

Improving ARIMA models prediction with designing deep learning hybrid models: A Case Study of Cryptocurrency

Kambiz Hojabr Kiani^{*}, Kambiz Peykarjou^{}**

Saeed Sadrzadeh Moghadam^{*}**

Abstract

In this paper, we investigate how novel approaches can improve the predictions made by traditional econometric approaches in the field of forecasting. Autoregressive integrated moving average (ARIMA) modeling is known as one of the most widely used methods for predicting economic and financial time series, providing a good framework especially for short-term linear predictions of time series. However, the assumption of nonlinear effects in time series and the emergence of novel deep learning algorithms, which have the ability to extract complex features of time series and model them, have motivated researchers to examine the predictive power of traditional and novel modeling approaches. In this study, two methods are examined for predicting the prices of the four most valuable cryptocurrency. ARIMA and three approaches in the field of deep learning, including (RNN, LSTM, and GRU), are investigated. In addition, a hybrid model of deep learning and ARIMA has been introduced, which is a combination of the strengths of both models to increase the accuracy of predictions. The results show that the hybrid models perform better in predicting future time series than

^{*} Professor in Economics, Faculty of Management and Economic, Science and Research Branch, Islamic Azad University, Tehran, Iran, khkiani@yahoo.com

^{**} Assistant Professor in Economics, Faculty of Management and Economic, Science and Research Branch, Islamic Azad University, Tehran, Iran, k.peykarjou@srbiau.ac.ir

^{***} Ph.D. student in Econometric, Faculty of Management and Economics, Islamic Azad University, Science and Research Branch, Tehran, Iran (Corresponding Author), saeed.sadrzadeh@srbiau.ac.ir

Date received: 28/11/2023, Date of acceptance: 12/04/2024



each of the ARIMA and deep learning models separately. Also, the ARIMA-GRU model has less prediction error values than all estimated models.

Keywords: ARIMA, Machine Learning, Hybrid Model, Cryptocurrency

JEL classification: C22, C89, G17

بهبود پیش‌بینی مدل‌های ARIMA با طراحی مدل‌های ترکیبی یادگیری عمیق: مطالعه موردی رمزارزها

کامبیز هژبر کیانی*

کامبیز پیکارجو**، سعید صدرزاده مقدم***

چکیده

این پژوهش بدنبال طراحی و ارائه رویکردی که بهبود نتایج پیش‌بینی بدست آمده از رویکردهای سنتی اقتصادسنجی با استفاده از روش‌های نوین مدل‌سازی است. مدل‌سازی خودرگرسیون هم‌انباشته میانگین متحرک (ARIMA)، بعنوان یکی از گسترده‌ترین روش‌های پیش‌بینی سری‌های زمانی اقتصادی و مالی شناخته می‌شود، که رویکرد مناسبی بویژه برای پیش‌بینی‌های خطی کوتاه‌مدت سری‌های زمانی محسوب می‌شود. با این حال فرض وجود اثرات غیرخطی در سری‌های زمانی و ظهور الگوریتم‌های نوین مدل‌سازی بخصوص روش‌های یادگیری عمیق، که قابلیت استخراج ویژگی‌های پیچیده سری‌های زمانی و مدل‌سازی آن را دارند، انگیزه‌ای برای محققین جهت بررسی و مقایسه قدرت پیش‌بینی رویکردهای سنتی و نوین مدل‌سازی گردیده‌است. در این پژوهش، دو روش برای پیش‌بینی قیمت چهار رمزارز، با بالاترین ارزش بازار مورد بررسی قرار می‌گیرد. روش مدل‌سازی (ARIMA) و سه رویکرد در حوزه یادگیری عمیق شامل (LSTM، RNN و GRU)، علاوه بر این یک رویکرد ترکیبی از مدل‌های یادگیری عمیق و ARIMA معرفی شده‌است که ترکیبی از نقاط قوت هر دو مدل برای افزایش دقت پیش‌بینی است. نتایج نشان می‌دهد مدل‌های ترکیبی ARIMA و یادگیری عمیق در

* استاد اقتصاد، دانشکده مدیریت و اقتصاد، دانشگاه آزاد اسلامی، واحد علوم و تحقیقات تهران،
khkiani@yahoo.com

** استادیار اقتصاد، دانشکده مدیریت و اقتصاد، دانشگاه آزاد اسلامی، واحد علوم و تحقیقات تهران،
k.peykarjou@srbiau.ac.ir

*** دانشجوی دکتری اقتصادسنجی، دانشکده مدیریت و اقتصاد، دانشگاه آزاد اسلامی، واحد علوم و تحقیقات
تهران (نویسنده مسئول)، saeed.sadrzadeh@srbiau.ac.ir

تاریخ دریافت: ۱۴۰۲/۰۹/۰۷، تاریخ پذیرش: ۱۴۰۳/۰۱/۲۴



پیش‌بینی مقادیر آتی سری‌زمانی نسبت به هر یک از مدل‌های ARIMA و یادگیری عمیق بصورت جداگانه، بهتر عمل می‌کنند. همچنین مدل ARIMA-GRU نسبت به تمام مدل‌های برآورد شده، مقادیر خطای پیش‌بینی کمتری دارد.

کلیدواژه‌ها: مدل‌های ARIMA، یادگیری ماشین، مدل‌های ترکیبی، رمز ارز

طبقه‌بندی JEL: G17, C89, C22

۱. مقدمه

در سالیان اخیر محبوبیت رمز ارزها بعنوان نوعی پول الکترونیک به شدت افزایش یافته، این موضوع باعث شده اغلب رمز ارزها بعنوان یک دارایی توسط بسیاری از مردم جهان معامله و نگهداری شوند. بگونه‌ای که ارزش بازار بیت کوین بعنوان محبوب‌ترین رمز ارز در سال ۲۰۲۳ میلادی بیش از ۵۰۰ میلیارد دلار تخمین زده شده است. (گزارش Coinmarketcap، آوریل ۲۰۲۳) همزمان با توسعه و گسترش بازار رمز ارزها، مطالعات در حوزه پیش‌بینی قیمت آن‌ها می‌تواند نتایج قابل توجهی برای سرمایه‌گذاران، معامله‌گران، موسسات مالی و سیاست‌گذاران داشته باشد. این پیش‌بینی‌ها به منظور بهینه‌سازی استراتژی‌های تجاری، کاهش خطرات و اطلاع‌رسانی به تصمیمات سرمایه‌گذاری استفاده می‌شود. تاکنون مطالعات بسیاری در خصوص پیش‌بینی قیمت رمز ارزها بویژه بیت‌کوین انجام شده است، اما درک و تجزیه و تحلیل این بازار هنوز یکی از موضوعات مورد بحث است. روش‌های آماری و اقتصادسنجی اغلب در زمان مدل‌سازی متغیرهای نامانا و یا متغیرهایی که وابستگی‌های پیچیده دارند، مشکلاتی را به وجود می‌آورند. (Dixon et al, 2015) خوشبختانه تکنیک‌های یادگیری ماشین می‌توانند این نوع ساختارهای پیچیده را شناسایی و با آن مقابله کنند. (Fischer & Krauss, 2018) رویکرد ARIMA یک مدل قدرتمند است که می‌تواند نتایج خوبی، حتی در مقایسه با رویکردهای یادگیری عمیق، در بازار سهام ارائه دهد. با این حال، در زمان بررسی و مطالعه رمز ارزها، جایکه ویژگی‌های فصلی شدید وجود دارد، دقت در پیش‌بینی‌های ARIMA کاهش محسوسی دارد، که ممکن است مدل‌سازی نیاز به تنظیم دقیق پارامترها و درک عمیق از داده‌ها داشته باشد. (Benzekri & Öztürler, 2002) محدودیت دیگر رویکرد ARIMA عدم امکان مدل‌سازی الگوی غیرخطی در قیمت‌ها است که می‌تواند منجر به پیش‌بینی‌های نادرست شود. رویکرد یادگیری عمیق، زیرمجموعه‌ای از یادگیری ماشین است که فرآیند استخراج ویژگی (Feature Extraction) را به صورت خودکار انجام و در کار با داده‌های بزرگ بدلیل همین موضوع و عدم

بهبود پیش‌بینی مدل‌های ARIMA ... (کامیاز هژبر کیانی و دیگران) ۱۶۷

نیاز به مهندسی ویژگی به صورت دستی، نسبت به مدل‌های یادگیری ماشین برتری محسوسی دارند.

این پژوهش با بکارگیری چندین مدل یادگیری عمیق (Deep Learning) و ترکیب آن‌ها با خروجی‌های مدل ARIMA بدنبال طراحی یک مدل ترکیبی به منظور بهبود پیش‌بینی‌ها است. نتایج این پژوهش می‌تواند مدل‌های پیش‌بینی را بهبود داده و به سرمایه‌گذاران کمک کند تصمیمات دقیق‌تری در دنیای رمزارزها بگیرند. این مطالعه با چند هدف کلیدی انجام می‌شود.

- پیش‌بینی قیمت چهار رمز ارز منتخب با رویکرد ARIMA
- مقایسه چند مدل یادگیری عمیق بصورت منفرد با رویکرد مدل‌سازی ARIMA
- استفاده از رویکردهای یادگیری عمیق در طراحی مدل ترکیبی به منظور بهبود نتایج مدل‌سازی ARIMA
- تجزیه تحلیل نتایج و مقایسه عملکرد مدل‌های پیاده‌سازی شده از نظر دقت در پیش‌بینی‌ها

با توجه به اهداف معرفی شده، این پژوهش تلاش می‌کند تا رویکرد جدیدی در حوزه مدل‌سازی معرفی نماید که براساس ابزارهای در دسترس برای ذینفعان بازار رمزارزها، در تصمیم‌گیری آگاهانه آن‌ها در حوزه اقتصادی و مالی مورد استفاده قرار گیرد. اطلاعات جمع‌آوری شده در این پژوهش مربوط به رمزارزهای دارای بیشترین ارزش بازار است. کلیه محاسبات از طریق زبان برنامه‌نویسی پایتون انجام شده است. داده‌ها به دو بخش آموزش (Train) و آزمون (Test) تقسیم شده و مدل‌های ARIMA و یادگیری عمیق بصورت منفرد برای بخش آموزش اجرا و پیش‌بینی‌ها برای بخش آزمون انجام شده است. نتایج براساس معیارهای خطای پیش‌بینی مورد بررسی قرار گرفته و سپس مدل ترکیبی براساس نتایج مدل ARIMA و سه مدل یادگیری عمیق طراحی و اجرا شده است. در بخش مدل ترکیبی بازه آزمون مرحله اول به دو بخش آموزش و آزمون تقسیم‌بندی شده است. در تمام دوره‌های آزمون مدل ترکیبی پیشنهادی در این پژوهش از نظر معیارهای خطا نسبت به مدل‌های منفرد یادگیری عمیق و ARIMA عملکرد بهتری داشته است. این پژوهش می‌تواند با نشان دادن پتانسیل استفاده نشده از اینکه چگونه ترکیب رویکردهای مدرن مدل‌سازی، دقت پیش‌بینی را افزایش می‌دهد، تصمیم‌گیری در بازار رمزارزها و تعیین استراتژی‌های سودآور را بهبود بخشد.

۲. مبانی نظری

۱.۲ مدل‌های ARIMA

مدل ARIMA بعنوان یک مدل رگرسیون خطی، روشی محبوب برای محققانی که تلاش می‌کنند مقادیر آتی سری‌های زمانی مالی را پیش‌بینی کنند است. (Hyndman & Athanasopoulos, 2018) مطالعات نشان داده است که مدل‌های ARIMA در پیش‌بینی چندین نوع مختلف از سری‌های زمانی مالی برتری دارند و اغلب قادر به اجرای روش‌های پیچیده‌تر و گسترده‌تر هستند (Levenbach, 2017). این مدل‌ها به دلیل سادگی در درک و کاربرد، مورد توجه محققان قرار گرفته است. علاوه بر این، سری‌های زمانی مالی به طور کلی و با احتمال بالا دارای اثرات فصلی هستند که مدل‌سازی ARIMA برای این منظور مناسب است (Hyndman & Athanasopoulos, 2018). همانطور که در بخش پیشینه تحقیق بیان شد، مدل‌های ARIMA قالب مناسبی بویژه برای پیش‌بینی‌های خطی کوتاه‌مدت سری‌های زمانی مالی محسوب می‌شوند. در یک مدل ARIMA مقادیر آتی متغیر به صورت یک تابع خطی از وقفه‌های گذشته و یک جمله خطا نمایش داده می‌شود. به طور طبیعی، طیف گسترده‌ای از روش‌ها می‌توانند برای توضیح گرایش‌های خطی داده‌های یک سری زمانی مالی مورد استفاده قرار گیرد، اما سادگی نسبی ARIMA، نیاز اندک برای پیش‌پردازش داده‌ها و کاربرد گسترده آن، باعث می‌شود که رویکردی جذاب در حوزه مدل‌سازی باشد. این مدل به صورت (p,d,q) ARIMA نشان داده می‌شود. پارامترهای p ، d و q مقادیر عدد صحیح هستند که ساختار مدل سری زمانی را تعیین می‌کنند، پارامترهای p ، q هر کدام ترتیب مربوط به مدل‌های خودرگرسیون (AR) و میانگین متحرک (MA) می‌باشند. پارامتر d تعداد دفعات تفاضل‌گیری مورد نیاز جهت مانایی سری زمانی را نشان می‌دهد. نمایش ریاضی مدل ARMA با مرتبه‌های (p,q) به صورت زیر است.

$$\hat{x}_t = c + \varphi_1 x_{t-1} + \varphi_2 x_{t-2} + \dots + \varphi_p x_{t-p} - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad (1)$$

$$= c + \sum_{k=1}^p \varphi_k x_{t-k} - \sum_{l=1}^q \theta_l \varepsilon_{t-l}$$

c مقدار ثابت، φ_k و θ_l و مقادیر ضرایب مدل‌های AR و MA هستند. ε_{t-l} مقدار خطا در زمان $t-l$ است ($\varepsilon_{t-l} = x_{t-l} - \hat{x}_{t-l}$). فرض می‌شود که ε_{t-l} دارای میانگین صفر و واریانس ثابت

بهبود پیش‌بینی مدل‌های ARIMA ... (کامیاز هژبر کیانی و دیگران) ۱۶۹

باشد. باکس-جنکینز یک روش استاندارد سه مرحله‌ای برای ساخت یک مدل ARIMA معرفی کردند.

(۱) شناسایی و انتخاب نوع مدل: مرتبه‌های p و q برای مدل‌های AR، MA یا ARMA تعیین می‌شود.

(۲) برآورد ضرایب: ضرایب مدل‌های انتخاب شده برآورد می‌شود.

(۳) بررسی مدل: باقیمانده‌های مدل برآورد شده، تجزیه و تحلیل می‌شود.


شرط لازم برای استفاده از مدل‌سازی سه مرحله‌ای ARIMA، مانایی سری زمانی است. در حقیقت به منظور اینکه برخی از ویژگی‌های آماری اصلی مانند میانگین و واریانس در طول زمان ثابت باشند، مانایی سری زمانی اهمیت دارد. در مواجهه با یک سری زمانی ناماننا از تفاضل‌گیری مرتبه‌های اول و دوم برای دستیابی به سری زمانی ماننا استفاده می‌شود. تفاضل‌گیری مرتبه‌های بالاتر از ۲ در سری‌های زمانی معمولاً بکار گرفته نمی‌شود. پس از برقراری شرط مانایی، نمودار توابع خودهمبستگی (ACF) و خودهمبستگی جزئی (PACF) به منظور انتخاب نوع مدل و مرتبه‌های آن مورد بررسی قرار می‌گیرد. مرحله برآورد شامل یک فرآیند بهینه‌سازی با استفاده از معیارهای خطا مانند معیار اطلاعات آکائیک (AIC)، بیزین (BIC) و یا معیار حنان‌کوین (HQIC) است. در این پژوهش از معیار AIC استفاده شده است.

$$AIC = -2\ln(\hat{L}) + 2k \quad (۲)$$

$\ln(\hat{L})$ مقدار تابع درست‌نمایی و K درجه آزادی است. مدلی که کمترین مقدار AIC را داشته باشد بعنوان مدل بهتر در میان مدل‌های مورد بررسی انتخاب می‌شود. روش‌های متفاوتی برای محاسبه تابع درست‌نمایی وجود دارد که در این پژوهش از برآوردگر حداکثر درست‌نمایی (Maximum Likelihood Estimator) استفاده شده که با وجود افزایش زمان محاسبات، نتایج دقیق‌تری را ارائه می‌دهد. در نهایت در مرحله بررسی مدل و بررسی باقیمانده‌های آن، در صورتیکه نتایج نشان دهد باقیمانده‌ها حالت استاندارد ندارند، مراحل قبلی تا زمان رسیدن به مدل بهینه تکرار می‌شود.

۲.۲ شبکه عصبی بازگشتی (Recurrent Neural Network / RNN)

شبکه‌های عصبی به دلیل تطبیق پذیری با ابعاد بزرگ پارامترها و استفاده از توابع فعال‌ساز غیرخطی در هر لایه، می‌توانند با روندهای غیرخطی در داده‌ها سازگار شوند. با این حال مطالعات انجام شده بر روی داده‌های مالی نشان می‌دهد که عملکرد شبکه‌های عصبی بسیار ناهمگون است. به عنوان مثال، در مطالعه نلسون و همکاران (Nelson et al, 2017)، دقت و عملکرد شبکه عصبی LSTM برای پیش‌بینی قیمت سهام، به صورت کلی بالاتر از کلیه مدل‌های طراحی شده (غیرشبکه عصبی) بود. با این وجود، بخش‌های همپوشانی در محدوده دقت برای هر مدل وجود دارد، به این معنی که یک مدل خاص همواره برتر از دیگر مدل‌ها عمل نمی‌کند. این موضوع زمینه برای طراحی مدل‌های ترکیبی به منظور بررسی اثرات خطی و غیرخطی یک سری زمانی را فراهم می‌کند. به منظور درک صحیح از مدل‌سازی در این حوزه ابتدا رویکرد شبکه عصبی بازگشتی مورد بررسی قرار می‌گیرد. RNN نوعی از مدل‌های ترتیبی (Sequential Model) است که برای داده‌های سری زمانی مورد استفاده قرار می‌گیرد. این مدل یک بردار از داده‌های سری زمانی را به عنوان ورودی دریافت و یک بردار خروجی را که براساس ساختار شبکه محاسبه شده، برمی‌گرداند. (شکل ۱)



شکل ۱. نمای کلی یک شبکه عصبی بازگشتی

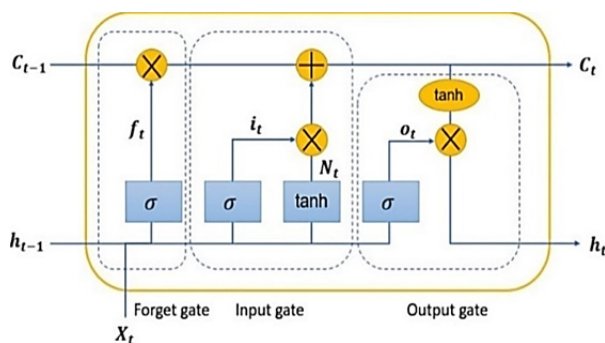
X یک سری زمانی در قالب بردار است که زمان صفر تا t را پوشش می‌دهد. مقادیر بردار X به صورت ترتیبی (به ترتیب زمان) وارد سلول A می‌شود. در هر مرحله از زمان، شبکه مقدار خروجی را که متناظر با داده ورودی در زمان بعدی است، تولید می‌کند. این فرایند تا زمان آخرین ورودی تکرار می‌شود. سپس براساس فرآیند انتشار رو به عقب در طول زمان (Backward Propagation Through Time / BPTT) ماتریس وزن‌ها بروزرسانی می‌شود. در شکل ۱ فرآیند BPTT نمایش داده نشده است. (برای بررسی بیشتر در این مورد به مطالعه هوکرایتر و

بهبود پیش‌بینی مدل‌های ARIMA... (کامیاز هزیر کیانی و دیگران) ۱۷۱

اشمیدهور (Hochreiter & Schmidhuber, 1997) رجوع شود) سلول A در شکل ۱ را می‌توان با انواع سلول‌های تعریف شده در شبکه‌های عصبی جایگزین نمود.

۳.۲ شبکه عصبی حافظه کوتاه مدت طولانی (LSTM)

یکی از اصلی‌ترین مشکلات در شبکه‌های عصبی بازگشتی، گرادیان‌های محو شونده (Vanishing Gradient) است، که باعث توقف یا کندی یادگیری شبکه می‌گردد. این مشکل زمانی اتفاق می‌افتد که گرادیان‌ها یا مشتقات تابع خطا نسبت به وزن‌های شبکه، در طول فرآیند یادگیری به سرعت کوچک می‌شوند و در نهایت به صفر می‌رسند. این مشکل باعث می‌شود تغییرات کمی در وزن‌های شبکه رخ داده و بهینه‌سازی متوقف شود. در واقع مشتق‌هایی که از لایه‌های انتهایی شبکه می‌آیند باید ضرب‌های متعددی را پشت سر بگذارند تا به لایه‌های ابتدایی برسند، لذا اگر این ضرب‌ها مقادیر کوچک (کمتر از یک) داشته باشند گردیان‌ها رفته‌رفته کوچک و محو می‌شوند. شبکه‌های LSTM، یکی از انواع شبکه‌های عصبی بازگشتی هستند که توسط هوکرایتر و اشمیدهور (Hochreiter & Schmidhuber, 1997) و برای حل مشکل گرادیان‌های محوشونده، معرفی شد. شبکه‌های LSTM اجازه می‌دهند اطلاعات در شبکه باقی بمانند و وابستگی‌های کوتاه‌مدت و طولانی‌مدت را در دنباله ورودی یاد بگیرند.



شکل ۲. نمای کلی یک شبکه عصبی حافظه کوتاه مدت طولانی

در واقع مشکل محوشوندگی تدریجی اطلاعات در شبکه‌های عصبی بازگشتی در اینجا برطرف شده است. شکل شماره ۲ یک سلول در شبکه LSTM را نشان می‌دهد. در هر سلول از شبکه LSTM، سه دروازه (Gate) ورودی، فراموشی و خروجی وجود دارد.

دروازه فراموشی: شبکه LSTM ابتدا در مورد اینکه چه بخشی از اطلاعات دوره قبل باید نادیده گرفته شوند، تصمیم می‌گیرد. این موضوع را با رابطه زیر می‌توان نمایش داد:

$$f_t = \sigma(X_t U_f + H_{t-1} W_f + b_f) \quad (3)$$

X_t ورودی در زمان جاری (t)، U_f وزن تخصیص داده شده به ورودی، H_{t-1} بلوک اطلاعاتی دوره قبلی و W_f یک ماتریس وزن‌دهی برای اطلاعات دوره قبلی است. یک تابع زیگموئید (Sigmoid) مطابق با رابطه ۴، روی f_t اعمال و مقدار صفر یا یک را برمی‌گرداند. مقدار صفر نشان می‌دهد همه اطلاعات فراموش شوند و مقدار یک باعث نگهداری اطلاعات دوره قبلی خواهد شد.

$$\sigma(x) = \frac{1}{1 + e^x} \quad (4)$$

دروازه ورودی: این دروازه اهمیت اطلاعات جدید را بصورت کمی تعیین می‌کند.

$$i_t = \sigma(X_t U_i + H_{t-1} W_i + b_i) \quad (5)$$

U_i و W_i به ترتیب وزن‌های مربوط به اطلاعات ورودی و اطلاعات موجود در شبکه است. یک تابع زیگموئید دیگر مقادیر را در بازه صفر و یک قرار داده و هر چه مقادیر مذکور به یک نزدیک‌تر باشند، نشان دهنده اهمیت بیشتر اطلاعات ورودی است. اطلاعات جدید به اطلاعات قبلی افزوده شده و یا از آن کسر می‌گردد. در اینجا از یک تابع تانژانت هایپربولیک استفاده می‌شود که اطلاعات را بین ۱- برای کسر کردن از اطلاعات موجود در شبکه و ۱+ برای اضافه کردن به اطلاعات موجود در شبکه قرار می‌دهد. N_t اطلاعات جدید است که با استفاده از دروازه فراموشی و دروازه ورودی، قبل از اضافه شدن به اطلاعات موجود بروزرسانی می‌شود.

$$N_t = \tanh(X_t U_c + H_{t-1} W_c + b_c) \quad (6)$$

$$C_t = f_t C_{t-1} + i_t N_t \quad (7)$$

بهبود پیش‌بینی مدل‌های ARIMA ... (کامبیز هژیر کیانی و دیگران) ۱۷۳

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (۸)$$

C_t سلول اطلاعات یا حافظه بلند مدت مدل در زمان $t-1$ است.

دروازه خروجی: این دروازه تصمیم می‌گیرد که چه بخشی از اطلاعات بعنوان خروجی وارد مرحله بعدی شود.

$$O_t = \sigma(X_t U_o + H_{t-1} W_o + b_o) \quad (۹)$$

$$h_t = O_t \tanh(C_{t-1}) \quad (۱۰)$$

۴.۲ شبکه عصبی واحد بازگشتی دروازه‌دار (GRU)

GRU نیز یکی از انواع شبکه‌های عصبی بازگشتی است که توسط چو و همکاران (Cho et al, 2014) به عنوان یک جایگزین ساده‌تر برای شبکه LSTM معرفی شد. شبکه GRU مانند LSTM می‌تواند داده‌های ترتیبی مانند سری‌های زمانی را پردازش کند. ایده اصلی GRU استفاده از مکانیزم دروازه برای به‌روزرسانی اطلاعات موجود در شبکه در هر مرحله زمانی است. GRU بسیار مشابه شبکه LSTM است، با این تفاوت که به‌جای سه دروازه، فقط دو دروازه تنظیم مجدد (Reset Gate) و دروازه به‌روزرسانی (Update Gate) دارد. هم‌چنین شبکه GRU چیزی به‌نام حالت سلول (Cell State) نداشته و برای انتقال اطلاعات از حالت پنهان (Hidden State) استفاده می‌کند. دروازه تنظیم مجدد تعیین می‌کند که چه مقدار از حالت پنهان قبلی باید فراموش شود، در حالی که دروازه به‌روزرسانی تعیین می‌کند که چه مقدار از ورودی جدید باید برای به‌روزرسانی حالت پنهان استفاده شود. خروجی GRU بر اساس حالت پنهان به‌روز شده محاسبه می‌شود. معادلات مورد استفاده برای محاسبه دروازه تنظیم مجدد، دروازه به‌روزرسانی و حالت پنهان GRU به شرح زیر است:


$$r_t = \sigma(W_r * [h_{t-1}, x_t]) \quad (۱۱)$$

$$z_t = \sigma(W_z * [h_{t-1}, x_t]) \quad (۱۲)$$

$$h_t' = \tanh(W_h * [r_t * h_{t-1}, x_t]) \quad (13)$$

$$h_t = (1 - z_t) * h_{t-1} + z_t * h_t' \quad (14)$$

ترتیب مقادیر لایه پنهان به ترتیب در زمان $t-1$ و t است. W_z ، W_h و W_r وزن‌های محاسبه شده توسط شبکه، x_t ورودی در زمان t و h_{t-1} و h_t به ترتیب مقادیر لایه پنهان به ترتیب در زمان $t-1$ و t است.



شکل ۳. نمای کلی یک شبکه عصبی GRU

۵.۲ مدل ترکیبی

همانطور که مدل ARIMA روند خطی داده‌ها را شناسایی می‌کند، فرض بر این است که باقیمانده‌های حاصل دارای اثرات غیرخطی نیز هستند. ژانگ (Zhang, 2003) بنابراین، یک سری زمانی را می‌توان با ترکیب این دو بخش نمایش داد.

$$x_t = L_t + N_t \quad (15)$$

که L_t نشان دهنده بخش خطی و N_t بخش غیرخطی داده‌ها در زمان t است. مدل ARIMA یکی از مدل‌های سستی اقتصادسنجی برای پیش‌بینی سری‌های زمانی است. این مدل براساس دقت بالای خود روی بخش خطی داده‌های شناخته می‌شود. باقیمانده‌های بدست آمده در فرآیند خطی ARIMA را می‌توان به صورت زیر نمایش داد:

$$\varepsilon_t = x_t - \hat{L}_t \quad (16)$$

بهبود پیش‌بینی مدل‌های ARIMA ... (کامبیز هژیر کیانی و دیگران) ۱۷۵

مقادیر باقیمانده ε_t را می‌توان بعنوان ورودی مدل‌های یادگیری ماشین در نظر گرفت. ε_t مقدار برآورد شده در مدل‌های یادگیری ماشین است. در نهایت خروجی نهایی مدل‌های ترکیبی را می‌توان از طریق جمع مقادیر برآورد شده برای بخش خطی سری زمانی (\hat{L}_t) از طریق مدل ARIMA و بخش غیرخطی سری زمانی از طریق مدل یادگیری ماشین بدست آورد.

$$\hat{x}_t = \hat{L}_t + \varepsilon_t \quad (17)$$

۶.۲ معیارهای ارزیابی مدل

هدف اصلی طراحی مدل‌های پیش‌بینی‌کننده در سری‌های زمانی، پیش‌بینی مقادیر آتی براساس داده‌های گذشته است. این امکان وجود دارد که بهترین مدل برآورد شده با داده‌های آموزش، بهترین مدل در پیش‌بینی‌های برون نمونه‌ای نباشد. لذا از معیارهایی برای ارزیابی دقت پیش‌بینی مدل استفاده می‌شود. بوتراک (Buturac, 2022) در یک مطالعه توصیفی، معیارهای ارزیابی پیش‌بینی در مدل‌های اقتصادی را معرفی و دسته‌بندی نموده است. معیارهای مورد استفاده جهت ارزیابی مدل برآورد شده و دقت پیش‌بینی، در این پژوهش مجذور میانگین مربعات خطا (RMSE) و مجذور درصد میانگین مربعات خطا (RMSPE) می‌باشند.

$$RMSE = \sqrt{\frac{1}{m} \sum_{t=T+1}^{T+m} (y_t^f - y_t)^2} \quad (18)$$

$$RMSPE = \sqrt{\frac{1}{m} \sum_{t=T+1}^{T+m} \left(\frac{y_t^f - y_t}{y_t} \right)^2} \quad (19)$$

m طول دوره پیش‌بینی، y_t مقادیر واقعی و y_t^f مقادیر پیش‌بینی شده است. در این پژوهش پس از برآورد مدل، با استفاده از داده‌های بخش آموزش، مقادیر برآورد شده با داده‌های بخش ارزیابی مورد مقایسه قرار گرفته و خطاهای پیش‌بینی، براساس روابط (۱۸) و (۱۹) محاسبه می‌شود.

۳. پیشینه تحقیق

رویکرد مدل‌سازی خودرگرسیون هم‌انباشته میانگین متحرک (ARIMA) بعنوان یک روش پیش‌بینی توسط باکس-جنکینز (Box & Jenkins, 1970) معرفی شد. این رویکرد یکی از گسترده‌ترین روش‌های پیش‌بینی سری‌های زمانی اقتصادی و مالی است (Hyndman & Athanasopoulos, 2018). از زمان معرفی این رویکرد مطالعات بسیاری در مورد سری‌های زمانی مالی مانند قیمت برق، قیمت مسکن و قیمت سهام با استفاده از مدل‌سازی ARIMA انجام و بصورت گسترده‌ای برای پیش‌بینی سری‌های زمانی مورد استفاده قرار گرفته است. ریموند (Raymond, 1997) از مدل ARIMA برای شناسایی روند قیمت املاک و مستغلات هنگ‌کنگ استفاده کرد و نتیجه گرفت که به دلیل تغییرات آهسته در عوامل کوتاه‌مدت، مدل ARIMA روش خوبی به ویژه برای پیش‌بینی‌های کوتاه‌مدت است. نتایج این تحقیق نشان داد که جزء اتورگرسیون (AR) در تعیین اثرات روند قیمت مسکن مفید است، در حالی که اجزای میانگین متحرک (MA) در تعیین نقاط چرخش نقش دارند. این دو مؤلفه که مفهوم مدل‌سازی ARIMA را تشکیل می‌دهند، در ردیابی جهت تغییرات قیمت‌های املاک و مستغلات موفق بودند. وایس (Weis, 2000) از رویکرد ARIMA برای ساخت مدل‌هایی استفاده کرد که قیمت برق اسپانیا را با دقت بالا در نتایج، پیش‌بینی می‌کرد. مدل معرفی شده توسط وی با اضافه کردن متغیرهای توضیحی و بدون آن‌ها، پیش‌بینی‌هایی با خطای متوسط حدود ۱۰٪ را ارائه کرد. هسین و همکاران (Hasin et al, 2011) از مدل‌سازی ARIMA برای پیش‌بینی صادرات پنبه استفاده کردند که نتایج نشان دهنده دقت پیش‌بینی بهتر نسبت به مدل‌های هموارسازی نمایی ساده (Simple Exponential Smoothing / SES) و هموارسازی نمایی دو پارامتری (Holt Two Parameters Exponential Smoothing / HES) بود. فتاح و همکاران (Fattah et al, 2018) برای پیش‌بینی تقاضا از مدل ARIMA استفاده کردند، نتایج نشان داد مدل‌سازی ARIMA نیازمند تعداد زیادی مشاهدات و تخمین‌ها از روابط توابع خودهمبستگی (ACF) و خود همبستگی جزئی (PACF) است. پس از استفاده از روش باکس-جنکینز و بررسی ACF و خود همبستگی جزئی PACF، آن‌ها دریافتند که معیار آکائیک (AIC) حداقل مقدار نیست و باقیمانده‌های غیرخطی وجود دارد. به طور مشابه، آدیبی و همکاران (Adebiyi et al, 2014) نشان دادند که مدل‌های ARIMA دارای پتانسیل قوی برای پیش‌بینی کوتاه‌مدت هستند. آن‌ها یک مدل ARIMA برای پیش‌بینی قیمت سهام شرکت نوکیا و بانک زینت طراحی کردند. پیش‌بینی‌های مدل رضایت‌بخش بود و نتایج نشان داد که مدل‌های ARIMA می‌توانند به خوبی با تکنیک‌های پیش‌بینی در حال ظهور مانند شبکه‌های

عصبی مصنوعی، در پیش‌بینی کوتاه‌مدت رقابت کنند. ابونوری و همکاران (Abounoori et al, 2016) جهت پیش‌بینی نوسانات بورس اوراق بهادار تهران، در افق‌های زمانی ۱ تا ۲۲ روز از مدل‌های ترکیبی انتقال رژیم مارکوف و گارچ (MRSGARCH) با توزیع‌های خطای مختلف استفاده و نتایج آن را با مدل‌های گارچ استاندارد مقایسه کردند. نتایج نشان داد که در افق زمانی یک روزه مدل AR(2)-MRSGARCH با توزیع خطا تعمیم یافته (GED) از عملکرد بهتری نسبت به دیگر مدل‌ها دارد. همچنین در افق زمانی ۵ روزه مدل AR(2)-MRSGARCH با توزیع GED و مدل AR(2)-MRSGARCH با توزیع خطای تی استیودنت (t-Student) پیش‌بینی‌های دقیق‌تری ارائه می‌دهند. در افق زمانی ۲۲ روزه، هیچ تفاوتی بین مدل‌های MRSGARCH با مدل‌های استاندارد GARCH وجود ندارد. نادمی و نادمی (Nademi & Nademi, 2018) به منظور پیش‌بینی قیمت نفت خام از یک مدل نیمه‌پارامتری (Semiparametric) ترکیبی AR-ARCH با رویکرد انتقال رژیم مارکوف استفاده کردند. آن‌ها عملکرد مدل طراحی شده را از طریق انتخاب تابع هدف مناسب در پیش‌بینی قیمت نفت خام مورد ارزیابی قرار داده و قدرت پیش‌بینی را با مدل‌های ARIMA و GARCH مقایسه نمودند. نتایج نشان داد که مدل‌های نیمه‌پارامتری انتقال رژیم مارکوف طراحی شده نسبت به مدل‌های ARIMA و GARCH برای هر دو دوره درون و برون‌نمونه‌ای (۱، ۵، ۱۰ و ۲۲ گام به جلو) پیش‌بینی‌های بهتری در خصوص قیمت نفت خام ارائه می‌کند.

در حوزه مدل‌های یادگیری ماشین برای پیش‌بینی‌های بازار سهام، گالر و همکاران (Galler et al, 1993)، یک مطالعه پیشگام انجام دادند. آن‌ها یک مدل طبقه‌بندی‌کننده با استفاده از یادگیری عمیق ایجاد کردند که طبقه‌بندی ۷۲٪ از حرکت‌های جهت‌دار بازده سهام یک ساله را به درستی پیش‌بینی می‌کرد. علاوه بر توانایی طبقه‌بندی حرکت‌های جهت‌دار، اولسون و ماسمن (Olson & Mossman, 2003) پتانسیل استفاده از یادگیری ماشین در مدل‌های رگرسیون را نشان دادند. آن‌ها مقادیر سالیانه شاخص در بورس اوراق بهادار کانادا را پیش‌بینی کردند. نتایج هر دو مطالعه نشان دهنده این موضع است که مدل‌های یادگیری عمیق می‌توانند با استفاده از تکنیک‌های سستی از مدل‌های رگرسیون موجود، بهتر عمل کنند. کراوس و همکاران (Krauss et al, 2017) در مطالعه‌ای تکنیک‌های مختلف یادگیری ماشین را برای پیش‌بینی قیمت سهام مقایسه کردند. نتیجه جالب این مطالعه عدم عملکرد بهتر این تکنیک‌ها در مقابل تکنیک‌های سستی، در شرایط کلی بود. با این حال رویکردهای معرفی شده در دوره‌هایی که بازارها با نوسانات زیاد مواجه می‌شدند، مانند دوره حباب دات کام (The dot-com bubble) و بحران مالی سال ۲۰۰۸ عملکرد

خوبی داشتند. یکی از جدیدترین و محبوب‌ترین تکنیک‌های یادگیری ماشین برای پیش‌بینی سری‌های زمانی، استفاده از شبکه‌های عصبی مصنوعی (Artificial Neural Networks /ANN) و به طور خاص، شبکه عصبی حافظه کوتاه‌مدت طوانی (Long Short-Term Memory / LSTM) است که اخیراً به شدت مورد استفاده قرار گرفته است. معمولاً شبکه‌های LSTM در زمان کار با مقادیر زیادی داده به کار گرفته می‌شوند، اما نمونه‌هایی از کاربرد موفق با تعداد داده کمتر نیز وجود دارد. سیامی و همکاران (Siami et al,2018) یک شبکه LSTM برای پیش‌بینی سری‌های زمانی داده‌های مالی طراحی کردند که موفق به ایجاد پیش‌بینی‌هایی با میانگین خطای بین ۱۳٪ تا ۱۶٪ شد. فیشر و کراوس (Fischer, & Kraus,2018) شبکه‌های LSTM را برای مدل‌سازی حرکت‌های جهت‌دار شاخص S&P500 طراحی کردند. مطالعه آن‌ها نشان داد شبکه‌های LSTM از سایر مدل‌های جایگزین یادگیری ماشین مانند جنگل تصادفی (Random Forest) و طبقه‌بندی‌کننده رگرسیون لجستیک (Logistic Regressio Classifier)، که بدون حافظه طراحی می‌شوند، بهتر عمل می‌کند.

طراحی مدل‌های ترکیبی این مزیت اساسی را دارد که ترکیب دو یا چند مدل منجر به افزایش پتانسیل و بهره‌برداری از مزایای و ویژگی‌های هر مدل می‌شود. ساخت مدل‌های ترکیبی با الهام از مطالعه ژانگ (Zhang,2003) عمدتاً بر اساس این ایده است که داده‌های سری‌های پیچیده از اجزای خطی و غیرخطی تشکیل شده و هر دو جزء به سادگی به صورت خطی اضافه می‌شوند. بنابراین، هنگام برخورد با مشکلات پیش‌بینی پیچیده، می‌توان سری‌های را به دو بخش تجزیه و براساس ویژگی‌های هر یک از بخش‌های تجزیه شده، مدل‌های مختلفی برای پیش‌بینی آن طراحی نمود. نتیجه نهایی از برهم‌نهی (Superposition) مقادیر پیش‌بینی مدل‌های منفرد بدست خواهد آمد. با این‌حال، اگر اجزای خطی و غیرخطی در سری‌های زمانی به سادگی و به صورت خطی بهم اضافه نشوند، روش‌های سنتی مدل‌سازی، دقت پیش‌بینی را کاهش داده بگونه‌ای که دقت پیش‌بینی حتی ممکن است کمتر از مدل‌های فردی باشد. ژانگ (Zhang,2003) مطالعه‌ای در مورد ترکیب مدل ARIMA و یک شبکه عصبی منتشر کرد. او پیشنهاد کرد، از آنجا که مدل‌های ARIMA و شبکه‌های عصبی اغلب در معرض مقایسه قدرت پیش‌بینی برای سری‌های زمانی با نتایج مختلف بودند، باید مفید بودن مدل ترکیبی با استفاده از نقاط قوت هر دو مدل بررسی شود. در این مطالعه، وی سری‌های زمانی مختلفی از جمله داده‌های لکه خورشیدی و نرخ ارز را بررسی کرد. او نشان داد که نه ARIMA و نه شبکه‌های عصبی به صورت جداگانه، برای طیف گسترده‌ای از سری‌های زمانی مناسب نیستند.

بیشتر سری‌های زمانی دارای روابط خطی و غیرخطی میان مشاهدات هستند و یک مدل ترکیبی متشکل از روش‌های مطلوب برای هر نوع رابطه، توصیه می‌شود. این مطالعه پیشگام، با ایجاد یک مفهوم جدید برای ترکیب بین مدل‌های ARIMA و شبکه‌های عصبی، الهام بخش مطالعات متعددی در زمان‌های اخیر بوده است. آدیبی و همکاران (Adebiyi et al, 2014) مدل ARIMA را با شبکه عصبی مصنوعی برای پیش‌بینی قیمت سهام مقایسه کردند. نتایج نشان داد مدل ANN از دقت پیش‌بینی بهتری نسبت به مدل ARIMA برخوردار است. هاولدولونا و جواهری (Haviluddina & Jawahir, 2015) به منظور پیش‌بینی گردشگران در اندونزی، مدل ARIMA را با یک شبکه عصبی توابع شعاعی پایه (Radial Basis Function Neural Network / RBFNN) مقایسه کردند. نتایج نشان داد براساس معیار خطا MSE مدل RBFNN پیش‌بینی‌های دقیق‌تری نسبت به مدل ARIMA ارائه می‌دهد. چوی (Choi, 2018) با الهام از ادبیات ژانگ، اثربخشی مدل ترکیبی شبکه ARIMA و LSTM را برای پیش‌بینی ضرایب همبستگی در شاخص S&P500 مورد بررسی قرار داد. نتایج نشان داد که مدل ترکیبی، پیش‌بینی‌هایی را در مورد ضرایب همبستگی برای جفت سهام، ارائه می‌دهد که به طور قابل توجهی نسبت به روش‌های سنتی دقیق‌تر است. آسیفول و همکاران (Asiful et al, 2018) یک مدل ترکیبی LSTM و واحد بازگشتی دروازه‌دار (Gated Recurrent Unit / GRU) برای بررسی داده‌های S&P500 جمع‌آوری شده از پایگاه یاهو‌فاینانس (YahooFinance) طراحی کردند. مدل ترکیبی آن‌ها مقدار مناسبی را برای معیار خطای MAE نشان داد، همچنین براساس نتایج بدست آمده دقت و عملکرد مدل ترکیبی نسبت به هر یک از مدل‌های LSTM و GRU به صورت منفرد بهتر بود. دوشا و همکاران (DevShah et al, 2018) یک تجزیه تحلیل کامل روی مدل‌های LSTM و شبکه عصبی عمیق (Deep Neural Network / DNN) برای داده‌های شاخص نرخ ارز بمبئی انجام دادند. نتایج نشان داد هر دو رویکرد برای پیش‌بینی‌های روزانه مناسب هستند. معیار خطای RMSE حدود ۱٪ بدست آمد. با این حال خطای مدل LSTM در پیش‌بینی داده‌های هفتگی به مراتب کمتر از مدل DNN بود. آکگون و تیمور (Akgün & Temür, 2019) یک مدل ترکیبی شامل یک جزء ARIMA و یک شبکه LSTM برای پیش‌بینی قیمت مسکن در ترکیه طراحی کردند. نتایج مطالعه آن‌ها با ادبیات ارائه شده توسط ژانگ مطابقت داشت. بهترین دقت با مدل ترکیبی طراحی شده به دست آمد و تفاوت قدرت پیش‌بینی بین مدل‌های ترکیبی و فردی قابل توجه بود.

اغلب مطالعات انجام شده بصورت مدل‌سازی منفرد مدل‌های سنتی اقتصادسنجی و مدل‌های یادگیری ماشین و مقایسه نتایج این دو رویکرد با یکدیگر است. مطالعات انجام شده

در خصوص طراحی مدل‌های ترکیبی نیز بصورت مدل‌های سستی اقتصادسنجی و مدل‌های یادگیری ماشین است که در مدل‌های یادگیری ماشین استخراج ویژگی‌های سری‌زمانی نه بصورت خودکار توسط الگوریتم بلکه توسط کاربر صورت می‌پذیرد. همانگونه که در بخش مقدمه ذکر شد رویکرد یادگیری عمیق، زیرمجموعه‌ای از یادگیری ماشین است که فرآیند استخراج ویژگی را به صورت خودکار انجام و در کار با داده‌های بزرگ بدلیل همین موضوع و عدم نیاز به مهندسی ویژگی به صورت دستی، نسبت به مدل‌های یادگیری ماشین برتری محسوسی دارند. لذا استفاده از این رویکرد و بکارگیری سه مدل RNN، GRU و LSTM بعنوان یک مطالعه جدید در این پژوهش معرفی می‌شود.

۴. مدل تحقیق و روش برآورد

در این پژوهش به منظور طراحی مدل، از میان رمزارزهای موجود و مورد معامله در بازار رمزارزها، داده‌های روزانه چهار رمزارز بیت‌کوین (Bitcoin / BTC)، اتریوم (Ethereum / ETH)، بایننس‌کوین (BinanceCoin / BNB) و ریپل (Ripple / XRP) براساس بالاترین ارزش بازار جمع‌آوری شده است. اطلاعات هر رمزارز شامل قیمت بازشدن، قیمت بسته شدن، بالاترین قیمت، پایین‌ترین قیمت و حجم معامله، همگی بصورت روزانه از طریق سایت کوین‌مارکت‌کپ جمع‌آوری شده است. کلیه محاسبات و برآوردها در این پژوهش توسط زبان برنامه‌نویسی پایتون صورت گرفته است. جدول (۱) خلاصه اطلاعات مربوط به قیمت بسته شدن روزانه هریک از رمزارزهای مورد بررسی را نشان می‌دهد.

جدول ۱. خلاصه اطلاعات رمزارزهای مورد استفاده در مدل‌سازی پژوهش

بیت‌کوین	اتریوم	بایننس‌کوین	ریپل	تعداد
۲۱۱۶	۲۱۱۶	۹۶۱	۱۷۵۱	
۲۱۱۷۲/۶۲	۱۲۲۶/۹۳	۳۴۳/۱۱	۰/۴۹	میانگین
۱۵۹۶۱/۳۳	۱۱۳۴/۳۶	۱۰۶/۴۶	۰/۲۹	انحراف معیار
۳۲۳۶/۷۶	۸۴/۳۱	۱۹۷/۰۴	۰/۱۴	کمترین قیمت
۶۷۵۶۶/۸۳	۴۸۱۲/۰۹	۶۷۵/۶۸	۱/۸۴	بیشترین قیمت
۰/۹۲۳۹	۰/۹۹۴۰۳	۱/۰۷۹۷	۱/۵۴۹۰۴	چولگی
-۰/۱۹۹۰	۰/۱۸۱۹۶	۰/۴۸۴۰	۲/۲۵۴۵	کشیدگی

منبع: یافته‌های تحقیق

بهبود پیش‌بینی مدل‌های ARIMA ... (کامبیز هژیر کیانی و دیگران) ۱۸۱

در اولین گام، مانایی چهار سری زمانی مورد بررسی قرار می‌گیرد. نتایج آزمون دیکی فولر (Dickey-Fuller Test) در جدول (۲) نشان می‌دهد هر چهار سری زمانی با یک مرتبه تفاضل گیری مانا می‌شوند.

جدول ۲. آزمون مانایی

d = 0		d = 1		
مقدار آماره آزمون دیکی فولر	مقدار بحرانی	مقدار آماره آزمون دیکی فولر	مقدار بحرانی	
۳/۶۵	۱/۰	-۴/۶۲	۰/۰۰۰۱	بیت‌کوین
-۲/۵۳	۰/۱۰۷۲	-۳/۹۴	۰/۰۰۱	اتریوم
-۲/۲۲	۰/۲۰۰۳۶۱	-۸/۶۱	۰/۰	بایننس‌کوین
-۲/۳۴	۰/۱۵۸۸۹۸	-۶/۰۸	۰/۰	ریپل

منبع: یافته‌های تحقیق

داده‌های قیمت بسته شدن روزانه هر چهار سری زمانی دو دوره آموزش و آزمون تقسیم می‌شوند. جدول (۳) اطلاعات مربوط به تقسیم بندی داده‌ها به دو بخش آموزش و آزمون را نشان می‌دهد.

جدول ۳. تفکیک داده‌ها به دو بخش آموزش و ارزیابی

از	تا	تعداد	درصد از کل داده‌ها		
۲۰۱۸-۰۱-۰۱	۲۰۲۱-۰۱-۰۴	۱۱۰۰	٪۵۲	آموزش	بیت‌کوین
۲۰۲۱-۰۱-۰۵	۲۰۲۳-۱۰-۱۷	۱۰۱۶	٪۴۸	ارزیابی	
۲۰۱۸-۰۱-۰۱	۲۰۲۱-۰۱-۰۴	۱۱۰۰	٪۵۲	آموزش	اتریوم
۲۰۲۱-۰۱-۰۵	۲۰۲۳-۱۰-۱۷	۱۰۱۶	٪۴۸	ارزیابی	
۲۰۲۱-۰۳-۰۱	۲۰۲۲-۰۷-۱۲	۴۹۹	٪۵۲	آموزش	بایننس‌کوین
۲۰۲۲-۰۷-۱۳	۲۰۲۳-۱۰-۱۷	۴۶۲	٪۴۸	ارزیابی	
۲۰۱۹-۰۱-۰۱	۲۰۲۱-۰۶-۲۸	۹۱۰	٪۵۲	آموزش	ریپل
۲۰۲۱-۰۶-۲۹	۲۰۲۳-۱۰-۱۷	۸۴۱	٪۴۸	ارزیابی	

منبع: یافته‌های تحقیق

تفکیک داده‌ها به دو بخش آموزش و آزمون با یک نسبت ثابت انجام شده است. در این تفکیک روند تغییرات قیمت بسته شدن هر یک از رمازرها در نظر گرفته شده است. بعنوان مثال داده‌های مربوط به بایننس کوین و ریپل به ترتیب از ابتدای سال ۲۰۲۱ و ۲۰۱۹ شروع شده است زیرا قبل از این تاریخ، قیمت رمازرهای مذکور بسیار پایین و نامتناسب با قیمت سالیان بعد بوده است. همچنین تقسیم بندی مذکور برای اجرای مدل ARIMA و مدل‌های یادگیری عمیق بصورت منفرد استفاده شده و بخش آزمون در مدل ترکیبی بعنوان کل داده‌ها، دو مرتبه تقسیم بندی شده است. در مدل‌سازی با الگوریتم‌های یادگیری ماشین، نرمال‌سازی داده‌ها اهمیت بسزایی دارد. در این پژوهش در زمان استفاده از مدل‌های یادگیری عمیق به تنهایی و همچنین در زمان طراحی مدل ترکیبی، کلیه داده‌های جمع‌آوری شده توسط تابع MinMaxScaler نرمال‌سازی می‌شوند. این تابع مقادیر یک بردار را در بازه صفر و یک قرار می‌دهد. نتایج پس از معکوس سازی مورد بررسی و ارزیابی قرار گرفته است.

$$x_{scaled} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (20)$$

در اولین گام، توابع ACF و PACF برای هر یک از سری‌های زمانی بررسی و از طریق یک تابع حلقه با مقادیر حداکثر $p=15$ و $q=15$ مرتبه‌های مدل ARIMA با در نظر گرفتن کمترین مقدار معیار آکائیک تعیین می‌شود. جدول (۴) مرتبه‌های p و q متناظر با کمترین مقدار آکائیک را نشان می‌دهد.

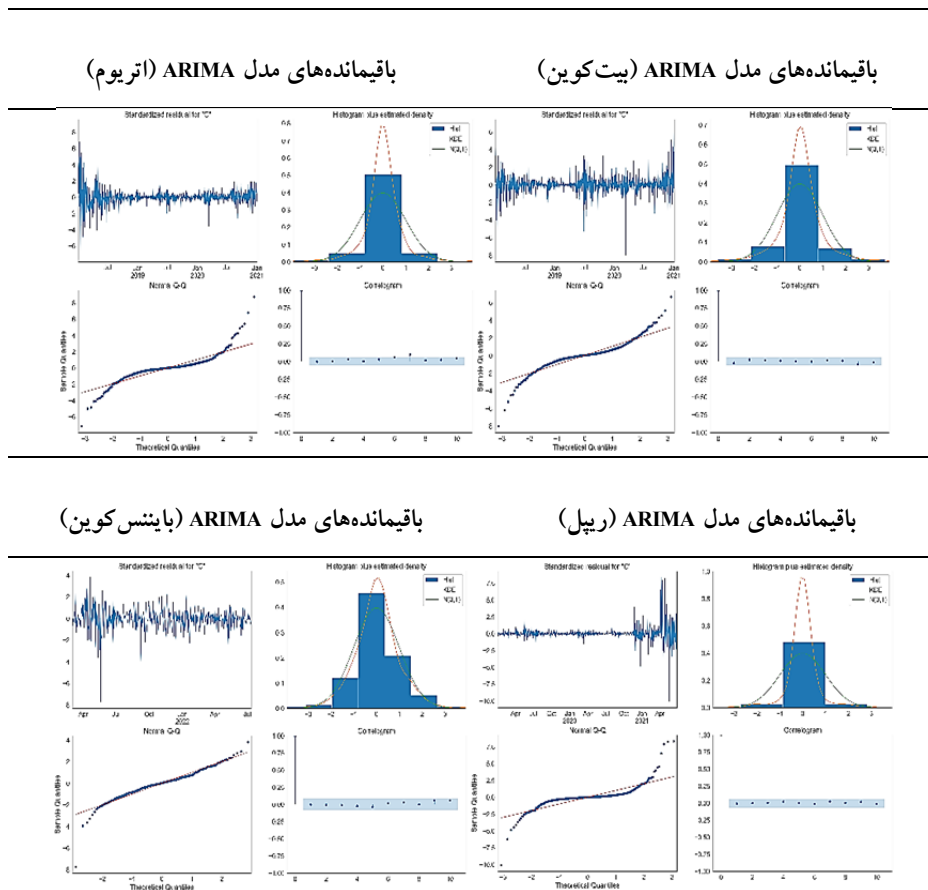
جدول ۴. مرتبه‌های مدل ARIMA براساس معیار آکائیک

ریپل	بایننس کوین	اتریوم	بیت کوین	(p,q)
(۱۲,۱,۹)	(۲,۱,۴)	(۷,۱,۶)	(۳,۱,۳)	
-۳۱۸۸/۵۹۴	۴۴۷۲/۳۳۲	۱۰۰۱۸/۵۳۸	۱۶۱۷۹/۱۰۵	AIC

منبع: یافته‌های تحقیق

پس از تعیین مرتبه‌های p و q برای هر یک از سری‌های زمانی، مدل ARIMA برای بخش آموزش داده‌ها، برآورد و در بخش آزمون پیش‌بینی شده است. شکل (۴) تحلیل باقیمانده‌های مدل ARIMA برای هر یک از سری‌های زمانی مورد بررسی را نشان می‌دهد.

شکل ۴. نمای کلی یک شبکه عصبی حافظه کوتاه مدت طولانی



منبع: یافته‌های تحقیق

در مرحله بعدی سه مدل یادگیری عمیق شامل مدل LSTM، RNN و GRU در بازه زمانی آموزش، برآورد و مجدداً در بازه آزمون پیش‌بینی انجام می‌شود. پارامترهای مدل‌های یادگیری ماشین در جدول (۵) گزارش شده است.

جدول ۵. پارامترهای طراحی مدل‌های یادگیری عمیق

optimizer	loss	Dense	Dropout	Bach size	Epoch	Layers
tanh	Binary_crossentropy	1,sigmoid	--	۵۰	۱۰۰	۲ لایه (۶۴ و ۳۲) RNN
adam	mse	1	۰.۲	۵۰	۱۰۰	۲ لایه (۶۴ و ۳۲) LSTM
adam	mse	1	۰.۲	۵۰	۱۰۰	۲ لایه (۶۴ و ۳۲) GRU

منبع: یافته‌های تحقیق

نتایج این بخش نشان می‌دهد که مدل‌های یادگیری عمیق بصورت کلی و برای هر چهار سری زمانی (رمزارزهای منتخب) نسبت به مدل ARIMA، عملکرد بهتری از نظر پیش‌بینی مقادیر آتی دارند. برای سری‌های زمانی قیمت بایننس‌کوین و ریپل مدل LSTM براساس هر دو معیار ارزیابی خطا، برتری کامل نسبت به دیگر مدل‌ها دارد. در سری‌های زمانی بیت‌کوین و اتریوم براساس معیار خطا RMSPE مدل LSTM عملکرد بهتری نسبت به دیگر مدل‌ها دارد. این نتایج در جدول (۵) گزارش شده است.

جدول ۶. مقایسه نتایج پیش‌بینی مدل ARIMA و مدل‌های یادگیری عمیق LSTM، RNN و GRU

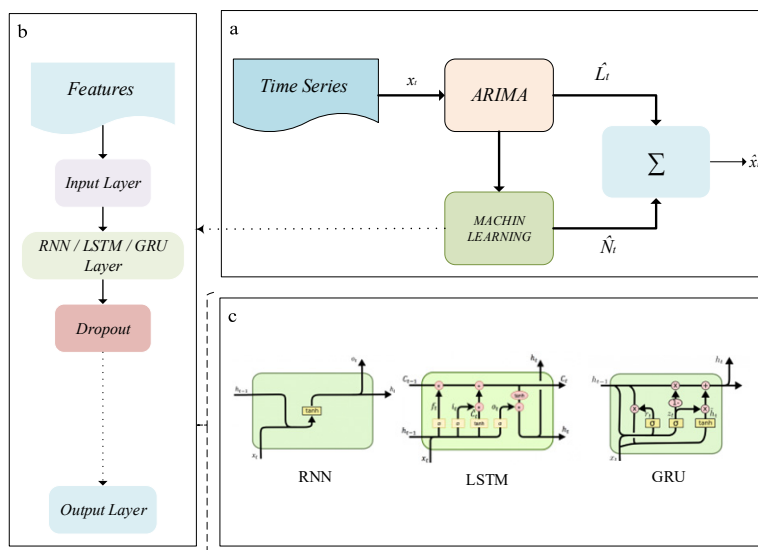
RMSPE	RMSE	Model
۱.۵۷۴۲	۳۶۱۶۵.۰۲	ARIMA
۰.۲۷۲۷	۱۱۲۳.۶۲	LSTM
۰.۲۹۲۵	۱۷۶۱.۹۸	RNN
۰.۲۹۳۷	۱۱۰۵.۶۶	GRU
<hr/>		
۰.۵۱۳۸	۱۵۰۰.۴۲	ARIMA
۰.۲۴۷۹	۸۲.۵۲	LSTM
۰.۲۶۰۷	۸۷.۱۰	RNN
۰.۲۵۲۴	۷۸.۷۰	GRU
<hr/>		
۰.۲۲۵۱	۶۸.۷۴	ARIMA
۰.۲۰۴۵۴۸	۱۲.۴۳	LSTM
۰.۲۱۵۷۷۷	۳۴.۳۶	RNN

بهبود پیش‌بینی مدل‌های ARIMA ... (کامبیز هژیر کیانی و دیگران) ۱۸۵

۰.۲۱۲۸۶۲	۱۲.۸۴	GRU	ریپل
۰.۵۳۰۴	۰.۲۶۰۲	ARIMA	
۰.۲۸۵۱	۰.۰۲۹۷	LSTM	
۰.۲۹۶۱	۰.۰۳۴۰۱	RNN	
۰.۲۹۴۰	۰.۰۳۰۴۰۹	GRU	

منبع: یافته‌های تحقیق

در نهایت به منظور طراحی مدل ترکیبی، باقیمانده‌های حاصل از مدل ARIMA بعنوان ورودی در سه مدل یادگیری عمیق (LSTM، RNN و GRU) وارد و پیش‌بینی باقیمانده‌ها انجام می‌شود و سه مدل ترکیبی ARIMA-RNN، ARIMA-LSTM و ARIMA-GRU طراحی و مورد بررسی به لحاظ دقت در پیش‌بینی قرار گرفته است. شکل (۵) فرآیند کلی طراحی مدل ترکیبی این پژوهش را نشان می‌دهد.



شکل ۵. مدل ترکیبی طراحی شده در پژوهش (ترسیم توسط محقق)

نتایج پیش‌بینی مدل‌های ترکیبی که در جدول (۶) آورده شده است نشان می‌دهد، استفاده از طراحی جدید باعث کاهش بسیار محسوس خطای پیش‌بینی در هر سه مدل ترکیبی ARIMA- RNN، ARIMA-LSTM و ARIMA-GRU نسبت به هریک از مدل‌های تکی ARIMA و یادگیری

عمیق در هر چهار سری زمانی (رمزارز منتخب) می‌شود. بعبارت دیگر زمانیکه جزء خطی سری زمانی توسط ARIMA و جزء غیرخطی آن توسط یک مدل یادگیری عمیق مدل‌سازی و با هم جمع زده شوند، پیش‌بینی‌های بسیار دقیق‌تری نسبت به مدل سازی ARIMA و همچنین مدل‌سازی به روش‌های یادگیری عمیق حاصل می‌شود.

جدول ۷. نتایج معیارهای خطای پیش‌بینی برای مدل‌های ترکیبی

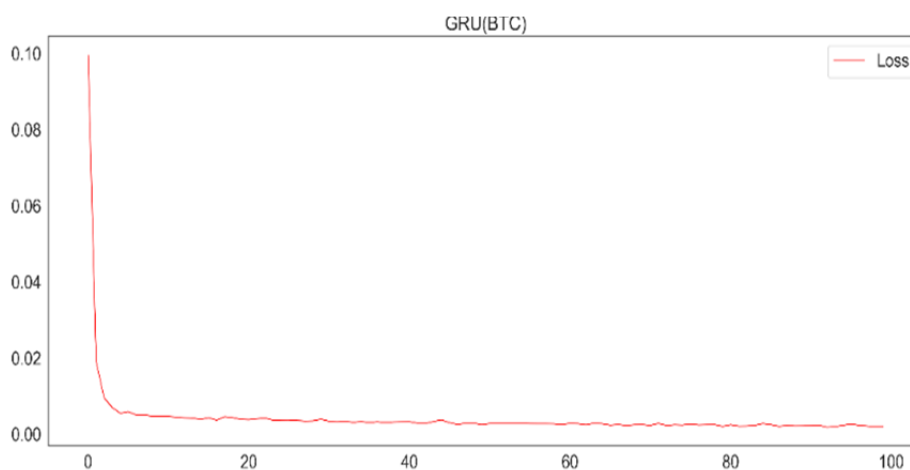
RMSPE	RMSE	Model	
۰.۰۴۸۱	۱۲۲۴.۷۳	ARIMA-LSTM	بیت کوین
۰.۰۷۴۲۹	۱۹۲۲.۸۰	ARIMA-RNN	
۰.۰۳۸۶۶	۹۷۸.۰۱	ARIMA-GRU	
۰.۰۴۳۴	۷۳.۶۶	ARIMA-LSTM	اتریوم
۰.۰۳۷۹	۶۳.۵۰	ARIMA-RNN	
۰.۰۳۲۷	۵۶.۰۷	ARIMA-GRU	
۰.۰۵۸۸	۱۳.۰۸	ARIMA-LSTM	بایننس کوین
۰.۱۳۰۹	۲۷.۹۲	ARIMA-RNN	
۰.۰۳۸۰	۸.۴۹	ARIMA-GRU	
۰.۰۵۸۸	۰.۰۳۷۱	ARIMA-LSTM	ریبل
۰.۰۶۸۷	۰.۰۴۱۸۳	ARIMA-RNN	
۰.۰۵۶۳	۰.۰۳۵۴۵	ARIMA-GRU	

منبع: یافته‌های تحقیق

براساس این نتایج مدل ترکیبی ARIMA-GRU بهترین عملکرد در میان تمام مدل‌های ترکیبی بکارگرفته شده در این پژوهش، برای تمام چهار مزارز منتخب را دارد. شکل (۶) روند کاهش معیار خطای فرآیند آموزش GRU در مدل‌سازی باقیمانده‌های بدست آمده از مدل ARIMA (سری زمانی بیت‌کوین) را نشان می‌دهد که نشان‌دهنده بهینه‌بودن فرآیند یادگیری و برآورد مدل است.

بهبود پیش‌بینی مدل‌های ARIMA ... (کامبیز هژیر کیانی و دیگران) ۱۸۷


شکل ۶. تغییرات معیار خطا در طی فرآیند آموزش مدل GRU برای سری زمانی باقیمانده‌های مدل ARIMA (بیت‌کوین)



منبع : یافته‌های تحقیق

شکل (۷) نمایش کلی مدل‌سازی ترکیبی ARIMA-GRU ، با در نظر گرفتن دوره‌های آموزش و آزمون را برای سری زمانی بیت‌کوین نشان می‌دهد.

شکل ۷. مدل ترکیبی ARIMA-GRU برای سری زمانی بیت‌کوین



منبع: یافته‌های تحقیق

۵. نتیجه گیری

در این پژوهش مقایسه‌ای میان مدل‌سازی ARIMA با روش‌های نوین مدل‌سازی یادگیری عمیق انجام گردید. سپس با استفاده از این فرض اساسی که داده‌های سری‌زمانی پیچیده از اجزای خطی و غیرخطی تشکیل شده و هر دو جزء به سادگی به صورت خطی اضافه می‌شوند، مدل‌های ترکیبی یادگیری عمیق به منظور بهبود پیش‌بینی‌های بدست آمده از مدل ARIMA طراحی گردید. نتایج نشان داد استفاده از باقیمانده‌های بدست آمده از مدل‌های ARIMA بعنوان وردی مدل‌های یادگیری عمیق می‌تواند بهبود قابل توجهی را در پیش‌بینی مقادیر آتی سری‌زمانی ایجاد نماید. با توجه به معرفی رویکرد مدل‌سازی ترکیبی نتایج کلی این پژوهش به صورت زیر دسته بندی شده است.

- درحوزه پیش‌بینی سری‌زمانی چهار رمز ارز منتخب، مدل‌های یادگیری عمیق (RNN، LSTM و GRU) بصورت منفرد نسبت به مدل ARIMA عملکرد بهتری در پیش‌بینی مقادیر آتی دارند. براساس معیارهای خطای متفاوت، یکی از مدل‌های یادگیری عمیق برتری دارد. این موضوع می‌تواند به ساختار سری‌زمانی مورد بررسی نیز بستگی داشته باشد.
- ایده وجود اجزای خطی و غیرخطی در داده‌های سری‌زمانی پیچیده در این پژوهش نیز تایید می‌شود. لذا این پژوهش نشان می‌دهد می‌توان سری‌زمانی را به دو بخش تجزیه

بهبود پیش‌بینی مدل‌های ARIMA ... (کامیاز هژیر کیانی و دیگران) ۱۸۹

و براساس ویژگی‌های هر یک از بخش‌های تجزیه شده، مدل‌های مختلفی برای پیش‌بینی آن طراحی نمود.

- طراحی مدل ترکیبی رویکرد ARIMA و مدل‌های یادگیری عمیق بهبود قابل توجهی در دقت پیش‌بینی سری زمانی ایجاد می‌کند.

- افزایش پیچیدگی‌های مدل‌های یادگیری عمیق مانند افزایش لایه‌ها، واحدهای هر لایه و ... لزوماً باعث بهبود عملکرد مدل از نظر معیارهای خطا، در پیش‌بینی مقادیر آتی نخواهد شد. لذا طراحی بهینه در مدل‌سازی یادگیری ماشین بسیار بااهمیت است.

- مدل ترکیبی ARIMA-GRU از نظر دقت در ارائه پیش‌بینی سری‌های زمانی منتخب بهترین عملکرد را دارد.

در پایان بعنوان تحقیقات آتی، طراحی مدل‌های ترکیبی ARIMA-GARCH و مدل‌های یادگیری عمیق به منظور مدل‌سازی واریانس سری‌های زمانی جهت بررسی و ارزیابی دقت پیش‌بینی مقادیر آتی پیشنهاد می‌شود.

پیوست: معیارهای خطا

RMSPE	RMSE	Model	
۱/۵۷۴۲۴۸۷۳۱	۳۶۱۶۵/۰۲۹۶۵	ARIMA	
۰/۲۷۲۷۲۴۳۳۳	۱۱۲۳/۶۲۹۰۸۸	Pure-LSTM	
۰/۲۹۲۵۹۲۳۹۴	۱۷۶۱/۹۸۷۲۲۱	Pure-RNN	
۰/۲۹۳۷۲۱۵۲۱	۱۱۰۵/۶۶۲۷۸۲	Pure-GRU	BTC
۰/۰۴۸۱۱۱۳۱	۱۲۲۴/۸۳۷۲۱۸	ARIMA-LSTM	
۰/۰۷۴۲۹۴۲۴۸	۱۹۲۲/۸۰۱۵۴۳	ARIMA-RNN	
۰/۰۳۸۶۶۲۷۷۸	۹۷۷/۰۱۴۶۱۷۵	ARIMA-GRU	
۰/۵۱۳۸۹۷۶۱۱	۱۵۰۰/۴۲۶۴۶۲	ARIMA	
۰/۲۴۷۹۵۶۲۶۱	۸۲/۵۲۳۵۴۷۷۶	Pure-LSTM	
۰/۲۶۰۷۱۵۰۰۳	۸۷/۱۰۰۷۵۱۸۹	Pure-RNN	
۰/۲۵۲۴۵۱۷۱۵	۷۸۷/۰۲۱۴۶۴۶	Pure-GRU	ETH
۰/۰۴۳۴۴۰۲۳۸	۷۳/۶۶۵۰۴۲۳۴	ARIMA-LSTM	
۰/۰۳۷۹۹۰۹۶	۶۳/۵۰۲۷۱۰۹	ARIMA-RNN	
۰/۰۳۲۷۰۰۵۸۵	۵۶/۰۷۰۴۴۲۱۴	ARIMA-GRU	
۰/۲۲۵۱۳۹۵۸۴	۶۸۷۴۲۸۶۷۸	ARIMA	BNB

۰/۲۰۴۵۴۸	۱۲/۴۳۲۱۱۹	Pure-LSTM	
۰/۲۱۵۷۷۷	۳۴/۳۶۴۳۹	Pure-RNN	
۰/۲۱۲۸۶۲	۱۲/۸۴۹۶۹۳	Pure-GRU	
۰/۰۵۸۱۲۸۵۸۵	۱۳/۰۸۹۷۶۷۳۵	ARIMA-LSTM	
۰/۱۳۰۹۴۳۶۴	۲۷/۹۲۹۰۶۵۶۵	ARIMA-RNN	
۰/۰۳۸۰۹۶۹۳۶	۸/۴۹۳۶۱۱۸۷۹	ARIMA-GRU	
۰/۵۳۰۴۶۱۱۷	۰/۲۶۰۲۷۶۸۰۴	ARIMA	
۰/۲۸۵۱۹۷۶۶۶	۰/۰۲۹۷۳۶۲۰۴	Pure-LSTM	
۰/۲۹۶۱۱۸۷۸	۰/۰۳۴۰۱۲۱۶	Pure-RNN	
۰/۲۹۴۰۷۵۵۹۱	۰/۰۳۰۴۰۹۰۹۶	Pure-GRU	XRP
۰/۰۵۸۸۴۹۰۴۵	۰/۰۳۷۱۳۸۹۰۲	ARIMA-LSTM	
۰/۰۶۸۷۸۳۲۷۷	۰/۰۴۱۸۳۳۵۴۳	ARIMA-RNN	
۰/۰۵۶۳۳۶۷۹۱	۰/۰۳۵۴۵۴۷۸۳	ARIMA-GRU	

کتابنامه

- Abounoori, E., Elmi, Z. M., & Nademi, Y. (2016). Forecasting Tehran stock exchange volatility; Markov switching GARCH approach. *Physica A: Statistical Mechanics and its Applications*, 445, 264-282.
- Adebisi, AA., Adewumi, AO., Ayo, CK. (2014). Comparison of ARIMA and Artificial Neural Networks Models for Stock Price Prediction. *Journal of Applied Mathematics*, 1-7.
- Asiful, M., Rezaul K., Ruppia T., Neil D., and Yang W. Hybrid Deep Learning Model for Stock Price Prediction. *IEEE Symposium Series on Computational Intelligence SSCI*, 1837-1844.
- Benzekri, M., Özütlü, H. On the Predictability of Bitcoin Price Movements: A Short-term Price Prediction with ARIMA. *J. Econ. Policy Res. İktisat Polit. Araştırmaları Derg.*, 8(2), 293-309.
- Buturac, Goran (2022). Measurement of economic forecast accuracy: A systematic overview of the empirical literature, *Journal of Risk and Financial Management*. Vol. 15. pp. 1-28.
- Choi, H K. (2018). Stock price correlation coefficient prediction with ARIMA-LSTM hybrid model. Seoul, Korea: Korea University. Retrieved from <https://arxiv.org/pdf/1808.01560v5.pdf>
- CoinMarketCap. Cryptocurrency Prices, Charts and Market Capitalizations. <https://coinmarketcap.com/> (accessed Apr. 07, 2023).
- Dev Shah, Wesley Campbell, Farhana H Zulkernine. (2018). A Comparative Study of LSTM and DNN for Stock Market Forecasting. *IEEE International Conference on Big Data (Big Data)*, Seattle, WA, USA, 2018, pp. 4148-4155.
- Fattah, J., Ezzine, L., Aman, Z., Moussami, HE., Lachhab, A. (2018). Forecasting of demand using ARIMA model. *International Journal of Engineering Business Management*, 10.

- Fischer, T., Krauss, C. (2018). Deep learning with long short-term memory networks for financial market predictions. *European Journal of Operational Research*, 270(2), 654–669.
- Hasin, MAA., Ghosh, S., Shareef, MA. (2011). An ANN Approach to Demand Forecasting in Retail Trade in Bangladesh. *International Journal of Trade, Economics and Finance*, 154–160.
- Haviluddina, Jawahir, A. (2015). Comparing of ARIMA and RBFNN for short-term forecasting. *Comparing of ARIMA and RBFNN for Short-Term Forecasting*, 1, 1-8.
- Hyndman, R. J., & Athanasopoulos, G. (2018). *Forecasting: Principles and Practice*. (2nd ed.). 384 p. OTexts. <https://otexts.org/fpp2/>
- Jenkins, G.E.P., Box. (1970). *Time series analysis, forecasting and control*. Holden-Day, San Francisco, CA. 575 p.
- Krauss C., Anh, X., & Huck, N. (2017). Deep neural networks, gradient-boosted trees, random forests: Statistical arbitrage on the S&P 500. *European Journal of Operational Research*, 259(2), 689-702.
- Kryzanowski, L., Galler, M., & Wright, D. W. (1993). Using Artificial Neural Networks to Pick Stocks. *Financial Analysts Journal*, 49(4), 21-27.
- Levenbach, H. (2017). *Change & Chance Embraced: Achieving Agility with Smarter Forecasting in the Supply Chain*. Delphus Publishing. 422 p.
- Nademi, A., & Nademi, Y. (2018). Forecasting crude oil prices by a semiparametric Markov switching model: OPEC, WTI, and Brent cases. *Energy economics*, 74, 757-766.
- Olson, D., Mossman, C. (2003). Neural network forecasts of Canadian stock returns using. *International Journal of Forecasting*. 19, 453-465.
- R.A. de Oliveira D.M.Q. Nelson, A.C.M. Pereira. (2017). Stock markets price movement prediction with lstm neural networks. In 2017 International Joint Conference on Neural Networks (IJCNN), 1419–1426.
- Raymond, Y. T. (1997). An application of the ARIMA model to real-estate prices in Hong Kong. *Journal of Property Finance*, 8(2), 152-163.
- Siami-Namini, S., Tavakoli, N., & Namin, A. (2018). A Comparison of ARIMA and LSTM in Forecasting Time Series. *IEEE International Conference on Machine Learning and Applications*, 17, 1394-1401.
- Temür, A., Akgün, M., & Temür, G. (2019). Predicting housing sales in Turkey using ARIMA, LSTM and hybrid models. *Journal of Business Economics and Management*, 20, 920-938.
- Weiss, E. (2000). Forecasting commodity prices using ARIMA. *Technical Analysis of Stocks & Commodities*, 18(1), 18-19.
- Zhang, P. (2003). Time Series Forecasting Using a Hybrid ARIMA and Neural Network Model. *Neurocomputing*, 50, pp. 159-175.