

UOT 004.056:351

DOI: 10.25045/jpit.v11.i1.10

*İmamverdiyev Y.N.*

AMEA İnformasiya Texnologiyaları İnstitutu, Bakı, Azərbaycan  
[yadigar@iit.science.az](mailto:yadigar@iit.science.az)

## BİTKOİNİN QİYMƏTİNİN PROQNOZLAŞDIRILMASI ÜÇÜN DƏRİN LSTM METODU

Daxil olmuşdur: 30.05.2019 Düzəliş olunmuşdur: 14.06.2019 Qəbul olunmuşdur: 02.07.2019

*Məqalədə Bitkoinin mübadilə kursunu proqnozlaşdırmaq üçün dərin neyron şəbəkə arxitekturası təklif olunur. Arxitekturanın əsasını rekurrent neyron şəbəkələrinin bir növü olan LSTM (ing. Long-Short Term Memory) təşkil edir. Son dövrlər kriptovalyutalar əhəmiyyətli maliyyə alətinə çevriliblər və bu səbəbdən onların ənənəvi valyutalara mübadilə kurslarının proqnozlaşdırılması məsələsi olduqca aktualıq qazanmışdır. Bitkoin ilk kriptovalyutadır, hazırda kriptovalyutaların ümumi bazar kapitallaşmasının yarısından çoxu ona məxsusdur və kriptovalyuta dünyasının “qızılı” rolunu oynayır, yəni digər kriptovalyutaların qiyməti çox zaman Bitkoin ilə ifadə edilir. Məhz bu səbəbdən Bitkoin kursunun proqnozlaşdırılması məsələsinə baxılmışdır və bir neçə il əhatə edən böyük həcmli real verilənlərlə eksperimentlərdə təklif edilmiş dərin LSTM yanaşması Bitkoin zaman sıralarının proqnozlaşdırılmasında geniş istifadə edilən statistik metodlarla müqayisədə daha üstün nəticələr göstərmişdir. Alınmış nəticələr həm kriptovalyutalarla ötəri maraqlanan adi istifadəçilər, həm də kriptovalyutalar sahəsində fəal işləyən investorlar üçün əhəmiyyətlidir. Əldə edilmiş nəticələr həmçinin dərin təlim yanaşmalarının kriptovalyutalara aid qeyri-stasionar zaman sıralarının intellektual analizinin digər məsələlərinə tətbiqində də kifayət qədər məhsuldar ola biləcəyini təsdiqləyir.*

**Açar sözlər:** Bitkoin, kriptovalyuta, zaman sıraları, proqnozlaşdırma, rekurrent neyron şəbəkələri, dərin təlim, LSTM.

### Giriş

Son on ildə meydana çıxan Bitkoin və digər kriptovalyutalar hazırda çox cəlbedici maliyyə alətlərinə çevriliblər [1]. Coinmarketcap.com saytının məlumatına görə, 22 may 2019-cu il tarixində kriptovalyutaların ümumi bazar kapitallaşması təxminən 238 milyard ABŞ dolları təşkil edirdi. Kriptovalyuta bazarının ümumi həcmi xeyli böyükdür, lakin bu nisbətən yeni maliyyə alətinin davranışının öyrənilməsi hələlik başlanğıc mərhələdədir. Kriptovalyutalar ənənəvi valyutalarla müqayisədə yüksək volatillik və spekulativlik ilə xarakterizə olunurlar [2]. Onların davranışının proqnozlaşdırılması həm milli, həm də korporativ səviyyədə böyük əhəmiyyətə malikdir. Ölkələr öz milli iqtisadi siyasətlərini müəyyən etmək, şirkətlər isə valyuta risklərini daha yaxşı idarə etmək və aktivlərdən səmərəli istifadə etmək üçün kriptovalyuta kurslarının qeyri-stabilliyini başa düşməyə çalışırlar. Buna görə kriptovalyutaların mübadilə qiymətlərinin ölçülməsi, proqnozlaşdırılması və modelləşdirilməsi yeni formalaşmaqda olan vacib tədqiqat istiqamətlərindən biridir [3].

Kriptovalyutaların kursunun qiymətləndirilməsi üçün zaman sıralarından istifadə edilməsi praktikada geniş yayılıb. Lakin kriptovalyutalar üzrə zaman sıraları, adətən, çox mürəkkəb, qeyri-stasionar və olduqca küylü olurlar [4]. Kriptovalyutaların xaotik təbiəti ARIMA (ing. *Auto-Regressive Integrated Moving Average*) kimi klassik zaman sıraları modellərinin tətbiqini çox çətinləşdirir, çünki onlar zaman sıralarının paylanmasına və stasionarlığına ciddi şərtlər irəli sürürlər [5]. Digər tərəfdən, maşın təlimi metodları [6], o cümlədən dərin təlim yanaşması (ing. *Deep Learning, DL*) maliyyə zaman sıralarının proqnozlaşdırılmasında getdikcə böyük diqqət çəkir [7, 8], çünki dərin neyron şəbəkələri əlamətləri avtomatik çıxarmaq imkanına malikdir, buna görə aprior analiz aparmağı və zaman sıralarının strukturunu əvvəlcədən bilməyi tələb etmir və qeyri-stasionar zaman sıralarına münasibətdə kifayət qədər etibarlıdırlar [9].

Bu tədqiqatın məqsədi kriptovalyutaların mübadilə kursunun daha dəqiq proqnozlarının

işlənməsi üçün dərin neyron şəbəkələrinin yuxarıda göstərilmiş potensialından istifadə etməkdir. Tətbiq obyektini kimi Bitkoin seçilmişdir, çünki Bitkoin ilk və ən məşhur kriptovalyuta olmaqla yanaşı, kriptovalyuta bazarının yarısından çoxunu tutur və digər kriptovalyutalar üçün bir növ “qızıl” rolunu oynayır və onların qiyməti çox zaman Bitkoin ilə ifadə edilir.

### Bitkoinin bəzi xüsusiyyətləri

Bitkoinin qiymətini dəqiq proqnozlaşdırmaq üçün onun qiymətinə təsir edən müxtəlif faktorları nəzərə almaq lazımdır. Bitkoinin qiymətini şərtləndirən əlamətlər haqqında təsəvvür əldə etmək üçün Bitkoin və ödəniş şəbəkəsi ilə əlaqəli müxtəlif verilənləri gündəlik qeydə almaqla xeyli müddət ərzində toplamaq lazımdır. Bu məqsədlə bu bölmədə Bitkoinin bəzi xüsusiyyətləri analiz edilir.

Bitkoin ilk kriptovalyutadır, onun konsepsiyası kimliyi hələ də anonim qalan Satoşi Nakomoto tərəfindən 31 oktyabr 2009-cu ildə açıqlanmışdı [10]. Bitkoin rəqəmsal pul mübadilələri üçün mərkəzləşməmiş, hər hansı aralıq vasitəçi olmayan mühit təqdim edir. Tranzaksiyalar maynerlər tərəfindən yoxlanılır və blok şəklində blokçeyn adlanan hamıya açıq reyestrə yazılır. Hər bir blokun başlığına özündən əvvəlki blokun başlığının SHA256 kriptografik heş funksiyası ilə iki dəfə hesablanmış heşi yazılır. Bununla da Bitkoin şəbəkəsində nə vaxtsa yerinə yetirilmiş bütün tranzaksiyalar bir zəncirlə əlaqələndirilmiş olur. Bu zəncirdə hər hansı tranzaksiyanı dəyişmək mümkün deyil, bunun üçün zəncirdəki bütün blokları dəyişmək lazımdır ki, bu da praktiki olaraq mümkün deyil. Qeyd edək ki, blokçeynə yeni blok yazmaq hüququnu əldə edən mayner hazırda 12,5 bitkoin qazanır, bunun üçün o, sıfır bitlərinin sayı verilmiş ədəddən kiçik olan heşi digər maynerlərdən tez hesablamalıdır (bu proses “Proof-of-Work” (PoW) protokolu kimi tanınır).

### Əlaqədar işlərin analizi

Qeyd edək ki, ən məşhur kriptovalyuta kimi Bitkoin kursunun proqnozu üçün bir çox analiz və tədqiqatlar aparılmışdır. İlk əvvəl, zaman sıralarının analizi üçün nəzərdə tutulmuş ARIMA, ARCH (*ing. Autoregressive Conditional Heteroskedasticity*) və GARCH (*ing. Generalized ARCH*) kimi statistik modellər tətbiq edilmişdir [5, 11, 12].

Gündəlik verilənlərdən istifadə etməklə Bitkoinin mübadilə kursunun (maksimal, minimal və bağlılaş qiymətləri) və Bitkoinin qiymətinin istiqamətinin proqnozlaşdırılmasına [13]-də baxılır. Əvvəlcə proqnozlaşdırmada ən relevant əlamətləri seçmək üçün əlamətlərin seçilməsinin müxtəlif metodları qiymətləndirilir. Sonra qiymətin istiqamətini proqnozlaşdırmaq üçün neyron şəbəkələrinin, dayaq vektorları metodunun (SVM) və ansambl alqoritmlərinin (rekurrent neyron şəbəkələri və  $k$ -ortalılar klasterizasiya metodu əsasında) davranışı analiz edilir. Neyron şəbəkələri və SVM metodları Bitkoinin maksimal, minimal və bağlılaş qiymətlərinin reqressiyası üçün istifadə edilir. Bundan başqa, reqressiyanın nəticələri qiymətin dəyişmə istiqamətinin proqnozunu yaxşılaşdırmaq üçün giriş verilənləri kimi istifadə edilir.

[14]-də dərin təlim metodları üç kriptovalyutanın: Bitcoin, Digital Cash və Ripple-in qiymətlərini proqnozlaşdırmaq üçün istifadə edilir. LSTM-in proqnozlaşdırma qabiliyyəti etalon sistem kimi istifadə edilən ümumiləşdirilmiş reqressiya neyron arxitekturasından xeyli yüksək olur. Baxılan etalon sistem qeyri-stasionar siqnalların yalnız lokal yaxınlaşmaları üçün yararlı olan Qauss nüvələrinə əsaslanır, buna görə qlobal qeyri-xətti gizli strukturları küyün dərəcəsiindən asılı olmadan approksimasiya edə bilmir. LSTM modelinin hesablama yükü böyük olsa da, kriptovalyuta bazarının xaotik dinamikasının proqnozlaşdırılmasında daha effektivdir.

Bitcoinin qiymətlərinin volatilliyini proqnozlaşdırmaq üçün [9] GARCH, neyron şəbəkələri və PCA metodunu (*ing. Principal Component Analysis*, ilkin emal üçün istifadə edilir) birləşdirən hibrid yanaşma təklif edir. Neyron şəbəkələri volatilliyin GARCH və törəmələrinin modelləşdirə bilmədikləri qeyri-xəttilik effektlərini tuta bilirlər.

[15] Bitkoinin mübadilə kursunun volatilliyini loqarifmik əmsalın gündəlik paylanmasıdan və reallaşdırılmış volatillikdən (5-dəqiqə əsasında loqarifmik əmsalların kvadratları cəmi) istifadə etməklə modelləşdirir. Müəlliflər reallaşdırılmış volatilliyin avtoreqressiya modelinin BTCUSD

verilənlər toplusuna kifayət qədər yaxşı tətbiq olunduğunu göstərir. Növbəti gün loqarifmik əmsalının qiymətləndirilməsi üçün 2 gizli layı olan irəli yayılma şəbəkəsi tətbiq edilir, sürüşən pəncərədən 10-günlük toplu istifadə edilir. Nəticələr belə neyron şəbəkəsinin proqnozunun loqarifmik əmsalın faktiki paylanması təxmini aproksimasiya etdiyini göstərir.

Kriptovalyutaların qiymətinin proqnozlaşdırılması KİV-lərin və investorların diqqətini cəzb edən cəlbedici mövzudur [16]. ARIMA kimi ənənəvi metodlara rəqib rekurrent neyron şəbəkələri (*ing. recurrent neural network, RNN*) ola bilərlər, həm də RNN müxtəlif endogen və ekzogen giriş mənbələri üçün əlverişlidir. Bu tədqiqatda ARIMA modelinin məhsuldarlığı müxtəlif giriş tipləri seçilməklə dərin rekurrent çoxlaylı neyron şəbəkəsi *seq2seq* ilə müqayisə edilir. Nəticələr *seq2seq* şəbəkəsinin məhsuldarlığının ARIMA ilə müqayisədə çox üstün olduğunu göstərir.

[17] Bitkoinin ABŞ dolları ilə qiymətinin istiqamətinin maşın təlimi metodları ilə proqnozlaşdırılmasının dəqiqliyini tədqiq edir. Qiymətlər haqqında verilənlər *Bitcoin Price Index*-dən əldə edilib. Bayes optimallaşdırılmış rekurrent neyron şəbəkəsi (RNN) və uzun-qısamüddətli yaddaş (LSTM) reallaşdırılıb. Dərin təlim modelləri ilə müqayisə etmək üçün zaman sıralarının proqnozlaşdırılmasında populyar model olan ARIMA da reallaşdırılmışdı. Gözlənilməli kimi, dərin təlim metodları ARIMA ilə müqayisədə daha dəqiq proqnoz verirlər.

[18] Bayes neyron şəbəkələrinin köməyi ilə Bitkoin proseslərinə aid zaman sıralarının analizi yolu ilə Bitkoinin qiymətinin proqnozlaşdırılması empirik tədqiq olunur (*ing. Bayesian neural network, BNN*). BNN transformasiya olunmuş çoxlaylı perseptronudur (*ing. MultiLayer Perceptron, MLP*), burada bütün çəkilərin ehtimal paylanması var. BNN “*overfitting*” hadisəsinə (maşın təlimi alqoritminin müəyyən verilənlərə izafi öyrəşməsinə) daha dayanıqlıdır və kiçik verilənlər toplusunda asanlıqla öyrənə bilir. Bitkoinin qiymətini proqnozlaşdırmaq üçün makroiqtisadi verilənlərlə yanaşı, blokçeyndən verilənlər də istifadə edilir, məsələn, blokun orta uzunluğu, blokdakı tranzaksiyaların sayı, orta təsdiqləmə müddəti, heşreyt, çətinlik, maynerlərin gəliri və s. Bu məlumatlar Bitkoinə olan tələb və təkliflə sıx bağlıdır və modellərin öyrədilməsi üçün onlardan istifadə edilməsi Bitkoinin qiymətinin proqnozlaşdırılması dəqiqliyini artırmağa imkan verir.

Yalnız Bitkoinin qiymətlər indeksi və çevrilmiş qiymətlərlə öyrədilmiş model aşağı proqnoz dəqiqliyi nümayiş etdirir. [19]-da Bitkoinin qiymətinin proqnozlaşdırılması dəqiqliyi binomial logistik reqressiya, dayaq vektorları və təsadüfi meşə metodları ilə müqayisə edilir.

[20] Bitkoinin qiymətini proqnozlaşdırmaq üçün çoxsəviyyəli perseptron əsasında (MLP) ekzogen girişli qeyri-xətti avtoreqressiya (*ing. Non-Linear Autoregressive with Exogeneous Inputs, NARX*) modeli təklif edir. Model keçmiş açılış, bağlanış, minimal və maksimal qiymətlərlə birlikdə sürüşən orta indikatorlarını da istifadə edir. Parametrlərin çoxsaylı kombinasiyasını yoxlamaq zəruri olduğu üçün NARX modelində gizli blokların sayını, giriş və çıxış gecikmələrini (*ing. lag*) optimallaşdırmaq üçün *Particle Swarm Optimization* (PSO) əsasında metod istifadə edilir.

Bitkoinin əlamətləri ilə Bitkoinin qiymətinin növbəti gündə dəyişməsinin arasındakı münasibəti tədqiq etmək üçün [21]-də genetik alqoritm əsasında neyron şəbəkələrinin ansamblı istifadə edilir. Ansamblda neyron şəbəkələri kimi çoxlaylı perseptronlar tətbiq edilir. Real praktikada effektivliyi yoxlamaq üçün ansambl növbəti gündə Bitkoinin qiymətinin istiqamətini proqnozlaşdırmaq üçün kriptovalyutanın təxminən 2 il müddətində 200 əlaməti nəzərə alınmaqla tətbiq edilmişdi. Ansambl əsaslanan treyding strategiyası 50 gün müddətində «əvvəlki günün strategiyasına əməl edilməsi» treyding strategiyası ilə müqayisə edilmişdi. Ansambl əsaslanan treyding strategiyasının daha üstün olması göstərilmişdi.

Son dövrlər KİV-lər kriptovalyutalara böyük maraq göstərir. Xüsusilə, kriptovalyutaların qiymətlərində böyük dalğalanmalar daha çox diqqət cəlb edir. Bəzi müəlliflər sosial şəbəkələrlə kriptovalyuta qiymətlərindəki tez-tez dəyişmələr arasında sıx əlaqənin olmasını göstərir. [22] KİV-lərin investorların əhvalına və Bitkoinin qiymətinə təsirini qiymətləndirir. Bir çoxları iddia edir ki, Bitkoin həqiqi dəyərə malik deyil və yalnız investorların situasiyanı qiymətləndirməsi və əhvalı kimi faktorlarla şərtlənir. Bunu yoxlamaq üçün [22] KİV sentimentini tətbiq edir və fərz olunur ki, investorlar bu informasiyaya uyğun hərəkət edirlər. Sentimentin avtomatik kəmiyyət

qiymətləndirilməsi üçün leksikona əsaslanan sentiment analizi metodu psixososial və maliyyə sənayesi üçün xüsusi Harvard lüğəti ilə birlikdə istifadə edilir. Sentimentə əsaslanan treyding strategiyaları reaksiya şablonlarının öyrənilməsi yolu ilə yaradılır.

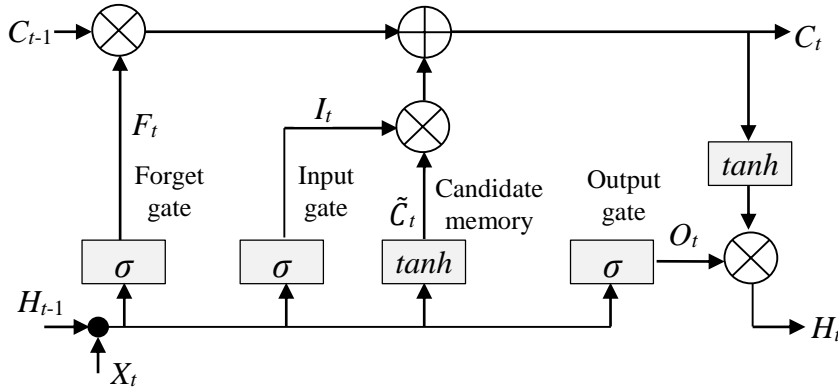
[23] Coinbase bazarında edilmiş, avro ilə ifadə edilmiş tranzaksiyaların qeyd edildiyi verilənlər toplusundakı (23.04.2015 – 15.08.2016 dövrünə aid) Bitkon zaman sırasını analiz edir. Gündəlik bitkoin-yevro (BTCEUR) mübadilə kurslarının proqnozlaşdırılması standart Elman modeli istifadə edilməklə rekurrent neyron şəbəkəsinin köməyi ilə həyata keçirilir. Elman şəbəkəsinin normallaşdırılmış orta kvadratik səhvi ilə reallaşdırılmış volatillik arasında güclü korrelyasiya aşkar edilmişdir.

### Təklif edilən dərin LSTM arxitekturası

LSTM (*ing. Long-Short Term Memory*) rekurrent neyron şəbəkələrinin bir növüdür [24], çox uzunmüddətli asılılıqları öyrənə bilir, bu, onu zaman sıralarının modelləşdirilməsi üçün çox əlverişli edir. O, əvvəlki girişlərdən vacib informasiyanı yadda saxlayır və bu informasiyanı cari çıxışı modifikasiya etmək üçün istifadə edir. Bu bölmədə LSTM blokunun əsas komponentləri və riyazi modeli daxil edilir.

#### A. LSTM modeli

LSTM-lər “yox olan” (*ing. vanishing*) və sürətlə böyüyən qradiyent problemlərini həll etmək üçün ventillər (*ing. gate*) konsepsiyasından istifadə edirlər. LSTM bloku şəkil 1-də göstərilib və üç ventildən: giriş ventillindən (*ing. input gate*), çıxış ventillindən (*ing. output gate*) və unutma ventillindən (*ing. forget gate*) ibarətdir. LSTM ixtiyari zaman intervalında qiymətləri yadda saxlamağa xidmət edir və ventillərin hər birinə adi süni neyron kimi baxmaq olar. Onlar cari  $X_t$  verilənlərinin, əvvəlki addımdakı  $H_{t-1}$  gizli vəziyyətinin və ixtiyari  $b$  sürüşməsinin çəkili cəmini hesablayırlar. Ventillər hər bir zaman addımında LSTM-də məlumat axını aşağıda göstəriləndiyi kimi tənzimləyirlər. Qeyd edək ki, aşağıdakı düsturlarda  $W_i$  dəyişəni  $i$  ventillində vurma ilə əlaqələndirilən çəkili,  $\sigma$  (*sigmoid*) və  $\tanh$  (*hiperbolik tangens*) aktivləşdirmə funksiyalarını işarə edir.



Şəkil 1. Long-Short Term Memory (LSTM) sxemi

LSTM ventillərinə daxil olan verilənlər cari zaman addımındakı  $X_t$  girişi və əvvəlki zaman addımındakı  $H_{t-1}$  gizli vəziyyətidir. Bu girişlər sigmoid aktivləşdirmə funksiyaları ilə emal olunaraq *input*, *output* və *forget* ventillərinin qiymətləri hesablanır. Nəticədə hər üç ventillər elementində qiymətlər  $[0, 1]$  intervalındadır.

Fərz edək ki,  $h$  gizli blok var və mini-paketin ölçüsü  $n$ -dir. Beləliklə, giriş  $X_t \in R^{n \times d}$  ( $n$  – nümunələrin sayı,  $d$  – girişlərin sayıdır) və əvvəlki addımdakı gizli vəziyyət  $H_{t-1} \in R^{n \times h}$  olacaq.

Uyğun olaraq ventillər belə təyin olunur: input ventili  $I_t \in R^{n \times h}$ , forget ventili  $F_t \in R^{n \times h}$  və output ventili  $O_t \in R^{n \times h}$  olacaq. Onlar aşağıdakı kimi hesablanır:

$$I_t = \sigma(X_t W_{xi} + H_{t-1} W_{hi} + b_i), \quad (1)$$

$$F_t = \sigma(X_t W_{xf} + H_{t-1} W_{hf} + b_f), \quad (2)$$

$$O_t = \sigma(X_t W_{xo} + H_{t-1} W_{ho} + b_o), \quad (3)$$

burada  $W_{xi}, W_{xf}, W_{xo} \in R^{d \times h}$  və  $W_{hi}, W_{hf}, W_{ho} \in R^{h \times h}$  – çəki parametrləri,  $b_i, b_f, b_o \in R^{1 \times h}$  – sürüşmə parametrləridir.

Giriş ventili yeni qiymətin xanaya nə dərəcədə keçməsinə nəzarət edir (*write əməli*), unutmə ventili cari blok qiymətinin nə dərəcədə yadda saxlandığına nəzarət edir (*reset əməli*), çıxış ventilində çıxış generasiya edilir (*read əməli*).

Namizəd yaddaş xanası oxşar qaydada yenilənir:

$$\tilde{C}_t = \tanh(X_t W_{xc} + H_{t-1} W_{hc} + b_c). \quad (4)$$

Bu qiymətləri birləşdirməklə uzunmüddətli yaddaş qiyməti generasiya edilir:

$$C_t = F_t \odot C_t + I_t \odot \tilde{C}_t, \quad (5)$$

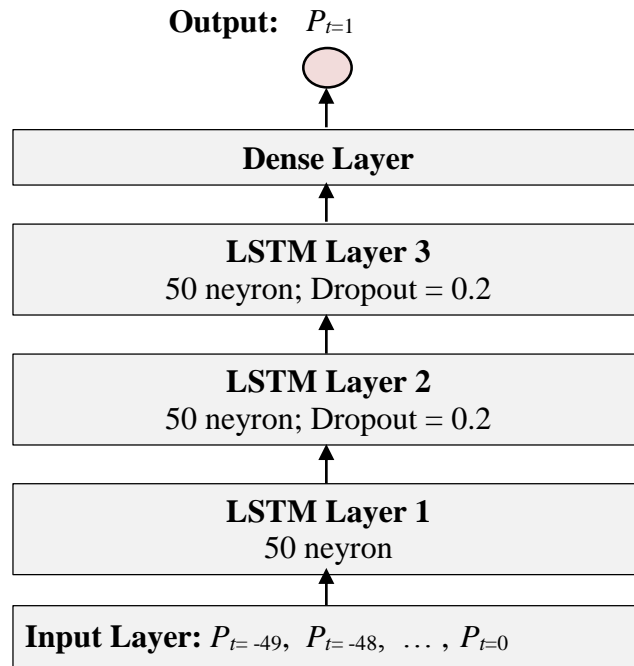
burada  $\odot$  ilə Adamar hasili işarə edilib (matrislərin uyğun elementlərinin hasili). Nəhayət, xananın gizli vəziyyəti tapılır:

$$H_t = O_t \odot \tanh(C_t) \quad (6)$$

Bu qiymət dərin şəbəkədəki digər xanalara ötürülür. Hər bir ventilin çəki və sürüşmə parametrləri var, dərin şəbəkədə çoxsaylı LSTM blokları olduğundan parametrlərin sayı çox böyük olur. Bu parametrlər şəbəkənin treninqi zamanı öyrənilir və yenilənir.

### B. Dərin LSTM arxitekturası

Təklif edilən 3-laylı Deep LSTM arxitekturası şəkil 2-də göstərilib. Arxitektura Giriş layından, LSTM-lərin üç layından, sıx laydan (*ing. dense layer*) və bir neyronun ibarət çıxış layından ibarətdir. İkinci və üçüncü LSTM laylarından sonra neyron şəbəkəsinin öyrədilməsində *overfitting* hadisəsinin qarşısını almaq üçün “*dropout*” layları istifadə edilir [25].



Şəkil 2. Deep LSTM arxitekturası

### Eksperimental qiymətləndirmə

**Verilənlərin toplanması.** Verilənlər <https://coinmarketcap.com> saytıdan götürülüb. Bu saytda 2000-dən çox kriptovalyuta barədə məlumatlar toplanıb. Məlumatların tərkibinə gündəlik açılış (*ing. Open*), bağlanış (*ing. Close*), ən yüksək (*ing. High*) və ən aşağı (*ing. Low*) mübadilə qiymətləri, mübadilə həcmi (*ing. Volume*) və bazar kapitallaşması (*ing. Market cap*) daxildir (dollar ilə ifadə olunur).

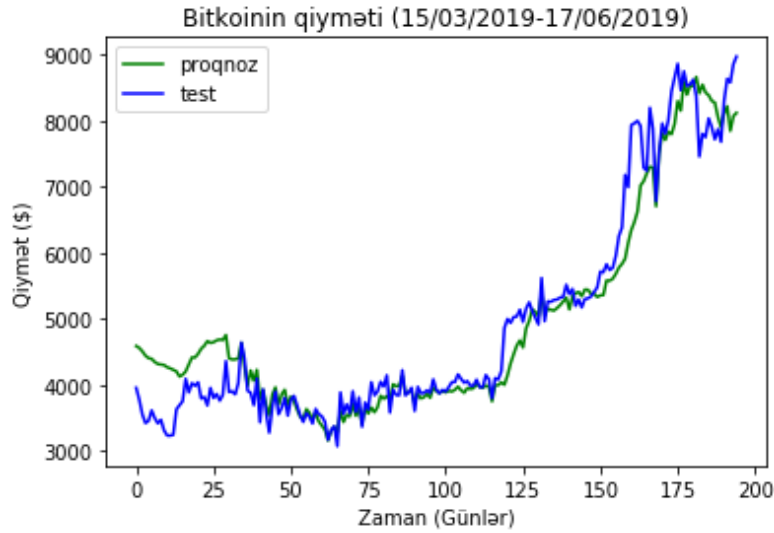
**Verilənlərin hazırlanması.** Toplanmış verilənlərə hər birində  $n$  əlamət olmaqla  $m$  nümunədən (gün) ibarət 2D tenzor kimi baxmaq olar. Bu verilənləri ölçüsü  $w$  gün olan və 1 gün addımla sürüşən pəncərə verilənləri çoxluğuna çevirsək, 3D tenzor alarıq. Onun ölçüləri  $(m-w)$  pəncərə, hər pəncərədə  $w$  günə aid  $n$  əlamət olacaq. Bizim eksperimentlərdə  $w=50$  götürülüb, buna görə birinci pəncərədə 0–49-cu, ikincidə 1–50-ci, üçüncüdə 2–51-ci günlərə aid məlumatlar olacaq.

Daha sonra verilənlər normallaşdırılır. Nəhayət, pəncərədəki verilənlər giriş və çıxış verilənlərinə ayrılır, pəncərədəki sonuncu gün çıxış veriləni, qalanlar isə giriş verilənləri kimi götürülür.

Modeldə aşağıdakı hiperparametrlər istifadə edilib:

- Paketin ölçüsü – 1024;
- Aktivləşmə funksiyası – ReLU (*ing. Rectified Linear Unit*);
- Optimizator – Adam;
- Dropout əmsalı = 0.2;
- Səhv funksiyası – MSE (*ing. Mean Squared Error*).

Model TensorFlow açıq kodlu kitabxanadan istifadə etməklə Python-da reallaşdırılıb. Bitkoinin Deep LSTM metodu ilə proqnozlaşdırılan qiymətlərinə nümunə şəkil 3-də göstərilib.



Şəkil 3. Bitkoinin 95-günlük dövrdə Deep LSTM ilə proqnozlaşdırılan qiymətləri

### Nəticə və gələcək tədqiqatlar

Kriptovalyutalar son bir neçə ildə meydana çıxsalar da, informasiya texnologiyalarında və maliyyə bazarlarında ən məşhur trendə çevrilmiş, dövriyyəsi milyardlarla ölçülən böyük bir ekosistem formalaşdırmağa nail olmuşlar. Bu ekosistemin mahiyyətini başa düşmək, əlaqədar sahələrdə baş verən dinamik dəyişiklikləri analiz etmək, gizli qanunauyğunluqları aşkarlamaq üçün kriptovalyutalarla əlaqəli verilənlərin intellektual analizi metodlarının işlənməsi olduqca vacibdir. Əlbəttə, həm adi istifadəçiləri, həm də investorları ən çox maraqlandıran məsələ Bitkoin və digər kriptovalyuta kurslarının proqnozlaşdırılması məsələsidir. Təklif edilən metod müasir tədqiqatlarla müqayisədə daha yaxşı nəticələr verir. Gələcək tədqiqatlarda baxılan məsələnin həlli üçün rekurrent neyron şəbəkələrinin digər növlərinin tətbiqi ilə yanaşı, konvolyusiya və rekurrent neyron şəbəkələri əsasında hibrid arxitekturaların yaradılması da nəzərdə tutulur.

### Ədəbiyyat

1. Narayanan A., Bonneau J., Felten E., Miller A., and Goldfeder S. Bitcoin and cryptocurrency technologies: A comprehensive introduction. Princeton University Press, 2016, 336 p.
2. Fry J., and Cheah E.T. Negative bubbles and shocks in cryptocurrency markets // *International Review of Financial Analysis*, 2016, vol.47, pp.343–352.
3. İmamverdiyev Y., Sadiyeva F. Kriptovalyuta verilənlərinin intellektual analizi məsələləri /

- “İnformasiya təhlükəsizliyinin aktual multidissiplinar elmi-praktiki problemləri” IV respublika konfransı, 14 dekabr 2018, s.47–52.
4. Catania L., Grassi S., and Ravazzolo F. Predicting the volatility of cryptocurrency time-series // *Mathematical and Statistical Methods for Actuarial Sciences and Finance*, 2018, pp.203–207.
  5. Azari A. Bitcoin price prediction: An ARIMA approach. arXiv preprint arXiv:1904.05315. 2019.
  6. Alessandretti L., ElBahrawy A., Aiello L.M., and Baronchelli A. Anticipating cryptocurrency prices using machine learning // *Complexity*, 2018, vol.2018, Article ID 8983590, 16 p. <https://doi.org/10.1155/2018/8983590>
  7. Dingli A. and Fournier K. Financial time series forecasting – A deep learning approach // *International Journal of Machine Learning and Computing*, 2017, vol.7, pp.118–122.
  8. Romeu P., Zamora-Martínez F., Botella-Rocamora P., Pardo J. Stacked denoising auto-encoders for short-term time series forecasting. In: Koprinkova-Hristova P., Mladenov V., Kasabov N. (eds) *Artificial Neural Networks. Springer Series in Bio-/Neuroinformatics*, Springer, Cham, 2015, vol.4, pp.463–486.
  9. Bao W., Yue J., and Rao Y. A deep learning framework for financial time series using stacked autoencoders and long-short term memory // *PloS One*, 2017, vol.12, no.7, e0180944.
  10. Nakamoto S. Bitcoin: A peer-to-peer electronic cash system. 2009. <https://bitcoin.org/bitcoin.pdf>
  11. Dyhrberg A.H. Bitcoin, gold and the dollar – A GARCH volatility analysis // *Finance Research Letters*, 2016, vol.16, pp.85–92.
  12. Kristjanpoller W., and Minutolo M.C. A hybrid volatility forecasting framework integrating GARCH, artificial neural network, technical analysis and principal components analysis // *Expert Systems with Applications*, 2018, vol.109, pp.1–11.
  13. Mallqui D.C., and Fernandes R.A. Predicting the direction, maximum, minimum and closing prices of daily Bitcoin exchange rate using machine learning techniques // *Applied Soft Computing*, 2019, vol.75, pp.596–606.
  14. Lahmiri S., and Bekiros S. Cryptocurrency forecasting with deep learning chaotic neural networks // *Chaos, Solitons & Fractals*, 2019, vol.118, pp.35–40.
  15. Pichl L., and Kaizoji T. Volatility analysis of Bitcoin price time series // *Quantitative Finance and Economics*, 2017, vol.1, no.4, pp.474–485. doi: 10.3934/QFE.2017.4.474.
  16. Rebane J., Karlsson I., Denic S., and Papapetrou P. Seq2Seq RNNs and ARIMA models for cryptocurrency prediction: A comparative study / *Proc. of SIGKDD Workshop on Fintech*, 2018, pp.1–5.
  17. McNally S., Roche J., and Caton S. Predicting the price of Bitcoin using Machine Learning / *26th IEEE Euromicro International Conference on Parallel, Distributed and Network-based Processing*, 2018, pp.339–343.
  18. Jang H., and Lee J. An Empirical Study on Modeling and Prediction of Bitcoin Prices with Bayesian Neural Networks Based on Blockchain Information // *IEEE Access*, 2017, vol.6, pp.5427–5437.
  19. Madan I., Saluja S., and Zhao A. Automated bitcoin trading via machine learning algorithms, 2015. Dept. Comput. Sci., Stanford Univ., Stanford, CA, USA, Tech. Rep., URL: <http://cs229.stanford.edu/proj2014/Isaac%20Madan>, 20.
  20. Indera N. I., Yassin I. M., Zabidi A., and Rizman Z. I. Non-linear autoregressive with exogeneous input (NARX) Bitcoin price prediction model using PSO-optimized parameters and moving average technical indicators // *Journal of Fundamental and Applied Sciences*, 2017, vol.9, no.3S, pp.791–808.
  21. Sin E., and Wang L. Bitcoin price prediction using ensembles of neural networks / *13th IEEE International Conference on Natural Computation, Fuzzy Systems and Knowledge Discovery*, 2017, pp.666–671.
  22. Karalevicius V., Degrande N., & De Weerd J. Using sentiment analysis to predict interday Bitcoin price movements // *The Journal of Risk Finance*, 2018, vol.19, no.1, pp.56–75.

23. Kodama O., Pichl L., and Kaizoji T. Regime change and trend prediction for Bitcoin time series data / CBU International Conference Proceedings, 2017, vol.5, pp.384–388.
24. Hochreiter S., and Schmidhuber J. Long short-term memory // Neural computation, 1997, vol.9(8), pp.1735–1780.
25. Srivastava N., Hinton G., Krizhevsky A., Sutskever I., and Salakhutdinov R. Dropout: a simple way to prevent neural networks from overfitting // The Journal of Machine Learning Research, 2014, vol.15, no.1, pp.1929–1958.

**УДК 004.056:351**

**Имамвердиев Ядигар Н.**

Институт Информационных Технологий НАНА, Баку, Азербайджан

[yadigar@iit.science.az](mailto:yadigar@iit.science.az)

**Метод Deep LSTM для прогнозирования цены Биткоина**

В этой работе для прогнозирования курса обмена биткойнов предлагается архитектура глубокой нейронной сети, основу которой составляют блоки LSTM (Long-Short Term Memory – долговременная кратковременная память), один из видов рекуррентных нейронных сетей. В последние годы криптовалюты стали важными финансовыми инструментами, и проблема прогнозирования обменных курсов криптовалют на традиционные валюты стала очень актуальной. Биткоин – это первая криптовалюта, и более половины общей капитализации криптовалют принадлежит ей, и он играет роль золота в мире криптовалют, то есть цена других криптовалют часто выражается в биткойнах. Исходя из этих соображений, была рассмотрена задача прогнозирования курса биткоина, и предложенная архитектура глубокого LSTM, в экспериментах с реальными данными большого объема, охватывающими несколько лет, показала лучшие результаты, чем статистические методы, обычно используемые при прогнозировании временных рядов. Полученные результаты важны как для обычных пользователей, заинтересованных в криптовалютах, так и для инвесторов, которые активно работают в сфере криптовалют. Результаты также показывают, что подходы глубокого обучения могут быть весьма продуктивными при применении в других задачах интеллектуального анализа нестационарных временных рядов по криптовалютам.

**Ключевые слова:** биткоин, криптовалюта, временные ряды, прогнозирование, глубокое обучение, рекуррентные нейронные сети, LSTM.

**Yadigar N. Imamverdiyev**

Institute of Information Technology of ANAS, Baku, Azerbaijan

[yadigar@iit.science.az](mailto:yadigar@iit.science.az)

**Deep LSTM method for forecasting Bitcoin prices**

This study proposes a deep neural network architecture for forecasting the Bitcoin exchange price, which is based on LSTM (Long-Short Term Memory) units, one of the types of recurrent neural networks. In recent years, cryptocurrencies have become important financial instruments, and the problem of forecasting cryptocurrency exchange rates for traditional currencies has become very urgent. Bitcoin is the first cryptocurrency, and more than half of the total cryptocurrency capitalization belongs to it and it plays the role of gold in the world of cryptocurrencies, that is, the price of other cryptocurrencies is often expressed in bitcoins. Based on these considerations, the problem of forecasting the Bitcoin exchange rate is considered, and the proposed deep LSTM architecture, in the experiments with real high-volume data spanning several years, shows better results than the statistical methods commonly used in forecasting of time series. The results obtained are important both for ordinary users interested in cryptocurrencies and for investors who are actively working in the field of cryptocurrencies. The results also show that deep learning approaches can be very productive when used in other tasks of the intellectual analysis of non-stationary time series on cryptocurrencies.

**Keywords:** Bitcoin, cryptocurrency, time-series, forecasting, deep learning, recurrent neural networks, LSTM.