priemonė. Užtikrintumo ir saugumo poreikis, skatina turėti mechanizmą ar prognozavimo modelį, kuris tai atliktų už juos ir garantuotų pelną su mažiausia rizika.

Mokslinės literatūros apžvalgos parodė, kad yra keli dirbinio intelekto naudojimo modeliai, kurie gali būti pritaikyti kriptovaliutų kainų ir operacijų prognozavime. Vieni iš dažniausiai naudojamų modelių buvo LSTM ir Random Forest. Tyrimui pasirinktas ilgalaikės trumpalaikės atminties tinklo algoritmas, dėl laiko-eilučių duomenų apdorojimo pritaikomumo. Gauti rezultatai parodė, kad prognozių paklaida yra didesnė kriptovaliutomis, turinčioms istoriškai didesnę kainos svyravimą, lyginant su stabilesnėmis, žemesnę kainą turinčios kriptovaliutomis. Nepaisant to, vidutinė absoliutinė procentinė paklaida analizuotoms kriptovaliutomis neviršijo 0,8 %, ką galima laikyti geru prognozavimo rezultatu. Taigi galima teigti, kad LSTM modelis yra tinkamas kriptovaliutų kainų prognozavimui. Remiantis šiais rezultatais, giliojo mokymosi algoritmų bei kriptografijos technologija gali būti pritaikyta sudarant optimalius investicinius portfelius bei jų rizikos valdyme. Šių technologijų pritaikymas finansų rinkoje užtikrintų finansinių pavedimų saugumą, greitį ir anonimiškumą. Plečiantis kriptovaliutų pritaikymui ir dvipusiškiškumui, auga fintech paslaugų paklausa bei reguliacinė reikmė, užtikrinanti finansinį makroekonomikos stabilumą. Visos šios technologinės galimybės kelia gilesnio tyrimo reikalaujančią problemą: kaip išlaikyti finansinį stabilumą, kai finansų dalyviai vis labiau remiasi kompiuterio sprendimais bei renkasi ncentralizuotas ir nereguliuojamas investavimo priemones. Tai verčia hipnotizuoti, kas bus jei visi finansų rinkos dalyviai žinos kaip uždirbti su maža rizika? Apibendrinant, giliojo mokymosi algoritmų pritaikymas investavimo procese, tiek pačios kriptovaliutų rinkos vystymasis rodydamas daug potencialo, neslepia ir galimų rizikų.

## Literatūra

- Aldweesh, A., Derhab, A., & Emam, A. Z. (2019). Deep learning approaches for anomaly-based intrusion detection systems: A survey, taxonomy, and open issues. *Knowledge-Based Systems*, 189, 105124. <https://doi.org/10.1016/j.knosys.2019.105124>
- Andrianto, Y. (2017). The effect of Cryptocurrency on investment portfolio effectiveness. *Journal of Finance and Accounting*, 5(6), 229–238. <https://doi.org/10.11648/j.jfa.20170506.14>
- Baur, D. G., Hong, K. H., & Lee, A. D. (2018). Bitcoin: Medium of exchange or speculative assets? *Journal of International Financial Markets, Institutions and Money*, 54, 177–189. <https://doi.org/10.1016/j.intfin.2017.12.004>
- Chang, J., Arbeláez, P., Switz, N., Reber, C., Tapley, A., Davis, J. L., Cattamanchi, A., Fletcher, D., & Malik, J. (2012). Automated tuberculosis diagnosis using fluorescence images from a mobile microscope. In N. Ayache, H. Delingette, P. Golland, & K. Mori (Eds.), *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2012*. (Lecture Notes in Computer Science, Vol. 7512). Springer. [https://doi.org/10.1007/978-3-642-33454-2\\_43](https://doi.org/10.1007/978-3-642-33454-2_43)
- Chen, Z., Li, C., & Sun, W. (2020). Bitcoin price prediction using machine learning: An approach to sample dimension engineering. *Journal of Computational and Applied Mathematics*, 365, 112395. <https://doi.org/10.1016/j.cam.2019.112395>
- Chohan, U. (2018). Cryptocurrencies: A brief thematic review. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.3024330>
- Dourado, E., & Brito, J. (2014). Cryptocurrency. *The New Palgrave Dictionary of Economics*, 50(1), 1–10. <https://doi.org/10.1016/j.jempfin.2018.11.002>
- Feuerriegel, S., & Fehrer, R. (2016). *Improving decision analytics with deep learning: The case of financial disclosures*. Paper presented at the 24<sup>th</sup> European Conference on Information Systems, ECIS 2016.
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Kim, Y. B., Kim, J. G., Kim, W., Im, J. H., Kim, T. H., Kang, S. J., & Kim, C. H. (2016). Predicting fluctuations in cryptocurrency transactions based on user comments and replies. *PLoS ONE*, 11(8), 0161197. <https://doi.org/10.1371/journal.pone.0161197>
- Lahmiri, S., & Bekiros, S. (2019). Cryptocurrency forecasting with deep learning chaotic neural networks. *Chaos, Solitons and Fractals*, 118, 35–40. <https://doi.org/10.1016/j.chaos.2018.11.014>
- Le, X. H., Ho, H. V., Lee, G., & Jung, S. (2019). Application of Long Short-Term Memory (LSTM) neural network for flood forecasting. *Water (Switzerland)*, 11(7). <https://doi.org/10.3390/w11071387>
- Lietuvos Bankas. (2017). *Lietuvos bankas skelbia poziciją dėl virtualiųjų valiutų*. <https://www.lb.lt/lt/naujienos/lietuvos-bankas-skelbia-pozicija-del-virtualiuju-valiutu>
- Lietuvos Respublikos Seimas. (2018). *Lietuvos Respublikos elektroninių pinigų ir elektroninių pinigų įstaigų įstatymo Nr. XI-1868 pakeitimo įstatymas* (XIII-1094). <https://e-seimas.lrs.lt/portal/legalAct/lt/TAD/dbe23950488011e89197e1115e5d8bec/KnGurqJGeD?positionInSearchResults=2&searchModelUUID=b12ba5d1-1a92-405d-b771-123d20928ad2>
- Love, J. (2007). Artificial Neural Networks. In *Process Automation Handbook* (pp. 929–943). [https://doi.org/10.1007/978-1-84628-282-9\\_109](https://doi.org/10.1007/978-1-84628-282-9_109)

- Madan, I., Saluja, S., & Zhao, A. (2015). *Automated Bitcoin trading via machine learning algorithms*. [http://cs229.stanford.edu/proj2014/Isaac Madan, Shaurya Saluja, Aojia Zhao,Automated Bitcoin Trading via Machine Learning Algorithms.pdf](http://cs229.stanford.edu/proj2014/Isaac%20Madan,%20Shaurya%20Saluja,%20Aojia%20Zhao,Automated%20Bitcoin%20Trading%20via%20Machine%20Learning%20Algorithms.pdf)
- Mahdavifar, S., & Ghorbani, A. A. (2019). Application of deep learning to cybersecurity: A survey. *Neurocomputing*, 347, 149–176. <https://doi.org/10.1016/j.neucom.2019.02.056>
- Mai, F., Shan, Z., Bai, Q., Wang, X. (Shane), & Chiang, R. H. L. (2018). How does social media impact bitcoin value? A test of the silent majority hypothesis. *Journal of Management Information Systems*, 35(1), 19–52. <https://doi.org/10.1080/07421222.2018.1440774>
- Platanakis, E., & Urquhart, A. (2019). Portfolio management with cryptocurrencies: The role of estimation risk. *Economics Letters*, 177, 76–80. <https://doi.org/10.1016/j.econlet.2019.01.019>
- Power, D. J. (2014). Using ‘Big Data’ for analytics and decision support. *Journal of Decision Systems*, 23(2), 222–228. <https://doi.org/10.1080/12460125.2014.888848>
- Rebane, J., Karlsson, I., Denic, S., & Papapetrou, P. (2018, August). *Seq2Seq RNNs and ARIMA models for cryptocurrency prediction: a comparative study*. Paper presented at the SIGKDD Fintech’18 (pp. 2–6).
- Schueffel, P. (2017). *The concise Fintech compendium*. [http://www.heg-fr.ch/FR/HEG-FR/Communication-et-evenements/evenements/SiteAssets/Pages/patrick-schueffel/Schueffel \(2017\) The Concise Fintech compendium.pdf](http://www.heg-fr.ch/FR/HEG-FR/Communication-et-evenements/evenements/SiteAssets/Pages/patrick-schueffel/Schueffel%20(2017)%20The%20Concise%20Fintech%20compendium.pdf)
- Selman, S. (2012). Distinction of the authors of texts using multilayered feedforward neural networks. *Southeast Europe Journal of Soft Computing*, 1(1). <https://doi.org/10.21533/scjournal.v1i1.82>
- Sun, X., Liu, M., & Sima, Z. (2020). A novel cryptocurrency price trend forecasting model based on LightGBM. *Finance Research Letters*, 32, 101084. <https://doi.org/10.1016/j.frl.2018.12.032>
- Talo, M., Baloglu, U. B., Yıldırım, Ö., & Rajendra Acharya, U. (2019). Application of deep transfer learning for automated brain abnormality classification using MR images. *Cognitive Systems Research*, 54, 176–188. <https://doi.org/10.1016/j.cogsys.2018.12.007>
- Tang, A., Tam, R., Cadrin-Chênevert, A., Guest, W., Chong, J., Barfett, J., ... Shabana, W. (2018, May 1). Canadian association of radiologists white paper on artificial intelligence in radiology. *Canadian Association of Radiologists Journal*, 69, 120–135. <https://doi.org/10.1016/j.carj.2018.02.002>
- Theblockcrypto.com. (2019). *Bitcoin has been the most volatile and best performing major cryptocurrency in June - The Block*. <https://www.theblockcrypto.com/linked/29595/bitcoin-has-been-the-most-volatile-and-best-performing-major-cryptocurrency-in-june>
- Torres, G. D., & Qiu, H. (2018). *Applying recurrent neural networks for multivariate time series forecasting of volatile financial data* (pp. 1–10). <https://www.researchgate.net/project/Applying-Recurrent-Neural-Networks-for-Multivariate-Time-Series-Forecasting-of-Volatile-Financial-Data>
- Tran, D., Mac, H., Tong, V., Tran, H. A., & Nguyen, L. G. (2018). A LSTM based framework for handling multiclass imbalance in DGA botnet detection. *Neurocomputing*, 275, 2401–2413. <https://doi.org/10.1016/j.neucom.2017.11.018>
- Zhong, G., Ling, X., & Wang, L. (2018). From shallow feature learning to deep learning: Benefits from the width and depth of deep architectures. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 9(1) <https://doi.org/10.1002/widm.1255>

## FORECASTING OF DIGITAL CURRENCY PRICES USING DEEP LEARNING ALGORITHM

Nijolė MAKNICKIENĖ, Kristina MIŠKINYTĖ

**Abstract.** Cryptocurrencies are still a novelty in the financial market which is not fully explored yet. This makes cryptocurrencies an interesting and relevant topic for researchers, regulators and investor. The cryptocurrency market is constantly growing, volatile and ever-changing, making it extremely risky for investments. Financial literacy, long-term prescience and correct focus without getting lost in chaos of risk, value and unpredictability are especially important in today's economy. Due to complex nature of the cryptocurrency market the large amount of profile data is generated, which can be processed using a variety of methods such as statistical, technical, sentiment, solution and other analysis. Previous studies have used two main method for cryptocurrency prices prediction: empirical and machine learning algorithm analysis. The aim of this article is to test the applicability of LSTM deep learning algorithm for cryptocurrency price forecasting as well as to evaluate the results. The research results showed that deep learning algorithm are able to forecast with low error magnitude, moreover trend of predicted values is accurate when compared to observed values. The results suggest that deep learning algorithm application for forecasting of cryptocurrency market price is a suitable alternative for risk minimization.

**Keywords:** artificial intelligence, deep learning, LSTM, forecasting, cryptocurrencies, cryptocurrencies market.