



## Cryptocurrency Price Prediction Using Parallel Gated Recurrent Units

M. Asadpour<sup>1</sup>, A. Rezaee<sup>2</sup>

- 1- Ph. D Candidate of Mechatronic Engineering Faculty of Intelligent Systems, College of Interdisciplinary Science and Technologies, University of Tehran, Tehran, Iran  
 2- Associate Professor, Mechatronic Engineering, Faculty of Intelligent Systems, College of Interdisciplinary Science and Technologies, University of Tehran, Tehran, Iran

(\*- Corresponding Author Email: [arrezaee@ut.ac.ir](mailto:arrezaee@ut.ac.ir))

<https://doi.org/10.22067/mfe.2024.73643.1133>

Received: 2021/11/14	<b>How to cite this article:</b> Asadpour, M., & Rezaee, A. (2024). Cryptocurrency Price Prediction Using Parallel Gated Recurrent Units, <i>Monetary &amp; Financial Economics Journal</i> , 30(2): 31-68. (in Persian with English abstract). <a href="https://doi.org/10.22067/mfe.2024.73643.1133">https://doi.org/10.22067/mfe.2024.73643.1133</a>
Revised: 2023/08/13	
Accepted: 2024/04/02	
Available Online: 2024/04/02	

### 1- INTRODUCTION

The current economic system is based on intermediaries and third parties such as banks and financial institutions. This system's drawbacks include the lack of trust, security, and flexibility. In 2009, Bitcoin was introduced to the public to facilitate finances and address the current financial system's shortcomings. Fluctuations and increases in the price of cryptocurrencies lead many researchers to look for influential factors to predict the price of Bitcoin. In this research, we study and predict Bitcoin's



©2022 The author(s). This is an open access article distributed under the terms of the Creative Commons Attribution (CC BY 4.0), which permits unrestricted use, distribution, and reproduction in any medium, as long as the original authors and source are cited. No permission is required from the authors or the publishers.

price as a regression problem by using a new model called Parallel Recurrent Neural Network (PRNN). The experimental results indicate that the proposed model has 3.243% and 2.641% errors for window lengths 20 and 15 respectively. So, our method uses fewer data at the input and has more accuracy along with lower computational cost compared to the other existing methods.

## **2- THEORETICAL FRAMEWORK**

The model proposed in this study consists of a combination of three separate neural networks that is coded and implemented in MATLAB 2020b software after preparing the data and generating input and output. Due to the sharp fluctuations in prices, an attempt is made to design the structure in such a way that it can fully and maximally understand the patterns and relationships between the input-output data pairs. The structure consists of three small neural. The tasks of the first and second networks are to identify patterns and predict prices separately. Each of these two networks is coded and implemented separately. A value is generated as output at the end of each of these two networks. In other words, in the designed structure, there are two intelligent systems, the first of which predicts prices based on the prices of the past days and the second based on the structural features of the past days. These two outputs are then combined in the third network, and thus the output is generated as a price prediction. The third network is responsible for combining the results of the previous two networks based on the accuracy and efficiency of each of the previous outputs.

## **3- METHODOLOGY**

The steps to do this research are as follows:

**Data Collection:** Reputable websites are used to collect data. For the first dataset the four characteristics that include the average daily price, opening price, low price, and high price are used and for the second dataset, which includes the structural and network features of Bitcoin, are used the five characteristics that include average block size, hash rate, difficulty, total daily transactions, and miners' rewards. **Data Preprocessing:** Datasets

include a wide range of numbers due to large fluctuations in the price of Bitcoin. Therefore, z-score normalization is used to normalize the data. Mean and standard deviation are involved in this normalization. So, the numbers are well separated. Input and Output Generation: After normalization, the data is divided into corresponding input and output pairs. Model design: In this section, a neural network consisting of three smaller neural networks was designed and implemented in MATLAB software. The first two networks of this collection consist of GRU neural networks with memory, then, a simple MLP neural network was implemented to combine the output results of the previous two networks and provide a value as the price of future days.

Result: Common measurement criteria that are commonly known in price index prediction studies are designed to know the performance of the overall structure. For example, the criteria of mean square error, root mean square error, mean absolute error, and mean absolute percentage error are used in this paper.

#### **4- RESULTS & DISCUSSION**

In this study, an innovative structure based on GRU neural networks was presented. By using two inputs, this structure can predict the price of bitcoin with higher accuracy than previous methods. The average error of the method is 3.2% for  $W=20$  and 2.6% for  $W=15$ .

Our proposed method uses fewer data so, the computational cost in this research is less than the existing methods, and the execution time of the program has been reduced to a minimum, which is one of the important innovations in the field of neural network structure optimization. In addition, most previous research used regular mapping methods like min-max-normalization to normalize the data. In this study, due to the nature and characteristics of cryptocurrencies, the z-score normalization method was used which is based on the mean and standard deviation of data. This could be about 5% to 7% improve the percentage of accuracy of predictions made.

## 5- CONCLUSIONS & SUGGESTIONS

The prediction of cryptocurrency prices has always been one of the most important challenges for economists and investors. A wide variety of methods have been proposed in economics and computer science to achieve higher accuracy and efficiency. Artificial neural networks are important machine learning tools used to predict time series data. There are many methods presented based on neural networks, the best of which are recurrent neural networks such as LSTM and GRU. In this study, a neural network was presented consisting of GRU layers that can achieve higher accuracy with fewer input features and low computational cost. For future research, one or more other input sets can be defined, including important global economic indicators, prices of other cryptocurrencies, and the rate of cryptocurrency trends in social networks. This action is expected to increase the accuracy of the neural network.

**Keywords:** Bitcoin, Recurrent Neural Networks, Data Fusion, Price Prediction, Parallel Processing.

## پیش بینی قیمت ارز دیجیتال با استفاده از شبکه های عصبی Gru

میلاذ اسدپور

دانشجوی دکتری دانشگاه تهران، تهران، ایران

علیرضا رضائی\*

دانشیار دانشگاه تهران، تهران، ایران

نوع مقاله: پژوهشی

<https://doi.org/10.22067/mfe.2024.73643.1133>

### چکیده

اقتصاد و پیش بینی شاخص های آن یکی از ارکان اصلی و تأثیرگذار در زندگی هر فردی است و می تواند زمینه ساز برتری افراد و دولت ها نسبت به سایرین باشد در نتیجه پیش بینی شاخص ها همواره یکی از چالش ها و دغدغه های اصلی اقتصاددانان و سرمایه گذاران است. از طرفی با ظهور رمزارزها و افزایش ارزش قیمتی آن ها سرمایه گذاری بسیاری در این زمینه انجام گرفته است؛ لذا یافتن روش هایی برای پیش بینی قیمت رمزارزها در آینده از اهمیت بسیاری برخوردار است. در این مقاله روشی برای پیش بینی قیمت بیت کوین با استفاده از الگوریتم های هوش مصنوعی ارائه شده است. بدین منظور ویژگی های تأثیرگذار بر روی قیمت آینده بیت کوین شناسایی و در دو مجموعه داده جداگانه شامل داده های قیمتی و داده های ساختاری شبکه بیت کوین دسته بندی و استانداردسازی شد، سپس ساختار نوینی متشکل از سه شبکه عصبی پیش خور و بازگشتی طراحی گردید که شبکه اول و دوم شامل لایه GRU است که به صورت موازی و مجزا از یکدیگر به پیش بینی قیمت ها می پردازند. در ادامه، خروجی هر یک از این شبکه ها توسط یک شبکه عصبی با یکدیگر تلفیق می شود و در نهایت مقادیری به عنوان پیش بینی قیمت روزهای آتی به دست می آید. نتیجه پژوهش ها و محاسبه خطا نشان می دهد استفاده از ۱۵ و یا ۲۰ روز گذشته بهترین بازه برای پیش بینی قیمت آینده بیت کوین می باشد که دقتی برابر با ۹۷/۳۶٪ و ۹۶/۷۶٪ دارند که نشان از دقت و کارایی بالای این روش دارد. هم چنین به دلیل انتخاب صحیح ویژگی های ورودی حجم محاسباتی این پژوهش به مقدار قابل توجهی کاهش یافته است.

**کلیدواژه ها:** بیت کوین، شبکه های عصبی بازگشتی، تلفیق داده ها، پیش بینی قیمت، پردازش موازی.

\* نویسنده مسئول: [arrezade@ut.ac.ir](mailto:arrezade@ut.ac.ir)

تاریخ دریافت: ۱۴۰۰/۰۸/۲۳ تاریخ پذیرش: ۱۴۰۳/۰۱/۱۴

صفحات: ۳۱-۶۸

## مقدمه

سیستم اقتصاد کنونی بر پایه حضور واسطه و جز سومی مانند بانکها و مؤسسات مالی بنا شده است و برای انجام هر تراکنش مالی و اقتصادی به این واسطهها (بانکها و مؤسسات مالی) نیاز است. از معایب این سیستم می توان به محدود بودن جابه جایی پول، فقدان اعتماد کامل به برخی از مؤسسات مالی و بانکها، فقدان امنیت کافی، عدم شفافیت برای عموم و همچنین عدم انعطاف پذیری در سطح بین المللی اشاره کرد. (Patel; Tanwar, Gupta & Kumar, 2020) برای تسهیل انجام امور مالی و همچنین برطرف ساختن معایب سیستم اقتصادی کنونی در سال ۲۰۰۸ وبسایتی با نام bitcoin.org راه اندازی شد. سپس در سال ۲۰۰۹ بیت کوین توسط شخصی به نام ساتوشی ناکاموتو در مقاله ای به عموم مردم معرفی گردید. (Nakamoto, 2008) (لازم به ذکر است که هویت اصلی ساتوشی ناکاموتو تاکنون مشخص نشده است).

پس از شروع سال ۲۰۲۰ میلادی قیمت بیت کوین روند بی سابقه صعودی را در پیش گرفت و توانست در این سال با پیشی گرفتن از طلا به عنوان بهترین زمینه سرمایه گذاری انتخاب شود و محبوبیت بسیاری در زمینه مالی و اقتصادی کسب کند. پس از آن نیز با شروع پاندمی ویروس کرونا و تعطیلی کسب و کارها به صورت حضوری، بسیاری از مردم به فضاهای مجازی و تجارت از این طریق پرداختند. در نتیجه بیت کوین توانست جایگاه خود را به عنوان اولین دارایی مجازی مستحکم نماید. علاوه بر این نوسانات بسیار در رمزارزها خود به زمینه ای در جهت کسب سود از طریق نوسان گیری تبدیل شد. لذا بسیاری از سرمایه گذاران و اقتصاددانان به سمت این بازار کشیده شدند. با وقوع چنین اتفاقاتی، وجود راهکارهایی برای پیش بینی قیمت رمزارزها برای روزهای آینده به یک مسئله چالش برانگیز و جهانی تبدیل شد و بسیاری از محققان در زمینه های مختلف مانند علوم کامپیوتر درصد یافتن روش هایی معتبر و دقیق برآمده اند. از این رو استفاده از هوش مصنوعی به ویژه شبکه های عصبی مصنوعی در پیش بینی قیمت شاخص های اقتصادی بسیار متداول و رایج گردید (Chatterjee; Kumar, Kumar & Balamurugan, 2020)

در کشور عزیزمان ایران نیز با توجه به مشکلات اقتصادی، میزان بالای تورم و کاهش ارزش پول ملی، بیشتر مردم درصد یافتن روش هایی برای افزایش درآمد خود هستند تا از این طریق بتوانند هزینه های اضافی که به دلیل تورم و افزایش مکرر قیمت ها به معیشتشان لطمه میزند، جبران نمایند تا بتوانند علاوه بر حفظ ارزش سرمایه خود، از خطر بروز فقر در زندگی جلوگیری نمایند. در این راستای بسیاری از افراد به بازارهای مالی جهانی همچون بازار رمزارزها کشیده می شوند؛ زیرا اولاً این بازارها با قیمت های جهانی

مانند دلار، نفت خام و طلا ارتباط مستقیمی دارند لذا رمزارزها از تورم داخلی در امان‌اند. ثانیاً به دلیل ماهیت غیرمتمرکز رمزارزها شناسایی آن‌ها و محل خریدوفروش آن‌ها غیرقابل ردگیری است؛ لذا رمزارزها به‌صورت کامل از تحریم‌های ظالمانه صورت گرفته علیه کشورمان نیز در امان‌اند، لکن اتباع ایرانی به‌راحتی می‌توانند در این بازارها به دادوستد در سطح جهانی بپردازند. ثالثاً رمزارزها نوسانات بسیار زیادی را نسبت به بقیه بازارهای مالی مثل طلا و نفت خام تجربه می‌کنند لذا برای سرمایه‌های اندکی که مردم در دسترس دارند مناسب‌تر است و راحت‌تر می‌توانند به سودهای بالاتری نسبت به سرمایه اولیه‌شان در مقایسه با دیگر بازارهای مالی برسند. مجموعه این عوامل در کنار عواملی دیگر مانند نوظهور بودن رمزارزها و امکان رشد وسیع آن در آینده باعث شده است که مردم کشورمان نیز استقبال بسیار خوبی از این بازار مالی داشته باشند و سرمایه‌گذاری‌های بسیاری در این حوزه انجام دهند. البته باید توجه داشت که عدم شناخت کافی از این بازارها می‌تواند باعث بروز ضررهای مالی هنگفتی در این سرمایه‌گذاری‌ها گردد لذا هدف اصلی این مقاله ارائه روشی معتبر و مطمئن بر پایه روش‌های هوش مصنوعی برای پیش‌بینی روند حرکتی قیمت بیت‌کوین در روزهای آینده و به‌صورت پیش‌بینی کوتاه‌مدت است. این هدف دارای دو بخش مجزا می‌باشد. بخش اول مربوط به دقت‌تر بودن پیش‌بینی‌ها نسبت به روش‌های متداول و پژوهش‌های پیشین است. بدین‌صورت که تفاوت مقدار عددی پیش‌بینی شده با مقدار واقعی قیمت، بسیار اندک باشد. بخش دوم نیز مربوط به کاهش حجم محاسبات است. در راستای این هدف تلاش بسیاری شده است تا روش ارائه شده با کمترین میزان داده ورودی عمل پیش‌بینی را انجام دهد. لذا در این تحقیق حجم محاسبات و زمان انجام آن توسط پردازشگر کامپیوتر به مقدار حداقل کاهش یافته است؛ به‌عبارت‌دیگر افزایش دقت در کنار کاهش حجم محاسبات دو فاکتور اساسی در این پژوهش است. به‌منظور رسیدن به این اهداف ابتدا هشت ویژگی مهم تأثیرگذار در قیمت بیت‌کوین شناسایی و انتخاب گردید سپس این دادگان در دو دسته داده‌های قیمتی و داده‌های ساختاری شبکه بیت‌کوین دسته‌بندی و توسط روش Z-score استانداردسازی گردید سپس ساختار نوینی بر پایه شبکه‌های عصبی بازگشتی و پیش‌خور با معماری موازی در نرم‌افزار Matlab 2020b طراحی و پیاده‌سازی گردید که در ابتدا دو مجموعه شبکه عصبی GRU با استفاده از دو مجموعه داده که پیش‌تر آماده‌سازی شده بود به پیش‌بینی قیمت روزهای آتی می‌پردازند سپس خروجی این شبکه‌ها، در شبکه سومی موسوم به شبکه تلفیق داده با یکدیگر ترکیب شده و مقدار نهایی به‌عنوان پیش‌بینی قیمت روزهای آینده بیت‌کوین حاصل می‌گردد که در انتها نیز به‌منظور بررسی کارایی و اعتبار این روش آزمایش‌های اعتبارسنجی مختلفی انجام گرفته است.

در بخش دوم مقاله خلاصه‌ای از تحقیقات پیشین انجام گرفته در زمینه پیش‌بینی شاخص‌های اقتصادی آورده شده است. در ادامه و به‌منظور غنی‌تر شدن تحقیق و درک صحیح‌تر روش‌های استفاده شده، توضیحات مختصری در رابطه با رمزارزها و نحوه عملکرد آن‌ها در بخش سوم آورده شده است. در بخش چهارم نیز روش مورد استفاده در این پژوهش توضیح داده شده است. در بخش‌های پنجم به نتایج حاصل از خروجی شبکه و میزان دقت و کارایی روش مقاله، اشاره شده است و در انتها و در بخش‌های ششم و هفتم نیز به بحث و نتیجه‌گیری و مقایسه با تحقیقات پیشین پرداخته شده است.

### پیشینه پژوهش

با توجه به اهمیت بالای پیش‌بینی‌های قیمتی در علوم اقتصاد و امور مالی، پژوهش‌های بسیار زیادی با روش‌ها و تکنیک‌های مختلف جهت دستیابی هر چه دقیق‌تر به شاخص‌های قیمتی در آینده صورت گرفته است. محققان در سراسر دنیا پژوهش‌ها و بررسی‌های بسیاری بر روی عوامل تأثیرگذار بر روی قیمت ارزهای دیجیتال انجام داده‌اند. در راستای یکی از همین پژوهش‌ها تکر و همکاران رابطه‌ای را بین تغییرات قیمتی طلا، نفت خام و ارزهای مجازی مانند بیت‌کوین، اتریوم و لایت‌کوین یافتند. این روابط در جهت درک صحیح‌تر تغییرات قیمتی ارزهای مجازی در سطح بین‌المللی کمک شایانی کرد (Teker; Teker & Ozyesil, 2019). پنگ و همکاران روش GARCH<sup>۱</sup> را که در سری‌های زمانی مالی و اقتصادسنجی مورد استفاده قرار می‌گیرد به همراه یک ماشین بردار پشتیبان برای پیش‌بینی قیمت بیت‌کوین و لایت‌کوین به کار بردند این روش جدید در مقایسه با روش‌های دیگر خود همبسته میانگین متحرک<sup>۲</sup> که پیش‌تر برای پیش‌بینی‌ها استفاده می‌شد دقت و عملکرد بهتری داشت (Peng; Albuquerque, de Sá, Padula & Montenegro, 2018)

از دیگر پژوهش‌هایی که از ماشین‌های بردار پشتیبان (SVM)<sup>۳</sup> استفاده شده است می‌توان به پژوهش کاراسو و همکاران اشاره کرد در این پژوهش از ماشین بردار پشتیبان به همراه کرنل‌های خطی و چند جمله استفاده شد. در فاز آموزش نیز روش اعتبارسنجی متقابل<sup>۴</sup> برای آموزش دقیق و بهتر سیستم مورد استفاده قرار گرفت در آخر نتیجه‌گیری شد که روش ماشین بردار پشتیبان عملکرد بهتری در مقایسه با

<sup>۱</sup> Generalized Autoregressive Conditional Heteroscedasticity

<sup>۲</sup> Autoregressive Moving Average Model

<sup>۳</sup> Support Vector Machine

<sup>۴</sup> Kfold-Crossvalidation



روش‌های رگرسیون خطی دارد (Karasu; Altan, Saraç & Hacıoğlu, 2018) در ادامه این پژوهش‌ها هیتما و همکاران از ماشین بردار پشتیبانی که ضرایب آن توسط الگوریتم بهینه‌سازی ازدحام ذرات<sup>۱</sup>، تعیین می‌شد، استفاده نمودند. این کار باعث گردید نتایج حاصل از پژوهش‌های ایشان نسبت به دیگران از دقت و سرعت نسبی بیشتری برخوردار باشد (Hitam; Ismail & Saeed, 2019). از دیگر پژوهش‌هایی که از الگوریتم‌های بهینه‌سازی به‌منظور آموزش بهتر شبکه استفاده کرد تحقیق رادیتو و همکاران بود در این پژوهش ایشان از یک شبکه عصبی چندلایه که ضرایب آن از طریق الگوریتم ژنتیک تعیین می‌شد، استفاده کردند. این تکنیک باعث شد که از گیرافتادن شبکه در کمینه‌های محلی جلوگیری گردد و همواره اطمینان حاصل شود که شبکه به‌صورت کامل و حداکثری آموزش یافته است (Radityo, Munajat & Budi, 2017).

راتان و همکاران از روش‌های متفاوت تری نسبت به یافته‌ها گذشته استفاده کردند. ایشان ترکیب روش‌های درخت تصمیم<sup>۲</sup> و رگرسیون خطی را برای پیش‌بینی قیمت بیت کوین ارائه داده و نشان دادند که این روش‌ها نسبت به روش‌های پیشین خود از حجم محاسباتی کمتر و اندکی دقت بالاتر برخوردار است. (Rathan; Sai & Manikanta, 2019) پس از این پژوهش‌ها، محققان بیشتر توجه خود را به سمت استفاده از شبکه‌های عصبی بازگشتی و روش‌های یادگیری عمیق معطوف کردند. از روش‌های نوین و متفاوت نسبت به پژوهش‌های پیشین می‌توان به پژوهش بشیری و همکاران اشاره کرد. در این پژوهش، مجموعه داده‌های مربوط به ده رمزارز مورد استفاده قرار گرفته و یک مجموعه داده جدید، با در نظر گرفتن قیمت نهایی هر رمز ارز ایجاد شده است در این پژوهش از روش یادگیری نظارت شده مانند جنگل تصادفی، طبقه‌بندی بردار پشتیبان، گرادیان تقویتی و شبکه عصبی در گروه طبقه‌بندی و از رگرسیون خطی، شبکه عصبی بازگشتی و رگرسیون گرادیان تقویتی استفاده شده است که الگوریتم‌های ماشین بردار پشتیبان، جنگل تصادفی، گرادیان تقویتی و شبکه عصبی مقدار صحت ۵۲/۷۶ درصد را ثبت کردند. (Bashiri & Paryab, 2021) از دیگر تحقیقات در این حوزه می‌توان به پژوهش چن و همکاران اشاره کرد. ایشان با استفاده از مهندسی انتخاب ویژگی موفق شدند دوازده ویژگی مهمی که بر روی قیمت بیت کوین تأثیرگذار است را پیدا کرده و سپس توسط روش کلاسه‌بندی و استفاده از مدل‌هایی مانند LSTM<sup>۳</sup> و

<sup>1</sup> Particle Swarm Optimization

<sup>2</sup> Decision tree

<sup>3</sup> Long short term memory

آنالیز تشخیصی درجه دوم<sup>۱</sup> به پیش‌بینی افزایش و یا کاهش قیمت در روزهای آتی پردازند در این تحقیق مشخص شد استفاده از دوازده ویژگی و هم‌چنین شبکه LSTM دقت بیشتری نسبت به روش‌های دیگر کلاس‌بندی دارد (Chen & Sun, 2020). عبدی و همکاران از شبکه عصبی بازگشتی LSTM برای پیش‌بینی قیمت‌های آینده ارزهای مجازی از طریق داده‌های سری‌های زمانی پرداختند. آنان در ابتدا این شبکه را از طریق داده قیمتی مورد آموزش قرار دارند و سپس به پیش‌بینی قیمت بیت‌کوین پرداختند و از طریق معیار میانگین قدر مطلق خطا شبکه پیاده‌سازی شده را بررسی نمودند و دریافته‌اند که شبکه با دقتی در حدود ۸۲٪ می‌تواند به پیش‌بینی قیمت ارز دیجیتال پردازد. (Abdi, Del Ara & Daneshjo, 2020) در ادامه این روش و به‌منظور تکمیل این تحقیق تاندون و همکاران از شبکه LSTM که توسط روش اعتبارسنجی متقابل آموزش داده می‌شد استفاده کردند. علی‌رغم اینکه این کار باعث افزایش چشمگیر حجم محاسبات می‌شد ولی شبکه درک عمیق و بهتری نسبت به تغییرات قیمتی پیدا می‌کرد لذا در هنگام استفاده از این روش دقت بیشتری حاصل می‌شد (Tandon; Tripathi, Saraswat & Dabas, 2019) در ادامه استفاده از شبکه‌های بازگشتی ریزوان و همکاران با استفاده از داده‌های قیمتی و هم‌چنین شاخص‌های مهم ارزهای مجازی مانند حجم کل معاملات، میانگین قدرت هش، کارمزد معاملات یک روز و ... شبکه عصبی‌ای بر مبنای لایه‌های GRU تشکیل دادند. سپس به مقایسه و بررسی با شبکه عصبی LSTM پرداختند و دریافته‌اند شبکه عصبی GRU علی‌رغم سادگی در محاسبات، دقت بهتری نیز دارد و نتایج به‌دست‌آمده از این روش به‌طور میانگین ۱۰ درصد نسبت به روش LSTM به مقادیر واقعی نزدیک‌تر است (Rizwan; Narejo & Javed, 2019)

تمامی پژوهش‌های اشاره شده از داده‌های قیمتی و ویژگی‌های ساختاری ارزهای مجازی در زمان‌های قبل برای پیش‌بینی قیمت در آینده استفاده می‌کردند. ولی عوامل مهم دیگری نیز در قیمت یک شاخص تأثیرگذار است؛ که از جمله این موارد می‌توان به شبکه‌های اجتماعی، میزان جست‌جو در گوگل و دید عمومی مردم نسبت به یک شاخص اشاره کرد. قربانی و همکاران به ارائه رویکردی برای پیش‌بینی تغییرات قیمتی بیت‌کوین با استفاده از الگوریتم‌های یادگیری ماشین همراه با استفاده از داده‌های تحلیل احساسات مردم نسبت به افراد مشهور مانند ایلان ماسک در شبکه‌های اجتماعی توییت، ردیت و تلگرام پرداختند و دریافته‌اند این ویژگی‌ها می‌تواند روی قیمت‌ها تأثیرگذار باشد؛ لذا از این روش توانستند قیمت

<sup>1</sup> Quadratic Discriminant Analysis

بیت کوین را با دقتی در حدود ۸۸٪ برای روزهای آینده پیش‌بینی نمایند. (Ghorbani; Rabbani, 2022) در ادامه این تحقیق راناسینگه و همکاران در یک شبکه عصبی با استفاده از داده‌های به‌دست‌آمده از توییتر و داده‌های قیمتی به پیش‌بینی قیمت بیت کوین و اتریوم پرداختند (Ranasinghe & Halgamuge, 2021). از دیگر پژوهش‌های تأثیرگذار در این زمینه می‌توان به پژوهش اسموتس و همکاران اشاره کرد. ایشان از داده‌های شبکه اجتماعی تلگرام در کنار داده‌های گوگل ترند به‌منظور درک دید مردم نسبت به ارزش‌های مجازی استفاده کردند. در این تحقیق ثابت شد که تعداد جست‌وجو در سایت گوگل تأثیر بسیاری زیاد بر روی قیمت ارزش‌های مجازی خصوصاً بیت کوین در کوتاه‌مدت دارند (Smuts, 2019). در زمینه پیش‌بینی قیمت باید به پژوهش موهانتی و همکاران نیز اشاره داشت. ایشان یک مجموعه کامل شامل ۲۶ ویژگی شاخص بیت کوین به‌مانند قیمت، تعداد تراکنش در روز، تعداد بلوک‌ها، زمان تولید بلوک و... را در کنار داده‌های توییتر برای پیش‌بینی نوسانات قیمتی بیت کوین استفاده کردند. این روش به دلیل حجم گسترده داده‌های ورودی دارای محاسبات بسیار زیادی بوده و پروسه زمانی پیش‌بینی قیمت در این روش بسیار طولانی است (Mohanty; Patel, Patel & Roy, 2018) در توضیحات فوق تلاش شد که تعدادی از پژوهش‌های شاخص که روشی نوین و مبتکرانه را در حوزه پیش‌بینی قیمت ارز دیجیتال ارائه شده است، بیان شود در جدول ۱ تمامی مطالب فوق اعم از نویسندگان مقاله، سال انتشار پژوهش، روش انجام و میزان دقت به دست آمده به‌صورت خلاصه و یکجا آورده شده است.

#### جدول (۱): خلاصه‌ای از پژوهش‌های انجام شده به همراه روش انجام آن

نام نویسندگان	روش انجام	سال انتشار	دقت
Radito et al [9]	شبکه عصبی چند لایه با بهینه‌ساز الگوریتم ژنتیک	۲۰۱۷	حدود ۹۰٪
Karasu et al [7]	ماشین بردار پشتیبان به همراه کرنل‌های خطی و چند جمله	۲۰۱۸	۸۸٪/۷
Peng et al [6]	روش GARCH به همراه ماشین بردار پشتیبان	۲۰۱۸	۸۹٪
Mohanty et Al [19]	شبکه عصبی به همراه ۲۶ ویژگی شاخص بیت کوین و داده‌های شبکه‌های اجتماعی	۲۰۱۸	۶۴٪ (مسئله کلاسه‌بندی)

<i>Teker et al [5]</i>	چگونگی تأثیر تغییرات قیمت طلا و نفت بر حرکت روزانه قیمت ارزهای دیجیتال باروش Dolado and Lütkepohl	۲۰۱۹	-----
<i>Hitma et al [8]</i>	ماشین بردار پشتیبانی با بهینه‌سازی الگوریتم ازدحام ذرات	۲۰۱۹	۹۰٪/۴
<i>Rathan et al [10]</i>	ترکیب روش‌های درخت تصمیم و رگرسیون خطی	۲۰۱۹	۹۵٪
<i>Tandon et al [14]</i>	شبکه LSTM با روش اعتبارسنجی متقابل	۲۰۱۹	۸۵٪/۳۲
<i>Rizwan et al [15]</i>	شبکه GRU	۲۰۱۹	۹۴٪/۷
<i>Smut et al [18]</i>	داده‌های شبکه اجتماعی تلگرام و گوگل ترند به منظور درک دید مردم نسبت به ارزهای مجازی در شبکه عصبی	۲۰۱۹	۸۳٪
<i>Chen et al [12]</i>	کلاسه‌بندی توسط شبکه LSTM و آنالیز تشخیصی درجه دوم	۲۰۲۰	۶۷٪/۲ (مسئله کلاسه‌بندی)
<i>Abdi et al [13]</i>	شبکه عصبی بازگشتی LSTM	۲۰۲۰	۸۲٪
<i>Bashiri et al [11]</i>	الگوریتم‌های ماشین بردار پشتیبان، جنگل تصادفی، گرادیان تقویتی و شبکه عصبی	۲۰۲۱	۵۲٪/۷۶ (مسئله کلاسه‌بندی)
<i>Ranasinghe et al [17]</i>	داده‌های توئیتر و داده‌های قیمتی در یک شبکه عصبی برای پیش‌بینی قیمت بیت کوین و اتریوم	۲۰۲۱	۹۳٪/۵۴

در جدول فوق برخی از پژوهش‌ها بجای استفاده از مسئله رگرسیون و پیش‌بینی مقدار قیمتی، مسئله پیش‌بینی قیمت را به صورت مسئله کلاسه‌بندی انجام داده‌اند. بدین صورت که در این پژوهش‌ها فقط افزایشی و یا کاهشی بودن قیمت در روزهای آینده مطرح می‌باشد و سیستم خبره فقط به بررسی شیب تغییرات قیمتی می‌پردازد این گونه پژوهش‌ها به صورت توضیح در قسمت دقت در جدول فوق مشخص شده‌اند.

همان‌گونه که جدول و توضیحات فوق نتیجه‌گیری می‌شود به دلیل اقبال عمومی به رمزارزها و نوسانات زیاد که مستعد کسب سودهای هنگفت هستند، در کشور عزیزمان ایران و همچنین در مابقی نقاط جهان سرمایه‌گذاران در تلاش‌اند که بتوانند با روش‌های نوینی همچون هوش مصنوعی و یادگیری ماشین به پیش‌بینی قیمت ارز دیجیتال با دقت و کارایی مناسب بپردازند تا از این راه بتوان علاوه بر جلوگیری از ضررهای مالی به کسب سود نیز پرداخت لذا در جهت دستیابی به چنین روش‌های این پژوهش انجام شده است.

## روش‌شناسی

### ۱. رمزارزها

رمزارزها گونه‌ای پول دیجیتال است که در آن تولید واحد پول و تأیید اصالت تراکنش پول با استفاده از الگوریتم‌های رمزگذاری کنترل می‌شود و معمولاً به طور نامتمرکز (بدون وابستگی به یک بانک مرکزی) کار می‌کند. صادرکننده یا تنظیم‌کننده مرکزی ندارد، اما از سامانه توزیع شده برای ذخیره تراکنش‌ها و مدیریت انتشار واحدهای جدید استفاده می‌کند و برای ممانعت از جعل و تراکنش‌های متقلبانه بر رمزنگاری تکیه دارد. بیت‌کوین و کریپتوکارنسی‌های دیگر جزوی از این رمزارزها هستند که با رایانه‌های قوی و مصرف انرژی برق بسیار زیادی و با محاسبات ریاضیاتی پیچیده خلق می‌شوند. از دیگر مزایای این تکنولوژی می‌توان به بلاک‌چین<sup>۱</sup> یعنی بستری که در آن رمزارزها تراکنش می‌شوند، اشاره داشت که امکان برقراری ارتباطی بی‌واسطه را میان افراد فراهم می‌کند و دیگر نیازی به واسطه‌هایی مانند بانک‌ها و مؤسسات مالی نخواهد بود علاوه بر این امکان تقلب در این رمزارز وجود ندارد زیرا کاربران مختلف که در

<sup>1</sup> Block Chain

شبکه بلاک چین حاضر هستند، گره نامیده می‌شوند و هر تراکنشی که در شبکه بلاک چین صورت می‌گیرد باید به تأیید اکثریت گره‌ها یا همان کاربران برسد. با توجه به این ویژگی، برای اینکه تغییر در داده‌ها به وجود بیاید باید بیش از نصف کاربران تراکنش‌ها را به غلط تأیید نمایند که این کار در عمل و بر بستر بلاک چین کاملاً غیرممکن است؛ به عبارتی دیگر می‌توان گفت امنیت در شبکه رمزارزها به صورت صددرصدی تضمین شده است (Borges & Neves, 2020)

به‌طور کلی عملکرد رمزارزهایی که بر پایه اثبات کار<sup>۱</sup> عمل می‌کنند از جمله بیت کوین را در ۷ مرحله زیر می‌توان خلاصه کرد. این مراحل عبارت‌اند از:

۱- یک کاربر از طریق کریپتوکارنسی‌های موجود در کیف پول خود تراکنشی را انجام می‌دهد و سعی می‌کند تا ارز دیجیتال یا توکن<sup>۲</sup> مدنظر خود را به شخص دیگری ارسال کند.

۲- این تراکنش از طریق نرم‌افزار کیف پول پخش می‌شود و در آن لحظه منتظر می‌ماند تا توسط یک ماینر، روی این بلاک چین انتخاب شود. تا زمانی که ماینری آن را انتخاب نکرده است، این تراکنش در استخر تراکنش‌های تأیید نشده معلق می‌ماند.

۳- ماینرهای موجود در شبکه - که به آن‌ها نود نیز گفته می‌شود - تراکنش‌ها را از این استخرها انتخاب کرده و آن‌ها را به شکل یک بلوک درمی‌آورند. یک بلوک در اصل شامل مجموعه‌ای از تراکنش‌ها که در این لحظه شامل تراکنش‌های تأیید نشده است. به‌علاوه برخی اطلاعات اضافی دیگر مانند امضای دیجیتال، زمان‌سنج و غیره می‌شود.

۴- ماینرها با انتخاب تراکنش‌ها و افزودن آن‌ها به بلوک خود، بلوکی از تراکنش‌ها توسط فرآیند هشینگ<sup>۳</sup> ایجاد می‌کنند. آن‌ها در بلاک چین برای اضافه کردن این بلوک از تراکنش‌ها به یک امضا نیاز دارند. این امضا که به آن اثبات کار<sup>۴</sup> گفته می‌شود با حل یک مسئله بسیار پیچیده ریاضی ساخته شده و برای هر بلوک از تراکنش‌ها

<sup>1</sup> Proof of work

<sup>2</sup> Token

<sup>3</sup> هشینگ یکی از راه‌های ایجاد امنیت در هنگام انتقال پیام است که با استفاده از یک تابع ریاضی مقداری را به مقدار دیگر تبدیل می‌کند.

<sup>4</sup> Proof of work

منحصربه‌فرد است. هر بلوک یک مسئله ریاضی متفاوت دارد که جواب آن به‌صورت یک رشته عدد رمزنگاری شده می‌باشد.

۵- ماینری که بتواند اولین امضای واجد شرایط را برای بلوک خود پیدا کند، این بلوک و امضای آن را برای سایر ماینرها منتشر خواهد کرد.

۶- اکنون باید سایر ماینرها صحت امضا را با استفاده از داده‌های بلوک پخش شده، تأیید کنند و بررسی نمایند که آیا هش خروجی با امضای موجود مطابقت دارد یا خیر. اگر تطابق داشته باشد، سایر ماینرها اعتبار آن را تأیید می‌کنند و در نتیجه این بلوک می‌تواند به بلاک‌چین اضافه شود.

۷- بعد از اینکه یک بلوک به زنجیره اضافه شد، هر بلوک دیگری که پس از آن اضافه می‌شود، تأییدیه برای آن بلوک به حساب می‌آید. (Huang; Huang & Ni, 2019)

در این مقاله روشی مناسب برای پیش‌بینی قیمت روزهای آینده بیت کوین بر اساس شبکه‌های عصبی بازگشتی که به‌صورت موازی در کنار یکدیگر قرار گرفته‌اند ارائه می‌شود. باید توجه داشت که این روش بر مبنای تحلیل تکنیکال در علوم اقتصادی شکل گرفته است. تحلیل تکنیکال خود بر سه اصل زیر بنا شده است:

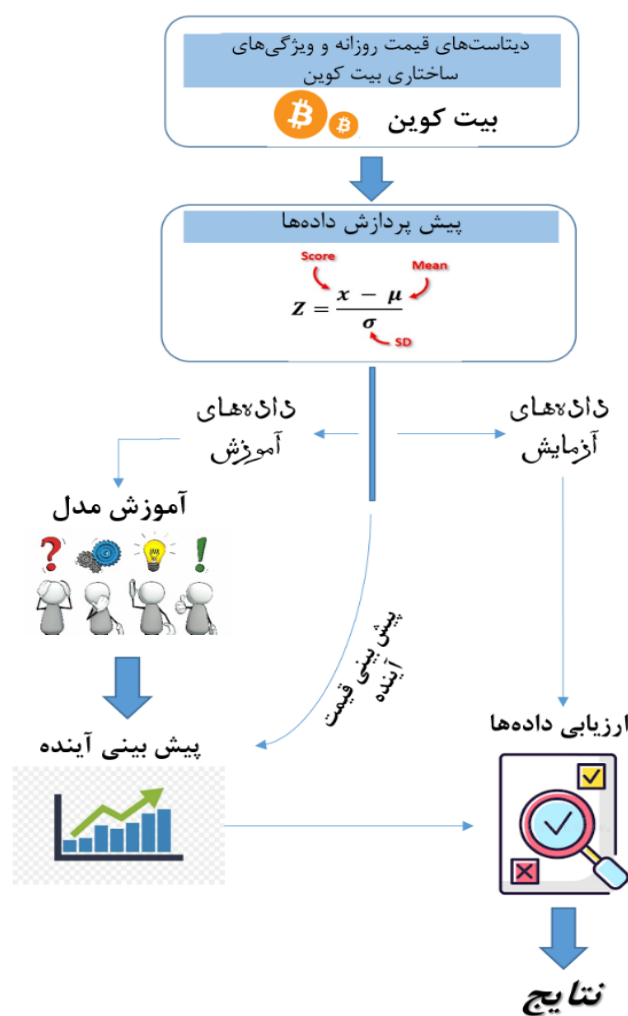
۱. اصل اول: همه چیز در قیمت سهم نهفته شده است

۲. اصل دوم: قیمت‌ها بر اساس روندها حرکت می‌کنند.

۳. اصل سوم: تاریخ همیشه تکرار می‌شود.

لذا هدف اصلی شبکه‌های عصبی بازگشتی در این پژوهش شناسایی و درک الگوهای حرکتی در داده‌های قیمتی و ساختاری شبکه بیت کوین می‌باشند؛ زیرا تمامی عوامل اجتماعی، سیاسی و اقتصادی به‌صورت مستقیم بر روی قیمت و ویژگی‌های ساختاری شبکه بیت کوین تأثیر می‌گذارند؛ و با بررسی و شناسایی این تأثیرات می‌توان به پیش‌بینی قیمت بیت کوین برای روزهای آینده پرداخت.

در بخش‌های بعدی به توضیحات مفصلی در رابطه با روش استفاده شده در تحقیق و نحوه اجرای آن می‌پردازیم. شکل شماره ۱ مراحل انجام این تحقیق را نشان می‌دهد.



شکل (۱): روش انجام تحقیق  
منبع: یافته‌های پژوهش

### جمع‌آوری داده‌ها

پس از گذشتن از سال ۲۰۱۷ میلادی قیمت بیت کوین سیر صعودی بی‌سابقه‌ای را تجربه کرد این روند صعودی باعث شد بسیاری از سرمایه‌گذاران به سمت این بازارها کشیده شوند از این رو وبسایت‌ها و منابع اطلاعاتی بسیاری برای رمزارزها در سطح اینترنت ایجاد گردید. در این وبسایت‌ها داده‌های اطلاعاتی



مختلف اعم از ویژگی‌های ساختاری و قیمتی رمز ارزها را ارائه می‌شود. در این پژوهش به‌منظور جمع‌آوری اطلاعات از دو وب‌سایت معتبر (investing.com) و (charts.coinmetrics.io) استفاده شده است. از وب‌سایت (charts.coinmetrics.io) اطلاعات دقیقی از ویژگی‌های ساختاری بیت‌کوین و از وب‌سایت (investing.com) داده‌های قیمتی جمع‌آوری شده است. به دلیل ماهیت نوسانی قیمت رمزارزها به‌خصوص بیت‌کوین و درک صحیح‌تر قیمت برای دادگان اول که شامل داده‌های قیمتی است از چهار ویژگی قیمت میانگین روز، قیمت باز شدن، کمترین و بیشترین قیمت استفاده شده است. برای دادگان دوم که شامل ویژگی‌های ساختاری و شبکه‌ای بیت‌کوین است از پنج ویژگی میانگین اندازه هر بلوک<sup>۱</sup>، قدرت هش<sup>۲</sup>، سختی شبکه<sup>۳</sup>، مجموع تراکنش‌های روزانه، پاداش ماینرها استفاده شده است. هر دو این دادگان‌ها از تاریخ ۲۰۱۶/۱/۱ تا ۲۰۲۱/۱/۳۱ است و هریک شامل ۱۸۵۹ داده می‌باشد و به‌صورت مجزا از هم مورد استفاده قرار می‌گیرند. در جدول ۲ توضیحاتی در رابطه با هر یک از ویژگی‌های ساختاری استفاده شده در پژوهش آورده شده است.

### جدول (۲): ویژگی‌های ساختاری و توضیحات آن

ویژگی	توضیحات
میانگین اندازه بلوک	میانگین اندازه بلوک‌های تولید شده در طول ۲۴ ساعت بر اساس بایت
قدرت هش	میانگین سرعت روزانه پردازش تمامی ماینرهای شبکه بر اساس تراشه
سختی شبکه	میانگین سختی یافتن هش جواب برای ساختن بلوک جدید
مجموع تراکنش	تعداد تمامی تراکنش‌های صورت گرفته
پاداش ماینرها	مجموع پاداش روزانه ماینرها حاصل از تراکنش‌ها و ساختن بلوک جدید

منبع: یافته‌های پژوهش

این پنج ویژگی بر اساس نتایج پژوهش‌های پیشین و آزمون‌های دقت و کارایی انجام شده بر روی ساختار شبکه عصبی این پژوهش از مجموع ۱۶ ویژگی اصلی موجود انتخاب شده است (Derbentsev; Datsenko, Stepanenko & Bezkorovainyi, 2019). می‌توان گفت این پنج ویژگی ساختاری به همراه

<sup>1</sup> Average block size

<sup>2</sup> Hash rate

<sup>3</sup> Difficulty

چهار ویژگی قیمتی از مهم ترین عوامل تأثیرگذار بر روی قیمت آینده رمزارزها هستند. تأثیر هر یک از ویژگی ها می تواند پیچیده و در شرایط مختلف متفاوت باشد برای ادامه کار، داده های قیمتی به عنوان دادگان اول در یک مجموعه و داده های ساختاری به عنوان دادگان دوم در مجموعه مجزای دیگری قرار می گیرد. جدول ۳ نمایی از داده های استفاده شده در این تحقیق را به همراه آمار توصیفی متغیرهای پژوهش نمایش می دهد.

جدول (۳): آمار توصیفی متغیرهای پژوهش

تعداد	میانگین	بیشینه	کمینه	انحراف معیار	
۱۸۵۹	۶۵۹۴/۱	۴۰۵۹۹/۳	۳۶۸	۵۹۵۷/۵	میانگین قیمت روزانه
۱۸۵۹	۶۵۷۶/۳	۴۰۶۰۷/۲	۳۶۵	۵۹۲۶/۶	قیمت باز شدن
۱۸۵۹	۶۷۷۰/۲	۴۱۹۲۱/۷	۳۷۵/۹	۶۱۶۱/۹	بیشینه قیمت روزانه
۱۸۵۹	۶۳۶۴/۶	۳۸۷۷۵/۱	۳۵۰/۴	۵۶۵۷/۳	کمینه قیمت روزانه
۱۸۵۹	$۹/۷۲۴۸ \times (۱۰^{\wedge}۵)$	$۱/۴۲۱۸ \times (۱۰^{\wedge}۶)$	$۴/۳۱۴۵ \times (۱۰^{\wedge}۵)$	$۱/۹۳۱۰ \times (۱۰^{\wedge}۵)$	میانگین اندازه بلوک
۱۸۵۹	$۴/۴۸۸۵ \times (۱۰^{\wedge}۷)$	$۱/۶۲۲۶ \times (۱۰^{\wedge}۸)$	$۶/۸۷۴۵ \times (۱۰^{\wedge}۵)$	$۴/۴۶۱۴ \times (۱۰^{\wedge}۷)$	قدرت هش
۱۸۵۹	$۶/۱۶۱۶ \times (۱۰^{\wedge}۱۲)$	$۱/۹۹۹۷ \times (۱۰^{\wedge}۱۳)$	$۱/۰۳۸۸ \times (۱۰^{\wedge}۱۱)$	$۶/۱۴۹۰ \times (۱۰^{\wedge}۱۲)$	سختی شبکه
۱۸۵۹	$۳/۳۲۳۰ \times (۱۰^{\wedge}۸)$	$۵/۹۵۶۱ \times (۱۰^{\wedge}۸)$	$۱/۰۱۷۹ \times (۱۰^{\wedge}۸)$	$۱/۴۳۵۰ \times (۱۰^{\wedge}۸)$	مجموع تراکنش
۱۸۵۹	$۱/۰۵۶۳ \times (۱۰^{\wedge}۷)$	$۵/۴۲۸۳ \times (۱۰^{\wedge}۷)$	$۹/۲۲۶۰ \times (۱۰^{\wedge}۵)$	$۸/۱۳۳۵ \times (۱۰^{\wedge}۶)$	پاداش ماینرها

#### استاندارسازی داده ها

به دلیل نوسانات و تغییرات زیاد قیمت بیت کوین دادگان ها شامل رنج وسیعی از اعداد می باشند به صورتی که بزرگ ترین عدد در میانگین قیمت حدود ۹۵ برابر بزرگ تر از کوچک ترین مقدار است در دادگان دوم که شامل ویژگی های ساختاری بیت کوین می باشد نیز به همین صورت است به طور مثال در مورد ویژگی سختی استخراج نسبت بیشترین مقدار به کمترین مقدار حدوداً برابر ۱۸۵ است. لذا استفاده از روش های متداولی مانند نگاشت کل مجموعه در یک بازه خاص که تمامی اعداد را بین ۰ تا ۱ قرار می دهد و یا اعداد را بین -۱ تا ۱ قرار می دهد نمی تواند به خوبی بین اعداد تفکیک ایجاد کند و بسیاری از اعداد که تفاوت های زیادی با یکدیگر دارند پس از اعمال این روش در فاصله بسیار اندکی از یکدیگر قرار می گیرند (Garg, 2018) این

فاصله اندک توانایی تشخیص نوسانات و الگوهای موجود در داده‌ها را از شبکه می‌گیرد و خروجی‌های حاصل از دقت کمتری برخوردار می‌شوند. در نتیجه برای استانداردسازی داده‌ها از رابطه ۳ استفاده شده است. در این استانداردسازی میانگین و انحراف معیار داده‌ها دخیل‌اند لذا تفکیک مناسبی بین اعداد ایجاد می‌شود و مشکل موجود در نرمالیزه سازی به روش پیشین به وجود نمی‌آید و اعداد با رنج‌های متفاوت در فواصل مناسبی از یکدیگر قرار می‌گیرند. این مهم باعث می‌شود که شبکه درک صحیح و دقیقی از داده‌های ورودی پیدا کند.

$$\text{mean}(x) = \frac{x_1 + x_2 + \dots + x_n}{n} \quad (1)$$

$$\text{std}(x) = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \text{mean}(x))^2} \quad (2)$$

$$x_{\text{normalized}} = \frac{x_i - \text{mean}(x)}{\text{std}(x)} \quad (3)$$

در روابط بالا  $\mu$  میانگین عددی و  $\text{std}$  نیز انحراف معیار داده‌ها است. نتایج خروجی‌ها نشان‌دهنده این است که استفاده از این روش می‌تواند تا حدود ۵ الی ۷ درصد دقت و کارایی شبکه را بهبود بخشد.

#### تشکیل زوج داده‌های ورودی-خروجی

پس از استانداردسازی داده، داده‌ها به زوج‌های متناظر ورودی و خروجی تقسیم شد. رابطه ۴، ۵ و ۶ نحوه تبدیل داده‌های هر دو دادگان را به مقادیر موردنظر نشان می‌دهد.

$$X = [x_1, x_2, \dots, x_n] \quad Y = [y_1, y_2, \dots, y_n] \quad (4)$$

$$in_{1i} = [x_{i-w+1}, x_{i-w+2}, x_{i-w+3}, \dots, x_i], out_{1i} = [x_{i+1}] \quad (5)$$

$$in_{2i} = [y_{i-w+1}, y_{i-w+2}, y_{i-w+3}, \dots, y_i], out_{2i} = [x_{i+1}] \quad (6)$$

در روابط بالا،  $X$  و  $Y$  به ترتیب بردارهای نشان‌دهنده دادگان استاندارد شده اول و دوم،  $n$  نشان‌دهنده طول داده‌های ورودی و  $w$  پارامتر تعیین کننده طول داده‌های ورودی است. به عبارت بهتر  $w$  تعداد روزهای استفاده شده برای پیش‌بینی روز آینده را نشان می‌دهد. انتخاب مقدار این پارامتر اختیاری است و بستگی به موضوع و ماهیت تحقیق می‌تواند مقادیر متفاوت

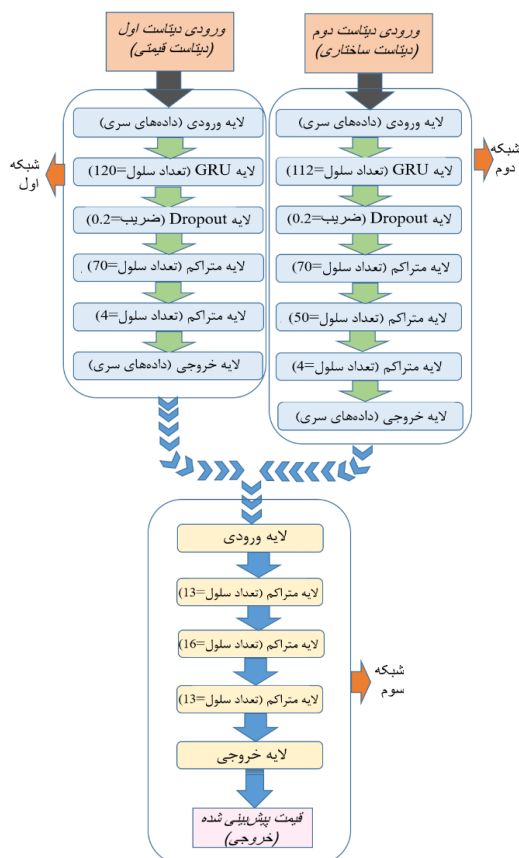
داشته باشد. این مقادیر باید به گونه‌ای انتخاب شوند که شبکه بتواند به درک صحیحی از روابط بین خروجی-ورودی دست یابد و همچنین منجر به افزایش بی‌رویه حجم محاسبات نگردد. لذا در زمینه پیش‌بینی قیمت آینده با استفاده از داده‌های پیشین انتخاب صحیح و به‌جای این پارامتر از اهمیت بالایی برخوردار است و باید به آن توجه ویژه‌ای شود.

در روابط ۵ و ۱۶ امین زوج ورودی و خروجی شبکه نشان داده شده است. همان‌گونه که مشاهده می‌شود شبکه دو ورودی مجزا و یک خروجی واحد به همراه دارد.

### طراحی پیاده‌سازی شبکه عصبی

پس از آماده‌سازی داده‌ها، شبکه عصبی موردنظر در نرم‌افزار MATLAB 2020b کدنویسی و پیاده‌سازی شد. به دلیل نوسانات شدید قیمتی تلاش شده است ساختار به‌گونه‌ای طراحی شود که بتواند به‌صورت کامل و حداکثری الگوها و روابط موجود بین زوج داده‌های ورودی-خروجی را دریابد در این ساختار از معماری لایه‌های GRU به‌صورت موازی استفاده شده است. در واقع این ساختار از سه شبکه عصبی کوچک تشکیل شده است که وظیفه تشخیص الگوها و پیش‌بینی قیمت را به‌صورت مجزا از دیگری بر عهده دارند هر یک از این دو شبکه به‌صورت جداگانه کدنویسی و پیاده‌سازی شده است در انتهای هر یک از این دو شبکه، مقداری به‌عنوان خروجی حاصل می‌شود به‌عبارتی دیگر در ساختار طراحی شده، دو سیستم هوشمند وجود دارند که سیستم اول بر اساس قیمت روزهای گذشته و سیستم دوم بر اساس مشخصات ساختاری روزهای گذشته به پیش‌بینی قیمت می‌پردازند. این دو خروجی در ادامه و در شبکه سوم با یکدیگر تلفیق می‌شوند و خروجی با عنوان پیش‌بینی قیمت، ایجاد می‌گردد. در واقع شبکه سوم بر اساس دقت و کارایی هر یک از خروجی‌های پیشین وظیفه ترکیب نتایج دو شبکه قبلی را بر عهده دارد. در ادامه ساختار هر یک از این شبکه‌ها به‌صورت مجزا توضیح داده می‌شود.

شکل ۲ نمای کلی این سه شبکه، نحوه قرارگیری آن‌ها در کنار یکدیگر، جهت حرکت داده‌ها و تعداد سلول‌های هر لایه را نشان می‌دهد.



شکل (۲) نمای کلی شبکه

منبع: یافته‌های پژوهش

همان‌گونه که در شکل فوق نیز مشاهده می‌شود ابتدا مجموعه دادگان اول که همان چهار ویژگی قیمتی می‌باشند وارد شبکه عصبی اول می‌شوند در همین حین و به‌طور موازی دادگان دوم که پنج ویژگی ساختاری شبکه بین‌کوبین هستند وارد شبکه دوم عصبی می‌گردند؛ و این شبکه‌ها بر اساس آموزش‌هایی که پیش‌تر بر روی آن‌ها صورت گرفته است به پیش‌بینی قیمت روزهای آینده بیت‌کوبین می‌پردازند و مقداری را به‌عنوان قیمت روزهای آینده بیت‌کوبین در خروجی خود ایجاد می‌کنند سپس این دو قیمت پیش‌بینی شده وارد یک شبکه سوم با عنوان شبکه تلفیق می‌شوند و شبکه تلفیق بر اساس میزان دقت هر

یک از شبکه‌ها ضریبی برای هر یک از پیش‌بینی‌ها در نظر می‌گیرد و این دو مقدار را با یکدیگر ترکیب می‌نماید تا یک مقدار واحد به‌عنوان قیمت نهایی پیش‌بینی ایجاد شود

### بحث و نتیجه

پس از پایان یادگیری، شبکه‌های اول و دوم به‌صورت جداگانه مورد اعتبارسنجی و آزمایش قرار گرفت تا بررسی شود که تا چه اندازه‌ای توانسته در یافتن روابط بین خروجی-ورودی موفق ظاهر شود. سپس اعتبارسنجی و آزمایش نهایی بر روی ساختار کلی طراحی که متشکل از هر سه شبکه در تعامل با یکدیگر می‌باشد انجام شد. بدیهی است که هرچه شبکه در این بخش دقت و کارایی بیشتری داشته باشد در بخش پیش‌بینی نیز بهتر عمل می‌کند. برای آگاهی از کارایی ساختار کلی طراحی شده از معیارهای متداول سنجش دقت که عموماً در پژوهش‌های حوزه پیش‌بینی شاخص قیمتی شناخته شده هستند، استفاده شد. روابط ۷، ۸، ۹ و ۱۰ به ترتیب نشان‌دهنده معیارهای میانگین مربع خطا<sup>۱</sup>، مجذور میانگین مربع خطا<sup>۲</sup>، میانگین قدرمطلق خطا<sup>۳</sup> و میانگین قدر مطلق درصد خطا<sup>۴</sup> است. از این معیارها علاوه بر استفاده در این بخش در قسمت نتایج و پیش‌بینی‌های آینده نیز استفاده شد.

$$MSE = \frac{1}{N} \sum_{i=1}^N (R - R')^2 \quad (7)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (R - R')^2} \quad (8)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |R - R'| \quad (9)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{R - R'}{R} \right| \quad (10)$$

در روابط بالا N تعداد کل داده‌های خروجی، R مقدار واقعی خروجی و R' مقدار خروجی حاصل از شبکه (قیمت پیش‌بینی شده) می‌باشد.

<sup>1</sup> Mean Square Error

<sup>2</sup> Root Mean Square Error

<sup>3</sup> Mean Absolute Error

<sup>4</sup> Mean Absolute Percentage Error

## اعتبارسنجی شبکه اول (شبکه قیمتی)

در ابتدا شبکه اول که بر مبنای قیمت روزهای گذشته به پیش‌بینی قیمت در روزهای آینده می‌پردازد، مورد بررسی و اعتبارسنجی قرار گرفت. دادگان مورد نیاز این بخش همان گونه که در فصل پیشین توضیح داده شد از وبسایت معتبر (investing.com) جمع‌آوری شده است. تعداد داده‌های موجود در این دادگان ۱۸۵۹ عدد می‌باشد و پیش‌بینی برای بخش بررسی و صحت عملکرد شبکه برای یک روز آینده انجام می‌گیرد.

در ابتدا میزان کارایی و دقت شبکه در مرحله آموزش از طریق چهار معیار توضیح داده شده در بالا برای مقادیر مختلف پارامتر  $W$  بررسی شد. همان گونه که در توضیحات فصل سوم نیز به آن اشاره شد پارامتر  $W$  در واقع نشان دهنده تعداد روزهای گذشته استفاده شده برای پیش‌بینی روز آینده می‌باشد. به عنوان مثال  $W=15$  بدین معناست که شبکه برای پیش‌بینی قیمت از داده‌های ۱۵ روز گذشته استفاده می‌نماید جدول ۴ نتایج حاصل از بررسی دقت و کارایی شبکه را نشان می‌دهد. در این جدول از مقادیر  $W=5, 10, 15, 20, 25$  استفاده شده است.

جدول (۴): جدول اعتبارسنجی میزان کارایی شبکه اول بر روی داده‌های تست

$MAPE$	$MAE$	$RMSE$	$MSE$	$W$
۴/۷۳۴٪	۱۹۰/۱۰۶	۴۱۱/۹۰۸	۱۶۹۶۶۸/۲	۵
۶/۲۹۹٪	۲۸۳/۷۸	۵۶۳/۶۱	۳۱۷۶۵۶/۲۳۲	۱۰
۷/۲۷۳٪	۳۲۰/۳۴	۶۴۳/۶۱	۴۱۴۲۳۳/۸۳۲	۱۵
۹/۵۵٪	۴۰۸/۸۹۴	۷۶۰/۵۵۱	۵۷۸۴۳۷/۸۲۳	۲۰
۱۱/۹۶۹٪	۴۸۶/۰۲۴	۸۸۰/۶۵۶	۷۷۵۹۳۱/۹۵۶	۲۵

منبع: یافته‌های پژوهش

باید دقت داشت مقادیر خطای بیش از ۱۰٪ نشان از عدم درک کامل از روابط ورودی-خروجی دارد. هم‌چنین مقادیر بسیار کم و نزدیک صفر هم برای خطای شبکه قابل قبول نیست و این مورد نشان از برآزش بیش از حد<sup>۱</sup> سیستم دارد. همان گونه که در جدول نشان داده شده است


<sup>۱</sup> Overfitting

میزان خطای شبکه اول طراحی شده در این پژوهش به طور میانگین ۷/۹۶۵ درصد می باشد که این نشان از یادگیری کامل و دقیق شبکه دارد.

با توجه به جدول، هر چه مقدار طول روزهای گذشته ( $W$ ) افزایش یابد. میزان خطای سیستم نیز افزایش می یابد؛ که این مورد به دلیل افزایش حجم محاسبات رخ می دهد. لذا با توجه به کاهش دقت و افزایش زمان محاسبات استفاده از مقادیر زیاد برای پارامتر  $W$  توصیه نمی شود همچنین باید توجه داشت که استفاده از بازه های کوتاه برای  $W$  نیز معتبر نیست و شبکه به دلیل تعداد کم داده نمی تواند درک صحیحی از روابط قیمتی روزهای گذشته به دست آورد. در این صورت شبکه صرفاً قیمتی را نزدیک آخرین قیمت داده ورودی برای روزهای آینده انتخاب می کند که باعث ایجاد پدیده همگرایی در شبکه می شود در این پدیده علی رغم اینکه داده ها از دقت بالایی برخوردار است ولی کارآمد و معتبر نیست و در این حالت شبکه درک صحیح و درستی از الگوهای قیمت به دست نیاورده است لذا نمی توان از آن در قسمت های بعدی که مربوط به پیش بینی قیمت روزهای آینده است، استفاده کرد. با توجه به توضیحات ارائه شده مقادیر  $W=15, 20$  برای پیش بینی روزهای آینده نسبت به مقادیر دیگر، برای رمز ارز بیت کوین از اعتبار بیشتری برخوردار هستند. از این رو برای بخش های آینده و پیش بینی قیمت در تحلیل های پیش رو نیز از این دو مقدار استفاده شد. (باید توجه داشت که چنانچه از داده های ورودی متفاوت و یا شاخص های قیمتی دیگر در این شبکه استفاده می شد مقادیر بهینه  $W$  می توانست متفاوت از حالت بهینه فعلی  $W$  باشد).

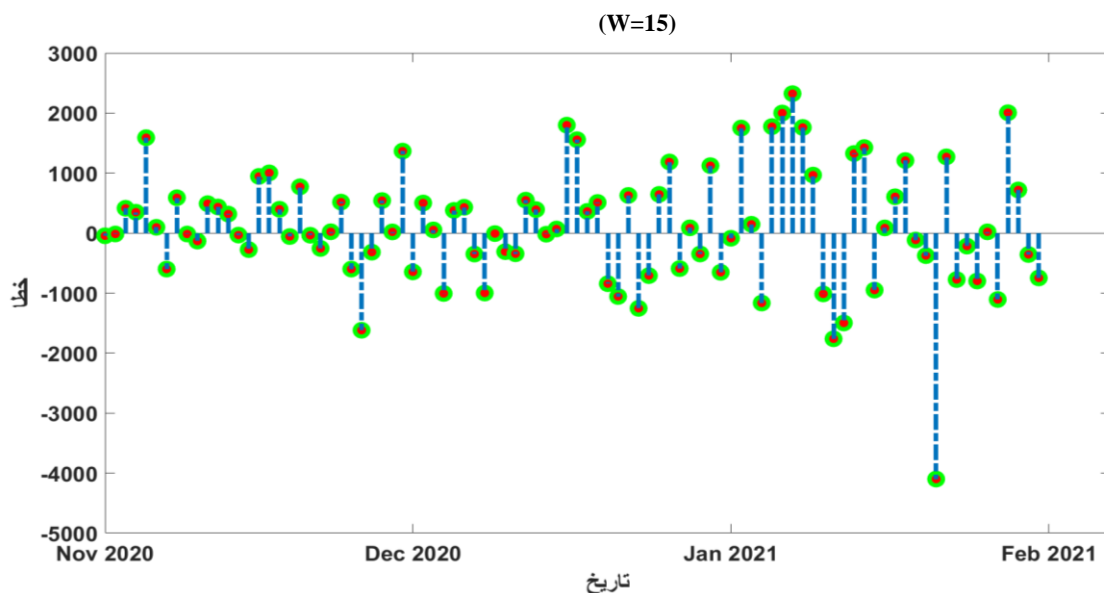
شکل شماره ۳ مقدار واقعی قیمت بیت کوین را در مقابل مقدار پیش بینی شده حاصل از شبکه عصبی شبکه اول (شبکه قیمتی) با پارامتر  $W=15$  نشان می دهد و شکل شماره ۴ نیز مقدار عددی این اختلاف را در همان بازه زمانی یعنی ۱۱ نوامبر سال ۲۰۲۰ تا ۳۱ ژانویه سال ۲۰۲۱ میلادی و با استفاده از نمودار میله ای نمایش می دهد.





شکل (۳): مقایسه قیمت واقعی و قیمت پیش بینی شده (W=15)

منبع: یافته های پژوهش



شکل (۴): اختلاف مقادیر واقعی و پیش بینی شده حاصل از شکل ۲

منبع: یافته های پژوهش

همان گونه که از جدول و اشکال فوق مشاهده می شود شبکه عصبی اول خود به تنهایی توانسته است الگوها و روندهای موجود در داده های قیمت را به خوبی شناسایی و درک کند؛ لذا پیش بینی های حاصل از این شبکه دقت و کارایی مناسبی دارد.

#### اعتبارسنجی شبکه دوم

در بخش جاری به بررسی و اعتبارسنجی شبکه دوم پرداخته شد. این شبکه بر اساس پنج ویژگی ساختاری بیت کوین به پیش بینی قیمت روزهای آینده این رمزارز می پردازد. دادگان این شبکه نیز همان گونه که در فصل سوم به آن اشاره شد از طریق دو وبسایت معتبر (investing.com) و (charts.coinmetrics.io) جمع آوری شده است و تعداد داده های این دادگان برابر ۱۸۵۹ عدد می باشد. این پیش بینی ها همچون شبکه اول در بخش اعتبارسنجی برای یک روز آینده انجام گرفته است.

در ابتدا میزان کارایی و دقت شبکه در مرحله آموزش همچون شبکه اول از طریق چهار معیار توضیح داده شده در بخش ۴-۱ برای مقادیر مختلف پارامتر  $W$  بررسی شد. جدول ۵ نتایج حاصل از بررسی دقت و کارایی شبکه را نشان می دهد. در این جدول از مقادیر  $W = 5, 10, 15, 20, 25$  استفاده شده است.

جدول (۵): جدول اعتبارسنجی میزان کارایی شبکه دوم بر روی داده های تست

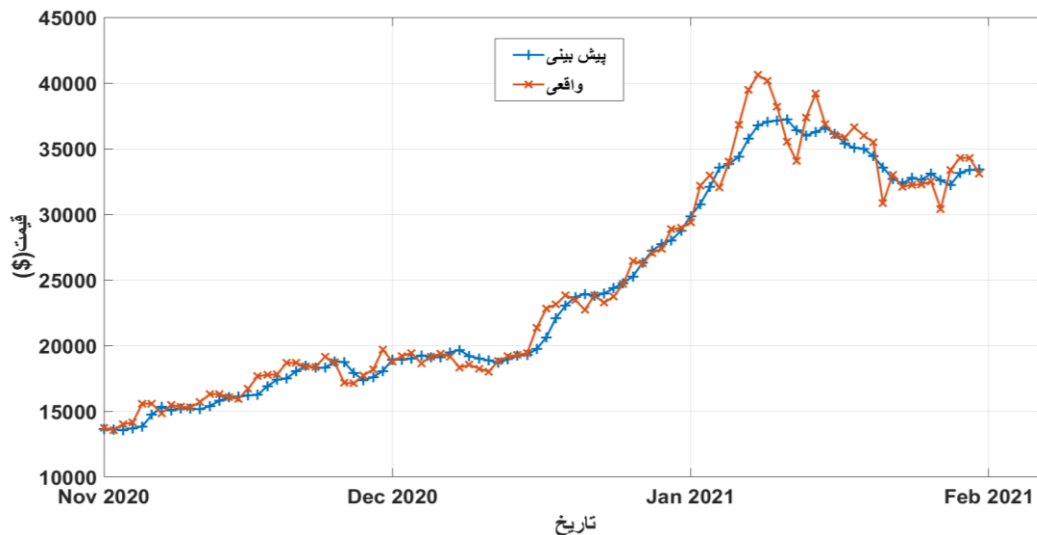
$MAPE$	$MAE$	$RMSE$	$MSE$	$W$
۷/۶۲۸٪	۳۳۲/۵۴	۶۶۰/۵۱۲	۴۳۶۲۷۶/۱۰۲	۵
۱۰/۱۹۲٪	۴۲۳/۳۸۲	۸۲۲/۷۵	۶۷۶۹۱۷/۵۶۲	۱۰
۱۴/۳۸۷٪	۶۳۴/۸۲۳	۹۳۴/۵۴	۸۷۳۳۶۵/۰۱۱	۱۵
۱۵/۵۵٪	۶۷۰/۲۹۴	۹۶۰/۵۱۱	۹۲۲۵۸۱/۳۸۱	۲۰
۱۹/۸۷۱٪	۷۴۰/۰۱	۱۱۲۹/۹۵	۱۲۷۶۷۸۷/۰۰۳	۲۵

منبع: یافته های پژوهش

همان طور که از نتایج جدول شماره ۵ مشاهده می شود میزان خطای این شبکه به طور میانگین برابر ۱۳/۵۲۵ درصد است که از مقدار خطای شبکه اول بیشتر می باشد. در رابطه با کمتر بودن


دقت شبکه دوم باید اشاره داشت که داده‌های قیمتی از نظر ارزش محتوایی از داده‌های ساختاری شبکه بیت کوین غنی‌تر می‌باشند و عوامل تأثیرگذار بیشتری را در خود جای داده‌اند. به عبارت بهتر تمامی عوامل کوچک و بزرگ در داده‌های قیمتی تأثیرگذار هستند لذا شبکه عصبی طراحی شده بر مبنای قیمت روزهای گذشته، از دقت و کارایی نسبی بیشتری نسبت به شبکه عصبی بر مبنای داده‌های ساختاری برخوردار است. در مجموع با توجه میزان خطای این شبکه استفاده از این برای پیش‌بینی قیمت روزهای آینده بیت کوین ارزشمند و کارا بوده و می‌توان از آن در این زمینه‌ها بهره‌برداری نمود.

همچون بخش پیشین در شکل شماره ۵ مقدار واقعی قیمت بیت کوین در مقابل مقدار پیش‌بینی شده حاصل از شبکه عصبی دوم (شبکه ساختاری) با پارامتر  $W=15$  نشان داده است و شکل شماره ۶ نیز در ادامه همین شکل و برای تکمیل آن، مقدار عددی این اختلاف را در همان بازه زمانی یعنی ۱۱ نوامبر سال ۲۰۲۰ تا ۳۱ ژانویه سال ۲۰۲۱ میلادی و با استفاده از نمودار میله‌ای نمایش می‌دهد.



شکل (۵) مقایسه قیمت واقعی و قیمت پیش‌بینی شده ( $W=15$ )

منبع: یافته‌های پژوهش



شکل (۶) اختلاف مقادیر واقعی و پیش‌بینی شده حاصل از شکل ۴ (W=15)

منبع: یافته‌های پژوهش

همان‌گونه که در اشکال ۵ و ۶ مشاهده می‌شود شبکه دوم با استفاده از پنچ ویژگی شبکه بیت کوین توانسته درک صحیح و مناسبی نسبت به روابط ورودی-خروجی بیابد. به دلیل ماهیت نوسانی زیاد رمزارزها و خصوصاً بیت کوین در چندین سال اخیر مقدار خطا همچون شبکه اول دارای نوسانات زیادی می‌باشد که می‌توان این مورد را در شکل‌های فوق نیز مشاهده کرد.

#### اعتبارسنجی ساختار اصلی

در قسمت قبل شبکه‌های اول دوم که به ترتیب بر مبنای قیمت روزهای گذشته و ویژگی‌های ساختاری به پیش‌بینی قیمت در روزهای آینده می‌پرداختند، مورد بررسی و اعتبارسنجی قرار گرفت و نتایج حاصل از این شبکه‌ها توسط جداول و اشکال مختلف گزارش شد.

در بخش جاری به بررسی و اعتبارسنجی ساختار اصلی طراحی شده که شامل شبکه‌های اول و دوم به صورت موازی و با همراهی یک شبکه تلفیق داده‌ها است، پرداخته شد. دادگان مورد استفاده برای این بخش عیناً همان دادگان استفاده شده در شبکه‌های اول و دوم می‌باشد. نمای کلی این ساختار به همراه توضیحات تفصیلی آن در شکل ۱ و ۲ موجود است. به منظور تعیین

میزان یادگیری شبکه و درک صحیح الگوهای قیمتی موجود بین داده‌های ورودی-خروجی همچون دو شبکه پیشین از چهار معیار توضیح داده شده در بخش قبلی برای مقادیر مختلف پارامتر  $W$  استفاده شد. جدول ۶ نشان دهنده نتایج به دست آمده از آزمون کارایی و میزان یادگیری ساختار موردنظر است. به‌منظور بررسی دقیق و کامل این مورد از طول‌های مختلفی از داده‌های ورودی شامل  $W=5, 10, 15, 20, 25$  استفاده شده است.

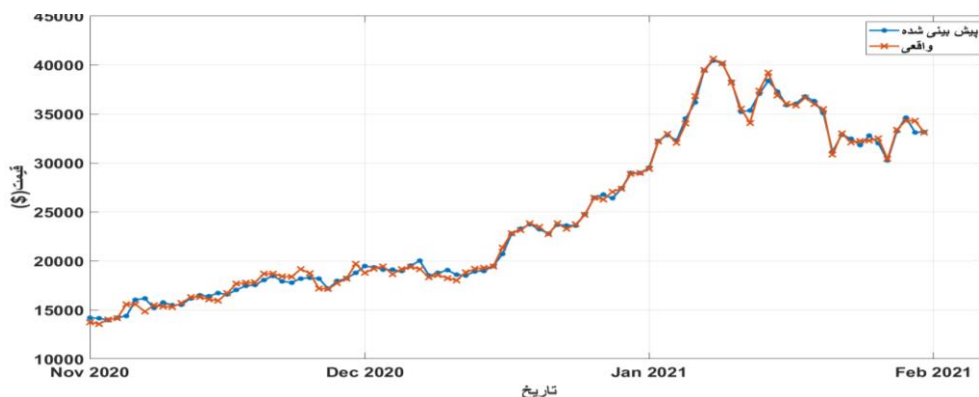
جدول (۶): جدول اعتبارسنجی میزان کارایی شبکه بر روی داده‌های تست

$MAPE$	$MAE$	$RMSE$	$MSE$	$W$
۲/۰۴۱٪	۱۲۰/۱۶۲	۳۲۲/۱۱۵	۱۰۳۷۵۸/۰۷۳	۵
۲/۵۶۳٪	۱۲۷/۲۴۶	۳۲۵/۷۰۱	۱۰۶۰۸۱/۱۴۱	۱۰
۲/۶۴۱٪	۱۳۶/۰۲۹	۳۳۳/۶۱۴	۱۱۱۲۹۸/۳۰۱	۱۵
۳/۲۴۳٪	۱۴۳/۲۶۱	۳۴۸/۲۹۰	۱۲۱۳۰۵/۹۲۴۱	۲۰
۳/۹۴۲٪	۱۶۵/۳۷۳	۳۵۹/۶۵۶	۱۲۹۳۵۲/۴۳۸	۲۵

منبع: یافته‌های پژوهش

همان‌گونه که در جدول نشان داده شده است، میزان خطای سیستم طراحی شده در این پژوهش در حدود ۲ الی ۴ درصد می‌باشد که این نشان از یادگیری کامل و دقیق شبکه دارد. با توجه به جدول، هر چه مقدار طول روزهای گذشته ( $W$ ) افزایش یابد، میزان خطای سیستم نیز افزایش می‌یابد؛ که عمده دلیل این مورد افزایش حجم محاسبات است. لذا همچون شبکه‌های پیشین در ساختار اصلی نیز از همان پارامتر ۱۵ و  $W=20$  استفاده شد.


شکل شماره ۷ مقدار واقعی قیمت بیت‌کوین را در مقابل مقدار پیش‌بینی شده حاصل از ساختار عصبی پژوهش با پارامتر  $W=15$  نشان می‌دهد و شکل شماره ۸ نیز مقدار عددی این اختلاف را در همان بازه زمانی یعنی ۱۱ نوامبر سال ۲۰۲۰ تا ۳۱ ژانویه سال ۲۰۲۱ میلادی و با استفاده از نمودار میله‌ای نمایش می‌دهد.



شکل (۷): مقایسه قیمت واقعی و قیمت پیش بینی شده

منبع: یافته‌های پژوهش

(W=15)




شکل (۸): اختلاف مقادیر واقعی و پیش بینی شده حاصل از شکل ۳ (W=15)

منبع: یافته‌های پژوهش

همان گونه که در مطالب پیشین توضیح داده شد استفاده از دو مقدار  $W=15, 20$  برای پیش بینی قیمت بیت کوین معتبرتر از بقیه مقادیر است و می توان اشکال بالا را برای پارامتر  $W=20$  نیز رسم نمود

پیش بینی روزهای آینده (ساختار اصلی)

در این بخش نتایج پیش بینی قیمت روزهای آینده ارائه شده است. دادگان استفاده شده در بخش آموزش از تاریخ ۲۰۱۶/۱/۱ تا ۲۰۲۱/۱/۳۱ است؛ لذا تاریخ پیش بینی های قیمت مربوط به بعد از ۳۱م ژانویه سال ۲۰۲۱ می باشد. به دلیل ماهیت نوسانی بالای رمزارزها این پیش بینی ها حداکثر تا ده روز آینده انجام شده است. شکل شماره ۹ نمودار قیمت واقعی و مقدار پیش بینی شده قیمت بیت کوین را برای بازه ۱۱م تا ۱۰ فوریه سال ۲۰۲۱ به همراه پارامتر طول بازه ای  $W=15$  نشان می دهد.



شکل (۹): نمودار مقایسه قیمت واقعی و پیش بینی شده برای روزهای آینده ( $w=15$ )

منبع: یافته های پژوهش

جدول ۷ به بررسی نتایج حاصل از پیش بینی قیمت بیت کوین در شکل ۹ به صورت عددی می پردازد. در این مقایسه از معیارهای استاندارد و متداول توضیح داده شده در روابط ۴-۱ الی ۴-۴ استفاده شد.

جدول (۷): مقایسه عددی نتایج حاصل از پیش بینی ( $W=20$ )

روز	قیمت واقعی	قیمت پیش بینی شده	خطا (MAE)	درصد خطا (MAPE)
اول	۳۳۵۱۵/۷	۳۲۸۵۰/۳	۶۶۵/۴	۱/۹۸۵٪
دوم	۳۵۴۸۵/۲	۳۶۱۳۲/۱	۶۴۶/۹	۱/۸۲۳٪
سوم	۳۷۶۴۶/۸	۳۸۱۴۹/۳	۵۰۲/۵	۱/۳۳٪
چهارم	۳۶۹۸۲/۱	۳۸۴۱۲/۷	۱۴۳۰/۶	۳/۸۶۸٪

۳/۲۰۱٪	۱۲۲۵/۸	۳۹۵۲۳/۴	۳۸۲۹۷/۶	پنجم
۶/۰۵۲٪	۲۳۷۶/۲	۳۶۸۸۰/۴	۳۹۲۵۶/۶	ششم
۵/۳۹۵٪	۲۰۹۶/۳	۳۶۷۵۶/۶	۳۸۸۵۲/۹	هفتم
۱۸/۰۸۸٪	۸۳۹۲/۳	۳۸۰۰۳/۴	۴۶۳۹۵/۷	هشتم
۱۷/۲۷۸٪	۸۰۳۶/۰	۳۸۴۷۲/۶	۴۶۵۰۸/۶	نهم
۱۵/۷۲۸٪	۷۰۵۲/۰	۳۷۷۸۴/۰	۴۴۸۳۶	دهم

منبع: یافته‌های پژوهش

عموماً پیش‌بینی‌ها در روزهای اولیه از دقت بالایی برخوردارند و تنایجی مشابه بخش اعتبارسنجی شبکه حاصل می‌شود. از این دقت به مرور زمان کاسته می‌شود و مقدار آن برای روزهای هشتم و بعد از آن به مقادیر بالای ۱۰ درصد می‌رسد. دلیل این امر علاوه بر ماهیت بسیار نوسانی ارزهای دیجیتال این است که برای پیش‌بینی هر روز از تمامی پیش‌بینی‌های ماقبل آن روز نیز استفاده می‌شود لذا علاوه بر خطای پیش‌بینی روز آتی، خطاهای پیش‌بینی روزهای گذشته نیز دخیل هستند.

#### مقایسه با نتایج پژوهش‌های پیشین

در این بخش به مقایسه روش ارائه شده توسط این تحقیق با پژوهش‌های محققان دیگر پرداخته شده است. در این پژوهش میانگین خطا، ۲/۶۴۱ درصد برای  $W=15$  و ۳/۲۴۳ درصد برای  $W=20$  برای ساختار اصلی پژوهش که متشکل از شبکه‌های عصبی GRU موازی است، به دست آمد. در ادامه توضیحات مختصری از روش‌های صورت گرفته پیشین آورده شده است و سپس این روش‌ها با روش انجام شده در این پژوهش مقایسه گردیده است. روی و همکاران در سه روش میانگین متحرک خودهمبسته یکپارچه<sup>۱</sup> و مدل خود همبسته<sup>۲</sup> و رگرسیون چند متغیره<sup>۳</sup> به ترتیب به میانگین خطای ۶/۶۹٪ و ۱۰/۷۵٪ و ۱۲/۴۲٪ دست یافتند (Roy; Nanjiba &

<sup>۱</sup> Auto Regressive Integrated Moving Average

<sup>۲</sup> Auto Regressive Model

<sup>۳</sup> Multi Regressive Model



Chakrabarty, 2018) پژوهش هیتما و همکاران با استفاده از روش ترکیب ماشین بردار پشتیبان<sup>۱</sup> با الگوریتم بهینه‌سازی ازدحامی ذرات<sup>۲</sup> مقدار ۹/۶٪ دارد (Hitam et al., 2019). روش گرگ و همکاران که بر اساس میانگین متحرک خودهمبسته یکپارچه است خطای کمتر از ۶ درصد دارد (Garg, 2018) در تحقیق دیگر ریزوان و همکاران از چندین روش مختلف بر پایه یادگیری عمیق برای پیش‌بینی قیمت بیت کوین استفاده کردند که در بهترین روش که مربوط به شبکه عصبی GRU است به خطای ۵/۳٪ رسیدند (Rizwan et al., 2019). جی و همکاران در پژوهش خود پارامترها و روش‌های مختلف را بررسی کردند. بهترین روش بر پایه شبکه عصبی LSTM، خطای ۴/۴۶٪ درصد برای پارامتر طول بازه‌ای w=20 دارد (Ji et al., 2019). پتل و همکاران نیز بر اساس شبکه‌های عصبی بر پایه لایه‌های GRU به خطای ۴/۰۷۲۷٪ برای ارز مونرو رسیدند. جدول شماره ۸ نتایج روش پیشنهادی این پژوهش را با روش‌های پیشین نشان می‌دهد (Patel et al., 2020).

جدول (۸): مقایسه نتایج روش پیشنهادی با نتایج پژوهش‌ها پیشین

پژوهش‌ها	درصد خطا
روش پیشنهادی این پژوهش	۲/۶۴۱٪ (W=۱۵) & ۳/۲۴۳٪ (W=۲۰)
روی [۲۱]	۹/۱۶۹
هیتما [۲۲]	۹/۶٪
گرگ [۲۳]	کمتر از ۶٪
ریزوان [۲۴]	۵/۳٪
جی [۲۵]	۴/۰۴۶ (W=۲۰)
پتل [۱]	۴/۰۷۲۷

منبع: یافته‌های پژوهش

<sup>1</sup> Support Vector Machines

<sup>2</sup> Particle Swarm Optimization

همان‌گونه که از جدول ۶ مشاهده می‌شود روش ارائه شده در این پژوهش بهترین دقت و عملکرد را در بین تمامی پژوهش‌های ذکر شده داراست. لذا استفاده از این روش به‌عنوان روشی معتبر و دقیق برای پیش‌بینی قیمت بیت‌کوین توصیه می‌گردد.

### بحث و نتیجه

در این مقاله ابتدا معیارهای سنجش خطا توضیح داده شد سپس هر یک از شبکه‌های قیمتی و ساختاری به‌صورت مجزا مورد بحث و بررسی قرار گرفت نتایج حاصل از پیش‌بینی آن‌ها به‌صورت عددی و شماتیک در تصاویر آورده شد. در انتها نیز ساختار کلی شبکه مورد بررسی در این پژوهش که متشکل از سه شبکه عصبی است بررسی و اعتبارسنجی شد و پس از آن نتایج حاصل از پیش‌بینی آینده قیمتی بیت‌کوین آورده شد و مشخص شد که می‌توان قیمت روزهای آینده بیت‌کوین را به ترتیب و با دقتی در حدود  $97/36\%$  و  $96/76\%$  برای  $W=15$  و  $W=20$  تخمین زد که نشان می‌دهد این روش در مقایسه با روش‌های پیشین از دقت و کارایی بالاتری و حجم محاسباتی کمتری برخوردار است. همچنین با استفاده از مقادیر مختلف پارامتر  $W$  می‌توان نتیجه گرفت که به دلیل نوسانات بالای رمزارزها نمی‌توان از مقادیر بالای پارامتر  $W$  استفاده نمود همچنین استفاده از مقادیر کم این پارامتر نیز توصیه نمی‌گردد و معتبرترین دقت‌ها در طول بازه‌های ۱۵ الی ۲۰ روزه اتفاق می‌افتد به‌عبارت‌دیگر بیش‌ترین مقدار تأثیر بر روی قیمت آینده بیت‌کوین مربوط به ۱۵ الی ۲۰ روز ماقبل می‌باشد و به تحلیل گران بازار توصیه می‌گردد که از این بازه برای پیش‌بینی قیمت استفاده نمایند.

به‌عنوان نتیجه‌گیری نهایی نیز می‌توان اشاره داشت که شبکه‌های عصبی با معماری موازی می‌توانند با دقت و کارایی بالایی به پیش‌بینی قیمت روزهای آینده پردازند. لذا به سرمایه‌گذاران و اقتصاددانان فعال در زمینه رمزارزها پیشنهاد می‌گردد از شبکه عصبی به‌عنوان یک ابزار کمکی شناسایی و رصد دقیق‌تر روزهای آینده استفاده نمایند همچنین برای هر چه کاراتر شدن این روش می‌توان از ویژگی‌های بیشتر شبکه بلاک چین، شبکه‌های اجتماعی پرفرمدار و خبرهای منتشر شده در آن‌ها، قیمت رمزارزهای دیگر و... استفاده نمود. همچنین استفاده از روش‌های یادگیری بدون ناظر<sup>۱</sup> و یادگیری تقویتی<sup>۲</sup> برای پیش‌بینی قیمت توصیه می‌گردد. از

<sup>۱</sup> Unsupervised Learning

دیگر توصیه‌هایی که می‌توان برای استفاده در پژوهش‌های آینده داشت این است که در خروجی و قسمت نتایج به جای استفاده از قیمت از دو کلاس افزایش و یا کاهش قیمت استفاده کرد بدین صورت که در انتها شبکه تعیین نماید که شرایط کنونی مناسب خرید بیت‌کوین می‌باشد یا بهتر است در این شرایط سرمایه‌گذار دارای‌های خود را به فروش بگذارد؛ و همچنین می‌توان در آینده نتایج حاصل از این شبکه را با توضیحات فوق ترکیب نمود بدین صورت که شبکه در انتها تعیین نماید که در روزهای آینده قیمت بیت‌کوین کاهشی می‌باشد یا افزایشی و این روند افزایشی یا کاهشی بودن تا چه قیمتی ادامه دار خواهد بود. امید است این پژوهش‌ها بتواند زمینه‌ساز ایجاد ابزاری کارا و موفق برای سرمایه‌گذاران در این زمینه باشد.

## References

- [cited 2021, february 10<sup>th</sup>] Available from: <https://charts.coinmetrics.io/network-data>
- [cited 2021, february 10<sup>th</sup>] Available from: <https://www.investing.com/crypto/bitcoin/historical-data>
- Abdi, N.; Del Ara, CH., & Daneshjo, P. (2020). Bitcoin price prediction using LSTM neural network, 9th National Conference on Computer Science and Engineering and Information Technology, Babylon,
- Akyildirim, E.; Corbet, S.; Lucey, B.; Sensoy, A., & Yarovaya, L. (2020). The relationship between implied volatility and cryptocurrency returns. *Finance Research Letters*, 33, 101212.
- Atsalakis, G. S., Atsalaki, I. G., Pasiouras, F., & Zopounidis, C. (2019). Bitcoin price forecasting with neuro-fuzzy techniques. *European Journal of Operational Research*, 276(2), 770-780.
- Bashiri, Maitham., & Pariab, Seyed Hossein. (2019). "Bitcoin price prediction using machine learning algorithms", *Applied Economics*. 1-13.
- Bishop Jr, G. W. (1961). Evolution of the Dow Theory. *Financial Analysts Journal*, 17(5), 23-26.
- Borges, T. A., & Neves, R. F. (2020). Ensemble of machine learning algorithms for cryptocurrency investment with different data resampling methods.

*Applied Soft Computing*, 90, 106187.

Chatterjee, J. M.; Kumar, P. S.; Kumar, A., & Balamurugan, B. (2020). Blockchain, Bitcoin, and the Internet of Things: Overview. *Blockchain Technology and the Internet of Things*, 47-67.

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.

Chin, Z. H.; Yap, T. T. V., & Tan, I. K. (2020, October). Simulating difficulty adjustment in blockchain with SimBlock. In *Proceedings of the 2nd ACM International Symposium on Blockchain and Secure Critical Infrastructure* 192-197

Derbentsev, V.; Datsenko, N.; Stepanenko, O., & Bezkorovainyi, V. (2019). Forecasting cryptocurrency prices time series using machine learning approach. In *SHS Web of Conferences* 65, 473-478

Garg, S. (2018). Autoregressive integrated moving average model based prediction of bitcoin close price. In *2018 international conference on smart systems and inventive technology (ICSSIT)* 473-478

Ghorbani, Ali.; Rabbani, Youssef.; Kamran Rad, Reza., & Falasfi, Peyman. (2022). Prediction of Bitcoin price changes using sentiment analysis in social networks and celebrities along with data mining approach, *Econometric Modeling*, 7(3), 163-182.

Gupta, R.; Tanwar, S.; Al-Turjman, F.; Italiya, P.; Nauman, A., & Kim, S. W. (2020). Smart contract privacy protection using AI in cyber-physical systems: tools, techniques and challenges. *IEEE access*, 8, 24746-24772.

Hitam, N. A.; Ismail, A. R., & Saeed, F. (2019). An optimized support vector machine (SVM) based on particle swarm optimization (PSO) for cryptocurrency forecasting. *Procedia computer science*, 163, 427-433.

Huang, J. Z.; Huang, W., & Ni, J. (2019). Predicting bitcoin returns using high-dimensional technical indicators. *The Journal of Finance and Data Science*, 5(3), 140-155.

Karasu, S.; Altan, A.; Saraç, Z., & Hacıoğlu, R. (2018, May). Prediction of Bitcoin prices with machine learning methods using time series data. In *2018 26th signal processing and communications applications conference (SIU) IEEE*. 1-4

Kimoto, T.; Asakawa, K.; Yoda, M., & Takeoka, M. (1990, June). Stock market prediction system with modular neural networks. In *1990 IJCNN international joint conference on neural networks* 1-6.

- Lo, Y. C., & Medda, F. (2019). Bitcoin mining: converting computing power into cash flow. *Applied Economics Letters*, 26(14), 1171-1176.
- Mohanty, P.; Patel, D.; Patel, P., & Roy, S. (2018). Predicting fluctuations in cryptocurrencies' price using users' comments and real-time prices. In *2018 7th International Conference on Reliability, Infocom Technologies and Optimization (Trends and Future Directions)(ICRITO)* 477-482
- Nakamoto, S. (2008). Bitcoin: A peer-to-peer electronic cash system. *Decentralized Business Review*, 21260.
- Nison, S. (1994). *Beyond candlesticks: New Japanese charting techniques revealed* 56
- Pant, D. R.; Neupane, P.; Poudel, A.; Pokhrel, A. K., & Lama, B. K. (2018, October). Recurrent neural network based bitcoin price prediction by twitter sentiment analysis. In *2018 IEEE 3rd International Conference on Computing, Communication and Security (ICCCS)* 128-132
- Patel, M. M.; Tanwar, S.; Gupta, R., & Kumar, N. (2020). A deep learning-based cryptocurrency price prediction scheme for financial institutions. *Journal of information security and applications*, 55, 102583.
- Peng, Y.; Albuquerque, P. H. M.; de Sá, J. M. C.; Padula, A. J. A., & Montenegro, M. R. (2018). The best of two worlds: Forecasting high frequency volatility for cryptocurrencies and traditional currencies with Support Vector Regression. *Expert Systems with Applications*, 97, 177-192.
- Radityo, A.; Munajat, Q., & Budi, I. (2017, October). Prediction of Bitcoin exchange rate to American dollar using artificial neural network methods. In *2017 International Conference on Advanced Computer Science and Information Systems (ICACSIS)* 433-438.
- Rafiei, A.; Rezaee, A.; Hajati, F.; Gheisari, S., & Golzan, M. (2021). SSP: Early prediction of sepsis using fully connected LSTM-CNN model. *Computers in biology and medicine*, 128, 104110.
- Ranasinghe, H., & Halgamuge, M. N. (2021). Twitter sentiment data analysis of user behavior on cryptocurrencies: bitcoin and ethereum. In *Analyzing Global Social Media Consumption* 277-291.
- Rathan, K.; Sai, S. V., & Manikanta, T. S. (2019). Crypto-currency price prediction using decision tree and regression techniques. In *2019 3rd International Conference on Trends in Electronics and Informatics (ICOEI)* 190-194
- Rezaee, A. (2015). Using coevolutionary genetic algorithms for estimation of blind fir channel. *Wireless Personal Communications*, 83(1), 191-201.

Rizwan, M.; Narejo, S., & Javed, M. (2019, December). Bitcoin price prediction using deep learning algorithm. In *2019 13th International Conference on Mathematics, Actuarial Science, Computer Science and Statistics (MACS)* 1-7

Roy, S.; Nanjiba, S., & Chakrabarty, A. (2018). Bitcoin price forecasting using time series analysis. In *2018 21st International Conference of Computer and Information Technology (ICCIT)* 1-5

Smuts, N. (2019). What drives cryptocurrency prices? an investigation of google trends and telegram sentiment. *ACM SIGMETRICS Performance Evaluation Review*, 46(3), 131-134.

Tandon, S.; Tripathi, S.; Saraswat, P., & Dabas, C. (2019, Mar) Bitcoin Price Forecasting using LSTM and 10-Fold Cross validation. In 2019 International Conference on Signal Processing and Communication (ICSC) 323-328.

Teker, D.; Teker, S., & Ozyesil, M. (2019). Determinants of cryptocurrency price movements. In *14th Paris international conference on marketing, economics, education and interdisciplinary studies*, 12(14), 29-34.

White, H. (1989). Learning in artificial neural networks: A statistical perspective. *Neural computation*, 1(4), 425-464.