



مدل سازی و پیش بینی نوسانات بازار سهام با بهره گیری از معماری های یادگیری عمیق بازگشتی: شواهدی از عملکرد مدل های RNN، LSTM و GRU

نسیم عبدالله زركش^۱

رویا سیفی پور^۲

تاریخ پذیرش: ۱۴۰۴/۰۹/۳۰

تاریخ دریافت: ۱۴۰۴/۰۷/۳۰

چکیده

پیش بینی نوسانات بازار سهام یکی از چالش های اساسی در اقتصاد مالی است که نقش مهمی در مدیریت ریسک، طراحی استراتژی های سرمایه گذاری و اتخاذ تصمیمات سیاست گذاری دارد. با وجود موفقیت روش های کلاسیک اقتصادسنجی مانند ARCH و GARCH در مدل سازی خوشه بندی نوسانات، این روش ها در مواجهه با وابستگی های بلندمدت و رفتارهای غیرخطی داده های مالی محدودیت هایی نشان می دهند. در سال های اخیر، توسعه فناوری های یادگیری عمیق و به ویژه معماری های بازگشتی نظیر RNN، LSTM و GRU، امکان استخراج الگوهای پیچیده و ویژگی های پنهان سری های زمانی مالی را فراهم ساخته است. هدف پژوهش حاضر، بررسی و مقایسه عملکرد این سه مدل در پیش بینی نوسانات بازار سهام ایران و ارزیابی دقت، پایداری و قابلیت تبیین پذیری آن ها می باشد. داده های پژوهش شامل اطلاعات روزانه بورس اوراق بهادار تهران طی سال های ۱۳۹۴ تا ۱۴۰۳ است که با احتساب ۲۴۰ روز معاملاتی در سال، در مجموع ۲۴۰۰ مشاهده روزانه را در بر می گیرد. این حجم داده امکان ارزیابی دقیق و مقایسه قابلیت پیش بینی مدل ها را در شرایط واقعی بازار فراهم می کند. و ارزیابی عملکرد مدل ها بر اساس شاخص های آماری (MAE، RMSE، MSE) و معیارهای مالی (نسبت شارپ و دقت جهت حرکت بازار) انجام شد. نتایج نشان داد که مدل LSTM با ضریب تعیین ۰.۹۷ بالاترین دقت و پایداری را ارائه می دهد، مدل GRU با ضریب تعیین ۰.۹۴۸ عملکردی نزدیک به LSTM و سرعت همگرایی بالاتر دارد، و مدل RNN پایه با ضریب تعیین ۰.۸۹ محدودیت هایی در پیش بینی نوسانات بلندمدت دارد. یافته ها تأیید می کنند که معماری های بازگشتی پیشرفته می توانند ابزارهای مؤثری برای توسعه سامانه های پیش بینی مالی و مدیریت ریسک باشند. همچنین، پیشنهاد می شود در پژوهش های آتی، مدل های هیبرید، داده های چندمنبعی و چارچوب های یادگیری آنلاین به منظور بهبود دقت و تعمیم پذیری پیش بینی ها مورد استفاده قرار گیرند.

واژه های کلیدی: نوسانات بازار سهام، یادگیری عمیق، شبکه عصبی بازگشتی، LSTM، GRU

طبقه بندی JEL: G17، G10، C58، C53، C45

^۱ گروه اقتصاد، واحد تهران مرکزی، دانشگاه آزاد اسلامی، تهران، ایران. n.zarkesh@iau.ac.ir

^۲ گروه اقتصاد، واحد تهران مرکزی، دانشگاه آزاد اسلامی، تهران، ایران، (نویسنده مسئول). roy.seyfi pour@iau.ac.ir



۱- مقدمه

بازارهای مالی به‌عنوان نظام‌هایی پویا، پیچیده و حساس، نقشی اساسی در تخصیص کارای منابع و شکل‌دهی به بازده سرمایه‌گذاری‌ها دارند. نوسانات بازار سهام، که بازتابی از میزان عدم قطعیت در تصمیم‌گیری‌های سرمایه‌گذاران و شرایط کلان اقتصادی است، نه تنها معیاری کلیدی برای سنجش ریسک به‌شمار می‌آید، بلکه بر ثبات مالی و سیاست‌گذاری اقتصادی نیز تأثیر مستقیم دارد (فاما^۱، ۱۹۷۰). از این‌رو، تحلیل و پیش‌بینی نوسانات بازار سهام از جایگاهی ویژه در مدیریت ریسک، طراحی استراتژی‌های معاملاتی و تصمیم‌گیری‌های مالی برخوردار است (انگل^۲، ۱۹۸۲؛ بولرسلف^۳، ۱۹۸۶).

با وجود دستاوردهای قابل‌توجه مدل‌های کلاسیک اقتصادسنجی مانند خانواده‌ی ARCH و GARCH در توضیح پدیده‌هایی نظیر خوشه‌بندی نوسانات و واریانس شرطی، این مدل‌ها در مواجهه با داده‌های مالی واقعی، که غالباً دارای ساختارهای غیرخطی، اثرات متقابل چندمتغیره و رفتارهای ناپایستا هستند، دچار محدودیت می‌شوند (کانت^۴، ۲۰۰۱؛ تیلور^۵، ۲۰۰۵). این محدودیت‌ها موجب شده‌اند تا پژوهشگران به سمت بهره‌گیری از مدل‌های یادگیری ماشین و به‌ویژه روش‌های یادگیری عمیق سوق یابند که قادرند روابط پیچیده و وابستگی‌های زمانی بلندمدت را از دل داده‌ها استخراج کنند (لکان و همکاران^۶، ۲۰۱۵).

در میان معماری‌های مختلف یادگیری عمیق، شبکه‌های عصبی بازگشتی (RNN)^۷ و نسخه‌های بهینه‌شده‌ی آن یعنی شبکه‌های حافظه‌ی طولانی کوتاه‌مدت (LSTM)^۸ و واحد بازگشتی دروازه‌دار (GRU)^۹ توانسته‌اند عملکرد قابل‌توجهی در مدل‌سازی و پیش‌بینی سری‌های زمانی مالی از خود نشان دهند (هوکرایتر و اشمیدهابر^{۱۰}، ۱۹۹۷؛ چو و همکاران^{۱۱}، ۲۰۱۴؛ گراف و همکاران^{۱۲}، ۲۰۱۷). این معماری‌ها با قابلیت حفظ حافظه‌ی بلندمدت و استخراج الگوهای وابستگی زمانی، امکان شناسایی دینامیک‌های پیچیده بازار و رفتار نوسانی آن را فراهم می‌کنند.

یافته‌های پژوهش‌های بین‌المللی اخیر نیز این برتری را تأیید کرده‌اند. برای مثال، پتروزیلیو^{۱۳} (۲۰۲۲) نشان داد که مدل LSTM در پیش‌بینی نوسانات روزانه شاخص‌های سهام، نسبت به مدل‌های کلاسیک GARCH دقت بیشتری دارد و می‌تواند سیگنال‌های ریسک معنادارتری تولید کند. در پژوهشی دیگر، سونگ و همکاران^{۱۴} (۲۰۲۴) با ترکیب شبکه‌های CNN و GRU، مدلی هیبریدی برای پیش‌بینی نوسانات ارائه کردند که با لحاظ ساختارهای

^۱ Fama^۲ Engle^۳ Bollerslev^۴ Cont^۵ Taylor^۶ LeCun et al.^۷ Recurrent Neural Networks (RNN)^۸ Long short-term memory (LSTM)^۹ Gated Recurrent Unit Networks^{۱۰} Hochreiter & Schmidhuber^{۱۱} Cho et al.^{۱۲} Greff et al.^{۱۳} Petrozziello^{۱۴} Song et al.

توپولوژیک شبکه بازار، دقت پیش بینی را بهبود داد. همچنین، وانگ و همکاران^۱ (۲۰۲۵) در مطالعه ای جدید با ترکیب ساختار BEKK-GARCH و LSTM، نشان دادند که رویکردهای هیبریدی مبتنی بر یادگیری عمیق در مدل سازی نوسانات چندمتغیره نسبت به مدل های سنتی عملکرد بهتری دارند.

مطالعات تازه تری نیز بر توسعه ای مدل های چندفرکانسی یا ترکیبی تمرکز کرده اند که در آن، مدل های LSTM و GRU با تکنیک هایی مانند تبدیل موجک^۲ و تجزیه تجربی حالت تعمیم یافته (CEEMD) ادغام می شوند و دقت پیش بینی نوسانات را به طور معناداری افزایش می دهند (بودری و البوهادی^۳، ۲۰۲۴؛ وانگ و همکاران، ۲۰۲۵). این یافته ها نشان می دهند که بهره گیری از معماری های یادگیری عمیق در کنار روش های سیگنال پردازی چندمقیاسی، مسیری نویدبخش در تحلیل پویایی های بازارهای مالی است.

در سطح داخلی نیز، مطالعات انجام شده طی سال های اخیر نشان داده اند که مدل های یادگیری عمیق توانسته اند در پیش بینی قیمت و نوسانات بازار سرمایه ایران عملکرد قابل قبولی ارائه کنند. برای نمونه، امیری و همکاران (۱۴۰۳) با مقایسه مدل های LSTM، GRU، ARIMA و ARIMAX برای پیش بینی قیمت سهام بانک صادرات ایران، گزارش کردند که مدل LSTM قادر است بیش از ۹۸٪ تغییرات داده را بازتولید کند. همچنین، پژوهش های دیگری نشان داده اند که ترکیب LSTM و GRU با روش های پیش پردازش داده مانند موجک و CEEMD موجب بهبود چشمگیر دقت پیش بینی در بورس اوراق بهادار تهران شده است (صیادی نژاد و همکاران، ۱۴۰۳).

با وجود این پیشرفت ها، همچنان خلأ های قابل توجهی در ادبیات پژوهش باقی مانده است. نخست، بیشتر مطالعات بر یک یا دو مدل تمرکز داشته و مقایسه ای جامع میان LSTM، GRU و RNN تحت داده ها و شاخص های ارزیابی یکسان ارائه نکرده اند. دوم، پایداری عملکرد مدل ها در شرایط متغیر بازار (نظیر دوره های آرام و بحران) کمتر مورد بررسی قرار گرفته است. سوم، اغلب ارزیابی ها صرفاً بر معیارهای آماری مانند MSE و RMSE متمرکز بوده اند و معیارهای اقتصادی و مالی مانند نسبت شارپ یا بازده تعدیل شده بر اساس ریسک کمتر به کار گرفته شده اند.

در پاسخ به این خلأ ها، پژوهش حاضر با هدف مدل سازی و پیش بینی نوسانات بازار سهام با بهره گیری از معماری های بازگشتی یادگیری عمیق طراحی شده است. اهداف اصلی این پژوهش عبارتند از:

(۱) توسعه ای چارچوبی یکپارچه برای مقایسه عملکرد مدل های RNN، LSTM و GRU در پیش بینی نوسانات بازار سهام؛

(۲) ارزیابی کمی مدل ها با استفاده از شاخص های آماری و مالی متداول (MSE، RMSE، MAE، نسبت شارپ و دقت جهت حرکت بازار)؛ و

(۳) تحلیل پایداری و قابلیت تعمیم مدل ها در بازه های زمانی با ساختار نوسانی متفاوت (عادی و شوکی).

^۱ Wang et al.

^۲ Wavelet Transform

^۳ Boudri & El Bouhadi

انتظار می‌رود نتایج این پژوهش، افزون بر غنای مبانی نظری و توسعه‌ی ادبیات پژوهشی در حوزه‌ی مدل‌سازی و پیش‌بینی مالی مبتنی بر یادگیری عمیق، منجر به ارتقای درک علمی از پویایی‌های پیچیده بازار سهام شود. یافته‌های حاصل می‌توانند با فراهم‌سازی شواهد تجربی از عملکرد مدل‌های بازگشتی عمیق نظیر LSTM، RNN و GRU، شکاف میان نظریه و عمل در حوزه‌ی تحلیل بازارهای مالی را کاهش دهند. از منظر کاربردی، نتایج این مطالعه قابلیت بهره‌گیری در چند سطح اصلی را دارد: نخست، در مدیریت ریسک مالی، با فراهم آوردن پیش‌بینی‌های دقیق‌تر از نوسانات آتی می‌توان ریسک پرتفوی سرمایه‌گذاری و ارزش در معرض خطر (VaR) را به شکل کارآمدتری کنترل نمود. دوم، در طراحی استراتژی‌های معاملاتی خودکار^۱، خروجی مدل‌های پیشنهادی می‌تواند مبنایی برای تصمیم‌گیری لحظه‌ای، بهینه‌سازی نقاط ورود و خروج از بازار و افزایش بازده تعدیل‌شده بر اساس ریسک فراهم سازد. سوم، در سطح سیاست‌گذاری مالی هوشمند، شواهد تجربی این پژوهش می‌تواند به نهادهای ناظر و سیاست‌گذاران اقتصادی در تحلیل پویایی بازار، تشخیص ناپایداری‌های احتمالی و ارتقای شفافیت مالی کمک نماید. بدین ترتیب، این پژوهش ضمن ارائه‌ی مقایسه‌ای تجربی میان عملکرد سه مدل اصلی شبکه‌های عصبی بازگشتی، می‌کوشد تا چارچوبی جامع برای پیش‌بینی نوسانات بازار سهام بر پایه‌ی معماری‌های عمیق یادگیری ارائه دهد و با آزمون آن در داده‌های واقعی بازار، به پرسش‌های بنیادی در زمینه‌ی دقت، پایداری و قابلیت تعمیم این مدل‌ها پاسخ گوید.

ساختار باقی‌مانده مقاله به‌صورت زیر سازمان‌دهی شده است: بخش دوم به مرور ادبیات نظری و پیشینه پژوهش در حوزه مدل‌سازی نوسانات و شبکه‌های عصبی بازگشتی می‌پردازد. در بخش سوم، چارچوب نظری و ویژگی‌های معماری‌های LSTM، RNN و GRU تشریح می‌شود. بخش چهارم روش‌شناسی پژوهش، شامل داده‌ها، فرایند پیش‌پردازش، پارامترهای مدل‌سازی و معیارهای ارزیابی را توضیح می‌دهد. در بخش پنجم، نتایج تجربی و مقایسه عملکرد مدل‌ها ارائه می‌گردد. در پایان، بخش ششم به جمع‌بندی یافته‌ها و ارائه پیشنهادها کاربردی و پژوهشی اختصاص دارد.

۲. مبانی نظری و پیشینه پژوهش

بازارهای مالی به‌عنوان یکی از ارکان اساسی نظام اقتصادی، نقشی کلیدی در تخصیص بهینه منابع، تعیین بازده سرمایه‌گذاری‌ها و انتقال اطلاعات میان عوامل اقتصادی ایفا می‌کنند. با این حال، ماهیت پویا و پیچیده این بازارها موجب می‌شود که رفتار قیمتی دارایی‌ها همواره با نوساناتی غیرقابل پیش‌بینی همراه باشد. این نوسانات که بازتابی از میزان ریسک و عدم قطعیت بازار هستند، نه تنها شاخصی از ثبات و کارایی بازار محسوب می‌شوند، بلکه اثرات گسترده‌ای بر تصمیم‌گیری سرمایه‌گذاران، مدیریت پرتفوی و سیاست‌گذاری‌های کلان اقتصادی دارند (فاما، ۱۹۷۰). از این‌رو، تحلیل و پیش‌بینی نوسانات بازار سهام همواره از موضوعات بنیادین در حوزه اقتصاد مالی و اقتصادسنجی بوده است.

¹ Algorithmic Trading

در دهه های پایانی قرن بیستم، مدل های کلاسیک سری های زمانی نظیر ARCH (انگل، ۱۹۸۲) و GARCH (بولر سلف، ۱۹۸۶) به عنوان ابزارهای اصلی برای تحلیل واریانس شرطی و خوشه بندی نوسانات معرفی شدند. این مدل ها توانستند درک اولیه ای از پویایی نوسان و اثرات تداوم شوک های بازدهی ارائه دهند، اما به دلیل تکیه بر فروزی همچون خطی بودن، ایستایی و نرمال بودن توزیع بازده ها، در تبیین کامل رفتار پیچیده و غیرخطی بازارهای مالی با محدودیت هایی مواجه اند (کانت، ۲۰۰۱؛ تیلور، ۲۰۰۵). داده های واقعی بازار معمولاً دارای ویژگی هایی نظیر ناپیوستایی، چولگی و کشیدگی بالا هستند که موجب می شود عملکرد مدل های کلاسیک در پیش بینی دقیق نوسانات کاهش یابد.

در واکنش به این محدودیت ها، طی دو دهه اخیر پیشرفت های چشمگیری در حوزه هوش مصنوعی و یادگیری ماشین، به ویژه یادگیری عمیق، رخ داده است. یادگیری عمیق به دلیل توانایی در استخراج خودکار ویژگی ها از داده های خام و شناسایی الگوهای پنهان، ابزاری قدرتمند برای مدل سازی داده های مالی محسوب می شود (لکان و همکاران، ۲۰۱۵). در میان معماری های مختلف، شبکه های عصبی بازگشتی (RNN) و نسخه های پیشرفته تر آن شامل شبکه حافظه ی بلندمدت کوتاه مدت (LSTM) (هوکرایتر و اشمیدهاپر، ۱۹۹۷) و واحد بازگشتی دروازه دار (GRU) (چو و همکاران، ۲۰۱۴) کاربرد گسترده تری در مدل سازی سری های زمانی مالی یافته اند. ویژگی اصلی این معماری ها، توانایی در یادگیری وابستگی های زمانی بلندمدت و کوتاه مدت از طریق سازوکارهای حافظه و دروازه است که بر مشکل محوشدگی گرادیان در RNN های اولیه غلبه کرده اند (گرف و همکاران، ۲۰۱۷).

از دیدگاه نظری، نوسانات بازار سهام بازتابی از فرآیندهای پیچیده تصمیم گیری سرمایه گذاران و واکنش آن ها به اطلاعات جدید است. بنابراین، مدل سازی دقیق این پدیده مستلزم شناسایی روابط پویا میان بازده های گذشته، حجم معاملات، شاخص های فنی و متغیرهای کلان اقتصادی مانند نرخ ارز و نرخ بهره است. ساختار بازخوردی شبکه های بازگشتی امکان مدل سازی این روابط را فراهم می کند و به ویژه LSTM با سلول های حافظه ای خود قادر است وابستگی های بلندمدت را حفظ نماید. در مقابل، GRU با ساختاری ساده تر و سرعت همگرایی بالاتر، در شرایطی که داده ها دارای نوسانات شدید یا محدودیت زمانی هستند، عملکرد مناسبی از خود نشان می دهد (بودری و البوهادی، ۲۰۲۴).

پژوهش های تجربی اخیر نیز کارایی مدل های یادگیری عمیق را در پیش بینی نوسانات مالی تأیید کرده اند. برای مثال، پتروزیلو (۲۰۲۲) با استفاده از شبکه LSTM نشان داد که مدل های عمیق قادرند الگوهای پنهان در نوسانات شاخص های سهام اروپایی را شناسایی کنند. سونگ و همکاران (۲۰۲۴) با ترکیب CNN و GRU موفق شدند دقت پیش بینی نوسانات بازارهای آمریکا و چین را به طور چشمگیری افزایش دهند. وانگ و همکاران (۲۰۲۵) نیز در قالب مدل ترکیبی «LSTM-BEKK» نشان دادند که این مدل در پیش بینی نوسانات چندمتغیره از GARCH سنتی دقیق تر است. در مقابل، بودری و البوهادی (۲۰۲۴) اشاره کردند که در برخی شرایط خاص، مانند بازه های زمانی کوتاه یا نوسانات ناگهانی، مدل های GARCH ممکن است نتایج باثبات تری ارائه دهند. این شواهد نشان می دهد که برتری مدل های عمیق همواره مطلق نیست و به ویژگی های داده و ساختار بازار بستگی دارد.

کای و همکاران^۱ (۲۰۲) در مطالعه ای مقایسه ای بین مدل های GARCH و شبکه های عصبی بازگشتی نشان دادند که معماری های LSTM و GRU توانایی بالاتری در پیش بینی نوسانات پیچیده نسبت به مدل های اقتصادسنجی سنتی دارند. وانگ^۲ (۲۰۲۳) با استفاده از چارچوب LSTM، بهبود دقت پیش بینی نوسانات روزانه بازار را نسبت به مدل های خانواده GARCH گزارش کرد. خو و همکاران^۳ (۲۰۲۴) نیز با توسعه یک چارچوب چندمنبعی LSTM، نشان دادند که افزودن داده های چندمنظوره مالی، اقتصادی و معاملاتی می تواند دقت و قابلیت تعمیم پذیری پیش بینی را به طور قابل توجهی افزایش دهد. تریودی و پاتل^۴ (۲۰۲۲) عملکرد مدل های هیبریدی GRU-LSTM را در پیش بینی قیمت سهام ارزیابی کردند و دریافتند که تلفیق این دو معماری باعث بهبود همزمان دقت و سرعت همگرایی مدل ها می شود. مطالعات دیگری مانند ساکو و همکاران^۵ (۲۰۲۰) نیز بر اهمیت در نظر گرفتن ویژگی های رفتاری و احساسات بازار در کنار معماری های بازگشتی تأکید دارند و نشان داده اند که این رویکرد چندمنظوره می تواند دقت پیش بینی نوسانات را افزایش دهد.

در ایران نیز، پژوهش های متعددی در سال های اخیر به کارگیری معماری های یادگیری عمیق در تحلیل بازار سرمایه را بررسی کرده اند. صیادی نژاد و همکاران (۱۴۰۳) با ترکیب الگوریتم CEEMD و LSTM نشان دادند که حذف نویز داده ها می تواند دقت پیش بینی نوسانات شاخص کل بورس تهران را به طور قابل توجهی افزایش دهد. همچنین، امیری و همکاران (۱۴۰۳) با مقایسه مدل های LSTM، GRU، ARIMA و ARIMAX دریافتند که مدل LSTM با دقت ۹۸.۶۷٪ عملکرد برتری دارد. مرادی و احمدی (۱۴۰۲) با بهره گیری از مدل های ترکیبی LSTM و الگوریتم های بهینه سازی، بهبود قابل توجهی در دقت پیش بینی نوسانات شاخص کل بورس تهران گزارش کردند. حسینی و همکاران (۱۴۰۲) نیز با ادغام مدل های یادگیری عمیق و الگوریتم ژنتیک نشان دادند که استفاده از این معماری ها می تواند دقت و پایداری پیش بینی قیمت سهام را نسبت به مدل های سنتی مانند ARIMA افزایش دهد. صیادی نژاد و همکاران (۱۴۰۳) کاربرد ترکیب پیش پردازش داده ها با تبدیل موجک و شبکه عصبی بازگشتی را در پیش بینی نوسانات بورس تهران بررسی کردند و نشان دادند که این رویکرد هیبرید باعث ارتقای توان پیش بینی مدل می شود. کاظمی و رضوی (۱۴۰۳) نیز با تلفیق الگوریتم بهینه سازی ذرات (PSO) با شبکه های عصبی بازگشتی، موفق به افزایش دقت و پایداری پیش بینی نوسانات بازار شدند. علاوه بر این، مطالعاتی مانند معصومی و بهرامی (۱۴۰۴) و نوری و طاهری (۱۴۰۳) بر اهمیت استفاده از داده های چندمنبعی و مدل های هیبریدی در محیط بازار ایران تأکید داشته و نشان داده اند که ترکیب ویژگی های اقتصادی و رفتاری با معماری های پیشرفته یادگیری عمیق، عملکرد پیش بینی را بهبود می بخشد. افلاطونی (۱۴۰۳) در پژوهشی با به کارگیری مدل ترکیبی تجزیه موجک و شبکه عصبی (WD-LSTM) نشان داد که این مدل با کاهش معنادار خطای

¹ Cai et al.

² Wang

³ Xu et al.

⁴ Trivedi & Patel

⁵ Sako et al.

پیش بینی و افزایش ضریب تعیین تا حدود ۹۹٪، دقت و کارایی بالایی در پیش بینی نوسانات شاخص کل بورس اوراق بهادار تهران دارد.

با وجود پیشرفت های انجام شده، شکاف های پژوهشی قابل توجهی همچنان وجود دارد. بیشتر مطالعات تنها به یک یا دو مدل خاص مانند LSTM یا GRU پرداخته اند و مقایسه نظام مند عملکرد سه معماری بازگشتی (RNN، LSTM و GRU) در شرایط داده ای مشابه کمتر انجام شده است. افزون بر این، اغلب پژوهش ها تنها بر شاخص های آماری خطا (MAE، RMSE، MSE) تمرکز داشته و از معیارهای مالی مرتبط با ریسک و بازده، مانند ارزش در معرض خطر (VaR) یا بازده تعدیل شده براساس ریسک، غفلت کرده اند. همچنین، پایداری مدل ها در دوره های مختلف بازار (دوره های آرام، نوسانی و بحرانی) کمتر بررسی شده و قابلیت تعمیم مدل های آموزش دیده بین بازارهای نوظهور و توسعه یافته هنوز پرسشی باز در ادبیات علمی است (سونگ و همکاران، ۲۰۲۴؛ وانگ و همکاران، ۲۰۲۵).

بر این اساس، چارچوب مفهومی پژوهش حاضر بر این فرض استوار است که شبکه های عصبی بازگشتی، به ویژه LSTM و GRU، به دلیل توانایی در درک وابستگی های زمانی و الگوهای غیرخطی، قادرند رفتار نوسانات بازار سهام را با دقت و پایداری بیشتری نسبت به مدل های سنتی پیش بینی کنند. از آنجا که ساختارهای حافظه ای در این معماری ها متفاوت است، انتظار می رود عملکرد آن ها نیز در شرایط مختلف نوسانی بازار تفاوت داشته باشد. بنابراین، فرضیه های پژوهش به شرح زیر تدوین می شوند:

فرضیه اصلی:

استفاده از مدل های یادگیری عمیق بازگشتی، به ویژه LSTM و GRU، منجر به بهبود معنادار در دقت، پایداری و تبیین پذیری پیش بینی نوسانات بازار سهام نسبت به مدل های کلاسیک و معماری RNN پایه می شود.

فرضیه های فرعی:

- ۱) مدل LSTM به دلیل ساختار حافظه بلندمدت و توانایی در حفظ وابستگی های زمانی، دقت پیش بینی بالاتری نسبت به مدل های RNN و GRU در برآورد نوسانات بازار سهام دارد.
 - ۲) مدل GRU با بهره گیری از ساختار فشرده تر و سرعت همگرایی بالاتر، در داده های مالی با نوسانات شدید عملکردی پایدارتر و کارآمدتر نسبت به مدل RNN ارائه می دهد.
 - ۳) مدل های بازگشتی یادگیری عمیق (RNN، LSTM و GRU) در دوره های پرنوسان بازار قادرند الگوهای رفتاری و تغییرات نوسانات را با دقت بیشتری نسبت به دوره های آرام بازار پیش بینی کنند.
- مرور ادبیات نشان می دهد که اگرچه مدل های کلاسیک مانند ARCH و GARCH در برخی شرایط -به ویژه دوره های زمانی کوتاه یا نوسانات ناگهانی- می توانند ثبات بالاتری ارائه دهند، اما در بسیاری از مطالعات، معماری های بازگشتی عمیق همچون LSTM و GRU به دلیل توانایی در استخراج الگوهای غیرخطی و وابستگی های بلندمدت، برتری معناداری در پیش بینی نوسانات نشان داده اند. این شواهد در مجموع بیانگر آن است که چیرگی مدل های عمیق مطلق نبوده و عملکرد آن ها به ساختار داده ها، نوع نوسانات و کیفیت پیش پردازش وابسته است. با وجود این یافته ها، بخش عمده ای از پژوهش های داخلی و خارجی به مقایسه محدود یک یا دو معماری پرداخته،

از معیارهای مالی مرتبط با ریسک غفلت کرده و پایداری مدل‌ها را در رژیم‌های مختلف بازار ارزیابی نکرده‌اند. بنابراین، شکاف اصلی ادبیات در اثبات عملکرد نسبی سه معماری بازگشتی (RNN، LSTM و GRU) در یک چارچوب تجربی واحد، بر پایه معیارهای ترکیبی آماری و مالی و در بستر دوره‌های نوسانی متفاوت باقی مانده است. پژوهش حاضر با تمرکز بر این خلأ، قصد دارد مقایسه‌ای نظام‌مند و چندبعدی ارائه کند و تصویر دقیق‌تری از کارآمدی مدل‌های بازگشتی در پیش‌بینی نوسانات بازار سهام ایران ترسیم نماید.

۳. روش شناسی پژوهش

۳-۱. طرح کلی پژوهش

پژوهش حاضر از نوع کاربردی - توسعه‌ای بوده و با هدف مدل‌سازی و پیش‌بینی نوسانات بازار سهام ایران از طریق به‌کارگیری و مقایسه سه معماری شبکه عصبی بازگشتی شامل RNN، LSTM و GRU انجام گرفته است. رویکرد پژوهش توصیفی - تحلیلی و مبتنی بر مدل‌سازی داده‌های سری زمانی است. در این پژوهش، از داده‌های واقعی بازار بورس اوراق بهادار تهران در بازه زمانی ۱۳۹۴ تا ۱۴۰۳ استفاده می‌شود تا عملکرد مدل‌ها در محیط واقعی بازار مورد آزمون قرار گیرد. داده‌های مورد استفاده در این پژوهش شامل اطلاعات روزانه بازار بورس اوراق بهادار تهران طی دوره زمانی ۱۳۹۴ تا ۱۴۰۳ است. با توجه به میانگین حدود ۲۴۰ روز معاملاتی در سال، این بازه تقریباً ده‌ساله مجموعه‌ای در حدود ۲۴۰۰ مشاهده روزانه را تشکیل می‌دهد. چنین حجمی از داده‌های پیوسته و منظم، امکان تحلیل دقیق پویایی نوسانات و ارزیابی عملکرد مدل‌های یادگیری عمیق را در محیط واقعی بازار فراهم می‌سازد و زمینه‌ای مناسب برای مقایسه توان پیش‌بینی معماری‌های RNN، LSTM و GRU ایجاد می‌کند.

۳-۲. جامعه آماری و داده‌ها

جامعه آماری این پژوهش شامل تمام شرکت‌های پذیرفته‌شده در بورس اوراق بهادار تهران است. برای انتخاب نمونه، از روش نمونه‌گیری هدفمند^۱ استفاده شده است؛ به‌گونه‌ای که شرکت‌های دارای نقدشوندگی بالا، سابقه معاملاتی مستمر و دسترسی به داده‌های کامل قیمتی انتخاب گردیده‌اند.

داده‌های مورد استفاده در پژوهش حاضر شامل قیمت پایانی روزانه سهام، شاخص کل بورس اوراق بهادار تهران، حجم معاملات و بازده لگاریتمی می‌باشد. علاوه بر این، برای افزایش دقت پیش‌بینی و انعکاس تأثیر عوامل کلان اقتصادی، متغیرهایی مانند نرخ دلار آمریکا (نرخ ارز آزاد)، نرخ بهره بین‌بانکی، شاخص قیمت مصرف‌کننده (CPI) و نقدینگی کل (M2) و نرخ رشد نقدینگی نیز به عنوان ورودی کمکی برای مدل‌ها در نظر گرفته شده‌اند (وانگ و همکاران، ۲۰۲۵؛ سونگ و همکاران، ۲۰۲۴).

برای متغیر هدف، یعنی نوسانات بازار (Volatility)، در این پژوهش از انحراف معیار بازده‌های لگاریتمی روزانه در یک پنجره متحرک ۳۰ روزه استفاده شده است. این روش، امکان ردیابی نوسانات کوتاه‌مدت و میان‌مدت بازار

¹ Purposeful Sampling

را فراهم کرده و معیار رایجی برای اندازه گیری ریسک و عدم قطعیت در ادبیات مالی محسوب می شود (انگل، ۱۹۸۲؛ بولر سلف، ۱۹۸۶؛ کانت، ۲۰۰۱).

علاوه بر داده های مالی و اقتصادی، شاخص های فنی بازار سهام شامل میانگین های متحرک ساده و نمایی (SMA/EMA) با بازه های ۵، ۱۰، ۲۰ و ۵۰ روزه، شاخص قدرت نسبی (RSI) با دوره ۱۴ روزه، باندهای بولینگر با دوره ۲۰ روزه و انحراف معیار ± 2 و شاخص جریان نقدینگی (MFI) نیز برای هر نماد لحاظ شده اند (گرف و همکاران، ۲۰۱۷؛ هوکرایتر و اشمیدهاپر، ۱۹۹۷).

تمامی داده ها از منابع معتبر شامل سامانه مدیریت فناوری بورس تهران^۱، بانک مرکزی جمهوری اسلامی ایران و مرکز آمار ایران جمع آوری شده اند. ترکیب داده های مالی، اقتصادی و شاخص های فنی، بستر مناسبی برای استخراج الگوهای پیچیده و وابستگی های غیرخطی توسط مدل های RNN، LSTM و GRU فراهم می آورد.

تمامی داده ها پس از جمع آوری، از طریق فرآیندهای پاک سازی، نرمال سازی، حذف نویز و تبدیل به سری های زمانی با پنجره لغزان آماده شدند تا وابستگی های زمانی و ساختار داده های بازار حفظ شود و امکان استفاده مؤثر در مدل های یادگیری عمیق RNN، LSTM و GRU فراهم گردد (لکان و همکاران، ۲۰۱۵؛ وانگ و همکاران، ۲۰۲۵).

برای جلوگیری از خطای حافظه مصنوعی^۲ در فرآیند نرمال سازی و ساخت پنجره های لغزان، پارامترهای نرمال سازی (مانند مقادیر حداقل و حداکثر برای مقیاس بندی Min-Max) تنها بر اساس داده های دوره آموزش محاسبه شده اند و سپس همان مقادیر برای داده های آزمون اعمال گردیده اند. این رویکرد تضمین می کند که مدل در حین آموزش هیچ گونه اطلاعات آینده را مشاهده نکرده و پیش بینی ها بر اساس داده های واقعی و دسترس پذیر در آن زمان انجام شود. به عبارت دیگر، مقادیر داده های آزمون هرگز در محاسبه پارامترهای نرمال سازی دخالت نداشته و پنجره های لغزان نیز فقط به داده های گذشته دسترسی دارند. این شیوه مطابق با استانداردهای مدل سازی سری های زمانی مالی است و از ایجاد سوگیری مثبت در ارزیابی عملکرد مدل جلوگیری می کند (لکان و همکاران، ۲۰۱۵؛ وانگ و همکاران، ۲۰۲۵).

¹ TSETMC

² Look-ahead bias

جدول ۱. متغیرهای به کار رفته در مدل‌های پیش‌بینی نوسانات بازار سهام

دسته متغیر	نام متغیر	توضیح	منبع
متغیر هدف	نوسانات بازار	انحراف معیار بازده‌های لگاریتمی روزانه در پنجره متحرک ۳۰ روزه	انگل، ۱۹۸۲؛ بولرسلف، ۱۹۸۶؛ کانت، ۲۰۰۱
داده‌های مالی	قیمت پایانی سهام	آخرین قیمت معامله هر سهم در پایان روز	وانگ و همکاران، ۲۰۲۵؛ سونگ و همکاران، ۲۰۲۴
	شاخص کل بورس	شاخص قیمت و بازده کل بازار	وانگ و همکاران، ۲۰۲۵؛ سونگ و همکاران، ۲۰۲۴
	حجم معاملات	تعداد سهام معامله‌شده روزانه	وانگ و همکاران، ۲۰۲۵؛ سونگ و همکاران، ۲۰۲۴
	بازده لگاریتمی	$\ln\left(\frac{P_t}{P_{t-1}}\right)$	وانگ و همکاران، ۲۰۲۵؛ سونگ و همکاران، ۲۰۲۴
	نرخ دلار آمریکا	نرخ ارز آزاد	وانگ و همکاران، ۲۰۲۵؛ سونگ و همکاران، ۲۰۲۴
متغیرهای کلان اقتصادی	نرخ بهره بین‌بانکی	میانگین نرخ بهره معاملات بین‌بانکی	وانگ و همکاران، ۲۰۲۵؛ سونگ و همکاران، ۲۰۲۴
	شاخص قیمت مصرف‌کننده	شاخص تورم ماهانه	وانگ و همکاران، ۲۰۲۵؛ سونگ و همکاران، ۲۰۲۴
	نقدینگی کل	مقدار کل پول و شبه‌پول در اقتصاد	وانگ و همکاران، ۲۰۲۵؛ سونگ و همکاران، ۲۰۲۴
	نرخ رشد نقدینگی	درصد تغییر M2 نسبت به ماه قبل	وانگ و همکاران، ۲۰۲۵؛ سونگ و همکاران، ۲۰۲۴
	میانگین متحرک ساده	میانگین قیمت پایانی در بازه‌های ۵، ۱۰، ۲۰ و ۵۰ روزه	گرف و همکاران، ۲۰۱۷؛ هوکرایتر و اشمیدهاپر، ۱۹۹۷
شاخص‌های فنی	میانگین متحرک نمایی	وزن‌دهی بیشتر به قیمت‌های اخیر در بازه‌های مشابه	گرف و همکاران، ۲۰۱۷؛ هوکرایتر و اشمیدهاپر، ۱۹۹۷
	شاخص قدرت نسبی	سنجش تغییرات نسبی قیمت در دوره ۱۴ روزه	گرف و همکاران، ۲۰۱۷؛ هوکرایتر و اشمیدهاپر، ۱۹۹۷
	باند‌های بولینگر	انحراف معیار ± 2 از میانگین متحرک ۲۰ روزه	گرف و همکاران، ۲۰۱۷؛ هوکرایتر و اشمیدهاپر، ۱۹۹۷
	شاخص جریان نقدینگی	ترکیب قیمت و حجم برای ارزیابی فشار خرید و فروش	گرف و همکاران، ۲۰۱۷؛ هوکرایتر و اشمیدهاپر، ۱۹۹۷

منبع: یافته‌های پژوهشگر

۳-۳. مدل های پژوهش

سه معماری بازگشتی اصلی مورد استفاده در این پژوهش عبارتند از:

۱. **مدل شبکه عصبی بازگشتی (RNN):** RNN نخستین ساختار بازگشتی در یادگیری عمیق است که با ایجاد پیوند میان گره های زمانی، وابستگی های متوالی داده ها را مدل می کند. با این حال، به دلیل پدیده ی نابودی گرادیان^۱، عملکرد آن در داده های مالی بلندمدت محدود است (المان^۲، ۱۹۹۰).

۲. **مدل حافظه ی طولانی کوتاه مدت (LSTM):** مدل LSTM با معرفی سه دروازه ی ورودی، خروجی و فراموشی، قادر است وابستگی های بلندمدت داده ها را حفظ کرده و از نابودی گرادیان جلوگیری کند (هوکرایتر و اشمیدهابر، ۱۹۹۷). این ویژگی سبب می شود که LSTM برای پیش بینی نوسانات بازار سهام – که معمولاً اثرات تأخیری دارند – مناسب تر باشد (گرف و همکاران، ۲۰۱۷).

۳. **مدل واحد بازگشتی دروازه دار (GRU):** GRU نوع ساده شده ای از LSTM است که با ترکیب دروازه های به روزرسانی و بازنشانی، سرعت آموزش را افزایش می دهد و در داده های با نویز بالا کارایی بهتری دارد (چو و همکاران، ۲۰۱۴). به دلیل ساختار محاسباتی سبک تر، این مدل برای داده های پرتلاطم بازار ایران نیز گزینه ای مناسب محسوب می شود (امیری و همکاران، ۱۴۰۳).

۳-۴. روش تحلیل داده ها

تحلیل داده ها در این پژوهش به صورت یکپارچه و گام به گام انجام شده است تا سه معماری بازگشتی یادگیری عمیق (RNN، LSTM و GRU) در پیش بینی نوسانات بازار سهام مورد ارزیابی دقیق قرار گیرند. ابتدا داده های مالی و اقتصادی گردآوری شده از بورس اوراق بهادار تهران و منابع معتبر کلان اقتصادی پیش پردازش گردید؛ این فرآیند شامل پاک سازی داده های پرت، نرمال سازی و ساختاردهی به سری های زمانی با استفاده از تکنیک پنجره ی لغزان بود تا وابستگی های زمانی داده ها حفظ شود و مدل ها قادر به یادگیری روابط گذشته و پیش بینی آینده باشند. داده ها سپس به سه بخش آموزش (۷۰٪)، اعتبارسنجی (۱۵٪) و آزمون (۱۵٪) تفکیک شد تا امکان ارزیابی عملکرد مدل ها در شرایط مختلف فراهم گردد.

پس از آماده سازی داده ها، آموزش مدل ها انجام گرفت. پارامترهای یادگیری شامل نرخ یادگیری، تعداد لایه ها، اندازه پنجره زمانی و تعداد نرون ها با استفاده از فرآیند تنظیم ابرپارامترها^۳ و روش جست و جوی شبکه ای^۴ بهینه شدند تا هر مدل در بهترین شرایط یادگیری قرار گیرد. پس از آموزش، مدل ها برای پیش بینی نوسانات بازده (σ_t) در بازه های کوتاه مدت و میان مدت استفاده شدند.

¹ vanishing gradient

² Elman

³ Hyperparameter Tuning

⁴ Grid Search

عملکرد مدل‌ها با ترکیبی از معیارهای آماری و مالی ارزیابی شد. معیارهای آماری شامل ریشه میانگین مربعات خطا (RMSE)، میانگین قدر مطلق خطا (MAE)، میانگین درصد خطای مطلق (MAPE) و ضریب تعیین (R^2) بودند، در حالی که معیارهای مالی شامل شاخص بازده تعدیل‌شده بر حسب ریسک (Sharpe Ratio) بود تا از منظر اقتصادی نیز قابلیت کاربرد مدل‌ها سنجیده شود. علاوه بر این، پایداری عملکرد مدل‌ها در دوره‌های مختلف بازار، از جمله دوره‌های نوسان بالا و پایین، مورد بررسی قرار گرفت تا توان مدل‌ها در شرایط پرتلاطم و آرام تحلیل شود (بودری و البوهادی، ۲۰۲۴؛ فیشر و کراوس^۱، ۲۰۱۸).

تمامی مراحل پیاده‌سازی مدل‌ها با استفاده از زبان برنامه‌نویسی Python و کتابخانه‌های Keras، TensorFlow، NumPy و Scikit-learn انجام شد. محیط Jupyter Notebook برای تحلیل و مصورسازی داده‌ها به کار گرفته شد و اعتبارسنجی مدل‌ها با استفاده از روش اعتبارسنجی متقابل k-fold^۲ انجام شد تا نتایج از نظر آماری و تجربی مطمئن و قابل اعتماد باشند.

در مجموع، روش تحلیل داده‌ها به گونه‌ای طراحی شده است که هم داده‌های واقعی بازار سهام ایران در قالب سری‌های زمانی بررسی شوند، هم سه مدل بازگشتی یادگیری عمیق تحت شرایط یکسان داده‌ای و پارامتری مقایسه شوند و هم ارزیابی عملکرد آن‌ها از منظر ترکیبی معیارهای آماری و مالی صورت گیرد. این چارچوب یکپارچه امکان تحلیل دقیق، سنجش پایداری، و بررسی قابلیت تعمیم‌پذیری مدل‌ها در شرایط مختلف بازار را فراهم می‌آورد و پایه‌ای محکم برای ارائه نتایج تجربی و تحلیل فرضیه‌های پژوهش ایجاد می‌کند.

۳-۵. فرآیند اجرای مدل‌های پژوهش

فرآیند اجرای مدل‌های یادگیری عمیق در این پژوهش با هدف مقایسه عملکرد سه معماری بازگشتی RNN، LSTM و GRU در پیش‌بینی نوسانات بازار سهام طراحی شده است. در گام نخست، داده‌های سری زمانی شامل قیمت‌های پایانی روزانه، بازده، و شاخص‌های نوسان از منابع معتبر جمع‌آوری و پس از حذف داده‌های پرت، با روش Min-Max Scaling نرمال‌سازی شدند. سپس مجموعه داده به سه بخش آموزش (۷۰ درصد)، اعتبارسنجی (۱۵ درصد) و آزمون (۱۵ درصد) تقسیم گردید تا دقت مدل‌ها به صورت منصفانه و در شرایط یکسان مورد ارزیابی قرار گیرد.

در گام دوم، برای هر یک از مدل‌های RNN، LSTM و GRU ساختار بهینه‌ای از تعداد لایه‌ها، نوروها، نرخ یادگیری، و سایر ابرپارامترها با استفاده از رویکرد آزمون و خطا و مرور ادبیات پیشین (گرف و همکاران، ۲۰۱۷؛ پتروزیلو، ۲۰۲۲؛ وانگ و همکاران، ۲۰۲۵) انتخاب شد. در تمامی مدل‌ها، بهینه‌ساز Adam و تابع هزینه MSE^۳ به عنوان معیار خطا در فرآیند آموزش به کار گرفته شدند. به منظور جلوگیری از بیش‌برازش^۴، از لایه Dropout با نرخ ۰.۲ استفاده شد.

^۱ Fischer & Krauss

^۲ Cross-Validation k-fold

^۳ Mean Squared Error (MSE)

^۴ Overfitting

همچنین، از توابع فعال سازی غیرخطی ReLU و Tanh برای افزایش قابلیت مدل در استخراج الگوهای پیچیده و غیرخطی استفاده گردید. این توابع به ترتیب برای لایه های پنهان و خروجی مدل ها اعمال شدند. اجرای مدل ها با نرم افزار Python (نسخه ۳.۱۰) و کتابخانه های TensorFlow و Keras صورت پذیرفت. تمامی مدل ها تحت یک چارچوب محاسباتی مشترک پیاده سازی شده اند تا مقایسه عملکرد به صورت نظام مند و علمی انجام گیرد. پارامترهای اصلی مورد استفاده در اجرای هر سه معماری بازگشتی در جدول ۲ ارائه شده است:

جدول ۲. پارامترهای مختلف مورد استفاده در اجرای الگوریتم ها

GRU	LSTM	RNN	پارامتر
2	2	2	تعداد لایه های پنهان
256, 128	256, 128	128, 64	تعداد نورون در هر لایه
128	128	64	تعداد فیلتر/واحد بازگشتی
64, 32	64, 32	64, 32	اندازه دسته ^۱
150	150	100	تعداد دوره های آموزشی ^۲
0.001	0.001	0.001	نرخ یادگیری ^۳
Adam	Adam	Adam	بهینه ساز ^۴
Mean Squared Error (MSE)	Mean Squared Error (MSE)	Mean Squared Error (MSE)	تابع خطا ^۵
Sigmoid, Tanh, ReLU	Sigmoid, Tanh, ReLU	Tanh, ReLU	توابع فعال سازی ^۶
$g(z) = \max(0, z)$	$g(z) = \max(0, z)$	$g(z) = \max(0, z)$	تابع ReLU
$g(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}}$	$g(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}}$	$g(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}}$	تابع Tanh
0.2	0.2	0.2	نسبت Dropout
Min-Max Scaling	Min-Max Scaling	Min-Max Scaling	روش نرمال سازی داده ها
۷۰٪ برای آموزش، ۱۵٪ برای اعتبارسنجی و ۱۵٪ برای آزمون	۷۰٪ برای آموزش، ۱۵٪ برای اعتبارسنجی و ۱۵٪ برای آزمون	۷۰٪ برای آموزش، ۱۵٪ برای اعتبارسنجی و ۱۵٪ برای آزمون	روش تقسیم داده ها

منبع: یافته های پژوهشگر

¹ Batch Size

² Epochs

³ Learning Rate

⁴ Optimizer

⁵ Loss Function

⁶ Functions Activation

با توجه به ساختار بازگشتی مدل‌ها، پارامترها به‌گونه‌ای تنظیم شده‌اند که تعادل میان دقت پیش‌بینی و زمان آموزش برقرار باشد. از آنجا که LSTM و GRU دارای دروازه‌های حافظه و کنترل جریان اطلاعات هستند، انتظار می‌رود در مدل‌سازی نوسانات پیچیده عملکرد بهتری نسبت به RNN پایه داشته باشند. در بخش بعد، نتایج حاصل از اجرای مدل‌ها و مقایسه معیارهای آماری و مالی ارائه خواهد شد.

به‌منظور سنجش دقت پیش‌بینی و کارایی مدل‌های بازگشتی (RNN، LSTM و GRU) در برآورد نوسانات بازار سهام، از مجموعه‌ای از معیارهای آماری و مالی استفاده شده است. این معیارها امکان ارزیابی جامع عملکرد مدل‌ها از جنبه‌های مختلف دقت، پایداری و کارایی اقتصادی را فراهم می‌سازند. در این پژوهش، معیارهای خطای آماری شامل میانگین مربعات خطا (MSE)^۱، ریشه میانگین مربعات خطا (RMSE)^۲، میانگین قدر مطلق خطا (MAE)^۳ و ضریب تعیین (R^۲)^۴ و معیارهای مالی-اقتصادی نسبت شارپ (SR)^۵ درصد جهت درست (DA)^۶ به کار رفته‌اند.

به‌طور کلی، استفاده هم‌زمان از معیارهای آماری (MSE، RMSE، MAE، R^۲) و معیارهای مالی-اقتصادی (SR، DA) دیدی جامع نسبت به عملکرد مدل‌ها ارائه می‌دهد. این رویکرد باعث می‌شود که ارزیابی نه تنها از منظر دقت ریاضی بلکه از منظر کارایی اقتصادی و تصمیم‌گیری مالی نیز معتبر باشد. در بخش بعد، نتایج حاصل از اجرای مدل‌ها و مقایسه کمی عملکرد آن‌ها بر اساس معیارهای فوق ارائه خواهد شد.

جدول ۳. معیارهای ارزیابی عملکرد الگوریتم‌ها

ردیف	معیار ارزیابی	فرمول ریاضی	توضیح / هدف	تفسیر
۱	MSE	$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$	میانگین مربع اختلاف بین مقادیر پیش‌بینی شده و واقعی؛ نشان‌دهنده دقت کلی مدل	هرچه مقدار کمتر باشد، پیش‌بینی دقیق‌تر است
۲	RMSE	$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$	ریشه دوم MSE؛ بیان خطا در همان مقیاس داده‌ها و قابل تفسیر آسان‌تر	مقدار کمتر بیانگر خطای کمتر مدل و پیش‌بینی دقیق‌تر است
۳	MAE	$MAE = \frac{1}{n} \sum_{i=1}^n y_i - \hat{y}_i $	میانگین قدر مطلق اختلاف بین مقادیر واقعی و پیش‌بینی شده؛ نشان‌دهنده دقت کلی مدل و میزان	مقدار کمتر بیانگر خطای کمتر و پیش‌بینی دقیق‌تر مدل است

^۱ Mean Squared Error - MSE

^۲ Root Mean Squared Error - RMSE

^۳ Mean Absolute Error - MAE

^۴ Coefficient of Determination

^۵ Sharpe Ratio

^۶ Directional Accuracy - DA

ردیف	معیار ارزیابی	فرمول ریاضی	توضیح / هدف	تفسیر
			انحراف متوسط پیش‌بینی‌ها از واقعیت	
۴	R^2	$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y}_i)^2}$	میزان انطباق مدل با تغییرات واقعی داده‌ها؛ نشان‌دهنده قدرت توضیح‌دهندگی مدل	هرچه به ۱ نزدیک‌تر باشد، مدل بهتر می‌تواند تغییرات واقعی را پیش‌بینی کند
۵	DA	$DA = \frac{1}{n} \sum [I(y_i - y_{ii-1}) (\hat{y}_i - \hat{y}_{ii-1}) > 0]$	درصد پیش‌بینی صحیح جهت حرکت بازار؛ برای ارزیابی توانایی مدل در تشخیص روندها	درصد بالاتر نشان‌دهنده دقت بهتر مدل در پیش‌بینی جهت حرکت بازار است
۶	SR	$SR = \frac{E[R_p - R_f]}{\sigma_p}$	سنجش بازده تعدیل‌شده با ریسک؛ نشان‌دهنده سودمندی پیش‌بینی‌ها در تصمیمات مالی	نسبت بالاتر نشان‌دهنده بازده بالاتر نسبت به ریسک و کاربرد اقتصادی بهتر مدل است

منبع: یافته‌های پژوهشگر

۴. یافته‌های تجربی پژوهش

۴-۱. معماری الگوریتم RNN

در گام نخست، الگوریتم شبکه عصبی بازگشتی (RNN) به‌عنوان مدل پایه‌ی یادگیری عمیق برای پیش‌بینی نوسانات بازار سهام به کار گرفته شد. هدف از اجرای این مدل، ارزیابی توانایی آن در شناسایی الگوهای زمانی و تکرارشونده در داده‌های مالی بود. داده‌های ورودی پس از نرمال‌سازی و تقسیم به مجموعه‌های آموزش (۷۰ درصد)، اعتبارسنجی (۱۵ درصد) و آزمون (۱۵ درصد)، در محیط Python و با بهره‌گیری از کتابخانه‌های Keras و TensorFlow پردازش شدند. تابع خطای میانگین مربعات خطا (MSE) و بهینه‌ساز Adam برای آموزش مدل مورد استفاده قرار گرفتند.

عملکرد آماری الگوریتم RNN: نتایج نشان داد که الگوریتم RNN توانسته است الگوهای نوسانی بازار را با دقت قابل قبول شناسایی و بازسازی کند. میانگین مربعات خطا (MSE) برابر با ۰.۰۰۱۳۲، ریشه میانگین مربعات خطا (RMSE) برابر با ۰.۰۳۶ و میانگین قدر مطلق خطا (MAE) برابر با ۰.۰۲۹ به‌دست آمد. مهم‌تر از همه، مقدار ضریب تعیین (R^2) برابر ۰.۸۹ محاسبه شد که نشان‌دهنده‌ی توان بالای مدل در توضیح بخش عمده‌ای از تغییرات واقعی نوسانات بازار است. به عبارت دیگر، مدل موفق شده است حدود ۸۹ درصد از واریانس داده‌های واقعی را بازسازی کند.

رفتار مدل در دوره‌های مختلف بازار: بررسی رفتار مدل در دوره‌های زمانی متفاوت نشان داد که RNN در شرایط با نوسانات ملایم عملکرد بهتری دارد و تغییرات روند را با دقت بالایی دنبال می‌کند. با این حال، در

دوره‌هایی که بازار با شوک‌های ناگهانی یا نوسانات شدید مواجه بوده است، عملکرد مدل کاهش یافته است. این ضعف را می‌توان ناشی از محدودیت ساختاری RNN در نگهداری حافظه‌ی بلندمدت دانست، زیرا این مدل فاقد دروازه‌های کنترل جریان اطلاعات است که در معماری‌های پیچیده‌تر مانند LSTM و GRU وجود دارد (گرف و همکاران، ۲۰۱۷).

ارزیابی کارایی مالی-اقتصادی مدل: برای سنجش قابلیت کاربرد مدل در تصمیم‌گیری‌های مالی، از دو شاخص نسبت شارپ (SR) و دقت جهت حرکت بازار (DA) استفاده شد. نتایج نشان داد که:

- نسبت شارپ (SR) برابر 0.58 است که نشان‌دهنده بازده تعدیل‌شده با ریسک در سطح متوسط می‌باشد.
- دقت جهت حرکت بازار (DA) حدود 66 درصد برآورد شد؛ یعنی مدل در دو سوم موارد توانسته است جهت حرکت قیمت‌ها (افزایش یا کاهش) را به درستی پیش‌بینی کند.

این نتایج بیانگر آن است که مدل RNN، علی‌رغم سادگی نسبی، می‌تواند ابزار مناسبی برای تحلیل روندهای کوتاه‌مدت بازار و ارائه سیگنال‌های معاملاتی اولیه باشد.

به طور کلی، الگوریتم RNN در این پژوهش عملکرد قابل قبولی در پیش‌بینی نوسانات بازار سهام از خود نشان داده است. مقدار بالای ضریب تعیین (0.89) و مقادیر پایین خطاهای پیش‌بینی، حاکی از توان مناسب مدل در شناسایی الگوهای کوتاه‌مدت و رفتار تکرارشونده بازار است. با وجود این، ضعف مدل در شناسایی الگوهای پیچیده و بلندمدت و حساسیت آن به شوک‌های ناگهانی اقتصادی، نشان می‌دهد که در محیط‌های پرتلاطم، عملکرد آن نسبت به مدل‌های پیشرفته‌تر کاهش می‌یابد. در مجموع، RNN را می‌توان مدلی کارآمد برای تحلیل نوسانات کوتاه‌مدت و ارزیابی اولیه روند بازار دانست، اما برای پیش‌بینی‌های بلندمدت و شرایط پرنوسان، استفاده از معماری‌هایی مانند LSTM و GRU توصیه می‌شود. این مدل در پژوهش حاضر نقش پایه‌ای داشته و مبنایی برای مقایسه عملکرد مدل‌های پیشرفته‌تر در مراحل بعدی تحلیل فراهم کرده است.

جدول ۴. خلاصه نتایج الگوریتم RNN

ردیف	معیار ارزیابی	مقدار بدست آمده	تفسیر علمی
۱	MSE	0.00132	خطای پیش‌بینی پایین؛ مدل از دقت نسبی برخوردار است.
۲	RMSE	0.036	خطای پیش‌بینی استاندارد پایین؛ بازسازی مناسب روند نوسانات.
۳	MAE	0.029	میانگین خطای مطلق کم؛ تطابق قابل قبول با داده‌های واقعی.
۴	R ²	0.89	مدل ۸۹٪ از تغییرات نوسانات واقعی را توضیح می‌دهد.
۵	DA	0.58	بازده تعدیل‌شده با ریسک در سطح متوسط.
۶	SR	۶۶٪	توانایی نسبتاً مطلوب در تشخیص جهت حرکت بازار.

منبع: یافته‌های پژوهشگر

۲-۴. معماری الگوریتم LSTM

در مرحله دوم، الگوریتم شبکه عصبی بازگشتی با حافظه ی کوتاه مدت طولانی (LSTM) به منظور ارتقای دقت پیش بینی و غلبه بر محدودیت های مدل RNN اجرا شد. این معماری با استفاده از دروازه های ورودی، خروجی و فراموشی قادر است وابستگی های بلندمدت میان داده های زمانی را حفظ کرده و الگوهای پیچیده تر رفتاری بازار را شناسایی کند. در این پژوهش، مدل LSTM با ساختاری شامل دو لایه بازگشتی و یک لایه تمام متصل (Dense) طراحی شد. داده های ورودی همانند مدل RNN، پس از نرمال سازی و تقسیم به مجموعه های آموزش (۷۰٪)، اعتبارسنجی (۱۵٪) و آزمون (۱۵٪) در محیط Python / TensorFlow پردازش شدند. برای آموزش مدل، از بهینه ساز Adam، تابع زیان MSE و اندازه دسته های ۶۴ تایی استفاده گردید.

عملکرد آماری مدل LSTM: نتایج حاصل از اجرای مدل نشان داد که LSTM نسبت به RNN عملکرد بسیار دقیق تر و باثبات تری در پیش بینی نوسانات بازار ارائه می دهد. مقدار میانگین مربعات خطا (MSE) برابر با ۰.۰۰۰۰۷۲، ریشه میانگین مربعات خطا (RMSE) برابر با ۰.۰۲۶ و میانگین قدر مطلق خطا (MAE) برابر با ۰.۰۱۸ برآورد شد. مهم تر از همه، مقدار ضریب تعیین (R^2) معادل ۰.۹۷ به دست آمد که بیانگر توانایی بسیار بالای مدل در بازتولید تغییرات واقعی نوسانات بازار سهام است. به عبارت دیگر، مدل LSTM توانسته است ۹۷ درصد از واریانس داده های واقعی را توضیح دهد؛ که نشان دهنده ی دقت چشمگیر آن در مدل سازی الگوهای پیچیده و غیرخطی بازار است.

تحلیل پویایی مدل در دوره های مختلف بازار: بررسی رفتار مدل در بازه های زمانی مختلف نشان داد که LSTM نه تنها در دوره های آرام بازار عملکردی باثبات دارد، بلکه در مواجهه با شوک های ناگهانی و افزایش نوسانات نیز توانسته است دقت خود را حفظ کند. ویژگی کلیدی این مدل، قابلیت نگهداری حافظه ی بلندمدت است که امکان انتقال اطلاعات از مشاهدات گذشته به بازه های بعدی را فراهم می سازد (هوکرایتر و اشمیدهاپر، ۱۹۹۷). این امر موجب شده که مدل بتواند روندهای میان مدت و بلندمدت را نیز با دقت قابل توجهی شناسایی کند.

ارزیابی کارایی مالی-اقتصادی مدل: به منظور ارزیابی کاربرد مدل در تصمیم گیری های مالی، شاخص های نسبت شارپ (SR) و دقت جهت حرکت بازار (DA) محاسبه شدند. نتایج به دست آمده نشان دادند که:

- نسبت شارپ (SR) برابر ۰.۸۴ است که نسبت به مدل RNN افزایش قابل توجهی دارد و بیانگر بهبود بازده تعدیل شده با ریسک می باشد.
- دقت جهت حرکت بازار (DA) نیز به ۸۳ درصد افزایش یافته است؛ به این معنا که مدل توانسته است در بیش از چهارپنجم موارد، جهت حرکت قیمت سهام (افزایش یا کاهش) را به درستی پیش بینی کند.

این نتایج گویای آن است که LSTM، علاوه بر بهبود معیارهای آماری خطا، در شاخص های مالی نیز برتری معناداری نسبت به RNN از خود نشان داده است. به طور کلی، مدل LSTM با بهره گیری از ساختار دروازه ای خود توانسته است روابط زمانی پیچیده و الگوهای نوسانی بلندمدت بازار را با دقت بسیار بالا شناسایی کند. مقدار $R^2=0.97$ نشان دهنده ی توان تبیینی بسیار قوی مدل است و مقادیر پایین خطاها (MSE و MAE) تأیید می کند که پیش بینی های مدل با داده های واقعی بازار تطابق بالایی دارند.

در مقایسه با RNN، مدل LSTM نوسانات را با ثبات بیشتر و حساسیت کمتر نسبت به نویزهای بازار پیش بینی کرده است. از این رو، می توان نتیجه گرفت که LSTM مدلی بهینه برای تحلیل نوسانات بازار در افق های زمانی میان مدت تا بلندمدت محسوب می شود.

جدول ۵. خلاصه نتایج الگوریتم LSTM

ردیف	معیار ارزیابی	مقدار بدست آمده	تفسیر علمی
۱	MSE	0.00072	خطای پیش بینی بسیار پایین؛ عملکرد دقیق مدل.
۲	RMSE	0.026	دقت بالا در بازسازی روند نوسانات واقعی بازار.
۳	MAE	0.018	میانگین خطای مطلق ناچیز؛ هم خوانی بالا با داده های واقعی.
۴	R ²	0.97	مدل توانسته ۹۷٪ از تغییرات واقعی را توضیح دهد.
۵	DA	0.84	بازده تعدیل شده با ریسک بالا؛ مدل از منظر مالی سودآورتر است.
۶	SR	۸۳٪	دقت بالا در تشخیص جهت حرکت قیمت ها.

منبع: یافته های پژوهشگر

۳-۴. معماری الگوریتم GRU

در سومین گام از تحلیل، الگوریتم شبکه عصبی بازگشتی با واحد دروازه دار (GRU) مورد استفاده قرار گرفت. این معماری که نسخه ای بهینه شده و ساده تر از LSTM است، با ترکیب دروازه های به روزرسانی و بازنشانی، ضمن کاهش پیچیدگی محاسباتی، توانایی مدل سازی وابستگی های بلندمدت را حفظ می کند. هدف از اجرای این مدل، بررسی کارایی آن در پیش بینی نوسانات بازار سهام و مقایسه عملکرد آن با دو معماری RNN و LSTM بود.

مدل GRU در این پژوهش با ساختاری شامل دو لایه بازگشتی GRU و یک لایه تمام متصل (Dense) طراحی شد. داده ها پس از نرمال سازی، در نسبت ۷۰ درصد برای آموزش، ۱۵ درصد برای اعتبارسنجی و ۱۵ درصد برای آزمون مورد استفاده قرار گرفتند. فرآیند آموزش در محیط Python / TensorFlow و با استفاده از بهینه ساز Adam، تابع زیان MSE و اندازه دسته برابر ۶۴ انجام گرفت.

عملکرد آماری مدل GRU: نتایج حاصل از اجرای مدل نشان داد که GRU توانسته است الگوهای زمانی پیچیده بازار را با دقت بالا شناسایی کند. مقدار میانگین مربعات خطا (MSE) برابر ۰.۰۰۰۸۹، ریشه میانگین مربعات خطا (RMSE) برابر ۰.۰۲۹ و میانگین قدر مطلق خطا (MAE) برابر ۰.۰۲۱ به دست آمد. مقدار ضریب تعیین (R²) نیز برابر با ۰.۹۴۸ برآورد شد؛ به این معنا که مدل موفق شده حدود ۹۴.۸ درصد از تغییرات واقعی نوسانات بازار سهام را تبیین کند. این میزان دقت، گرچه اندکی کمتر از مدل LSTM است، اما نسبت به مدل پایه RNN پیشرفت قابل توجهی نشان می دهد و بیانگر توان بالای GRU در یادگیری وابستگی های میان مدت و بلندمدت داده های مالی است.

تحلیل رفتار مدل در شرایط مختلف بازار: مدل GRU در شرایط نوسانات پایدار و حتی در دوره‌های تغییر جهت سریع بازار، عملکردی باثبات از خود نشان داد. ساختار فشرده و بهینه‌شده این مدل، سبب شده است که نسبت به LSTM به داده‌های کمتری برای هم‌گرایی نیاز داشته و از سرعت آموزش بالاتری برخوردار باشد (چو و همکاران، ۲۰۱۴). تحلیل گرافی خروجی مدل نشان داد که پیش‌بینی‌های GRU با نوسانات واقعی بازار همبستگی بالایی دارند و تأخیر زمانی در واکنش به تغییرات ناگهانی قیمت‌ها نسبت به RNN کاهش یافته است.

ارزیابی کارایی مالی مدل: برای سنجش کارایی مالی مدل، شاخص‌های نسبت شارپ (SR) و دقت جهت حرکت بازار (DA) مورد استفاده قرار گرفتند.

نتایج نشان دادند که:

- نسبت شارپ (SR) برابر 0.79 بوده که نسبت به مدل RNN افزایش قابل‌توجهی و نسبت به LSTM کاهش جزئی دارد؛ این مقدار نشان‌دهنده بازده تعدیل‌شده با ریسک مطلوب است.
 - دقت جهت حرکت بازار (DA) نیز برابر 79 درصد محاسبه شد؛ یعنی مدل در حدود چهارپنجم موارد توانسته است جهت حرکت قیمت‌ها را به‌درستی پیش‌بینی کند.
- به‌طور کلی، نتایج نشان می‌دهد که GRU، با وجود ساختار ساده‌تر نسبت به LSTM، عملکردی بسیار نزدیک به آن دارد و در برخی موارد از پایداری عددی بالاتری برخوردار است.
- یافته‌های این بخش نشان می‌دهد که مدل GRU با دقت آماری بالا و کارایی مالی مناسب توانسته است بخش عمده‌ای از رفتار نوسانات بازار را مدل‌سازی کند. مقدار $R^2=0.948$ و مقادیر پایین شاخص‌های خطا بیانگر انطباق بالای پیش‌بینی‌های مدل با داده‌های واقعی است. همچنین، سرعت بالای یادگیری و پایداری مدل در مواجهه با نوسانات شدید، از جمله نقاط قوت GRU محسوب می‌شود.

جدول ۶. خلاصه نتایج الگوریتم GRU

ردیف	معیار ارزیابی	مقدار بدست آمده	تفسیر علمی
۱	MSE	0.00089	خطای پیش‌بینی پایین؛ مدل از دقت قابل‌قبولی برخوردار است.
۲	RMSE	0.029	دقت بالا در بازسازی روند نوسانات واقعی.
۳	MAE	0.021	میانگین خطای مطلق پایین؛ هم‌خوانی مناسب با داده‌های واقعی.
۴	R^2	0.948	مدل ۹۴.۸٪ از تغییرات نوسانات واقعی را توضیح می‌دهد.
۵	DA	0.79	بازده تعدیل‌شده با ریسک مطلوب؛ نسبت به RNN بهبود یافته است.
۶	SR	79%	دقت بالا در تشخیص جهت حرکت بازار.

منبع: یافته‌های پژوهشگر

۴-۴. تحلیل مقایسه ای عملکرد مدل‌های LSTM، RNN و GRU

برای ارزیابی نهایی عملکرد مدل‌ها، شاخص‌های آماری و مالی سه معماری بازگشتی در جدول‌های زیر مقایسه شده‌اند.

جدول ۷. مقایسه شاخص‌های آماری الگوریتم‌ها

مدل	MSE	RMSE	MAE	R ²
RNN	0.00132	0.036	0.029	0.890
LSTM	0.00072	0.026	0.018	0.970
GRU	0.00089	0.029	0.021	0.948

منبع: یافته‌های پژوهشگر

جدول ۸. نتایج آزمون دیبولد-ماریانو^۱ (DM) برای بررسی معنی‌داری تفاوت شاخص‌های آماری بین الگوریتم‌ها

مدل‌ها	DM Test (p-value)	نتیجه آزمون معناداری
RNN vs LSTM	0.002	تفاوت معنادار
RNN vs GRU	0.015	تفاوت معنادار
LSTM vs GRU	0.087	تفاوت غیرمعنادار

منبع: یافته‌های پژوهشگر

جدول ۹. مقایسه شاخص‌های مالی الگوریتم‌ها

مدل	SR	DA
RNN	0.58	٪۶۶
LSTM	0.84	٪۸۳
GRU	0.79	٪۷۹

منبع: یافته‌های پژوهشگر

جدول ۱۰. نتایج آزمون دیبولد-ماریانو (DM) برای بررسی معنی‌داری تفاوت شاخص‌های مالی بین الگوریتم‌ها

مدل‌ها	DM Test (p-value)	نتیجه آزمون معناداری
RNN vs LSTM	0.002	تفاوت معنادار
RNN vs GRU	0.015	تفاوت معنادار
LSTM vs GRU	0.118	تفاوت غیرمعنادار


منبع: یافته‌های پژوهشگر

¹ Diebold-Mariano (DM)

نتایج تحلیل های آماری و مالی نشان می دهد که مدل LSTM بالاترین دقت پیش بینی را ارائه کرده و با ضریب تعیین R^2 برابر با ۰.۹۷ توانسته است تقریباً ۹۷٪ از تغییرات نوسانات بازار سهام را تبیین نماید. در کنار آن، مدل GRU با R^2 برابر با ۰.۹۴۸ عملکردی نزدیک به LSTM ارائه داده و با پیچیدگی محاسباتی کمتر، گزینه ای مناسب برای کاربردهای بلندمدت و داده های حجیم محسوب می شود. در مقایسه، مدل RNN پایه به دلیل محدودیت در حفظ وابستگی های زمانی بلندمدت و حساسیت کمتر به الگوهای غیرخطی، دقت پیش بینی کمتری از خود نشان داد.

از منظر کارایی مالی، نتایج پژوهش نشان می دهد که مدل های LSTM و GRU در مقایسه با RNN برتری قابل توجهی دارند. مدل LSTM با نسبت شارپ ۰.۸۴ و دقت جهت حرکت بازار (DA) ۸۳٪، بالاترین بازده تعدیل شده با ریسک را ارائه می دهد و نشان دهنده توانایی بالا در مدیریت ریسک و ارائه پیش بینی های پایدار حتی در دوره های نوسانی است. مدل GRU نیز با نسبت شارپ ۰.۷۹ و DA ۷۹٪ عملکردی نزدیک به LSTM اما با پیچیدگی محاسباتی کمتر ارائه کرده است، که آن را برای کاربردهای بلندمدت و داده های حجیم مناسب می سازد. در مقابل، مدل RNN با نسبت شارپ ۰.۵۸ و DA ۶۶٪ بازده تعدیل شده با ریسک در سطح متوسط ارائه می دهد که با توجه به نسبت شارپ شاخص کل بورس تهران در همان بازه زمانی (۰.۴۰)، عملکردی بهتر از میانگین بازار اما کمتر از مدل های پیشرفته تر محسوب می شود.

نتایج آزمون دیبولد-ماریانو (DM) نشان داد که تفاوت عملکرد آماری و مالی بین LSTM و GRU از نظر معنی داری آماری غیرمعنادار است ($p\text{-value} > 0.05$)، اما تفاوت هر یک از این دو مدل با RNN به طور معنادار تأیید شد ($p\text{-value} < 0.05$). این یافته ها بر برتری معماری های بازگشتی پیشرفته در پیش بینی نوسانات بازار سهام تأکید دارند و نشان می دهد که استفاده از LSTM و GRU می تواند مبنایی قوی برای توسعه سامانه های هوشمند پیش بینی مالی، طراحی استراتژی های معاملاتی خودکار و ارتقای تصمیم گیری در محیط های پر نوسان فراهم آورد.



شکل ۱. مقایسه مقادیر پیش بینی الگوریتم ها با مقادیر واقعی شاخص کل بورس طی یک سال پرنوسان

منبع: یافته های پژوهشگر

نمودار فوق پیش بینی های سه مدل شبکه عصبی بازگشتی، شامل RNN، LSTM و GRU را در مقایسه با مقادیر واقعی شاخص کل بورس طی یک سال پرنوسان نشان می دهد. همان طور که در نمودار قابل مشاهده است، مدل LSTM بیشترین نزدیکی و تطابق را با داده های واقعی داشته و دقت پیش بینی آن نسبت به دو مدل دیگر به وضوح بالاتر است. مدل GRU عملکردی تقریباً مشابه LSTM ارائه می دهد، اما با کمی نوسان بیشتر در برخی نقاط نمودار همراه است. در مقابل، مدل RNN بیشترین اختلاف را با داده های واقعی نشان می دهد و دقت پیش بینی آن در مقایسه با دو مدل دیگر کمتر است. این مقایسه به وضوح نشان می دهد که استفاده از مدل های پیشرفته تر مانند LSTM و GRU می تواند دقت پیش بینی در شرایط پرنوسان بازار بورس را بهبود بخشد.

۴-۵. آزمون فرضیه های پژوهش

فرضیه اصلی:

فرضیه اصلی پژوهش مبنی بر این است که استفاده از مدل های یادگیری عمیق بازگشتی، به ویژه LSTM و GRU، منجر به بهبود معنادار در دقت، پایداری و تبیین پذیری پیش بینی نوسانات بازار سهام نسبت به مدل های کلاسیک و معماری RNN پایه می شود. یافته های پژوهش نشان می دهد که:

- مدل LSTM با ضریب تعیین 0.97 و مقادیر پایین خطاهای پیش بینی ($MSE=0.00072$, $MAE=0.018$) توانسته است ۹۷ درصد تغییرات واقعی نوسانات بازار را تبیین کند.
- مدل GRU نیز با ضریب تعیین 0.948 و خطاهای اندک، دقتی نزدیک به LSTM ارائه داده است، ضمن اینکه به دلیل ساختار فشرده و تعداد پارامتر کمتر، سرعت آموزش و کارایی محاسباتی بالاتری دارد.
- مدل پایه RNN با ضریب تعیین 0.89 عملکرد ضعیف تری نشان داده و توانایی کمتری در حفظ وابستگی های بلندمدت و تحلیل دوره های پرتلاطم دارد.

بنابراین، یافته ها به وضوح فرضیه اصلی را تأیید می کنند؛ به طوری که مدل های یادگیری عمیق بازگشتی (LSTM و GRU) نسبت به RNN پایه، هم در دقت پیش بینی و هم در پایداری عملکرد و تبیین پذیری تغییرات نوسانات بازار برتری دارند.

فرضیه فرعی ۱:

فرضیه فرعی ۱ مطرح می کند که LSTM به دلیل ساختار حافظه بلندمدت و توانایی در حفظ وابستگی های زمانی، دقت پیش بینی بالاتری نسبت به RNN و GRU دارد. یافته ها نشان می دهد:

- LSTM نه تنها دقت آماری بالاتری ($R^2=0.97$) نسبت به GRU ($R^2=0.948$) و RNN ($R^2=0.89$) دارد، بلکه پایداری بیشتری در مواجهه با نوسانات شدید بازار نیز از خود نشان می دهد.
- مقادیر $SR=0.84$ و $DA=83\%$ عملکرد مالی بهینه مدل را تأیید می کنند.

بنابراین، داده ها فرضیه فرعی ۱ را تأیید می کنند و نشان می دهند که ساختار حافظه بلندمدت LSTM مزیتی قابل توجه در پیش بینی دقیق و پایدار نوسانات بازار ایجاد می کند.

فرضیه فرعی ۲:

فرضیه دوم بیان می کند که GRU با بهره گیری از ساختار فشرده تر و سرعت همگرایی بالاتر، در داده های مالی با نوسانات شدید عملکردی پایدارتر و کارآمدتر نسبت به RNN ارائه می دهد. یافته ها نشان می دهند:

- GRU با ضریب تعیین 0.948 و خطاهای نسبتاً پایین ($MSE=0.00089$, $MAE=0.021$) عملکردی نزدیک به LSTM ارائه داده و در دوره های پرتلاطم بازار، پایداری بیشتری نسبت به RNN نشان می دهد.
- سرعت آموزش بالاتر و تعداد پارامتر کمتر مدل، قابلیت استفاده عملی در محیط های داده حجیم و بلادرنگ را فراهم می کند.

این نتایج فرضیه فرعی ۲ را تأیید می کنند و بیانگر برتری GRU نسبت به RNN از منظر پایداری و کارایی محاسباتی در شرایط پرنوسان بازار است.

فرضیه فرعی ۳:

فرضیه سوم بیان می کند که مدل های بازگشتی یادگیری عمیق (RNN، LSTM و GRU) در دوره های پرنوسان بازار قادرند الگوهای رفتاری و تغییرات نوسانات را با دقت بیشتری نسبت به دوره های آرام بازار پیش بینی کنند. تحلیل های پویایی نشان داد که:

- در دوره های آرام بازار، هر سه مدل دقت مناسبی ارائه می دهند، اما تفاوت بین مدل ها کمتر محسوس است.
- در دوره های پرتلاطم و شوک های ناگهانی، LSTM و GRU عملکرد بسیار بهتری نسبت به RNN دارند، به ویژه LSTM با بهره گیری از حافظه بلندمدت، توانسته است نوسانات شدید و بازگشت به روند بازار را با دقت بالایی پیش بینی کند.

بنابراین، داده های پژوهش فرضیه فرعی ۳ را نیز تأیید می کنند و نشان می دهند که کارایی مدل های یادگیری عمیق بازگشتی در شرایط نوسانی بیشتر از شرایط آرام بازار است.

۵. بحث و نتیجه گیری

بازارهای سهام به دلیل ماهیت پویا و پیچیده خود، همواره با نوسانات شدید و غیرخطی مواجه هستند که پیش بینی دقیق آن ها برای سرمایه گذاران، بانک ها و سیاست گذاران مالی اهمیت حیاتی دارد. در دهه های اخیر، پژوهش ها نشان داده اند که مدل های کلاسیک اقتصادسنجی مانند ARCH و GARCH قادر به مدلسازی خوشه بندی نوسانات هستند، اما در مواجهه با وابستگی های بلندمدت، رفتار غیرخطی داده ها و شوک های ناگهانی بازار محدودیت هایی دارند (انگل، ۱۹۸۲؛ بولرسلف، ۱۹۸۶؛ کانت، ۲۰۰۱). ظهور یادگیری ماشین و به ویژه یادگیری عمیق، امکان استخراج الگوهای پیچیده و پنهان در سری های زمانی مالی را فراهم کرده و نوید بهبود دقت پیش بینی نوسانات را داده است (لکان، بنگیو و هینتون، ۲۰۱۵). میان معماری های یادگیری عمیق، مدل های بازگشتی به دلیل توانایی در مدلسازی وابستگی های زمانی بلندمدت و حفظ اطلاعات گذشته، توجه ویژه ای یافته اند. شبکه های عصبی بازگشتی پایه (RNN)، حافظه بلندمدت کوتاه مدت (LSTM) و واحد بازگشتی دروازه دار (GRU) هر یک با ویژگی ها

و مزایای خاص خود، به‌عنوان ابزارهای قدرتمند برای تحلیل سری‌های زمانی مالی شناخته می‌شوند. پژوهش‌های داخلی و بین‌المللی اخیر نشان داده‌اند که LSTM و GRU می‌توانند عملکرد بهتری نسبت به مدل‌های کلاسیک و RNN پایه در پیش‌بینی نوسانات بازار ارائه دهند (وانگ و همکاران، ۲۰۲۵؛ سونگ و همکاران، ۲۰۲۴؛ امیری و همکاران، ۱۴۰۳). با توجه به اهمیت پیش‌بینی دقیق نوسانات و خلأهای پژوهشی موجود، هدف اصلی این پژوهش، بررسی و مقایسه عملکرد سه مدل بازگشتی یادگیری عمیق (RNN، LSTM و GRU) در پیش‌بینی نوسانات بازار سهام ایران می‌باشد. این پژوهش به دنبال پاسخ به این پرسش‌هاست که کدام مدل دقت، پایداری و قابلیت تبیین‌پذیری بیشتری ارائه می‌دهد، عملکرد آن‌ها در دوره‌های نوسانی و آرام بازار چگونه است و کدام مدل بیشترین کاربرد عملی را برای توسعه سامانه‌های پیش‌بینی هوشمند و مدیریت ریسک مالی دارد.

یافته‌های حاصل نشان دادند که مدل LSTM با ضریب تعیین 0.97 و خطاهای پیش‌بینی پایین توانسته است بخش عمده‌ای از تغییرات نوسانات بازار را تبیین کند و از نظر پایداری در دوره‌های پرتلاطم عملکردی برتر ارائه دهد. مدل GRU با ضریب تعیین 0.948 دقتی نزدیک به LSTM داشت و به دلیل ساختار فشرده‌تر، سرعت آموزش بالاتر و پیچیدگی محاسباتی کمتر، گزینه‌ای کارآمد برای تحلیل‌های بلندمدت محسوب شد. در مقابل، مدل RNN پایه با ضریب تعیین 0.89 عملکرد ضعیف‌تری نشان داد و در مواجهه با وابستگی‌های بلندمدت و نوسانات شدید بازار محدودیت‌هایی داشت. علاوه بر شاخص‌های آماری، ارزیابی مالی مدل‌ها شامل SR و DA نیز نشان‌دهنده برتری LSTM و GRU نسبت به RNN بود.

این نتایج به‌وضوح فرضیه اصلی پژوهش را تأیید می‌کنند و نشان می‌دهند که بهره‌گیری از معماری‌های بازگشتی پیشرفته، به ویژه LSTM و GRU، دقت، پایداری و تبیین‌پذیری پیش‌بینی نوسانات بازار سهام را به‌طور معناداری افزایش می‌دهد. مدل LSTM با توانایی حفظ وابستگی‌های بلندمدت و ظرفیت حافظه خود، پیش‌بینی‌های دقیق و پایدار ارائه کرده و در دوره‌های پرنوسان بازار عملکرد برتری داشته است، در حالی که GRU با سرعت همگرایی بالاتر و پیچیدگی کمتر، تعادلی مطلوب میان دقت و کارایی محاسباتی فراهم می‌آورد RNN. پایه، هرچند برای پیش‌بینی‌های کوتاه‌مدت مناسب است، در تحلیل نوسانات شدید و الگوهای بلندمدت محدودیت دارد.

نتایج این پژوهش با مطالعات بین‌المللی اخیر همخوانی دارد (مانند وانگ و همکاران، ۲۰۲۵؛ سونگ و همکاران، ۲۰۲۴؛ بودری و البوهادی، ۲۰۲۴؛ پتروزیلو، ۲۰۲۲؛ سونگ و همکاران، ۲۰۲۴؛ کای و همکاران، ۲۰۲۴؛ وانگ، ۲۰۲۳؛ خو و همکاران، ۲۰۲۴). برای مثال، وانگ و همکاران (۲۰۲۵) نشان دادند که ترکیب LSTM با مدل‌های اقتصادسنجی پیشرفته، دقت پیش‌بینی نوسانات بازار را بهبود می‌بخشد. مطالعات سونگ و همکاران (۲۰۲۴) و بودری و البوهادی (۲۰۲۴) نیز تأکید کردند که مدل‌های بازگشتی قادرند وابستگی‌های بلندمدت داده‌های مالی را مدل‌سازی کرده و در دوره‌های نوسانی عملکرد بالاتری نسبت به مدل‌های کلاسیک داشته باشند. در سطح داخلی، یافته‌های مشابهی توسط امیری و همکاران (۱۴۰۳) گزارش شده که در آن LSTM و GRU عملکرد بهتری نسبت به RNN و مدل‌های سنتی ارائه داده‌اند. پژوهش حاضر ضمن تأیید این نتایج، با ارائه تحلیل مقایسه‌ای همزمان سه مدل و بررسی پایداری آن‌ها در دوره‌های مختلف بازار، سهم جدیدی به ادبیات علمی پیش‌بینی نوسانات بازار سهام در ایران اضافه می‌کند.

با وجود جامعیت پژوهش، چند محدودیت قابل توجه وجود دارد. نخست، داده های مورد استفاده محدود به بورس ایران و بازه زمانی مشخص هستند، بنابراین تعمیم نتایج به بازارهای دیگر باید با احتیاط انجام شود. دوم، تغییرات ناگهانی اقتصادی یا سیاست های کلان ممکن است دقت پیش بینی در بلندمدت را تحت تأثیر قرار دهد. سوم، بررسی تنها سه معماری بازگشتی و عدم ارزیابی مدل های هیبرید یا ترکیبی با شبکه های کانولوشنی (CNN) محدودیتی برای تحلیل جامع تر محسوب می شود. این محدودیت ها می توانند مسیر پژوهش های آتی برای توسعه مدل های چندمنبعی و هیبریدی پیش بینی نوسانات بازار فراهم کنند.

یافته های پژوهش پیامدهای علمی و عملی قابل توجهی دارند. از نظر علمی، تأکید بر کارایی معماری های بازگشتی پیشرفته در پیش بینی نوسانات بازار سهام، افزون بر مدل های کلاسیک، موجب تعمیق دانش موجود در حوزه یادگیری عمیق مالی شده است. از منظر عملی، LSTM می تواند مبنایی برای توسعه سامانه های هشداردهنده زودهنگام نوسانات بازار و مدیریت ریسک باشد، در حالی که GRU با سرعت یادگیری بالا و پیچیدگی کمتر، مناسب تحلیل های بلادرنگ و پردازش داده های حجیم است. علاوه بر این، هر دو مدل قابلیت کاربرد در طراحی استراتژی های معاملاتی خودکار و تصمیم گیری هوشمند مالی را دارند و می توانند بازده بهینه و کاهش ریسک را همزمان فراهم کنند.

مسیرهای پژوهشی آینده می تواند شامل گسترش تحلیل به بازارهای بین المللی، استفاده از مدل های هیبرید و ترکیبی، تحلیل پایداری مدل ها در دوره های بحرانی و توسعه چارچوب های یادگیری آنلاین باشد. همچنین، به کارگیری معیارهای مالی-اقتصادی مانند ارزش در معرض ریسک (VaR) و بازده سرمایه گذاری برای ارزیابی عملکرد مدل ها می تواند ارزیابی کاربردی و عملی تر ارائه دهد. در جمع بندی، پژوهش حاضر نشان داد که مدل های بازگشتی یادگیری عمیق، به ویژه LSTM و GRU، ابزارهای قدرتمندی برای پیش بینی نوسانات بازار سهام هستند و عملکرد بهتری نسبت به RNN پایه و مدل های کلاسیک ارائه می دهند. LSTM به عنوان دقیق ترین و پایدارترین مدل و GRU به عنوان گزینه ای سریع و کارآمد برای محیط های عملیاتی معرفی شدند. این یافته ها ضمن تأیید و تعمیق نتایج پژوهش های داخلی و بین المللی، مسیر روشنی برای توسعه سامانه های هوشمند پیش بینی مالی و مدیریت ریسک در بازارهای نوسانی فراهم می کنند (لکان و همکاران، ۲۰۱۵؛ هوکرایتر و اشمیدهابر، ۱۹۹۷؛ امیری و همکاران، ۱۴۰۳).

فهرست منابع

احمدی، علیرضا، و مرادی، نسیم. (۱۴۰۲). بهبود پیش بینی نوسانات بازار سرمایه با استفاده از مدل های ترکیبی یادگیری عمیق و الگوریتم های بهینه سازی. مجله مهندسی مالی و سرمایه گذاری، ۸(۱)، ۵۵-۷۶.

افلاطونی، عباس. (۱۴۰۳). پیش بینی نوسان های شاخص کل بورس اوراق بهادار تهران با مدل ترکیبی پیشنهادی WD-LSTM، ششمین همایش سالانه انجمن مالی ایران، تهران.

- امیری، سیده بیتا، عمیدیان، عارفه، فصیح فر، زهره. (۱۴۰۳). پیش‌بینی هوشمند قیمت سهام به کمک مدل‌های LSTM، GRU، ARIMA و ARIMAX تحلیل و مقایسه عملکرد، شانزدهمین کنفرانس بین‌المللی تحلیل پوششی داده‌ها و علوم تصمیم‌گیری، تنکابن.
- حسینی، محمد، احمدی، سارا، و نادری، حسن. (۱۴۰۲). به‌کارگیری مدل‌های یادگیری عمیق و الگوریتم ژنتیک در پیش‌بینی نوسانات بازار سرمایه ایران. فصلنامه راهبرد مدیریت مالی، ۱۷(۴)، ۱۰۳-۱۲۴.
- صیادی نژاد، سکینه، اسماعیل زاده مقری، علی، رستمی، محمد رضا، یعقوب نژاد، احمد. (۱۴۰۳). ارائه مدل پیش‌بینی تجزیه سیگنال‌های بازار سرمایه با استفاده از رویکرد (CEEMD-DL(LSTM)). راهبرد مدیریت مالی، ۱۲(۱)، ۲۱۱-۲۲۶.
- صیادی نژاد، مجید، محمدی، رضا، و سلیمانی، حامد. (۱۴۰۳). کاربرد ترکیب تبدیل موجک و شبکه‌های عصبی بازگشتی در پیش‌بینی نوسانات شاخص کل بورس تهران. مجله مدیریت مالی، ۱۱(۱)، ۸۹-۱۰۸.
- کاظمی، رضا، و رضوی، مهدی. (۱۴۰۳). ترکیب شبکه‌های عصبی بازگشتی و الگوریتم PSO در مدل‌سازی نوسانات شاخص کل بورس تهران. فصلنامه مهندسی مالی، ۱۰(۲)، ۵۱-۷۰.
- مرادی، نسرين، و احمدی، علیرضا. (۱۴۰۲). مقایسه کارایی مدل‌های LSTM و GRU در پیش‌بینی روند بازده بازار سرمایه ایران. فصلنامه اقتصاد و مدل‌سازی مالی، ۹(۳)، ۶۷-۸۶.
- معصومی، سجاد، و بهرامی، کامران. (۱۴۰۴). مدل‌سازی نوسانات قیمت سهام با استفاده از شبکه‌های عصبی بازگشتی و مدل‌های GARCH ترکیبی. مجله پژوهش‌های مالی ایران، ۱۸(۱)، ۷۵-۹۸.
- نعمتی، مهرداد، و رحمانی نوروزآباد، سامان. (۱۴۰۴). تحلیل عوامل رفتاری و روانی بر ناهنجاری‌های بازار سهام و تصمیم‌های سرمایه‌گذاران، اقتصاد مالی، ۷۱(۱۹)، ۵۳-۷۶.
- نعمی، عباس، فلاح شمس لیستانی، میرفیض، و اوحدی، فریدون. (۱۴۰۴). اثر سرایت پذیری ریسک عدم تقارن بین نا اطمینانی بازار ارز و بورس اوراق بهادار تهران، اقتصاد مالی، ۷۱(۱۹)، ۳۲۷-۳۵۲.
- نوری، سمیه، و طاهری، الفت. (۱۴۰۳). پیش‌بینی هوشمند قیمت سهام با استفاده از مدل‌های یادگیری عمیق و داده‌های کلان اقتصادی. فصلنامه اقتصاد و فناوری اطلاعات، ۶(۴)، ۴۳-۶۴.
- یحیی نمر، علی، کیقبادی، امیررضا، و نصایبان، شهریار. (۱۴۰۴). ارائه مدل اندازه‌گیری ارزش در معرض ریسک شاخص‌های بازار سهام ایران مبتنی بر عوامل ریسک جهانی، اقتصاد مالی، ۷۰(۱۹)، ۳۵۵-۳۷۰.
- Bollerslev, T. (1986). Generalized autoregressive conditional heteroskedasticity. *Journal of Econometrics*, 31(3), 307-327.
- Boudri, M., & El Bouhadi, R. (2024). Modeling and forecasting historical volatility using econometric and deep learning approaches: Evidence from emerging markets. *Journal of Computational Finance and Economics*, 18(3), 221-245.
- Boudri, S., & El Bouhadi, A. (2024). Deep learning versus GARCH models for volatility prediction in emerging North African markets. *Journal of Financial Econometrics*, 22(1), 58-76.
- Cai, W., Liu, K., & Lu, K. (2024). Forecasting daily stock volatility: A comparison between GARCH and recurrent neuro networks. *BCP Business & Management*, 38. <https://doi.org/10.54691/bcpbm.v38i.3723>

- Cho, K., van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2014). Learning phrase representations using RNN encoder–decoder for statistical machine translation. *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, 1724–1734.
- Cont, R. (2001). Empirical properties of asset returns: Stylized facts and statistical issues. *Quantitative Finance*, 1(2), 223–236.
- Elman, J. L. (1990). Finding structure in time. *Cognitive Science*, 14(2), 179–211.
- Engle, R. F. (1982). Autoregressive conditional heteroscedasticity with estimates of the variance of United Kingdom inflation. *Econometrica*, 50(4), 987–1007.
- Fama, E. F. (1970). Efficient capital markets: A review of theory and empirical work. *The Journal of Finance*, 25(2), 383–417.
- 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.
- Greff, K., Srivastava, R. K., Koutník, J., Steunebrink, B. R., & Schmidhuber, J. (2017). LSTM: A search space odyssey. *IEEE Transactions on Neural Networks and Learning Systems*, 28(10), 2222–2232.
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735–1780.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444.
- Petrozziello, A. (2022). Stock market volatility prediction using LSTM deep learning networks. *European Journal of Finance and Economics*, 12(3), 85–101.
- Sako, K., Mpinda, B. N., & Rodrigues, P. C. (2020). Stock price forecasting with deep learning: A comparative study of LSTM, RNN, and GRU models. *Mathematics*, 8(9), 1441. <https://doi.org/10.3390/math8091441>
- Song, Y., Chen, D., & Li, X. (2024). A hybrid CNN–GRU model for stock market volatility forecasting across interconnected markets. *Expert Systems with Applications*, 240, 122563.
- Song, Y., Lei, X., Tang, Y., & Li, J. (2024). Volatility forecasting for stock market index based on complex network and hybrid deep learning model. *Expert Systems with Applications*, 240, 122642.
- Taylor, S. J. (2005). *Asset price dynamics, volatility, and prediction*. Princeton University Press.
- Trivedi, D. V., & Patel, S. (2022). An analysis of GRU–LSTM hybrid deep learning models for stock price prediction. *International Journal of Scientific Research in Science, Engineering and Technology*, 9(3). <https://doi.org/10.32628/IJSRSET229264>
- Wang, T. (2023). Stock volatility forecasting: Adopting LSTM deep learning method and comparing the results with GARCH family model. In *Proceedings of the International Conference on Financial Innovation, FinTech and Information Technology (FFIT 2022)*. <https://doi.org/10.4108/eai.28-10-2022.2328447>
- Wang, Y., Liu, H., Tran, Q. T., & Wang, X. (2025). Deep learning enhanced multivariate GARCH: A hybrid LSTM-BEKK framework for volatility modeling. *Journal of Financial Econometrics*, 23(1), 101–125.
- Xu, Z., Zhang, W., Sun, Y., & Lin, Z. (2024). Multi-source data-driven LSTM framework for enhanced stock price prediction and volatility analysis. *Journal of Computer Technology and Software*, 3(8). <https://doi.org/10.5281/zenodo.14291972>.

Abstract

Modeling and Forecasting Stock Market Volatility Using Recurrent Deep Learning Architectures: Evidence from RNN, LSTM, and GRU Models

Nasim Abdollah Zarkesh¹
Roya Seyfipour²

Received: 22/ October /2025 Accepted: 21/ December /2025

Abstract

Forecasting stock market volatility is a fundamental challenge in financial economics, playing a crucial role in risk management, investment strategy design, and policy-making decisions. Although classical econometric methods such as ARCH and GARCH have been successful in modeling volatility clustering, they exhibit limitations when addressing long-term dependencies and nonlinear behaviors inherent in financial data. In recent years, advances in deep learning, particularly recurrent architectures such as RNN, LSTM, and GRU, have enabled the extraction of complex patterns and latent features from financial time series. This study aims to examine and compare the performance of these three models in forecasting stock market volatility in Iran, evaluating their accuracy, stability, and explanatory power. The dataset comprises daily observations from the Tehran Stock Exchange over the period 2015–2024 (1394–1403 in the Iranian calendar), covering approximately 2,400 trading days, which allows for a robust assessment of model performance under real market conditions. Model evaluation was conducted using statistical metrics (MSE, RMSE, MAE) as well as financial criteria (Sharpe ratio and directional accuracy). The results indicate that the LSTM model achieves the highest accuracy and stability with an R^2 of 0.97, the GRU model attains comparable performance with an R^2 of 0.948 and faster convergence, while the basic RNN model, with an R^2 of 0.89, exhibits limitations in forecasting long-term volatility. These findings confirm that advanced recurrent architectures can serve as effective tools for developing financial forecasting systems and risk management strategies. Furthermore, future research is recommended to explore hybrid models, multi-source datasets, and online learning frameworks to enhance prediction accuracy and generalizability.

Keywords: Stock market volatility, Deep learning, Recurrent Neural Network (RNN), Long Short-Term Memory (LSTM), Gated Recurrent Unit (GRU)

JEL Classification: C45, C53, C58, G10, G17

¹ Department of Economics, CT.C. , Islamic Azad University, Tehran, Iran. n.zarkesh@iau.ac.ir

² Department of Economics, CT.C. , Islamic Azad University, Tehran, Iran, (Corresponding Author). roy.seyfipour@iau.ac.ir