

## Validation of Machine Learning Methods in Predicting Stock Indices of Iranian Energy Industries

Reza Taleblou \*

Associate Professor, Department of Economics, Allameh Tabataba'i University, Tehran, Iran

Parisa Mohajeri 

Associate Professor, Department of Economics, Allameh Tabataba'i University, Tehran, Iran

### Abstract

The stock market is one of the most volatile and complicated markets, making accurate price forecasting a challenging task. However, the emergence of machine learning in recent decades has alleviated some of these limitations by engaging the development of models for accurate stock price prediction through neural networks. This study investigates the application of recurrent neural network (RNN) models—specifically RNN, long short-term memory (LSTM), and gated recurrent unit (GRU)—in predicting the stock indices of the Iranian energy industry. Using daily time series data from May 1, 2020, to May 1, 2021, the dataset was divided into a training period (80%) and a testing period (20%). In the first step, the optimal architectures of each model (estimating hyper-parameters) were determined for prediction horizons of 1, 3, 6 (one week), and 20 trading days (one month). Subsequently, prediction errors of the three machine learning models were compared with the linear econometric model (ARIMA) across various forecast horizons. The findings in two areas of cross validations of machine learning models as well as prediction error reveal the following insights: First, as the forecast horizon increases, the batch size of optimal prediction decreases for all three machine learning models, and the larger the input training sample size leads to the smaller batch size. Second, in short-term forecast horizons (1, 3, and 6 trading days), machine learning models—particularly LSTM—demonstrate lower prediction errors than ARIMA, while in the 20-trading-day (1-month) forecast horizon, ARIMA's predictive accuracy approaches to the nonlinear machine learning models. Third,

\* Corresponding Author: talebloo.r@atu.ac.ir

How to Cite: Taleblou, R., Mohajeri, P. (2021). Validation of Machine Learning Methods in Predicting Stock Indices of Iranian Energy Industries. *Iranian Energy Economics*,

forecast accuracy decreases as the horizon lengthens, with accuracy dropping from approximately ۹۸,۵% (for a ۱-day horizon) to ۹۲,۵% (for a ۲۰-day horizon). Finally, selecting the appropriate forecasting method for the stock market indices of energy industries depends on the forecast horizon and data characteristics.

### **Introduction**

In the past decade, the stock market has gained significant popularity, attracting both individual and institutional investors despite its inherent risks. As a result, predicting stock price indices has become an appealing endeavor for both institutional and private investors. Beyond the inherent complexities of forecasting, there is ongoing debate about the predictability of stock prices and returns. Research efforts across a wide range of disciplines, including physics, economics, computer science, and statistics, have focused on modeling stock price indices and employing various forecasting strategies.

Predicting nonlinear time series, such as stock price indices, often relies on neural network models to overcome some challenges. Among neural network models, Long Short-Term Memory (LSTM) and Gated Recurrent Unit (GRU) are two prominent models, which, according to international research findings, have demonstrated superior performance. RNNs are among the most effective methods for processing sequential or time-series data, as they possess a high capability to identify complex nonlinear relationships, unlike traditional forecasting models.

Despite extensive international research on the application of various machine learning models for predicting economic variables, the Iranian research landscape indicates a scarcity of published scientific articles in this domain. Furthermore, the prediction of stock indices for energy-related industries has not been explored in any prior studies. Given the above context, the primary objective of this study is to predict four energy industry indices using three models—RNN, LSTM, and GRU—and to identify the best-performing model with the lowest prediction error. This will be achieved using daily data from four energy industry stock indices from May ۱, ۲۰۲۰, to May ۱, ۲۰۲۴.

This paper contributes to the literature in several ways. First, in addition to the RNN and LSTM methods, which have been more commonly used in domestic studies, the GRU method is also employed—a technique that, with the exception of one article, has not been widely used in Iranian research. Second, for the first time, stock indices for energy-related industries are being predicted, filling a significant gap in the literature.

### Methods and Materials

Recurrent Neural Networks (RNNs) are among the most effective methods for processing sequential or time-series data due to their superior ability to identify complex nonlinear relationships, unlike traditional forecasting models. The Long Short-Term Memory (LSTM) model, a prominent member of the RNN family, replaces standard artificial neurons in the hidden layers of the network with memory cells. These memory cells enable the network to dynamically consider the architecture of the data and connect memories with input data, thereby improving prediction accuracy. Given its enhanced memory capacity for storing and interpreting historical data, the LSTM model typically yields better results for large datasets. In contrast, the Gated Recurrent Unit (GRU) has fewer parameters than LSTM, making its estimation significantly faster.

In this study, data from four energy-related stock indices in the Iranian stock market from May ۱, ۲۰۲۰, to May ۱, ۲۰۲۴, were used. The energy indices were predicted using three models: RNN, LSTM, and GRU.

### Results and Discussion

Table (۱) presents the forecasting errors (RMSE) of different models for various time horizons, using ۲۰۰ daily data points (approximately one year) and ۱۰ forecasting windows.

**Table (۱). Forecasting errors of different time horizons using three machine learning models (RNN, LSTM, and GRU) and one linear econometric model (ARIMA)**

Time Horizons	Indices	RNN	LSTM	GRU	ARIMA
۱ day	Chemical	۰,۰۱۲	۰,۰۰۷	۰,۰۱۱	۰,۰۰۸
	Coal	۰,۰۲۷	۰,۰۲۴	۰,۰۲۵	۰,۰۲۵
	Energy	۰,۰۱۰	۰,۰۲۰	۰,۰۱۰	۰,۰۱۸
	Oil Products	۰,۰۱۵	۰,۰۲۱	۰,۰۱۷	۰,۰۱۸
۲ days	Chemical	۰,۰۱۱	۰,۰۱۲	۰,۰۱۶	۰,۰۱۳
	Coal	۰,۰۳۲	۰,۰۲۵	۰,۰۳۳	۰,۰۳۰
	Energy	۰,۰۱۵	۰,۰۱۱	۰,۰۱۳	۰,۰۱۵
	Oil Products	۰,۰۲۱	۰,۰۲۰	۰,۰۲۲	۰,۰۲۳
۵ days (۱ week)	Chemical	۰,۰۱۷	۰,۰۲۲	۰,۰۱۹	۰,۰۲۱
	Coal	۰,۰۶۸	۰,۰۵۱	۰,۰۵۷	۰,۰۶۶
	Energy	۰,۰۲۵	۰,۰۲۰	۰,۰۲۱	۰,۰۲۲
	Oil Products	۰,۰۳۲	۰,۰۳۵	۰,۰۳۲	۰,۰۳۶
۲۰ days (۱ month)	Chemical	۰,۰۸۸	۰,۰۶۸	۰,۰۶۴	۰,۰۳۲

	Coal	۰,۱۲۲	۰,۱۱۸	۰,۱۲۱	۰,۱۲۵
	Energy	۰,۰۵۱	۰,۰۵۷	۰,۰۵۶	۰,۰۶۰
	Oil Products	۰,۰۸۴	۰,۰۶۶	۰,۰۶۰	۰,۰۶۱

➤ For a very short-term forecasting horizon (۱ trading day), the LSTM model performs well in predicting the chemical and coal indices. The RNN and GRU models perform better for predicting the oil products and energy indices, respectively. The econometric ARIMA model does not outperform any of the other models in forecasting the indices.

➤ For a two-business-day forecasting horizon, the LSTM model performs well in forecasting the coal, energy, and oil products indices. The RNN model, with a slight margin, outperforms the LSTM model in predicting the chemical index. The GRU and ARIMA models do not outperform any of the other models in predicting the indices.

➤ For a five-business-day (one-week) forecasting horizon, the LSTM model performs better in predicting the coal and energy indices. The RNN model outperforms others in forecasting the chemical index. Both the RNN and GRU models show similar performance in predicting the oil products index. Similar to previous findings, the ARIMA model underperforms compared to the other models. Notably, the RMSE values for the five-day horizon are higher than those for the two-day horizon, indicating a decrease in forecasting accuracy as the forecasting horizon expands.

➤ For a relatively long-term forecasting horizon (۲۰ trading days or ۱ month), the LSTM model performs better in predicting the coal index. The nonlinear RNN and GRU models perform better in predicting the energy and oil products indices, respectively. Similar to previous findings, the RMSE values for the ۲۰-day horizon are higher than those for the ۵-day horizon, further confirming the decline in forecasting accuracy as the prediction horizon expands.

In summary, the LSTM model demonstrates superior performance in most scenarios, particularly for short- to medium-term horizons. The RNN and GRU models also show competitive performance, depending on the specific index and forecasting horizon. In contrast, the ARIMA model consistently underperforms across all horizons, highlighting the limitations of linear econometric models in capturing the complexities of nonlinear time-series data. The increase in RMSE values as the forecasting horizon expands underscores the inherent challenges in maintaining prediction accuracy over longer periods.

### **Conclusion**

This study demonstrates that machine learning and time-series methods can be effectively used to predict data related to the chemical, coal, energy, and oil products indices. However, the choice of the appropriate method depends on the forecasting horizon and the characteristics of the data. Given the high accuracy of machine learning models, particularly the LSTM model, in forecasting, it is recommended that investors in financial markets pay attention to signaling mechanisms and the existence of profitable strategies across parallel markets. By understanding and predicting movements between markets, it becomes possible to manage risk and achieve favorable returns.

Furthermore, the superior performance of the LSTM model across various forecasting horizons highlights its potential as a reliable tool for predicting complex and nonlinear time-series data. Future research could explore the integration of these models with other advanced techniques or the application of hybrid models to further enhance prediction accuracy. Additionally, policymakers and market regulators could benefit from these findings by incorporating predictive analytics into their decision-making processes to improve market stability and investor confidence

**JEL Classification:** C۰۳, C۷۰, G۱۷, G۲۰

**Keywords:** Machine Learning, Artificial Intelligence, Recurrent Neural Network, Long Short-Term Memory, Gated Recurrent Unit, Stock Market Forecasting

## اعتبارسنجی روش‌های یادگیری ماشین در پیش‌بینی شاخص‌های صنایع بورسی انرژی ایران

دانشیار، گروه اقتصاد، دانشکده اقتصاد، دانشگاه علامه طباطبایی تهران، ایران

رضا طالبلو \*<sup>ID</sup>

دانشیار، گروه اقتصاد، دانشکده اقتصاد، دانشگاه علامه طباطبایی تهران، ایران

پریسا مهاجری <sup>ID</sup>

### چکیده

بدون شک بازار سهام، یکی از پرنوسان‌ترین بازارها به شمار می‌رود و همین امر، پیش‌بینی حرکت قیمت سهام را بسیار دشوار می‌کند. با این حال، ظهور یادگیری ماشین در دهه‌های اخیر، بخشی از محدودیت‌ها را مرتفع نموده، زیرا با وجود برخی شبکه‌های عصبی، امکان توسعه مدل‌هایی برای پیش‌بینی مؤثر و دقیق قیمت سهام فراهم شده است. مقاله حاضر به بررسی کاربرد الگوهای خانواده شبکه عصبی بازگشتی (مشمول بر RNN، LSTM و GRU) در پیش‌بینی شاخص صنایع بورسی انرژی با استفاده از داده‌های سری زمانی از ۱ مه ۲۰۲۰ تا ۱ مه ۲۰۲۴ پرداخته است. داده‌های روزانه به دو قسمت دوره آموزش یا یادگیری (۸۰ درصد) و دوره آزمون (۲۰ درصد) تقسیم شدند و در گام اول، معماری بهینه الگوها (برآورد ابرپارامترها) برای پیش‌بینی ۱، ۲، ۵ (یک هفته) و ۲۰ روز کاری (یک‌ماه) با استفاده از داده‌های دوره یادگیری انجام شد و سپس، خطاهای پیش‌بینی سه الگوی غیرخطی یادگیری ماشین با الگوی خطی اقتصادسنجی ARIMA در افق‌های مختلف زمانی مقایسه شدند. یافته‌ها در دو حوزه اعتبارسنجی متقابل مدل‌های یادگیری ماشین و همچنین خطای پیش‌بینی حاکی از آن است که: نخست، با افزایش افق پیش‌بینی، اندازه رسته لازم برای حصول به بهترین پیش‌بینی برای هر سه الگوی یادگیری ماشین کاهش می‌یابد و هر چه اندازه حجم نمونه ورودی یادگیری بزرگتر باشد، اندازه رسته کوچکتر خواهد بود. دوم، در افق‌های پیش‌بینی کوتاه‌مدت ۱، ۲ و ۵ روز کاری، مدل‌های یادگیری ماشین خصوصاً LSTM، خطای پیش‌بینی کمتری در مقایسه با ARIMA دارند، این در حالی است که در افق پیش‌بینی ۲۰ روز کاری (۱ ماه)، دقت پیش‌بینی ARIMA نزدیک به مدل‌های غیرخطی هوش مصنوعی می‌شود. سوم، به موازات با افزایش افق پیش‌بینی، بر مقدار خطا افزوده می‌شود به طوری که دقت پیش‌بینی از حدود ۹۸/۵ درصد (برای افق ۱ روزه) به ۹۲/۵ درصد (برای افق ۲۰ روزه) کاهش می‌یابد. چهارم، انتخاب روش مناسب در پیش‌بینی شاخص صنایع بورسی انرژی، بستگی به افق پیش‌بینی و مشخصات داده‌ها دارد.

طبقه‌بندی JEL: G۲۰، G۱۷، C۷۵، C۵۳

کلیدواژه‌ها: یادگیری ماشین، هوش مصنوعی، شبکه عصبی بازگشتی، حافظه کوتاه‌مدت ماندگار، واحد بازگشتی دروازه‌ای، پیش‌بینی بازار سهام

\* نویسنده مسئول: talebloo.r@atu.ac.ir

## ۱. مقدمه

بازار سهام در دهه اخیر، محبوبیت بالایی پیدا کرده است و سرمایه‌گذاران خصوصی و نهادی به رغم وجود ریسک‌های بالا در این بازار، پول را وارد این بازار نموده‌اند. از این رو پیش‌بینی شاخص قیمت سهام برای سرمایه‌گذاران نهادی و شخصی جذاب است. صرف‌نظر از پیچیدگی‌های ذاتی انجام پیش‌بینی، مجادلات مستمری درباره قابل پیش‌بینی بودن قیمت و بازده سهام وجود دارد. تمرکز پژوهش‌ها در طیف وسیعی از زمینه‌ها نظیر فیزیک، اقتصاد، علوم رایانه و آمار، مدل‌سازی شاخص قیمت سهام و به‌کارگیری استراتژی‌های مختلف پیش‌بینی بوده است. نظریه بازار کارا که توسط فاما در سال ۱۹۷۰ ارائه شد، مدعی است که ارزش فعلی دارایی، تمامی اطلاعات در دسترس پیشین را منعکس می‌سازد. فرض اصلی در این مدل‌ها، خطی بودن ساختار همبستگی مقادیر سری زمانی است و بنابراین، این الگوها را نمی‌توان با مدل‌های غیرخطی بیان کرد.

پیش‌بینی سری‌های زمانی غیرخطی مانند شاخص قیمت سهام، غالباً از مدل‌های شبکه عصبی برای فائق آمدن بر این محدودیت‌ها استفاده می‌کند. در میان مدل‌های شبکه عصبی، الگوی حافظه کوتاه‌مدت ماندگار (LSTM)<sup>۱</sup> و واحد بازگشتی دروازه‌ای (GRU)<sup>۲</sup>، دو ساختار از شبکه عصبی بازگشتی (RNN)<sup>۳</sup> هستند که طبق یافته‌های پژوهش‌های خارجی، بهترین عملکرد را دارند. خانواده RNN ها، یکی از کارآمدترین روش‌ها برای پردازش داده‌های دنباله‌ای یا متوالی هستند زیرا بر خلاف مدل‌های پیش‌بینی سنتی، توانمندی بالایی در شناسایی روابط غیرخطی پیچیده دارند. مدل LSTM، در لایه‌های پنهان شبکه، سلول‌های حافظه را جایگزین عصب‌های مصنوعی استاندارد می‌کند. سلول‌های حافظه، به شبکه‌ها این امکان را می‌دهند که معماری داده‌ها را به صورت پویا در نظر بگیرند و حافظه‌ها را با داده‌های ورودی متصل نمایند و بدین ترتیب، دقت پیش‌بینی را بهبود بخشند. با توجه به حافظه بیشتری که LSTM برای ذخیره و تفسیر داده‌های تاریخی دارد، این مدل معمولاً نتایج بهتری را برای مجموعه داده‌های بزرگ به دست می‌دهد. در مقابل GRU نسبت به LSTM، پارامترهای کمتری دارد و از این رو برآورد آن، بسیار سریع‌تر انجام می‌شود.

---

۱. Long Short Term Memory

۲. Gated Recurrent Unit

۳. Recurrent Neural Network

به رغم پژوهش‌های گسترده خارجی که در به‌کارگیری انواع مدل‌های یادگیری ماشین به منظور پیش‌بینی متغیرهای اقتصادی وجود دارد، فضای پژوهشی ایران حاکی از اندک بودن مقالات علمی انتشار یافته دارد. همچنین پیش‌بینی شاخص صنایع بورسی حوزه انرژی در هیچ یک از پژوهش‌ها تاکنون مورد بررسی قرار نگرفته است. با عنایت به توضیحات فوق، هدف اصلی مقاله حاضر، پیش‌بینی ۴ شاخص صنایع انرژی کشور با استفاده از سه الگوی RNN، LSTM و GRU و معرفی مدل برتر با کمترین خطای پیش‌بینی با استفاده از داده‌های روزانه ۴ شاخص بورسی صنایع انرژی در دوره ۱ مه ۲۰۲۰ تا ۱ مه ۲۰۲۴ است. پژوهش حاضر از چند جنبه دارای نوآوری است. نخست آنکه علاوه بر روش‌های RNN و LSTM که در مطالعات داخلی بیشتر به کار گرفته شده‌اند، روش GRU نیز استفاده می‌شود که به استثنای یک مقاله، مورد توجه مقالات داخلی نبوده است. دوم، برای نخستین بار، شاخص صنایع بورسی حوزه انرژی پیش‌بینی می‌شوند. سوم، یک‌پنجم از مشاهدات انتهای دوره (حدود ۲۰۰ مشاهده) به منظور آزمون دقت پیش‌بینی، کنار گذاشته شده و سپس خطای پیش‌بینی در افق‌های کوتاه‌مدت ۱، ۲ و ۵ روز کاری و افق میان‌مدت ۲۰ روز کاری (یک‌ماه) محاسبه می‌شوند.

در راستای واکاوی دقیق ابعاد موضوع، مقاله حاضر در شش بخش سازماندهی می‌شوند. پس از مقدمه که بخش نخست از مقاله را تشکیل می‌دهد، مبانی نظری و پیشینه تجربی به ترتیب در بخش‌های دوم و سوم ارائه می‌شوند. روش تحقیق و پایه‌های آماری، محور بخش چهارم را تشکیل می‌دهند. در بخش پنجم، ساختار بهینه (ابریارمترها) برای سه الگوی RNN، LSTM و GRU با استفاده از چهار-پنجم از مشاهدات (بیش از ۷۰۰ مشاهده) برآورد شده و سپس خطای پیش‌بینی در افق‌های مختلف زمانی برای هر یک از این الگوها ارائه می‌گردد. در نهایت، بخش ششم از مقاله حاضر به جمع‌بندی از مهم‌ترین یافته‌ها و ارائه پیشنهادها اختصاص می‌یابد.

## ۲. مبانی نظری

به‌کارگیری مجموعه‌ای از تکنیک‌های نوین و روش‌های محاسباتی جدید در یادگیری ماشین به منظور برآورد و پیش‌بینی پاسخ‌های دریافتی از سیستم‌های پیچیده، شاکله اصلی شبکه‌های عصبی مصنوعی را تشکیل می‌دهد. این شبکه‌ها، ساختارهای متشکلی از



واحدهای ساده پردازشی هستند که ضمن به هم پیوستگی و متراکم بودن، توانایی بسیار بالایی در انجام محاسبات موازی به منظور پردازش داده‌ها دارند. ایده اصلی شبکه‌های عصبی مصنوعی، ریشه در شیوه کارکرد سیستم عصبی زیستی دارد که با پردازش داده‌ها و اطلاعات، در تلاش برای یادگیری است (گودفلو و همکاران، ۲۰۱۶).<sup>۱</sup>

مزایای متعدد شبکه‌های عصبی مصنوعی نسبت به سایر روش‌ها سبب شده است تا پژوهشگران در زمینه‌های تحقیقاتی متنوعی از آن‌ها استفاده نمایند که برای نمونه می‌توان به «غیرخطی بودن توابع مورد استفاده»، «امکان انجام محاسبات موازی»، «توانایی استفاده از اطلاعات و داده‌ها برای یادگیری»، «قابلیت استفاده از اطلاعات کیفی» و نظایر آن اشاره کرد. به بیان دیگر، استفاده از توابع غیرخطی در شبکه‌های عصبی منجر به بهبود ارزیابی داده‌ها و اطلاعات ورودی شده و زمان مورد نیاز برای این ارزیابی به دلیل انجام محاسبات موازی به شدت کاهش می‌یابد (لیمسومبونچای و همکاران، ۲۰۰۴).<sup>۲</sup>

شبکه‌های عصبی دارای لایه‌های پنهان هستند و هرچه بر تعداد این لایه‌ها افزوده می‌شود، از آن شبکه به عنوان «شبکه عصبی عمیق» یاد می‌شود. گروهی از شبکه‌های عصبی که دارای لایه بازخورد هستند، شبکه‌های عصبی بازگشتی نامیده می‌شوند که در آن‌ها، خروجی شبکه به همراه ورودی بعدی، به شبکه بازگردانده می‌شوند. این شبکه‌ها به دلیل برخوردار بودن از حافظه داخلی، توانایی به خاطر سپردن ورودی پیشین خود را دارند و از این‌رو قادر به پردازش داده‌های دنباله‌ای و متوالی هستند. از این رو، خانواده شبکه‌های عصبی بازگشتی، یکی از بهترین روش‌ها برای پیش‌بینی سری‌های زمانی به حساب می‌آیند (یو و همکاران، ۲۰۱۸).<sup>۳</sup> در ادامه شبکه عصبی بازگشتی (RNN) تبیین خواهد شد و سپس، روش‌های LSTM و GRU مورد بررسی قرار خواهند گرفت.

## ۲-۱. شبکه عصبی بازگشتی (RNN)

شبکه‌های عصبی بازگشتی (RNN) برای چند دهه یکی از پایه‌های تحقیقات یادگیری عمیق بوده‌اند. مفهوم RNN برای اولین بار در دهه ۱۹۸۰ توسط دیوید روملارت<sup>۴</sup>، جفری هینتون<sup>۵</sup> و رونالد ویلیامز<sup>۶</sup> معرفی شد، که استفاده از اتصالات بازگشتی را برای مدل‌سازی

۱. Goodfellow et al. (۲۰۱۶)

۲. Limsombunchai et al. (۲۰۰۴)

۳. Yu et al. (۲۰۱۸)

۴. David Rumelhart


۵. Geoffrey Hinton

۶. Ronald Williams

روابط زمانی در داده‌ها پیشنهاد کردند. مدل‌های RNN اولیه با مشکل ناپدید شدن گرادیان مواجه بودند که توانایی آنها برای یادگیری وابستگی‌های بلندمدت را محدود می‌کرد. هر چند در دهه ۱۹۹۰، الگوهای حافظه کوتاه‌مدت ماندگار (LSTM) معرفی شد که مشکل ناپدید شدن گرادیان را با استفاده از سلول‌های حافظه و دروازه‌ها حل کرد.

پیشرفت‌های محاسباتی و در دسترس بودن مجموعه داده‌های بزرگ منجر به تکامل الگوهای RNN و پیشرفت‌های بسیاری در آنها منجر شد. در دهه ۲۰۰۰، استفاده از واحد پردازش گرافیکی (GPU) و چارچوب‌های محاسبات توزیع‌شده امکان آموزش مدل‌های RNN بزرگ‌تر و پیچیده‌تر را فراهم کرده است. مدل‌های RNN برای داده‌های سری زمانی چندمتغیره مناسب بوده و قادر به لحاظ وابستگی‌های موقت در دوره‌های متفاوت هستند (چی و همکاران، ۲۰۱۸، گریوز، ۲۰۱۲). در RNN، مقادیر ورودی به شبکه وارد می‌شود و سپس مقادیر خروجی بر مبنای ورودی‌ها و پارامترهای شبکه بازگردانده می‌شود. در شکل (۱)، ساختار یک معمولی به تصویر کشیده شده است.

نمودار (۱). تصویری از ساختار RNN



به طور کلی، هنگامی که حلقه‌هایی در شبکه وجود دارد، RNN گفته می‌شود. الگوریتم انتشار بازگشتی<sup>۳</sup> را می‌توان برای آموزش یک شبکه تکراری با باز کردن شبکه در طول

<sup>۱</sup> Che et al. (2018)

<sup>۲</sup> Graves (2012)

<sup>۳</sup>. Backpropagation algorithm

زمان و محدود کردن برخی اتصالات برای حفظ وزن‌های یکسان در همه زمان‌ها تطبیق داد (خو و همکاران، ۲۰۱۸)<sup>۱</sup>. بدین ترتیب، RNN می‌تواند اطلاعات قبلی را در فرآیند یادگیری لایه پنهان فعلی، رمزگذاری کند تا امکان یادگیری داده‌های سری زمانی به طور مؤثر فراهم گردد (بنجیو و همکاران، ۱۹۹۴)<sup>۲</sup>. مسئله «ناپدید شدن یا محو شدن گرادیان»<sup>۳</sup>، یکی از چالش‌های اساسی RNN ها است و زمانی رخ می‌دهد که گرادیان تابع فعال‌سازی<sup>۴</sup> بسیار کوچک شود. هنگام انتشار بازگشتی از طریق شبکه، گرادیان کوچک و کوچک‌تر می‌شود و بدین ترتیب مدل‌سازی وابستگی‌های بلندمدت یا طولانی شبکه را دشوار می‌سازد. نقطه مقابل مسئله «محو شدن گرادیان»، مشکل «گرادیان انفجاری»<sup>۵</sup> است که در آن، گرادیان بزرگ می‌شود.

## ۲-۲. الگوهای حافظه کوتاه‌مدت طولانی (LSTM)<sup>۶</sup>

از بعد نظری، RNN ها باید توانایی یادگیری دنباله‌هایی با هر سطح از پیچیدگی را داشته باشند، اما مشاهدات تجربی حاکی از عملکرد ضعیف این شبکه‌ها در ذخیره‌سازی اطلاعات مرتبط با ورودی‌های گذشته به مدت طولانی است. ناتوانی این شبکه‌ها در ذخیره‌سازی اطلاعات مربوط به ورودی‌های گذشته و فراموشی آن‌ها موجب می‌شود تا RNN ها به هنگام تولید دنباله‌ها با مسئله ناپایداری روبرو گردند (هانسون و رستمی، ۲۰۱۹)<sup>۷</sup>. مقابله با مسئله ناپایداری مستلزم برخورداری از حافظه بلندمدت‌تر است، زیرا شبکه‌ای که از حافظه بلندمدت‌تر برخوردار باشد حتی با وجود وقفه‌های طولانی بین رویدادهای مهم، توانایی یادگیری از ورودی‌ها را دارد. همین امر سبب معرفی الگوی حافظه کوتاه‌مدت طولانی (LSTM) به عنوان یکی از زیرمجموعه‌های RNN گردید، با این تفاوت که در LSTM، توانایی ذخیره‌سازی و دسترسی بهتر به داده‌ها و اطلاعات گذشته در مقایسه با نسخه سنتی آن فراهم شده است. بدین ترتیب LSTM قادر است در صورت تشخیص ویژگی مهم در داده‌های ورودی دنباله در گام‌های اولیه، آن را طی یک مسیر طولانی انتقال دهد و ضمن

۱. Xu et al (۱۹۹۴)

۲. Bengio et al (۲۰۱۸)

۳. Vanishing Gradient Descent

۴. Activation Function

۵. Exploding Gradient Problem


۶. Long Short-Term Memory

۷. Hansson & Rostami (۲۰۱۹)

لحاظ نمودن وابستگی‌های بلندمدت، آن را در طول مسیر حفظ نماید (چن و همکاران، ۲۰۱۷).<sup>۱</sup>

هوکرایتر و اشمیدوبر<sup>۲</sup> اولین بار در سال ۱۹۹۷، الگوی LSTM را معرفی کردند. این الگو به عنوان یکی از جایگزین اصلی RNN برای رفع سایر مشکلاتی مانند ناپدید شدن گرادیان و تسهیل محاسبات طراحی شد. در بسیاری از پژوهش‌های انتشار یافته اخیر، LSTM‌ها عملکرد بسیار خوبی را از خود به نمایش گذاشته‌اند و آموزش آن‌ها نیز نسبتاً آسان‌تر بوده است. بنابراین LSTM‌ها به عنوان معماری‌های مبنا یا پایه‌ای برای پردازش داده‌های متوالی با اطلاعات زمانی تبدیل شده‌اند. به مرور زمان، اشکال بسط یافته‌ای از LSTM‌ها در خصوص اجزای انفرادی آن‌ها معرفی شده است که می‌تواند معماری بهینه‌تری را ارائه دهد (جوزفویچ و همکاران، ۲۰۱۵).<sup>۳</sup> واحدهای LSTM از سلول و سه دروازه تشکیل شده است که عبارتند از؛ دروازه‌های فراموشی، ورودی و خروجی. نمودار (۲)، معماری واحدهای LSTM را نشان می‌دهد. سلول، حافظه LSTM است که در طول بازه‌های زمانی دلخواه برای به خاطر سپردن مقادیر استفاده می‌شود.

نمودار (۲). تصویری از ساختار LSTM



۱. Chen et al (۲۰۱۷)

۲. Hochreiter & Schmidhuber (۱۹۹۷)

۳. Jozefowicz et al. (2015)

پژوهشگران، LSTM های مختلفی را پیشنهاد نموده‌اند که در شرایط خاص، بسیار کارآمد هستند. برای اینکه مدل بتواند ساختار دقیق‌تری را به تصویر بکشد، پژوهشگران، دروازه‌های جدیدی را به LSTM اصلی افزوده‌اند. در حالی که طیف دیگری از پژوهشگران، برعکس عمل نموده و دروازه‌های مختلف را با یکدیگر ادغام نموده‌اند تا مدلی تحت عنوان «واحد بازگشتی دروازه‌ای» (GRU)<sup>۱</sup> را ایجاد نمایند. الگوهای GRU، پارامترهای کمتری نسبت به LSTM ها دارد اما در عمل، نتایج نسبتاً مشابهی را به دست می‌دهد. بر خلاف شبکه‌های عصبی بازگشتی مرسوم، الگوهای حافظه کوتاه‌مدت ماندگار (LSTM) و واحد بازگشتی دروازه‌ای (GRU) برای طبقه‌بندی، پردازش سری‌های زمانی پیش‌بینی با گام‌های زمانی دلخواه مناسب‌تر هستند (چائو و همکاران، ۲۰۱۴)<sup>۲</sup>.

### ۲-۳. الگوهای واحد بازگشتی دروازه‌ای (GRU)

واحد بازگشتی دروازه‌دار (GRU)، مشابهت زیادی با LSTM دارد و توسط چو و همکاران (۲۰۱۴) معرفی شده است. تفاوت اصلی GRU با LSTM در نحوه اعمال دروازه‌ها است. به جای ۳ دروازه، صرفاً ۲ دروازه در GRU وجود دارد که دروازه بازتنظیم و به‌روزرسانی<sup>۳</sup> نامیده می‌شوند. دروازه بازتنظیم، نحوه ترکیب ورودی جدید و حافظه قبلی را تعیین می‌کند و میزان نادیده گرفتن حافظه قبلی را کنترل می‌نماید. مقادیر کوچکتر برای دروازه بازتنظیم به معنای آن است که حافظه قبلی، بیشتر نادیده گرفته می‌شود. دروازه به‌روزرسانی نیز مشخص می‌کند که چه مقدار از حافظه قبلی حفظ شود. هر چه مقدار دروازه به‌روزرسانی بزرگتر باشد، اطلاعات قبلی بیشتری آورده می‌شود. تفاوت‌های اندکی بین GRU و LSTM وجود دارد. نخست، LSTM می‌تواند در معرض نمایش قرار دادن حافظه را کنترل سازد، حال آنکه در GRU، حافظه غیرقابل کنترل است. دوم آنکه، GRU همانند LSTM دارای دروازه خروجی نیست. در واقع، دروازه‌های ورودی و فراموشی در LSTM با دروازه به‌روزرسانی در GRU جایگزین می‌شوند، دروازه بازتنظیم به طور مستقیم در وضعیت پنهان قبلی اعمال می‌شود. از آنجایی که GRU پارامترهای کمتری نسبت به LSTM دارد، برآورد GRU سریع‌تر از LSTM خواهد بود

۱. Gated Recurrent Unit

۲. Cho, K., et al. (2014)

۳. Reset and Update Gate

و به داده‌های کمتری نیاز دارد. با این حال، اگر مقیاس داده‌ها بزرگ باشد، LSTM می‌تواند به نتیجه بهتری منجر شود (سانگ، ۲۰۱۸)<sup>۱</sup>.

### ۳. پیشینه تجربی

پیش‌بینی قیمت سهام، یک حوزه تحقیقاتی رو به رشد است که در آن از تکنیک‌های سنتی شامل مدل‌های آماری و اقتصادسنجی استفاده می‌شود. روش‌های سنتی عموماً شامل میانگین متحرک (MA)<sup>۲</sup>، رگرسیون خطی، میانگین متحرک خودرگرسیون انباشته (ARIMA)<sup>۳</sup>، GARCH و ماشین‌های بردار پشتیبان (SVM)<sup>۴</sup> هستند (یان و اویانگ، ۲۰۱۸)<sup>۵</sup>؛ حمزه و همکاران، ۲۰۲۳<sup>۶</sup>). میانگین متحرک، تکنیکی است که میانگین قیمت سهام را در یک دوره مشخص محاسبه می‌کند، روندها را شناسایی نموده و بر اساس میانگین‌های تاریخی، حرکات آتی قیمت را پیش‌بینی می‌نماید (ادواردز و مگی، ۲۰۰۱)<sup>۷</sup>. رگرسیون خطی، مدل آماری است که رابطه خطی بین متغیر وابسته (قیمت سهام) و یک یا چند متغیر مستقل (مانند زمان، حجم یا علل بازاری) را بررسی نموده و ضرایب مستقل را برای پیش‌بینی قیمت سهام در آینده برآورد می‌کند (انگل و سارگان، ۲۰۰۳)<sup>۸</sup>. یکی از مدل‌های محبوب سری زمانی مورد استفاده برای پیش‌بینی قیمت سهام، ARIMA است که الگوها، روندها و فصلی بودن داده‌های سری زمانی را برای انجام پیش‌بینی در نظر می‌گیرد (باکس و همکاران، ۲۰۱۵)<sup>۹</sup>. مدل‌های GARCH، معمولاً برای پیش‌بینی نوسانات بازار سهام استفاده می‌شوند و خوشه‌بندی واریانس و تلاطمات در سری‌های زمانی مالی را که به طور غیرمستقیم، اطلاعاتی درباره حرکات قیمت سهام در بر دارد، لحاظ می‌کند (بلرسلو، ۱۹۸۶)<sup>۱۰</sup>. ماشین‌های بردار پشتیبان (SVM)، الگوریتم یادگیری ماشینی نظارت شده هستند که می‌توانند برای پیش‌بینی قیمت سهام به کار گرفته شوند. در این الگوریتم‌ها،

۱. Song (2018)

۲. Moving Averages

۳. Autoregressive Integrated Moving Average

۴. Support Vector Machines

۵. Yan & Ouyang (2018)

۶. Hamzah et al (2023)

۷. Edwards & Magee (2001)

۸. Engle & Sargan (2003)

۹. Box et al. (2015)

۱۰. Bollerslev (1986)

یک ابرصفحه ساخته می‌شود که طبقات متفاوت از داده‌ها را تفکیک می‌کند و بر اساس آن، افزایش یا کاهش قیمت سهام را پیش‌بینی می‌نماید (ناکانیشی و همکاران، ۲۰۰۶)<sup>۱</sup>. برخی از روش‌های سنتی برای مدت طولانی در مباحث مالی بررسی شده و پایه‌ای برای پیش‌بینی قیمت سهام فراهم نموده‌اند. با این حال، آن‌ها توانایی لحاظ نمودن الگوهای پیچیده و تغییرات ناگهانی در بازارها را به اندازه مدل‌های یادگیری عمیق ندارند. پژوهش‌های خارجی به ویژه در یک دهه اخیر، برای پیش‌بینی قیمت سهام از یادگیری عمیق استفاده می‌کنند. از آنجایی که RNN ها از مزیت پردازش داده‌های سری‌های زمانی برخوردارند، ابزار مناسبی برای پیش‌بینی سهام هستند. یافته‌های مطالعات حاکی از آن است که دقت پیش‌بینی این مدل‌ها، بالغ بر ۹۵ درصد است (یانکیانگ، ۲۰۲۰)<sup>۲</sup>. پژوهش‌های اخیر نیز مدل LSTM را برای بررسی قیمت‌های آتی سهام پیشنهاد می‌کنند که به کارگیری آن برای اخذ تصمیمات سرمایه‌گذاری، پیش‌بینی‌های دقیق‌تری از قیمت‌های بازار سهام ارائه می‌کند (کی جی و همکاران، ۲۰۲۱)<sup>۳</sup>.

لوکا و الکساندر (۲۰۱۶)<sup>۴</sup>، عملکرد RNN، LSTM و GRU را در پیش‌بینی سهام گوگل مقایسه نموده و دریافته‌اند که شبکه‌های عصبی LSTM در مقایسه با سایر روش‌ها، پیش‌بینی دقیق‌تری را ارائه می‌دهد. یانگ و وانگ (۲۰۱۹)<sup>۵</sup> تحقیقات خود را به ۳۰ شاخص جهانی سهام گسترش داده و از مدل LSTM برای مقایسه عملکرد پیش‌بینی کوتاه‌مدت، میان مدت و بلندمدت استفاده نمودند. نتایج پژوهش آنان حاکی از آن بود که LSTM، دقت پیش‌بینی بالاتری در مقایسه با روش‌های اقتصادسنجی و برخی روش‌های سنتی یادگیری ماشین در هر سه دوره دارد. وانگ و همکاران (۲۰۱۹)<sup>۶</sup>، مدل‌های LSTM و GRU را برای پیش‌بینی قیمت سهام در سه شاخص سهام مقایسه می‌کنند و توانایی پیش‌بینی هر یک از این مدل‌ها را با شفاف نمودن نقاط قوت و ضعف مربوط به هر نوع شبکه تبیین می‌نمایند. خودکه و دشپنده (۲۰۲۳)<sup>۷</sup> نشان می‌دهند که مدل‌های LSTM و GRU می‌توانند قیمت سهام را با دقت قابل ملاحظه ۹۲/۳۶ درصدی پیش‌بینی کنند که عملکرد

۱. Nakanishi et al. (۲۰۰۶)

۲. Yongqiong (۲۰۲۰)

۳. K. J. et al. (۲۰۲۱)

۴. Luca & Oleksandr (۲۰۱۶)

۵. Yang & Wang (۲۰۱۹)

۶. Wang et al. (۲۰۱۹)

۷. Khodke & Deshpande (۲۰۲۳)

بهتری نسبت به روش‌های سنتی مورد استفاده در این زمینه دارند. اخاس رحمدیان (۲۰۲۴)<sup>۱</sup> نیز به طور همزمان از مدل LSTM و GRU برای پیش‌بینی قیمت سهام استفاده نموده و یافته‌های این پژوهش نیز حکایت از عملکرد بهتر مدل GRU دارد.

به رغم استفاده گسترده از روش‌های هوش مصنوعی در پیش‌بینی سری‌های زمانی اقتصادی در پژوهش‌های خارجی، فضای پژوهشی داخلی تصویر متفاوتی ارائه می‌دهد. به رغم آنکه روش‌های یادگیری عمیق و هوش مصنوعی در حوزه‌های زبان‌شناسی و جامعه‌شناسی، کاربرد گسترده‌ای دارد و بیش از صدها مقاله علمی به ویژه در سال‌های اخیر در حوزه‌های مذکور انتشار یافته است، اما پژوهش‌های انگشت‌شماری پیرامون پیش‌بینی‌های سری‌های زمانی اقتصادی با استفاده از این روش‌ها انجام شده است. در ادامه مشاهدات کلیدی در ارتباط با پژوهش‌های اقتصادی ارائه می‌شود.

❖ نخست، با جستجو در پایگاه‌های اطلاعات علمی کشور، ۱۶ مقاله علمی-پژوهشی اقتصادی تاکنون منتشر شده و در دسترس می‌باشد. تاریخ انتشار حدود ۷۰ درصد این مقالات (۱۱ مقاله) به بعد از سال ۱۴۰۰ بازمی‌گردد، در حالی که صرفاً ۳۰ درصد مقالات (۵ مقاله) در دهه ۱۳۹۰ انتشار یافته‌اند. بدین ترتیب نه تنها به لحاظ اندک بودن کمیّت مقالات انتشار یافته، بلکه از منظر وقفه زمانی در به‌کارگیری روش‌های هوش مصنوعی (که سابقه دست‌کم ۳ دهه‌ای دارند)، وضعیت چندان مطلوبی در فضای پژوهشی داخلی مشاهده نمی‌شود.

❖ دوم، حدود ۸۰ درصد مقالات (۱۳ مقاله) بر پیش‌بینی سری‌های زمانی اقتصادی تمرکز داشته و ۲۰ درصد مقالات (۳ مقاله) نیز بهینه‌سازی سبب سهام با استفاده از روش‌های هوش مصنوعی را مبنای مطالعه خود قرار داده‌اند. از ۱۳ مقاله فارسی مرتبط با پیش‌بینی، ۱ مقاله بر پیش‌بینی تورم، ۱ مقاله بر پیش‌بینی قیمت مسکن، ۲ مقاله بر پیش‌بینی قیمت بیت‌کوین، ۲ مقاله بر پیش‌بینی شاخص بورس اوراق بهادار و ۷ مقاله بر پیش‌بینی قیمت سهام یک شرکت یا مجموعه‌ای از شرکت‌ها تمرکز دارند. بدین ترتیب تاکنون، پیش‌بینی شاخص صنایع بورسی با استفاده از روش‌های هوش مصنوعی در مقالات داخلی مدنظر قرار نگرفته است.

❖ سوم، روش‌های RNN و LSTM بیشترین فراوانی را در مطالعات داخلی به خود اختصاص داده است و در این مجموعه مقالات مورد بررسی، به استثنای یک مقاله، روش GRU در پیش‌بینی سری‌های زمانی به کار گرفته نشده است.

<sup>۱</sup> Akhas Rahmadyan (۲۰۲۴)



❖ چهارم، برای سنجش توان پیش‌بینی هر یک از روش‌های هوش مصنوعی، لازم است داده‌ها به دو قسمت «آموزش یا یادگیری» و «آزمایش یا آزمون» تقسیم شوند. بدین صورت که با استفاده از بخش نخست از داده‌ها و از طریق یادگیری یا آموزش، معماری بهینه‌ای از هر یک از روش‌های هوش مصنوعی ارائه می‌شود. در گام بعدی برای اعتبارسنجی یا ارزیابی توان پیش‌بینی، آن معماری برای پیش‌بینی متغیر مورد بررسی در دوره آزمون به کارگرفته شده و در ادامه، با روش‌های مختلف سنجش خطا، میزان انحراف یا خطای پیش‌بینی از داده‌های واقعی محاسبه می‌شود. متأسفانه یکی از کاستی‌های اکثر مقالات داخلی (۱۲ مورد از ۱۶ مورد) آن است که خطای پیش‌بینی برای دوره آزمون برآورد نشده است. به عبارت دیگر، ۷۵ درصد از مقالات منتشره، داده‌ها را به دو دوره یادگیری و آزمایش، تفکیک نکرده‌اند و خطای پیش‌بینی را برای کل داده‌ها (یعنی دوره یادگیری و نه دوره آزمون) محاسبه نموده‌اند.

با عنایت به فضای پژوهشی داخلی، مقاله حاضر از ۳ جنبه دارای نوآوری است. نخست، ساختار بهینه (یعنی ابرپارامترها) برای سه روش RNN، LSTM و GRU به منظور پیش‌بینی شاخص صنایع منتخب بورسی برآورد می‌شود. لازم به یادآوری است که روش GRU، به استثنای یک مقاله، مورد توجه پژوهش‌های داخلی نبوده است. دوم، شاخص صنایع بورسی حوزه انرژی (مشمول بر فرآورده‌های نفتی، پتروشیمی-شیمیایی، زغال سنگ و انرژی) با استفاده از روش‌های فوق‌الذکر پیش‌بینی می‌شوند. سوم، ۲۰۰ مشاهده از داده‌های انتهای دوره (حدود ۲۰ درصد داده‌ها) برای آزمون کنار گذاشته می‌شوند و سپس خطای پیش‌بینی برای نخستین بار در افق‌های ۱ روز، ۲ روز، ۵ روز (یک هفته) و ۲۰ روز کاری (یک ماه) در هر سه روش برآورد می‌گردند.

#### ۴. روش تحقیق و پایه‌های آماری

##### ۴-۱. روش تحقیق

##### ۴-۱-۱. شبکه‌های عصبی بازگشتی ساده (RNN)

شبکه‌های عصبی بازگشتی (RNN) ساده، خروجی  $y_t$  را به صورت زیر محاسبه می‌کنند:

$$y_t = f(W_y h_t) \quad (1)$$

$$h_t = \sigma(W_h h_{t-1} + W_x x_t) \quad (2)$$

که  $W_x$  و  $W_h$ ،  $W_y$  به ترتیب ماتریس‌هایی برای خروجی لایه پنهان  $h_t$ ، فعالیت لایه پنهان دوره گذشته  $h_{t-1}$  و ورودی  $x_t$  هستند. بازگشت زمانی در معادله (۲) نشان داده شده است که فعالیت لایه پنهان جاری  $h_t$  را به فعالیت لایه پنهان گذشته  $h_{t-1}$  مرتبط می‌کند. این وابستگی، غیرخطی است زیرا از تابع لگاریتمی  $\sigma(\cdot)$  استفاده شده است (یائو و همکاران، ۲۰۱۵).<sup>۱</sup>

#### ۴-۱-۲. حافظه کوتاه‌مدت طولانی یا ماندگار (LSTM)

آموزش RNN ساده ارائه شده در معادلات فوق به دلیل مشکلات کاهش گرادیان و انفجار دشوار است. این مسئله به دلیل رابطه غیرخطی  $h_t$  و  $h_{t-1}$  به وجود می‌آید. برای حل مشکل، LSTM در ابتدا توسط هوکرایتر و اشمیدوبر (۱۹۹۷)<sup>۲</sup> پیشنهاد شد و بعداً در پژوهش گریوز (۲۰۱۳)<sup>۳</sup> اصلاح گردید. در LSTM، یک وابستگی خطی بین سلول‌های حافظه  $c_t$  و  $c_{t-1}$  گذشته خودش معرفی می‌شود. همچنین LSTM دارای دروازه‌های ورودی و خروجی است. این دو گیت یا دروازه روی یک تابع غیرخطی در ورودی و یک تابع غیرخطی در خروجی LSTM اعمال می‌شوند. روابط مرتبط با LSTM به صورت زیر نوشته می‌شود:

$$i_t = \sigma(W_{xi}x_t + W_{hi}h_{t-1} + W_{ci}c_{t-1}) \quad (۳)$$

$$f_t = \sigma(W_{xf}x_t + W_{hf}h_{t-1} + W_{cf}c_{t-1}) \quad (۴)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \tanh(W_{xc}x_t + W_{hc}h_{t-1}) \quad (۵)$$

$$o_t = \sigma(W_{xo}x_t + W_{ho}h_{t-1} + W_{co}c_t) \quad (۶)$$

$$h_t = o_t \odot \tanh(c_t) \quad (۷)$$

که  $i_t$ ،  $f_t$  و  $o_t$  به ترتیب دروازه‌های ورودی، فراموشی و خروجی هستند (یائو و همکاران، ۲۰۱۵).

#### ۴-۱-۳. واحد بازگشتی دروازه‌ای (GRU)

واحد بازگشتی دروازه‌ای (GRU) توسط چو و همکاران (۲۰۱۴)<sup>۴</sup> معرفی گردید. این روش در به کارگیری توابع دروازه‌ای شبیه LSTM است اما تفاوت آن با LSTM در این است که سلول حافظه ندارد. عملیات آن را می‌توان به صورت زیر خلاصه کرد:

۱. Yao et al. (۲۰۱۵)

۲. Hochreiter & Schmidhuber (۱۹۹۷)

۳. Graves (۲۰۱۳)

۴. Cho et al. (۲۰۱۴)

$$h_t = (1 - z_t)h_{t-1} + z_t\tilde{h}_t \quad (۸)$$

$$z_t = \sigma(W_z x_t + U_z h_{t-1}) \quad (۹)$$

$$\tilde{h}_t = \tanh(W_h x_t + U(r_t \odot h_{t-1})) \quad (۱۰)$$

$$r_t = \sigma(W_r x_t + U_r h_{t-1}) \quad (۱۱)$$

که خروجی GRU،  $h_t$  است. همچنین  $z_t$  و  $r_t$  دروازه‌های به‌روزرسانی و بازنشانی هستند،  $\tilde{h}_t$  نیز نماینده خروجی است. همچنین  $W_z, W_h, W_r, U_z, U_r$  نیز ماتریس‌ها در GRU هستند (یائو و همکاران، ۲۰۱۵).

#### ۴-۲. اعتبارسنجی متقابل

اعتبارسنجی متقابل سری زمانی، روشی برای ارزیابی نحوه عملکرد مدل روی داده‌های تاریخی است. اجرا کردن اعتبارسنجی متقابل برای ارزیابی مدل‌ها بر روی داده‌های تاریخی شامل تعیین ابرپارامترهای<sup>۱</sup> متعددی است. این روش با تعریف یک پنجره غلتان (لغزنده) روی مشاهدات گذشته و پیش‌بینی دوره بعد از آن انجام می‌شود که با اعتبارسنجی متقابل استاندارد تفاوت دارد، زیرا به جای آنکه آن را به صورت تصادفی تقسیم کند، ترتیب زمانی داده‌ها را حفظ می‌کند. روش مذکور اجازه می‌دهد تا برآورد بهتری از قابلیت‌های پیش‌بینی مدل با در نظر گرفتن چند دوره صورت گیرد. هنگامی که فقط یک پنجره استفاده می‌شود، شبیه به تقسیم استاندارد آموزش-آزمایش است، جایی که داده‌های آزمایش، آخرین مجموعه مشاهدات است و مجموعه آموزش شامل داده‌های قبلی است.

ابتدا باید بازه پیش‌بینی با توجه به فراوانی داده‌ها تعیین شود. با توجه به آنکه در پژوهش حاضر از تواتر روزانه برای داده‌ها استفاده شده است، برای پیش‌بینی یک هفته می‌توان از  $h=5$  روز و یا برای یک ماه از  $h=20$  استفاده کرد. در مرحله بعد باید طول پنجره برای پیش‌بینی را با هر مضربی از بازه پیش‌بینی تعیین نمود. برای مثال برای پیش‌بینی یک هفته کاری آینده ( $h=5$ ) می‌توان پنجره را  $20 * h = \text{windows}$  در نظر گرفت. در این مقاله از بازه‌های ۲۰۰ روز کاری (حدود یک سال) تا ۹۰۰ روز کاری یعنی حدود ۴ سال در پیش‌بینی‌های مختلف استفاده شده است. پارامتر دیگر طول گام برای به جلو آوردن پنجره داده می‌باشد که در پژوهش حاضر، طول یا اندازه گام ۵ روز کاری (یک هفته) و ۲۰ روز

۱. Hyperparameter

کاری (حدود یک‌ماه) در برآوردهای مختلف در نظر گرفته شده است. پارامتر دیگر تعیین تعداد پنجره‌های پیش‌بینی است که برابر با ۵ تا ۲۰ پنجره تعیین شده است.

#### ۳-۴. اعتبارسنجی مدل‌ها

برای ارزیابی نتایج پیش‌بینی مدل‌ها، در پژوهش حاضر از معیار ریشه میانگین مربعات خطا (RMSE)<sup>۱</sup> استفاده می‌شود. معیار مذکور برای ارزیابی میزان انحراف بین نتایج پیش‌بینی شده و داده‌های واقعی به کار گرفته می‌شود و هر چه مقدار آن کمتر باشد، نشان‌دهنده دقت بالاتر برای مدل پیش‌بینی است. بیان ریاضی معیار RMSE به صورت رابطه (۱۲) است.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - y'_i)^2} \quad (12)$$

#### ۴-۴. پایه آماری و آمارهای توصیفی

در این مقاله از داده‌های چهار شاخص بورسی مرتبط با انرژی در بورس ایران در دوره ۱ مه ۲۰۲۰ تا ۱ مه ۲۰۲۴ استفاده شده است. در جدول (۱)، آمارهای توصیفی مربوط به این چهار شاخص ارائه شده‌اند و در نمودار (۱)، روند تحولات داده‌های لگاریتمی ترسیم شده‌اند.

جدول (۱). آمارهای توصیفی بازده متغیرها

تعداد مشاهدات	بازه زمانی	بازه	حداکثر	حداقل	میانگین	انحراف معیار	تاریخ شروع	تاریخ پایان
۹۷۲	۱۱/۶۴۱	۱۰/۸۳۹	۱۲/۲۰۵	۱۱/۴۳۱	۱۱/۶۱۵	۱۱/۹۸۸	۰/۳۱۷	۰/۳۱۷
۹۸۰	۱۰/۷۳۳	۱۰/۰۵۳	۱۱/۳۵۶	۱۰/۵۳۸	۱۰/۷۸۵	۱۰/۹۴۳	۰/۲۵۱	۰/۲۵۱
۹۶۸	۷/۹۹۹	۷/۳۱۶	۸/۷۷۴	۷/۷۳۶	۷/۹۶۷	۸/۳۸۳	۰/۴۱۸	۰/۴۱۸
۹۷۲	۱۵/۶۲۳	۱۴/۷۴۶	۱۶/۲۳۹	۱۵/۲۹۴	۱۵/۶۲۶	۱۶/۰۳۲	۰/۳۸۴	۰/۳۸۴

مأخذ: یافته‌های پژوهش

همانطور که در این داده‌ها مشخص است رفتار روندی و رفتار ادواری (فصلی) در کنار بخش‌های تصادفی در این نمودارها مشهود است. در ادامه به برآورد الگوها جهت تجزیه این عناصر در چهار شاخص بورسی حوزه انرژی کشور پرداخته شده است.

۱. Root Mean Squared Error

نمودار (۱). روند تحولات داده‌های لگاریتمی چهار شاخص بورسی انرژی



مأخذ: یافته‌های پژوهش

### ۵. یافته‌های پژوهش

در ابتدا سه روش از مهمترین روش‌های پیش‌بینی سری‌های زمانی در یادگیری ماشین بر اساس رویکرد شبکه‌های مصنوعی بازگشتی RNN برای مقایسه عملکرد انتخاب شده است. هر یک از این الگوها با توجه به ابرپارامترهای مختلف، اعتبارسنجی متقابل شده‌اند که در ادامه، چهار مورد از این پیش‌بینی‌ها و عملکرد آنها در اعتبارسنجی متقابل ارائه شده است.

جدول (۲). ابرپارامترهای سه مدل LSTM، RNN و GRU در افق‌های مختلف

اندازه رسته	حداکثر گام‌ها	نرخ آموزش یا یادگیری	لایه دیکودر (decoder)	اندازه لایه‌های پنهان دیکودر (decoder)	لایه انکودر (encoder)	اندازه لایه‌های پنهان انکودر (encoder)	اندازه ورودی	تکرار یادگیری	تابع زیان		
۱ روز	۲	۰/۰۰۱۸۴	۸	۳۲	۲	۶۴	۳۰	۱۰	۰/۰۰۵۷	RNN	
	۱۵	۰/۰۰۰۷۰	۴	۳۲	۲	۱۶	۳۰	۱۰	۰/۰۰۵۶	GRU	
	۱۵	۰/۰۰۰۷۰	۴	۳۲	۲	۱۶	۳۰	۱۰	۰/۰۰۴۴	LSTM	
۲ روز	۱۵	۰/۰۰۰۷۰	۴	۳۲	۲	۱۶	۳۰	۱۰	۰/۰۰۷۵	RNN	
	۶	۰/۰۰۰۵۴	۸	۱۲۸	۴	۶۴	۳۰	۱۰	۰/۰۰۶۶	GRU	
۵ روز (یک هفته)	۱۰	۰/۰۰۰۴۵۰	۴	۶۴	۴	۱۶	۶۰	۱۰	۰/۰۰۸۹	LSTM	
	۱۵	۰/۰۰۲۱۴	۲	۳۲	۲	۱۶	۶۰	۵	۰/۰۱۲۲	RNN	
	۲	۰/۰۰۱۲۶	۲	۱۲۸	۲	۳۲	۶۰	۵	۰/۰۱۲۱	GRU	
۲۰ روز (یک ماه)	۴	۰/۰۰۴۹۹	۴	۱۲۸	۴	۳۲	۱۲۰	۴	۰/۰۱۰۸	LSTM	
	۱۰	۰/۰۰۰۴۵۰	۴	۶۴	۴	۱۶	۱۲۰	۱۰	۰/۰۷۴۵	RNN	
	۲	۰/۰۰۱۸۴	۸	۳۲	۲	۶۴	۱۲۰	۱۰	۰/۰۷۳۶	GRU	
	۲	۰/۰۰۱۸۴	۸	۳۲	۲	۶۴	۱۲۰	۱۰	۰/۰۷۱۲	LSTM	

مأخذ: یافته‌های پژوهش

در تعیین مشخصات الگوها، چند یافته کلیدی وجود دارد:  
 یک- با افزایش افق پیش‌بینی، اندازه رسته لازم برای حصول به بهترین پیش‌بینی به طور متوسط برای تمامی الگوها کاهش می‌یابد.  
 دو- هرچه اندازه حجم نمونه ورودی در یادگیری بزرگتر باشد اندازه رسته لازم کمتر خواهد بود.  
 جدول (۳) خطای پیش‌بینی ۴ الگوی مختلف برای افق‌های زمانی متفاوت را با ۲۰۰ داده روزانه (حدود ۱ سال) با ۱۰ پنجره پیش‌بینی نشان می‌دهد.

جدول (۳). خطای پیش‌بینی RMSE برای افق‌های مختلف زمانی با سه الگو یادگیری ماشین (LSTM, GRU و RNN) و یک الگوی خطی اقتصادسنجی (ARIMA)

ARIMA	LSTM	GRU	RNN	شاخص صنایع	
۰/۰۰۸	۰/۰۰۷	۰/۰۱۱	۰/۰۱۲	شیمیایی	۱ روز کاری
۰/۰۲۵	۰/۰۲۴	۰/۰۲۵	۰/۰۲۷	زغال سنگ	
۰/۰۱۸	۰/۰۲۰	۰/۰۱۰	۰/۰۱۰	انرژی	
۰/۰۱۸	۰/۰۲۱	۰/۰۱۷	۰/۰۱۵	فرآورده نفتی	
۰/۰۱۳	۰/۰۱۲	۰/۰۱۶	۰/۰۱۱	شیمیایی	۲ روز کاری
۰/۰۳۰	۰/۰۲۵	۰/۰۳۳	۰/۰۳۲	زغال سنگ	
۰/۰۱۵	۰/۰۱۱	۰/۰۱۳	۰/۰۱۵	انرژی	
۰/۰۲۳	۰/۰۲۰	۰/۰۲۲	۰/۰۲۱	فرآورده نفتی	
۰/۰۲۱	۰/۰۲۲	۰/۰۱۹	۰/۰۱۷	شیمیایی	۵ روز کاری (یک هفته)
۰/۰۶۶	۰/۰۵۱	۰/۰۵۷	۰/۰۶۸	زغال سنگ	
۰/۰۲۲	۰/۰۲۰	۰/۰۲۱	۰/۰۲۵	انرژی	
۰/۰۳۶	۰/۰۳۵	۰/۰۳۲	۰/۰۳۲	فرآورده نفتی	
۰/۰۳۲	۰/۰۶۸	۰/۰۶۴	۰/۰۸۸	شیمیایی	۲۰ روز کاری (۱ ماه)
۰/۱۲۵	۰/۱۱۸	۰/۱۲۱	۰/۱۲۲	زغال سنگ	
۰/۰۶۰	۰/۰۵۷	۰/۰۵۶	۰/۰۵۱	انرژی	
۰/۰۶۱	۰/۰۶۶	۰/۰۶۰	۰/۰۸۴	فرآورده نفتی	

مأخذ: یافته‌های پژوهش

یافته‌ها حاکی از آن است که

یک- در افق پیش‌بینی بسیار کوتاه‌مدت یعنی یک روز کاری، مدل LSTM در پیش‌بینی شاخص‌های شیمیایی و زغال‌سنگ عملکرد خوبی دارد، مدل‌های RNN و GRU به ترتیب

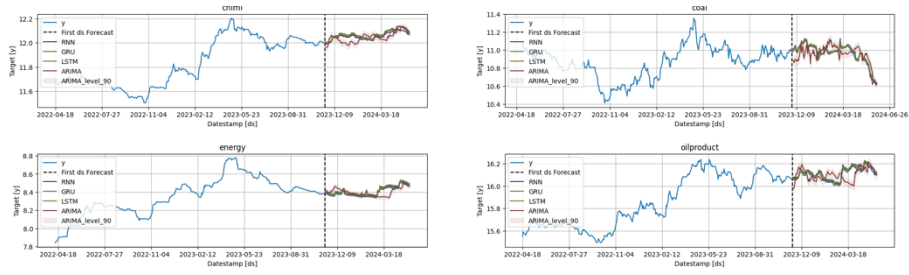
برای پیش‌بینی شاخص‌های فرآورده‌های نفتی و انرژی عملکرد بهتری دارند، در حالی که مدل اقتصادسنجی ARIMA در پیش‌بینی هیچ‌یک از شاخص‌ها عملکرد بهتری ندارد. دو- در افق پیش‌بینی دو روز کاری، مدل LSTM در پیش‌بینی سه شاخص زغال‌سنگ، انرژی و فرآورده‌های نفتی عملکرد خوبی دارد و مدل‌های RNN با اختلاف اندکی نسبت به مدل LSTM، برای پیش‌بینی شاخص شیمیایی، بهتر عمل می‌کند. این در حالی است که مدل‌های ARIMA، GRU، در پیش‌بینی هیچ‌یک از شاخص‌ها عملکرد بهتری ندارند. ذکر این نکته ضروری است که مقادیر RMSE نسبتاً اندک هستند که بیانگر توانایی بالای الگوها در پیش‌بینی دقیق برای افق ۲ روزه می‌باشد.

سه- یافته‌های حاصل از خطای پیش‌بینی مدل‌ها در ۵ روز کاری (یک هفته) نشان می‌دهد که مدل LSTM در پیش‌بینی شاخص‌های زغال‌سنگ و انرژی بهتر عمل نموده است. مدل RNN برای پیش‌بینی شاخص شیمیایی عملکرد بهتری دارد و همچنین عملکرد هر دو مدل RNN و GRU در پیش‌بینی شاخص فرآورده‌های نفتی مشابه یکدیگر است. مشابه با یافته‌های گذشته، عملکرد مدل ARIMA در پیش‌بینی شاخص‌ها در مقایسه با سایر مدل‌ها ضعیف‌تر بوده است. شایان ذکر است که مقادیر RMSE در افق‌های ۵ روزه، بیشتر از افق ۲ روزه است که به معنای کاهش دقت پیش‌بینی به موازات با موسع شدن افق پیش‌بینی می‌باشد. چهار- در افق نسبتاً بلندمدت و ظرف ۲۰ روز کاری (یک ماه)، مدل LSTM در پیش‌بینی شاخص زغال‌سنگ بهتر عمل نموده است. مدل‌های غیرخطی RNN و GRU به ترتیب برای پیش‌بینی شاخص انرژی و فرآورده‌های نفتی عملکرد بهتری دارد. جالب آنکه در افق‌های پیش‌بینی دورتر، عملکرد الگوی پیش‌بینی خطی ARIMA نزدیک به مدل‌های غیرخطی هوش مصنوعی می‌شود، به طوری که حتی در پیش‌بینی شاخص شیمیایی، عملکرد به مراتب بهتری را از خود نشان می‌دهند و کمترین خطای پیش‌بینی شاخص شیمیایی متعلق به این دو روش خطی است. در پیش‌بینی شاخص‌ها در مقایسه با سایر مدل‌ها ضعیف‌تر بوده است. مشابه با یافته‌های قبل مقادیر RMSE در افق‌های ۲۰ روزه، بیشتر از افق ۵ روزه است که به معنای کاهش دقت پیش‌بینی به موازات با موسع شدن افق پیش‌بینی می‌باشد.

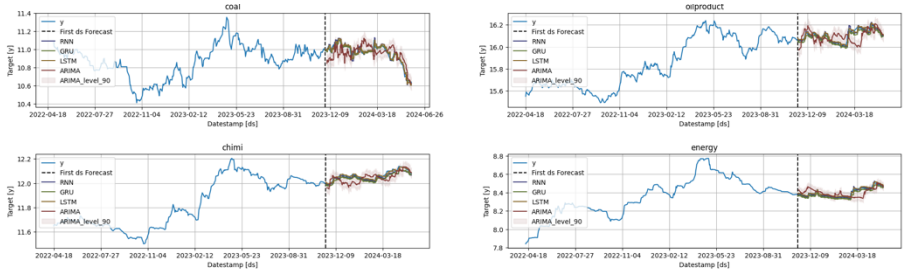
در انتها برای بررسی دقیق‌تر قدرت پیش‌بینی الگوهای غیرخطی یادگیری ماشین (RNN، GRU و LSTM) و روش خطی اقتصادسنجی (ARIMA) برای چهار شاخص مورد بررسی در افق‌های ۱، ۲، ۵ و ۲۰ روز کاری آینده، نمودار (۲) در قالب چهار پانل مجزا ترسیم شده است.

نمودار (۲). پیش‌بینی چهار شاخص با استفاده از روش‌های یادگیری ماشین و اقتصادسنجی برای افق‌های مختلف ۱، ۲، ۵ و ۲۰ روز کاری

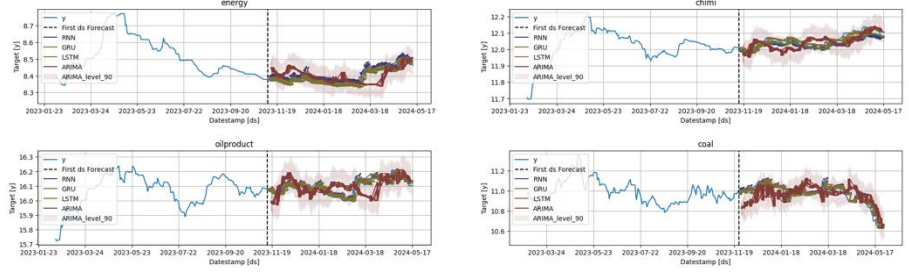
الف- ۱ روز کاری



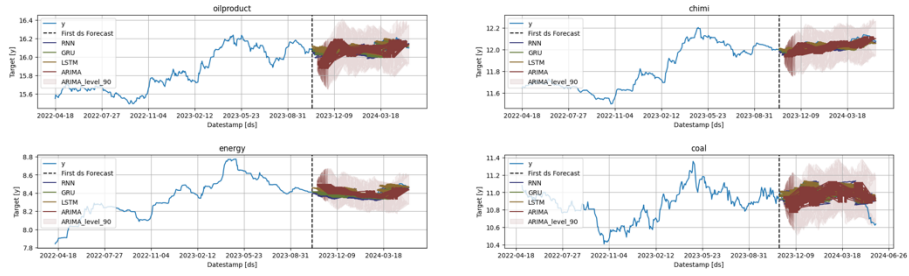
ب- ۲ روز کاری



ج- ۵ روز کاری (یک هفته)



د- ۲۰ روز کاری (۱ ماه)



مأخذ: یافته‌های پژوهش



## ۶. جمع‌بندی یافته‌ها

در این پژوهش، با استفاده از رویکرد یادگیری ماشین، عملکرد روش‌های مختلف پیش‌بینی داده‌های مربوط به شاخص‌های صنایع شیمیایی، زغال‌سنگ، انرژی و فرآورده‌های نفتی در بورس اوراق بهادار ارزیابی شده است. داده‌های مورد استفاده به صورت روزانه و در بازه زمانی ۱ مه ۲۰۲۰ تا ۱ مه ۲۰۲۴ (۱۲ اردیبهشت ۱۳۹۹ تا ۱۲ اردیبهشت ۱۴۰۳) جمع‌آوری شده‌اند. از الگوهای خانواده RNN که از مهمترین الگوهای روش‌های یادگیری ماشین و هوش مصنوعی برای پیش‌بینی سری‌های زمانی هستند (مشمول بر سه الگوی RNN، LSTM و GRU)، برای تحلیل و پیش‌بینی این شاخص‌ها استفاده شده است. با توجه به اهمیت روش‌های پیش‌بینی سری‌های زمانی در زمینه‌های مختلف، از جمله اقتصاد و مالی، نتایج الگوهای پیش‌بینی با روش‌های یادگیری ماشین با یکی از متداول‌ترین الگوهای سری‌های زمانی (یعنی ARIMA) مقایسه شده‌اند. همچنین به منظور انجام پیش‌بینی، ۸۰ درصد کل داده‌ها در ابتدای دوره (حدود ۳ سال اول) به عنوان دوره آموزش یا یادگیری و ۲۰ درصد کل داده‌ها در انتهای دوره (حدود ۱ سال آخر) به عنوان دوره آزمایش یا آزمون به کار گرفته شده است.

در ابتدا، سه روش از مهمترین روش‌های پیش‌بینی سری‌های زمانی در یادگیری ماشین بر اساس رویکرد شبکه‌های مصنوعی بازگشتی RNN برای مقایسه عملکرد انتخاب شدند. سپس، الگوها برای پیش‌بینی ۱ روز، ۲ روز، ۵ روز (یک هفته) و ۲۰ روز (یک ماه) بررسی شدند. سپس هر یک یک از این الگوها، با توجه به ابرپارامترهای مختلف، مورد اعتبار سنجی متقابل قرار گرفتند. یافته‌های به دست آمده در تعیین مشخصات الگوها و مقایسه عملکرد ۳ الگوی غیرخطی مبتنی بر یادگیری ماشین (مدل‌های RNN، LSTM و GRU) با الگوی خطی مبتنی بر روش‌های سری‌های زمانی (مدل ARIMA) به شرح زیر هستند:

- با افزایش افق پیش‌بینی، اندازه رسته لازم برای حصول به بهترین پیش‌بینی به طور متوسط برای تمامی الگوها کاهش می‌یابد.
- هرچه حجم نمونه ورودی در یادگیری بزرگتر باشد، اندازه رسته مورد نیاز کمتر خواهد بود.

➤ به موازات با توانایی الگوهای مبتنی بر یادگیری ماشین در عملکرد درون نمونه‌ای، آنها مزیت قابل‌ملاحظه‌ای در مقایسه با روش‌های سری‌های زمانی در عملکرد برون‌نمونه‌ای دارند.

➤ در افق‌های زمانی کوتاه‌مدت (۱ روز، ۲ روز و ۵ روز کاری)، روش‌های یادگیری ماشین به ویژه مدل LSTM، پیش‌بینی بهتری از شاخص‌های مختلف صنایع انرژی کشور ارائه نموده‌اند به طوری که دقت پیش‌بینی آن‌ها بین ۹۶/۵ تا ۹۸/۵ درصد در نوسا است. در افق پیش‌بینی بلندمدت (۲۰ روز کاری معادل ۱ ماه) روش سری‌های زمانی، عملکردی تقریباً مشابه با الگوهای یادگیری ماشین و در مورد شاخص صنایع شیمیایی عملکردی بهتر) داشته‌اند و با دقت حدوداً ۹۳ درصدی، قادر به پیش‌بینی شاخص‌های مختلف صنایع بورسی انرژی کشور هستند.

این پژوهش نشان می‌دهد که روش‌های یادگیری ماشین و سری‌های زمانی می‌توانند برای پیش‌بینی داده‌های مربوط به شاخص صنایع شیمیایی، زغال‌سنگ، انرژی و فرآورده‌های نفتی استفاده شوند، اما انتخاب روش مناسب بستگی به افق پیش‌بینی و مشخصات داده‌ها دارد. با عنایت به نتایج پیش‌بینی و دقت بالای الگوهای یادگیری ماشین به ویژه مدل LSTM، پیشنهاد می‌شود مباحث سیگنال‌دهی و وجود استراتژی‌های سودآور بین بازارهای موازی توسط سرمایه‌گذاران و عوامل فعال در بازارهای مالی مورد توجه قرار گیرد تا با آگاهی از حرکات بین بازارها و پیش‌بینی آن‌ها، امکان کنترل ریسک و کسب بازده‌های مناسب فراهم گردد.

## ۷. تعارض منافع

تعارض منافع وجود ندارد.

## ۸. سپاسگزاری

نویسندگان مقاله از هیئت تحریریه محترم سپاسگزارند.

## ORCID

Reza Taleblou



<http://orcid.org/0000-0002-8679-2920>

Parisa Mohajeri



<http://orcid.org/0000-0001-7971-0678>

## ۹. منابع

- Akhas Rahmadeyan, M. (۲۰۲۴). Long Short-Term Memory and Gated Recurrent Unit for Stock Price Prediction. *Procedia Computer Science*, ۲۳۴, ۲۰۴-۲۱۲, <https://doi.org/10.1016/j.procs.2024.02.167>.
- Bengio, Y., Simard, P., & Frasconi, P. (1994). Learning Long-Term Dependencies with Gradient Descent Is Difficult. *IEEE Trans. Neural Networks*, 5(2), 157-166, <https://doi.org/10.1109/72.279181>.
- Bollerslev, T. (۱۹۸۶). ARCH Modeling in Finance: A Review of the Theory and Empirical Evidence. *Journal of Econometrics*, ۳۱(۳), ۵-۵۹.
- Box, G. E. P., Jenkins, G. M., & Reinsel, G. C. (۲۰۱۵). *Time Series Analysis: Forecasting and Control*. Hoboken, NJ: Wiley.
- Edwards, R. D., & Magee, J. (۲۰۰۱). Technical Analysis of Stock Trends. *Journal of Technical Analysis*, ۵۶(۳), ۲۲۴-۲۳۹, <https://doi.org/10.4324/97813151105719>.
- Che, Z., Purushotham, S., Cho, K., Sontag, D. & Liu, Y. (۲۰۱۸). Recurrent Neural Networks for Multivariate Time Series with Missing Values. *Scientific Reports*. ۸(۱), ۶۰۸۵, ۱-۱۲, <https://doi.org/10.1038/s41598-018-24271-9>.
- Chen, X., Wei L. & Xu, J. (۲۰۱۷). *House Price Prediction using LSTM*. *The Computing Research Repository (CoRR)*- ۲۰۱۷.
- Cho, K., van Merriënboer, B., Culcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2014). Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation. *arXiv preprint arXiv:1406.1078*.
- Engle, R. F., & Sargan, J. D. C. (۲۰۰۳). A Linear Market Model with Recursive Estimation of Predictive Coefficients. *Journal of Financial Economics*, ۲۱(۱), ۱۳۵-۱۷۱.
- Goodfellow, I., Bengio, Y. & Courville, A. (۲۰۱۶). *Deep Learning*. MIT Press.
- Graves, A. (۲۰۱۲). Sequence Transduction with Recurrent Neural Networks. *arXiv preprint arXiv:1211.3711*.
- Hamzah, et al, (۲۰۲۳). Effective Stock Prediction Model Using MACD Method. *International Journal of Informatics and Computation*, ۵ (۲), ۱-۶.
- Hansson, F. & Rostami J. (۲۰۱۹). *Time Series Forecasting of House Prices: an Evaluation of a Support Vector Machine and a Recurrent Neural Network with LSTM ells*. Uppsala University Thesis. May ۲۰۱۹.
- Hochreiter, S., & Schmidhuber, J. (۱۹۹۷). Long Short-Term Memory. *Neural computation*, 9, 1735-178۰, <https://doi.org/10.1162/neco.1997.9.8.1735>.
- Jozefowicz, R., Zaremba, W., & Sutskever, I. (2015). An Empirical Exploration of Recurrent Network Architectures. *International*

*Conference on Machine Learning*, Lille, France, *JMLR:W&CP*, Volume 37, 2342–2350.

- Khodke, Y. & Deshpande, S. (۲۰۲۳). Stock Price Prediction Using LSTM and GRU. *International Journal for Research in Applied Science & Engineering Technology*, ۱۱(۶), ۱۱۶۳-۱۱۶۷, <https://doi.org/۱۰.۲۲۲۱۴/ijraset.۲۰۲۳.۰۳۸۲۶>.
- K. J, H. E, M. S. Jacob & D. R. (۲۰۲۱). Stock Price Prediction Based on LSTM Deep Learning Model. *International Conference on System, Computation, Automation and Networking (ICSCAN)*, Puducherry, India, pp. ۱-۴, <https://doi.org/۱۰.۱۱۰۹/ICSCAN۰۳۰.۶۹,۲۰۲۱,۹۰۲۶۴۹۱>.
- Limsombunchai, V., Gan Ch., & Lee, M. (۲۰۰۴). House Price Prediction: Hedonic Price Model vs. ANN. *American Journal of Applied Sciences*, ۱ (۳), ۱۹۳-۲۰۱.
- Luca, D.P. & Oleksandr, H. (۲۰۱۶). Artificial Neural Networks Architectures for Stock Price Prediction: Comparisons and Applications. *International Journal of Circuits, Systems and Signal Processing*, ۱۰, ۴۰۳-۴۱۳.
- Nakanishi, M., Morimoto, Y., & Morishita, S. (۲۰۰۶). A Self-Adaptive Support Vector Machine and Time Series Prediction. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, ۳۶(۱), ۱۰۱-۱۰۷.
- Song, Y. (2018). Stock Trend Prediction: Based on Machine Learning Methods. UCLA Electronic Theses and Dissertations.
- Wang, Y., Liu, Z., Wang, J., & Sun, Y. (۲۰۱۹). Comparative Study of LSTM and GRU for Stock Price Prediction on Three Major Stock Indices. *IEEE International Conference on Big Data (Big Data)*, ۱۷۶۳-۱۷۷۰.
- Xiao, F. (۲۰۲۰). Time Series Forecasting with Stacked Long Short-Term Memory Networks. *Presented for Toronto Transit Commission*. <https://doi.org/۱۰.۴۸۰۰۰/arXiv.۲۰۱۱.۰۰۶۹۷>.
- Xu, L., Li, C., Xie, X., & Zhang, G. (2018). Long-Short-Term Memory Network Based Hybrid Model for Short-Term Electrical Load Forecasting. *Information*, 9(2), 165, <https://doi.org/۱۰.۳۳۹۰/info۹.۰۷.۱۶۵>.
- Yan, H., & Ouyang, H. (۲۰۱۸). Financial Time Series Prediction Based on Deep Learning. *Wireless Personal Communications*. ۱۰۲, ۶۸۳-۷۰۰, <https://doi.org/۱۰.۱۰۰۷/s۱۱۲۷۷-۰۱۷-۰۰۸۶-۲>.
- Yang, Q. & Wang, C. (۲۰۱۹). A Study on Forecast of Global Stock Indices Based on Deep LSTM Neural Network. *Statistical Research*, ۳۶, ۶۵-۷۷.
- Yao, K., Cohn, T., Vylomova, K., & Duh, K. (۲۰۱۵). Depth-Gated Recurrent Neural Networks. arXiv: ۱۵۰۸.۰۳۷۹۰۷۲.

- Yongqiong Zh. (۲۰۲۰). Stock Price Prediction using the RNN Model. *Journal of Physics Conference Series*, ۱۶۵۰:۰۳۲۱۰۳, <https://doi.org/10.1088/1742-6596/1650/3/032103>
- Yu, L., Jiao, C., Xin, H., Wang, Y. & Wang, K. (۲۰۱۸). Prediction on Housing Price Based on Deep Learning. *International Journal of Computer and Information Engineering*, ۱۲(۲), ۹۰-۹۹.