



Paper Type: Original Article



Stock Option Pricing Using Deep Learning and Gated Recurrent Neural Networks

Mehrdad Heidari¹, Morteza Moradi^{2,*}

¹ Department of Industrial Engineering, Urmia University of Technology, Urmia, Iran; mehrdadheidari@ine.uut.ac.ir; moradi@uut.ac.ir.

Citation:



Heidari, M., & Moradi, M. (2026). Stock option pricing using deep learning and gated recurrent neural networks. *Management: Modeling, Analysis and Applications*, 3(2), 123-130.

Received: 02/01/2026

Reviewed: 13/03/2026

Revised: 27/04/2026

Accepted: 19/06/2026

Abstract

Purpose: Accurate option pricing is one of the most important challenges in financial engineering and investment management, as it directly affects risk hedging decisions, asset valuation, and market efficiency. Classical option pricing models, particularly the Black–Scholes model, have been widely applied but rely on restrictive assumptions that often fail to capture real market dynamics. In recent years, deep learning approaches have attracted significant attention due to their ability to extract complex and nonlinear patterns from financial data. Therefore, this study aims to investigate the effectiveness of Gated Recurrent Unit (GRU) networks for stock option pricing and compare their performance with the Black–Scholes model.

Methodology: This applied study focuses on European call options written on Iran Khodro stock. Daily stock and option contract data covering the period from March to December 2023 were collected and preprocessed. A set of technical indicators, including Exponential Moving Averages, Moving Average Convergence Divergence, Relative Strength Index, and historical volatility, was extracted from the data. The dataset was then structured using a sliding-window approach, and three GRU architectures, namely single-layer, two-layer, and three-layer models, were developed. Model performance was evaluated using forecasting error measures and the coefficient of determination and compared against the Black–Scholes benchmark.

Findings: The results demonstrate that the single-layer GRU model achieves the highest predictive accuracy among all evaluated models and outperforms the Black–Scholes benchmark. Furthermore, increasing network depth through two-layer and three-layer architectures does not improve performance and, in some cases, leads to inferior results compared with the benchmark model. These findings suggest that, for the option pricing problem and the available dataset, simpler GRU architectures may provide superior learning and generalization capabilities.

Originality/Value: The main contribution of this study is the empirical evaluation of GRU-based deep learning models for option pricing in the Iranian capital market and their comparison with a well-established analytical pricing model. The findings indicate that deep learning approaches can serve as effective alternatives or complements to traditional option pricing methods. The proposed framework provides valuable insights for financial analysts, investors, and researchers seeking to develop intelligent pricing and decision-support tools for financial markets.

Keywords: Option pricing, Deep learning, Gated recurrent unit network, Black-Scholes model, Financial time series, Artificial intelligence.



Corresponding Author: moradi@uut.ac.ir



<https://doi.org/10.22105/mmaa.v3i2.125>



Licensee. **Management: Modeling, Analysis and Application**. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<http://creativecommons.org/licenses/by/4.0>).



قیمت گذاری اختیار معامله سهام با بهره گیری از یادگیری عمیق و شبکه های بازگشتی دروازه ای

مهرداد حیدری^۱، مرتضی مرادی^۲

^۱گروه مهندسی صنایع، دانشگاه صنعتی ارومیه، ارومیه، ایران.

چکیده

هدف: قیمت گذاری دقیق اختیار معامله یکی از مهم ترین مسایل در مهندسی مالی و مدیریت سرمایه گذاری است، زیرا بر تصمیمات پوشش ریسک، ارزش گذاری دارایی ها و کارایی بازارهای مالی تاثیر مستقیم دارد. مدل های کلاسیک قیمت گذاری اختیار معامله، به ویژه مدل بلک-شولز، اگرچه کاربرد گسترده ای دارند، اما بر مجموعه ای از فرضیات محدودکننده استوار هستند که در بسیاری از شرایط واقعی بازار برقرار نیستند. در سال های اخیر، روش های مبتنی بر یادگیری عمیق به دلیل توانایی در استخراج الگوهای پیچیده و غیرخطی از داده های مالی مورد توجه قرار گرفته اند. بر این اساس، پژوهش حاضر با هدف بررسی قابلیت شبکه های بازگشتی دروازه ای در قیمت گذاری اختیار معامله سهام و مقایسه عملکرد آن ها با مدل بلک-شولز انجام شده است.

روش شناسی پژوهش: این پژوهش از نوع کاربردی بوده و بر داده های اختیار معامله خرید اروپایی سهام شرکت ایران خودرو متمرکز است. داده های روزانه سهام و قراردادهای اختیار معامله طی دوره فروردین تا آذر ۱۴۰۲ گردآوری شدند. پس از پیش پردازش داده ها، مجموعه ای از شاخص های فنی شامل میانگین متحرک نمایی، شاخص همگرایی-واگرایی میانگین متحرک، شاخص قدرت نسبی و نوسان پذیری تاریخی استخراج شد. سپس داده ها با استفاده از روش پنجره متحرک ساختاردهی و سه معماری مختلف شبکه بازگشتی دروازه ای شامل مدل های تک لایه، دولایه و سه لایه توسعه یافت. عملکرد مدل ها با استفاده از معیارهای خطای پیش بینی و ضریب تعیین ارزیابی و با نتایج مدل بلک-شولز مقایسه شد.

یافته ها: نتایج نشان داد که مدل مبتنی بر شبکه بازگشتی دروازه ای تک لایه بهترین عملکرد را در میان تمامی مدل های بررسی شده ارائه می کند و از نظر دقت پیش بینی از مدل بلک-شولز نیز برتر است. همچنین مشاهده شد که افزایش عمق شبکه و استفاده از معماری های دولایه و سه لایه منجر به بهبود عملکرد نمی شود و در برخی معیارها حتی نتایج ضعیف تر از مدل مرجع به همراه دارد. یافته ها بیانگر آن است که در مساله قیمت گذاری اختیار معامله و با حجم داده های مورد مطالعه، مدل های ساده تر می توانند توانایی بیشتری در استخراج الگوهای موثر و تعمیم پذیری مناسب داشته باشند.

اصالت/ارزش افزوده علم: ارزش افزوده اصلی این پژوهش در ارزیابی تجربی کارایی شبکه های بازگشتی دروازه ای برای قیمت گذاری اختیار معامله در بازار سرمایه ایران و مقایسه آن ها با یکی از شناخته شده ترین مدل های مالی است. نتایج مطالعه نشان می دهد که روش های یادگیری عمیق می توانند به عنوان مکمل یا جایگزین رویکردهای کلاسیک در مسائل ارزش گذاری ابزارهای مالی مورد استفاده قرار گیرند. این یافته ها می تواند به تحلیلگران مالی، سرمایه گذاران و پژوهشگران در توسعه مدل های هوشمند قیمت گذاری و تصمیم گیری در بازارهای مالی کمک کند.

کلیدواژه ها: قیمت گذاری اختیار معامله، یادگیری ژرف، واحد بازگشتی دروازه ای، بلک-شولز، سری های زمانی مالی، هوش مصنوعی.

۱- مقدمه

اختیارات معامله^۱ به عنوان یکی از ابزارهای کلیدی مشتقه مالی، نقشی حیاتی در مدیریت ریسک و استراتژی های سرمایه گذاری در بازارهای مالی ایفا می کنند. این قراردادها به دارنده خود حق و نه تعهد خرید (اختیار خرید) یا فروش (اختیار فروش) یک دارایی پایه^۲ را با قیمتی معین^۳ تا تاریخی مشخص^۴ اعطا می کنند [1]. اهمیت این ابزارها نه تنها در قابلیت پوشش ریسک در برابر نوسانات بازار، بلکه در اهرم مالی بالایی است که می توانند

¹ Options

² Underlying asset

³ Strike price

⁴ Expiration date

برای افزایش بازدهی سرمایه‌گذاری ایجاد کنند. از این‌رو، قیمت‌گذاری دقیق و منصفانه اختیارات معامله، یک مساله بنیادین برای سلامت و کارایی بازارهای مالی محسوب می‌شود [2]. مساله قیمت‌گذاری باتوجه به نوع اختیار معامله، پیچیدگی‌های متفاوتی دارد. اختیارات اروپایی^۱ که تنها در تاریخ سررسید قابل اعمال هستند، ساختار ساده‌تری نسبت به اختیارات آمریکایی^۲ دارند؛ چرا که اختیارات آمریکایی را می‌توان در هر زمانی پیش از سررسید نیز اعمال کرد. این ویژگی "حق اعمال زودهنگام"، قیمت‌گذاری اختیارات آمریکایی را به مراتب پیچیده‌تر می‌سازد [3]. نخستین پیشرفت چشم‌گیر در این حوزه، مدل تحلیلی بلک-شولز^۳ بود که در سال ۱۹۷۳ برای قیمت‌گذاری اختیارات اروپایی ارائه شد و سنگ بنای تحقیقات بعدی قرار گرفت [4]. با این حال، مدل بلک-شولز یک مدل پارامتریک است که بر پایه مفروضات اقتصادی سخت‌گیرانه‌ای بنا شده است که با پویایی‌های بازارهای مالی واقعی تطابق ندارند. این عدم انطباق، منجر به بروز اختلاف میان قیمت‌های پیش‌بینی شده توسط مدل و ارزش واقعی بازار می‌شود و پژوهشگران را به سمت توسعه مدل‌هایی با مفروضات منعطف‌تر سوق داده است [5]. در سال‌های اخیر، روش‌های مبتنی بر هوش مصنوعی، به‌ویژه یادگیری ژرف^۴، به دلیل توانایی در شناسایی الگوهای پیچیده از داده‌ها، عملکردی موفق در حوزه‌های مختلف مالی از خود نشان داده‌اند. با این وجود، کاربرد این مدل‌ها در زمینه تخصیص قیمت‌گذاری اختیار معامله همچنان با کمبود مطالعاتی مواجه است [6].

بنابراین در این مقاله اختیار معامله سهام شرکت ایران خودرو با واحد بازگشتی دروازه‌ای^۵ که یکی از الگوریتم‌های یادگیری ژرف برای تحلیل داده‌های دنباله‌ای است، قیمت‌گذاری می‌شود. برای این منظور ابتدا پیشینه پژوهش مرور می‌گردد، سپس روش‌شناسی تحقیق تشریح می‌شود، در ادامه یافته‌ها ارائه شده و در نهایت، مقاله با نتیجه‌گیری و ارائه پیشنهادهایی برای تحقیقات آتی به پایان می‌رسد.

۲- بررسی پی‌ش‌ی‌نه پژوهش

در سال‌های اخیر، تلاش‌های متعددی برای بهبود دقت و کارایی محاسباتی مدل‌های قیمت‌گذاری اختیار معامله با بهره‌گیری از روش‌های هوش مصنوعی صورت گرفته است. این رویکردها از مدل‌های ترکیبی ساده تا معماری‌های پیچیده یادگیری ژرف را دربر می‌گیرند.

پژوهشگران در ابتدا به دنبال ترکیب مدل‌های کلاسیک با شبکه‌های عصبی بودند. برای مثال، فوناویشی [7] روشی هیبریدی مبتنی بر بسط مجانبی^۶ و شبکه عصبی مصنوعی^۷ را به منظور افزایش سرعت، پایداری و دقت محاسبات ارائه داد. با این حال، کارایی شبکه‌های عصبی در مقایسه با مدل‌های استاندارد همواره قطعی نبوده است. در تحقیقی قابل توجه، ویسوسکی و ایشلپاکزوک [8] عملکرد شبکه‌های پرسپترون چندلایه^۸ را برای قیمت‌گذاری اختیارات شاخص *WIG20* بررسی کردند. نتایج آن‌ها نشان داد که علی‌رغم تنظیم دقیق ابرپارامترها، مدل بلک-شولز، به‌ویژه در شرایط متغیر بازار، عملکردی دقیق‌تر و با خطای کمتری نسبت به شبکه عصبی از خود به جای گذاشت. این یافته نشان می‌دهد که معماری شبکه و شرایط بازار، نقش تعیین‌کننده‌ای در موفقیت این مدل‌ها دارند.

با پیشرفت معماری‌های یادگیری ماشین، تمرکز پژوهش‌ها به سمت مدل‌های توانا‌تر در تحلیل داده‌های سری زمانی معطوف شد. وانگ و شو [9] قابلیت شبکه‌های عصبی بازگشتی^۹ و به‌طور خاص *LSTM* را در پیش‌بینی حرکت قیمت اختیار معامله ارزیابی کردند. آن‌ها نشان دادند که مدل *LSTM* به دلیل توانایی ذاتی در شناسایی وابستگی‌های بلندمدت در داده‌های زمانی، برتری معناداری نسبت به مدل‌های یادگیری ماشین سنتی مانند درخت تصمیم، جنگل تصادفی و رگرسیون لجستیک دارد.

اخیراً، رویکردهای ترکیبی نوینی ظهور کرده‌اند که به جای جایگزینی کامل مدل‌های سنتی، به دنبال تلفیق هوشمندانه آن‌ها با یادگیری ژرف هستند. در همین راستا، شویمر و ژو [10] یک مدل هیبریدی توسعه دادند که مدل بلک-شولز را با یک شبکه عصبی ترکیب می‌کند. در این ساختار، شبکه عصبی به‌صورت پویا تصمیم می‌گیرد که چه وزنی به خروجی مدل بلک-شولز و چه وزنی به پیش‌بینی خود اختصاص دهد. نتایج نشان داد که این

¹ European options

² American options

³ Black-Scholes

⁴ Deep learning

⁵ Gated Recurrent Unit (GRU)

⁶ Asymptotic expansion

⁷ Artificial Neural Network (ANN)

⁸ Multilayer Perceptron (MLP)

⁹ Recurrent Neural Network (RNN)

مدل ترکیبی، دقت بالاتری نسبت به هر یک از مدل‌های بلک-شولز یا شبکه عصبی به‌تنهایی، در تمام سطوح پولی^۱ و به‌ویژه برای اختیارات در زیان^۲ ارایه می‌دهد.

بررسی پیشینه پژوهش نشان می‌دهد که علی‌رغم کاربرد گسترده مدل‌های یادگیری ژرف در مسایل مالی، شکاف تحقیقاتی قابل‌توجهی در زمینه قیمت‌گذاری اختیار معامله با استفاده از این رویکردها در بازار سرمایه ایران وجود دارد. پژوهش حاضر با هدف پرکردن این شکاف، به ارزیابی کارایی مدل‌های یادگیری ژرف برای قیمت‌گذاری اختیار خرید اروپایی می‌پردازد. برای این منظور، سه معماری مختلف مبتنی بر *GRU* پیاده‌سازی شده و عملکرد آن‌ها با مدل تحلیلی بلک-شولز، به‌عنوان یک معیار پایه، مقایسه می‌گردد.

۳- روش‌شناسی پژوهش

روش‌شناسی این پژوهش با الهام از چارچوب استاندارد فرایند صنعتی متقابل برای داده‌کاوی^۳ طراحی شده است. این چارچوب به دلیل ارایه یک رویکرد ساختاریافته و کاربردی، به‌عنوان مدلی معتبر در پروژه‌های علم داده و داده‌کاوی شناخته می‌شود [11].

فرایند اجرایی این تحقیق در چهار مرحله اصلی سازمان‌دهی شده است:

۱. جمع‌آوری داده‌ها: انتخاب و گردآوری داده‌های مورد نیاز برای قیمت‌گذاری اختیار معامله.
۲. پیش‌پردازش و آماده‌سازی داده‌ها: مهندسی ویژگی، پاک‌سازی و تغییر مقیاس داده‌ها.
۳. مدل‌سازی: طراحی و پیاده‌سازی مدل یادگیری ژرف (*GRU*) و مدل معیار (بلک-شولز).
۴. ارزیابی مدل: سنجش و مقایسه عملکرد مدل‌ها با استفاده از معیارهای عملکردی.

در بخش‌های آتی، جزئیات هر یک از این مراحل به تفصیل تشریح خواهد شد.

۳-۱- جمع‌آوری داده‌ها

مجموعه داده مورد استفاده در این پژوهش بر اساس اطلاعات سهام و اختیارات معامله شرکت ایران‌خودرو (با نماد "خودرو")، به‌عنوان یکی از بزرگ‌ترین و نقدشونده‌ترین شرکت‌های پذیرفته‌شده در بورس اوراق بهادار تهران، انتخاب شده است. اهمیت و حجم بالای معاملات این سهم، آن را به یک نمونه مطالعاتی مناسب برای قیمت‌گذاری ابزارهای مشتقه تبدیل می‌کند. داده‌های خام، شامل قیمت روزانه سهام و اطلاعات قراردادهای اختیار معامله خرید با تاریخ سررسید در بازه زمانی فروردین تا پایان آذر ۱۴۰۲، از وب‌سایت رسمی شرکت مدیریت فناوری بورس تهران (*TSETMC*) استخراج گردیده است^۴.

۳-۲- پیش‌پردازش و آماده‌سازی داده‌ها

پس از جمع‌آوری داده‌ها، یک فرایند پیش‌پردازش چندمرحله‌ای به‌منظور آماده‌سازی مجموعه داده برای مدل‌سازی انجام شد. این فرایند شامل مهندسی ویژگی، مقیاس‌سازی، ساختاردهی داده‌ها و تقسیم مجموعه داده به دو بخش آموزش و آزمون بود که جزئیات آن در ادامه تشریح می‌شود.

¹ Moneyness

² Out of The Money (OTM)

³ Cross Industry Standard Process for Data Mining (CRISP-DM)

⁴ <https://www.tsetmc.com/instInfo/65883838195688438>

⁵ <https://esale.ikco.ir/#!/about>

۱-۲-۳- مهندسی ویژگی^۱

در این مرحله، ویژگی های ورودی مدل از داده های خام استخراج و ساخته شدند. ابتدا، مجموعه ای از شاخص های فنی^۲ برای هر روز معاملاتی محاسبه گردید که عبارت اند از:

۱. میانگین متحرک نمایی^۳ برای دوره های ۱۲ و ۲۶ روزه.
۲. شاخص همگرایی-واگرایی میانگین متحرک^۴.
۳. شاخص قدرت نسبی^۵ با دوره زمانی ۱۴ روزه.


علاوه بر این، نوسان پذیری تاریخی^۶ به عنوان معیاری از ریسک دارایی پایه، برای یک پنجره زمانی ۲۲ روزه (معادل یک ماه معاملاتی) محاسبه شد. در نهایت، اطلاعات مربوط به هر قرارداد اختیار معامله، شامل قیمت اعمال و زمان باقی مانده تا سررسید، با ویژگی های روزانه دارایی پایه (سهام "خودرو") ادغام گردید تا مجموعه داده نهایی شکل گیرد.

۲-۲-۳- مقیاس سازی داده ها^۷

باتوجه به تفاوت قابل توجه در مقیاس متغیرهای ورودی (مانند قیمت سهم در مقابل شاخص RSI)، نرمال سازی داده ها یک گام ضروری برای عملکرد بهینه مدل های یادگیری ژرف است. این فرایند از طریق یکنواخت کردن توزیع ویژگی ها، به همگرایی سریع تر الگوریتم بهینه سازی و تسریع فرایند یادگیری منجر می شود. در این پژوهش، از مقیاس ساز $Min-Max$ استفاده شد تا تمام ویژگی ها به بازه عددی $[0, 1]$ نگاشت شوند.

۳-۲-۳- ساختاردهی داده ها برای مدل GRU

برای انطباق داده ها با ماهیت سری زمانی مدل GRU ، از روش پنجره متحرک^۸ استفاده شد. در این تحقیق، اندازه پنجره برابر با ۵ روز معاملاتی تعیین گردید. بر این اساس، ویژگی های ورودی مدل در یک پنجره ۵ روزه (روزهای $t-5$ تا $t-1$) برای پیش بینی قیمت اختیار معامله در روز بعد (روز t) به کار گرفته می شوند (همان طور که در شکل ۱ نشان داده شده است). لازم به ذکر است که روزهای با حجم معاملات صفر برای قراردادهای اختیار معامله، به دلیل عدم وجود قیمت معتبر، از مجموعه داده حذف گردیدند.



شکل ۱- نحوه ساختاردهی داده ها به صورت پنجره متحرک.

Figure 1 - How to structure data as a floating window.

ویژگی های نهایی که به عنوان ورودی مدل GRU در هر گام زمانی استفاده شدند شامل قیمت اعمال و مانده تا سررسید اختیار معامله، قیمت پایانی دارایی پایه، EMA ۱۲ و ۲۶ روزه، $MACD$ ، RSI ۱۴ روزه، نوسان پذیری تاریخی ۲۲ روزه و نرخ بهره بدون ریسک (ثابت ۲۳%) است.

¹ Feature engineering

² Technical indicators

³ Exponential Moving Average (EMA)

⁴ Moving Average Convergence Divergence (MACD)

⁵ Relative Strength Index (RSI)

⁶ Historical volatility

⁷ Data scaling

⁸ Sliding window

۳-۲-۴- تقسیم داده‌ها به مجموعه‌های آموزش و آزمون

به منظور ارزیابی دقیق عملکرد مدل مجموعه داده بر اساس ساختار زمانی خود به دو بخش مجزا تقسیم شد: مجموعه آموزش^۱؛ شامل ۸۰٪ اولیه داده‌ها که برای یادگیری الگوها و تنظیم وزن‌های شبکه عصبی استفاده می‌شود. مجموعه آزمون^۲؛ شامل ۲۰٪ انتهایی داده‌ها که مدل پس از تکمیل فرایند آموزش روی آن ارزیابی می‌شود تا عملکرد نهایی و قدرت تعمیم آن بر داده‌های کاملاً جدید سنجیده شود.

۳-۳- مدلسازی

در این بخش مدل‌های پیش‌بینی قیمت اختیار معامله تشریح می‌شود. ابتدا مدل‌های مورد استفاده معرفی شده و سپس جزئیات مربوط به معماری و تنظیمات مدل اصلی ارایه می‌گردد.

۳-۳-۱- مدل اصلی (GRU)

GRU یکی از انواع شبکه‌های عصبی بازگشتی می‌باشد. این مدل برای حل مشکلات محوشدگی گرادیان^۳ و انفجار گرادیان^۴ در شبکه‌های عصبی بازگشتی و در مواجهه با داده‌های دنباله‌ای طولانی پیشنهاد شده است. این مدل از یک مکانیزم دروازه‌ای برای کنترل جریان اطلاعات استفاده می‌کند. بنابراین این مدل بهبود یافته شبکه عصبی بازگشتی پایه (ساده) است [12]. همچنین معماری GRU پشته‌ای^۵ بر اساس مدل‌های شبکه عصبی GRU بنا شده است. در GRU پشته‌ای، هر لایه خروجی یک سلول GRU به عنوان ورودی برای بلوک بعدی و در لایه بعدی عمل می‌کند؛ در نتیجه، این قابلیت را به مدل می‌دهد که ساختار سری زمانی را درک کند و بازنمایی‌های آموخته شده از لایه‌های قبلی را ترکیب کند، در حالی که سطح بالاتری از انتزاع را در نتایج نهایی ایجاد می‌کند. پشته‌سازی GRU در شبکه‌های عصبی معمولاً برای افزایش دقت پیش‌بینی، همراه با امکان یادگیری ویژگی‌های زمانی طولانی مدت، به کار می‌رود. پشته‌سازی به حداکثر رساندن اندازه حافظه مدل کمک می‌کند، اگرچه مدل پشته‌ای برای آموزش به مجموعه داده بزرگتری نیاز دارد [13].

۳-۳-۲- مدل معیار (بلک-شولز)

مدل بلک-شولز که در اوایل دهه ۱۹۷۰ توسط بلک و شولز [14] و مرتون [15] ارایه شد، نقطه عطفی در حوزه قیمت‌گذاری اختیار معامله محسوب می‌شود. این مدل با ارایه یک چارچوب تحلیلی برای قیمت‌گذاری اوراق اختیار معامله، تأثیری عمیق بر استراتژی‌های پوشش ریسک و توسعه مهندسی مالی در دهه‌های ۱۹۸۰ و ۱۹۹۰ گذاشت. اهمیت این دستاورد با اعطای جایزه نوبل علوم اقتصادی در سال ۱۹۹۷ به شولز و مرتون به رسمیت شناخته شد [16]. با وجود تأثیرگذاری گسترده، مدل بلک-شولز بر پایه مجموعه‌ای از مفروضات سخت‌گیرانه (مانند نوسان‌پذیری ثابت و عدم وجود هزینه معاملات) بنا شده است که اعتبار آن‌ها در شرایط واقعی بازار همواره محل بحث بوده و ممکن است معتبر نباشند [2].

۳-۳-۳- معماری مدل GRU

در این پژوهش، به منظور بررسی تأثیر عمق شبکه بر عملکرد مدل، سه معماری مبتنی بر GRU پیاده‌سازی و مقایسه شده‌اند:

۱. مدل GRU تک‌لایه: یک معماری پایه با یک لایه GRU.
۲. مدل GRU پشته‌ای دو لایه: مدلی با دو لایه GRU که به صورت متوالی روی هم قرار گرفته‌اند.
۳. مدل GRU پشته‌ای سه لایه: ساختاری عمیق‌تر با سه لایه متوالی GRU.

¹ Training set

² Test set

³ Gradient vanishing

⁴ Gradient explosion

⁵ Stacked GRU

پیکربندی ابرپارامترها برای تمامی این معماری ها به صورت یکسان تنظیم گردید تا مقایسه ای منصفانه حاصل شود. جزئیات این تنظیمات به شرح زیر است:

۱. تعداد واحدهای GRU در هر لایه: ۵۰ واحد.

۲. اندازه دسته^۱: ۳۲.

۳. تعداد دوره های آموزش^۲: ۱۰۰۰.

۴. بهینه ساز^۳: $Adam$ با نرخ یادگیری پیش فرض.

این رویکرد مقایسه ای، امکان ارزیابی دقیق تاثیر افزایش پیچیدگی مدل بر توانایی پیش بینی آن را فراهم می آورد.

۴-۳- ارزیابی مدل ها

به منظور ارزیابی و مقایسه کمی عملکرد مدل GRU و مدل بلک-شولز، از چهار شاخص عملکردی MSE ، $RMSE$ ، MAE و R^2 که به ترتیب بر اساس رابطه (۱) تا رابطه (۴) تعریف شده اند، استفاده گردید. این شاخص ها میزان اختلاف بین مقادیر پیش بینی شده ($\hat{Y}_i$) و مقادیر واقعی (Y_i) را بر اساس تعداد n داده، از جنبه های مختلف اندازه گیری می کنند.

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2. \quad (1)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2}. \quad (2)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_i - \hat{Y}_i|. \quad (3)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2}. \quad (4)$$

۴- نتایج پژوهش

پس از اتمام فرایند آموزش روی مجموعه داده های آموزش مقیاس بندی شده، هر یک از سه معماری GRU برای پیش بینی قیمت اختیار معامله بر روی مجموعه داده آزمون به کار گرفته شدند. عملکرد هر مدل از طریق مقایسه مقادیر پیش بینی شده با قیمت های واقعی بازار و با استفاده از معیارهای ارزیابی ذکر شده، سنجیده شد. به طور هم زمان، مدل کلاسیک بلک-شولز نیز بر روی همین مجموعه داده آزمون پیاده سازی شد تا نتایج آن به عنوان یک مدل معیار برای سنجش کارایی مدل های پیشنهادی مورد استفاده قرار گیرد.

جدول ۱، نتایج حاصل از این ارزیابی را به صورت مقایسه ای ارائه می دهد و عملکرد هر یک از مدل های GRU را در کنار مدل بلک-شولز نمایش می دهد.

جدول ۱- نتایج ارزیابی مدل ها.

Table 1- Results of model evaluation.

مدل	MSE	RMSE	MAE	R ²
GRU1	4513.3	67.2	40.4	0.89
GRU2	6294.1	79.3	51.2	0.84
GRU3	5028.3	70.9	47.4	0.88
بلک-شولز	6317.1	79.5	45.7	0.84

¹ Batch Size

² Epochs

³ Optimizer

بر اساس نتایج ارائه‌شده، مدل *GRU* تک‌لایه بهترین عملکرد را در میان تمامی مدل‌های مورد بررسی از خود نشان داد و نه تنها از مدل‌های *GRU* عمیق‌تر (دو و سه لایه) بلکه از مدل معیار بلک-شولز نیز پیشی گرفت. نکته قابل تأمل آن است که مدل‌های *GRU* دو لایه و سه لایه، بر اساس شاخص *MAE*، عملکردی ضعیف‌تر از مدل بلک-شولز داشتند. این یافته نشان می‌دهد که برای این مجموعه داده خاص، افزایش عمق و پیچیدگی مدل و پشته‌سازی آن لزوماً به بهبود دقت پیش‌بینی‌ها منجر نمی‌شود و حتی ممکن است به دلیل افزایش ریسک بیش‌برازش، به تضعیف عملکرد بینجامد. در این پژوهش مدل ساده‌تر تک‌لایه توانسته است الگوی اصلی داده‌ها را با کارایی بیشتری بیاموزد و بر روی مجموعه داده آزمون عملکرد دقیق‌تری داشته باشد.

۵- نتایج‌گیری و پی‌شهادها

پیش‌بینی قیمت اختیار معامله به دلیل ماهیت پیچیده و غیرخطی بازارهای مالی، همواره یک چالش اساسی بوده است. این پژوهش با هدف مقایسه کارایی مدل یادگیری ژرف *GRU* و مدل کلاسیک بلک-شولز در قیمت‌گذاری اختیار معامله خرید اروپایی بر روی سهام شرکت ایران خودرو انجام شد. نتایج به‌وضوح نشان داد که مدل *GRU* با یک لایه، به دلیل انعطاف‌پذیری بالاتر در شناسایی الگوهای پیچیده داده‌های مالی، توانسته است پیش‌بینی‌های دقیق‌تری نسبت به مدل بلک-شولز و همچنین معماری‌های ژرف‌تر *GRU* ارائه دهد.

باتوجه به برتری عملکرد مدل *GRU* تک‌لایه می‌توان نتیجه گرفت که برای بازه زمانی و دارایی پایه مورد مطالعه، این مدل ابزاری کارآمد و قابل اتکا برای قیمت‌گذاری اختیار معامله است. توانایی این مدل در ارائه برآوردهای دقیق‌تر می‌تواند به سرمایه‌گذاران و تحلیل‌گران مالی در فرایند ارزش‌گذاری و تصمیم‌گیری‌های معاملاتی کمک شایانی نماید.

باتوجه به یافته‌های این پژوهش و به‌منظور گسترش دانش در این حوزه، موارد زیر برای تحقیقات آتی پیشنهاد می‌شود:

۱. بررسی سایر معماری‌های یادگیری ژرف: ارزیابی و مقایسه عملکرد مدل‌های دیگری مانند *LSTM* و شبکه‌های عصبی پیچشی (*CNN*) می‌تواند به شناسایی بهترین معماری برای این نوع داده‌ها کمک کند.
۲. بهینه‌سازی ابرپارامترها: استفاده از روش‌های بهینه‌سازی ابرپارامترها می‌تواند به دستیابی به مدلی با عملکرد بالاتر منجر شود.
۳. تحلیل حساسیت ورودی نوسان‌پذیری: از آنجا که نوسان‌پذیری یکی از ورودی‌های کلیدی در مدل‌های قیمت‌گذاری است، پیشنهاد می‌شود تاثیر استفاده از دوره‌های زمانی مختلف برای محاسبه نوسان‌پذیری تاریخی بر دقت هر دو مدل بلک-شولز و یادگیری ژرف مورد مطالعه قرار گیرد.
۴. مقایسه آماری نتایج
۵. گسترش مجموعه داده: تکرار این پژوهش بر روی سهام شرکت‌های دیگر و در بازه‌های زمانی طولانی‌تر می‌تواند به ارزیابی قدرت تعمیم‌پذیری یافته‌ها کمک کند.

منابع

- [1] Sisodia, N., & Gor, R. (2021). A study on the effect of historical volatility using two option pricing models. *IOSR journal of economics and finance (IOSR-JEF)*, 12(1), 19–26. <https://doi.org/10.9790/5933-1201031926>
- [2] Lin, L., Wang, M., Cheng, H., Liu, R., & Chen, F. (2023). OptionNet: A multiscale residual deep learning model with confidence interval to predict option price. *The journal of finance and data science*, 9, 100105. <https://doi.org/10.1016/j.jfds.2023.100105>
- [3] Schneider, J., & Helms, N. (2021). *Early exercise of American call options under negative interest rates*. <https://dx.doi.org/10.2139/ssrn.3854489>
- [4] Liang, L., & Cai, X. (2022). Time-sequencing European options and pricing with deep learning—Analyzing based on interpretable ALE method. *Expert systems with applications*, 187, 115951. <https://doi.org/10.1016/j.eswa.2021.115951>
- [5] Wang, C., Chen, Y., Zhang, S., & Zhang, Q. (2022). Stock market index prediction using deep Transformer model. *Expert systems with applications*, 208, 118128. <https://doi.org/10.1016/j.eswa.2022.118128>
- [6] Arin, E., & Ozbayoglu, A. M. (2022). Deep learning based hybrid computational intelligence models for options pricing. *Computational economics*, 59(1), 39–58. <https://doi.org/10.1007/s10614-020-10063-9>
- [7] Funahashi, H. (2021). Artificial neural network for option pricing with and without asymptotic correction. *Quantitative finance*, 21(4), 575–592. <https://doi.org/10.1080/14697688.2020.1812702>
- [8] Wysocki, M., & Ślepaczuk, R. (2022). Artificial neural networks performance in WIG20 index options pricing. *Entropy*, 24(1). <https://doi.org/10.3390/e24010035>

- [9] Wang, W., & Xu, J. (2024). Deep learning option price movement. *Risks*, 12(6), 1-17. <https://doi.org/10.3390/risks12060093>
- [10] Shvimer, Y., & Zhu, S. P. (2024). Pricing options with a new hybrid neural network model. *Expert systems with applications*, 251. <https://doi.org/10.1016/j.eswa.2024.123979>
- [11] Schröer, C., Kruse, F., & Gómez, J. M. (2021). A systematic literature review on applying CRISP-DM process model. *Procedia computer science*, 181, 526–534. <https://doi.org/10.1016/j.procs.2021.01.199>
- [12] Zhang, Y., & Tumibay, G. M. (2024). Stock price prediction based on the Bi-GRU-attention model. *Journal of computer and communications*, 12(4), 72–85. <https://doi.org/10.4236/jcc.2024.124007>
- [13] Muhammad, A. U., Yahaya, A. S., Kamal, S. M., Adam, J. M., Muhammad, W. I., & Elsafi, A. (2020). A hybrid deep stacked lstm and gru for water price prediction. *2020 2nd international conference on computer and information sciences (ICCIS)* (pp. 1–6). IEEE. <https://doi.org/10.1109/ICCIS49240.2020.9257651>
- [14] Black, F., & Scholes, M. (1973). The pricing of options and corporate liabilities. *Journal of political economy*, 81(3), 637–654. <https://doi.org/10.1086/260062>
- [15] Merton, R. C. (1973). Theory of rational option pricing. *The bell journal of economics and management science*, 4(1), 141–183. <https://doi.org/10.1142/5860>
- [16] Hull, J. C. (2018). *Risk management and financial institutions*. Wiley & Sons. <https://www.wiley.com/en-fr/shop/general-finance-investments/risk-management-and-financial-institutions-6th-edition-p-9781119932482>