Doi: 10.22034/IAES.2025.2058957.2124

اقتصاد کشاورزی/جلد ۲۰/شماره۲/صفحه های ۷۳-۴۳

به‌کارگیری یادگیری ماشین در تجزیه‌وتحلیل اثرپذیری شاخص صنایع غذایی: شبکه عصبی حافظه طولانی کوتاه‌مدت (LSTM)

معصومه محمدنسب چمازی، فؤاد عشقی، سیدمجتبی مجاوریان، سیده سمیرا کمال‌موسوی[۱]

تاریخ دریافت: ۱۴۰۴/۰۲/۰۶ تاریخ پذیرش: ۱۴۰۴/۰۷/۰۱

چکیده

این پژوهش باهدف تحلیل اثرپذیری شاخص صنایع غذایی از بازارهای مالی منتخب ایران شامل شاخص کل بورس، نرخ ارز و قیمت سکه، با بهره‌گیری از مدل شبکه عصبی حافظه بلندمدت کوتاه‌مدت (LSTM) انجام شده است. صنایع غذایی، به‌عنوان یکی از ارکان اقتصاد کشور، به‌شدت تحت‌تأثیر دگرگونی‌های کلان اقتصادی و مالی قرار دارد و بررسی پویایی آن می‌تواند به شناسایی ساختارهای میان بازاری و چگونگی سرایت نوسان‌ها کمک کند. در این راستا، داده‌های سری زمانی مربوط به دوره فروردین ۱۳۹۶ تا اسفند ۱۴۰۲ برای مدل‌سازی مورداستفاده قرار گرفت. مدل LSTM با توانایی شناسایی الگوهای غیرخطی و وابستگی‌های زمانی پیچیده، در پیش‌بینی هم‌زمان سطح و نوسان‌های متغیرهای مورد بررسی به کار گرفته شد. نتایج نشان داد که شاخص صنایع غذایی بیشترین همبستگی را با شاخص کل بورس دارد و ارتباط آن با نرخ ارز و قیمت سکه، به‌ویژه در سطح قیمت‌ها، ضعیف‌تر است. در سطح نوسانات نیز همبستگی‌ها میان بازارها افزایش می‌یابد که بیانگر اهمیت تکانه‌های کوتاه‌مدت در رفتار بازارهاست. ارزیابی مدل LSTM بر مبنای شاخص‌های خطای آماری مانند MSE و MAE نشان داد که این مدل می‌تواند رفتار متغیرها را بادقت مناسبی بازتولید کند و از پایداری مناسبی برخوردار باشد. همچنین، تفاوت معنادار میان همبستگی‌های سطح قیمت و نوسان‌ها، لزوم تجزیه‌وتحلیل هم‌زمان این دو بُعد را در بررسی و ارزیابی بازارهای مالی برجسته سازد. یافته‌های این پژوهش تصویری جامع از ساختار پویای اثرگذاری متقابل بازارها ارائه می‌دهد و کارایی بالای LSTM را در تجزیه‌وتحلیل پیش‌بینانه دوره‌های مالی نشان می‌دهد.

طبقه‌بندی JEL: C45, C53, G14, E37

واژه‌های کلیدی: یادگیری عمیق، بازارهای موازی، سکه، نرخ ارز، نوسان بازارها

[۱] به‌ترتیب: دانشجوی دکتری، استادیار (نویسنده مسئول)، استاد و دانشجوی دکتری گروه اقتصاد کشاورزی دانشگاه علوم کشاورزی و منابع طبیعی ساری.

Email: fesh.foad@gmail.com

مقدمه

صنایع غذایی از جمله ارکان مهم اقتصاد کلان کشور بوده و نقش تعیین‌کننده‌ای در تحقق امنیت مواد غذایی، اشتغال‌زایی، ارزآوری و توسعه پایدار دارد. این صنعت، با پیوندهای گسترده‌ای که با بخش‌های کشاورزی، تولید، تجارت و صادرات دارد، دارای جایگاه راهبردی مناسبی بوده و عملکرد آن می‌تواند بازتابی از شرایط اقتصادی کلان در کشور باشد (Azarm & Farajzadeh, 2022). در این راستا، شاخص صنایع غذایی در بازار سرمایه به‌عنوان یکی از شاخص‌های بخشی مهم، می‌تواند میزان اثرگذاری نوسان‌ها در بازارهای مالی بر این صنعت را نمایان کند. تجزیه‌وتحلیل رفتار این شاخص در رویارویی با بازارهای موازی، امکان درک عمیق‌تری از پویایی‌های درونی اقتصاد را برای تحلیل‌گران، سرمایه‌گذاران و سیاست‌گذاران فراهم می‌سازد.

بازارهای مالی به دلیل ماهیت نوسانی و نبود اطمینان ذاتی خود، همواره چالشی برای تحلیل‌گران و سرمایه‌گذاران بوده‌اند (Bhanuse et al., 2023). این نوسان‌ها که ناشی از عامل‌های اقتصادی، سیاسی و روان‌شناختی هستند، می‌توانند بر تصمیم‌گیری‌های سرمایه‌گذاری و مدیریت ریسک تأثیر شایان توجهی داشته باشند. یکی از مهم‌ترین جنبه‌های این نوسان‌ها، سرایت بین بازاری است که نشان می‌دهد تکانه‌های قیمتی در یک بازار می‌توانند به دیگر بازارها منتقل شوند. این اثرگذاری متقابل، به‌ویژه در شرایط بی‌ثباتی اقتصادی، اهمیت بیشتری پیدا می‌کند و می‌تواند منجر به افزایش ریسک‌های سیستماتیک در سطح کلان شود. ازاین‌رو، شناسایی سازوکارهای این انتقال و درک چگونگی اثرگذاری بازارها بر یکدیگر، نقش مهمی در مدیریت سرمایه‌گذاری و نظارت یا کنترل ریسک دارد (Keshavarzhaddad et al., 2011; Doostian & Mirashrafi, 2025).

سرمایه‌گذاران و فعالان اقتصادی به طور معمول برای کسب سود یا جلوگیری از آسیب و زیان، دارایی‌های خود را بین بازارهای موازی جابه‌جا می‌کنند. این بازارها که شامل بازار سهام، ارز، طلا و سپرده‌های بانکی هستند، در رقابت با یکدیگر قرار دارند و تغییرات قیمتی یکی از آن‌ها می‌تواند به سایرین سرایت کند. در واقع، این بازارها به دلیل رقابت در جذب نقدینگی، تأثیرهای متقابلی بر یکدیگر دارند و سرمایه‌گذاران بسته به انتظارهای خود از بازدهی و ریسک، بین آن‌ها جابه‌جا می‌شوند (Jahangiri & Hoseini Ebrahimabad, 2017; Ziyadi et al., 2023). به دلیل این وابستگی‌های

متقابل، رخدادها و سیاست‌های اقتصادی در یک بخش می‌توانند منجر به واکنش‌های زنجیره‌ای در دیگر بازارها شوند که در نهایت تصمیم‌گیری سرمایه‌گذاران را تحت‌تأثیر قرار می‌دهد. این موضوع نه‌تنها برای سرمایه‌گذاران و معامله‌گران، بلکه برای سیاست‌گذاران و حتی همهٔ مردم نیز اهمیت دارد، چراکه دگرگونی‌ها در یک بازار می‌تواند اثرگذاری‌های گسترده‌ای بر رفاه اقتصادی و امنیت مالی جامعه داشته باشد.

برای تجزیه‌وتحلیل این روابط بین بازاری، توجه به متغیرهای کلیدی که نمایانگر عملکرد بازارهای مختلف و چگونگی انتقال نوسان‌ها هستند، اهمیت دارد. در این پژوهش، شاخص کل بورس، شاخص صنایع غذایی، نرخ ارز و قیمت سکه به‌عنوان متغیرهای اصلی در نظر گرفته شده‌اند. شاخص کل بورس بازتاب‌دهنده وضعیت کلی بازار سرمایه و انتظارهای سرمایه‌گذاران است (Shaki & Tofighi, 2012; Dourandish et al., 2014). شاخص صنایع غذایی به دلیل نقش کلیدی این صنعت در تأمین نیازهای داخلی و ارزآوری از طریق صادرات، می‌تواند نشانه‌ای از تغییرپذیری‌های کلان اقتصادی باشد (Securities & Exchange Organization, 2019). نرخ ارز به‌عنوان یک متغیر کلیدی، از طریق تأثیر بر هزینه‌های تولید، تورم و جریان سرمایه‌گذاری، نقشی بنیادین در دگرگونی‌های اقتصادی ایفا می‌کند (Chkili & Nguyen, 2014; Adibpour, 2017). در نهایت، قیمت سکه به‌عنوان یک دارایی امن در زمان‌های نبود اطمینان اقتصادی، تحت‌تأثیر نرخ ارز، سیاست‌های پولی و قیمت جهانی طلا قرار دارد (Sadeghi Shahdani & Mohseni, 2018).

باتوجه‌به درهم‌تنیدگی بازارهای مالی و ارتباط تنگاتنگ میان آن‌ها، سرمایه‌گذاران و معامله‌گران بر این باورند که افزون بر بررسی بازدهی و ریسک هر دارایی به‌صورت مستقل، باید تأثیرگذاری‌های متقابل بازارها بر یکدیگر نیز در نظر گرفته شود. رخدادها و تصمیم‌گیری‌ها در یک بازار مالی می‌توانند به دیگر بازارها سرایت کنند و بر بازدهی و ریسک آن‌ها در سطح خرد و کلان اثرگذار باشند (Shinagawa, 2014). در دنیای امروز، یکپارچگی اقتصادی، باز بودن بازارها و سرعت جهانی‌شدن موجب افزایش انتقال تکانه‌های مالی بین بازارهای مختلف شده است. این پویایی بازارها ضرورت بهره‌گیری از ابزارهای تجزیه‌وتحلیل دقیق‌تر را برجسته می‌سازد (Aghaei et al., 2024).

در چند دهه گذشته، تجزیه‌وتحلیل اقتصادسنجی داده‌های مالی توجه زیادی را از سوی پژوهشگران و دانشگاهیان جلب کرده است. پیشرفت‌های چشمگیر در توانایی رایانه‌ها برای ضبط، پردازش،

ذخیره‌سازی و بازیابی حجم عظیمی از داده‌ها، این علاقه را به طور چشمگیری افزایش داده است (Kazemi, 2012). بااین‌حال، مدل‌های سنتی مانند مدل‌های خودرگرسیون برداری و معادلات هم‌زمان با چالش‌هایی روبه‌رو هستند. یکی از مسئله‌های اصلی این مدل‌ها، ایجاد همبستگی کاذب میان اجزای اخلال است، به این معنا که حتی اگر ارتباط واقعی میان متغیرها وجود نداشته باشد، ممکن است مدل همبستگی‌ای غیرواقعی ایجاد کند. افزون بر این، این روش‌ها در شناسایی رابطه‌های غیرخطی و وابستگی‌های پیچیده میان بازارها با محدودیت روبه‌رویند.

در سال‌های اخیر، این چالش‌ها با ظهور ابزار یادگیری عمیق تا حد زیادی برطرف شده است. به‌ویژه، شبکه‌های حافظه بلندمدت کوتاه‌مدت (LSTM)[1] به‌عنوان یکی از مدل‌های توانمند یادگیری ماشینی[2]، توانسته‌اند در تحلیل سری‌های زمانی پیچیده عملکرد مناسبی ارائه دهند. این مدل‌ها به دلیل توانایی در پردازش داده‌های سری زمانی درازمدت، شناسایی الگوهای پنهان و لحاظ‌کردن تأخیرهای زمانی متغیرها، ابزار مناسبی برای تجزیه‌وتحلیل سرایت نوسان‌ها بین بازارهای مالی به شمار می‌آیند. در این پژوهش، با استفاده از مدل LSTM، تأثیر نوسان‌های بازارهای مالی ایران بر یکدیگر بررسی می‌شود. هدف اصلی، شناسایی چگونگی سرایت نوسان‌ها میان شاخص کل بورس، شاخص صنایع غذایی، نرخ ارز و قیمت سکه و ارائه یک مدل کارآمد برای پیش‌بینی این تأثیرگذاری‌ها است. نتایج این پژوهش می‌تواند در مدیریت سبد دارایی‌ها، کاهش ریسک سرمایه‌گذاری و تدوین سیاست‌های اقتصادی پایدار نقش مؤثری ایفا کند.

بنابراین، در کنار بررسی ساختارهای میان بازاری از طریق مدل LSTM، ضروری است که توجه ویژه‌ای نیز به نوسان‌های متغیرها معطوف شود؛ چراکه تنها بررسی و ارزیابی سطح متغیرها کافی نبوده، بلکه نوسان آن‌ها نیز نقشی تعیین‌کننده در شناسایی ساختارهای پویای بازار ایفا می‌کنند. نوسان‌ها می‌توانند حاوی اطلاعات مهمی درباره میزان نااطمینانی، ریسک سیستماتیک و شدت واکنش بازارها نسبت به تکانه‌های داخلی و خارجی باشند. ازاین‌رو، تجزیه‌وتحلیل هم‌زمان اثر متغیرها و نوسانات آن‌ها، امکان درک دقیق‌تری از فرایند سرایت در بازارهای مالی را فراهم می‌آورد. این

[1] Long-Short Term Memory
[2] Machine Learning

رویکرد چندلایه، تصویر روشن‌تری از پویایی‌های بازار ارائه داده و به سیاست‌گذاران، سرمایه‌گذاران و تحلیل‌گران کمک می‌کند تا نه‌تنها سطح اثرگذاری بازارها بر یکدیگر، بلکه شدت و الگوی انتقال ریسک را نیز بادقت بیشتری شناسایی کنند.

تجزیه‌وتحلیل‌های کمی مالی پیشینه‌ای درازمدت دارد و در طول سال‌ها مدل‌های مختلفی، از ساده‌ترین تا پیچیده‌ترین، برای حل مسئله‌های مالی گسترش یافته‌اند. بااین‌حال، همه این مدل‌ها به طور یکسان پذیرفته نشده‌اند و برخی هنوز به طور گسترده در عمل استفاده نمی‌شوند. یکی از نخستین تلاش‌ها در این زمینه در دهه ۱۹۷۰ توسط دو آمارشناس بریتانیایی، باکس و جنکینز، انجام شد. آنان با بهره‌گیری از داده‌های تاریخی قیمت و حجم، مدل ARIMA[1] را برای تحلیل سری‌های زمانی ایستا معرفی کردند (Hansen et al., 1999). این مدل تنها برای داده‌های ایستا مناسب بوده و در صورت بهره‌گیری از آن برای داده‌های غیرایستا، عملکرد ضعیفی خواهد داشت. بنابراین، برای کاربرد بهینه مدل ARIMA، در آغاز داده‌ها باید به حالت ایستا تبدیل شوند، فرآیندی که ممکن است منجر به از دست رفتن ساختار اصلی داده‌ها و کاهش قابلیت تفسیر آن‌ها شود (Bhandari et al., 2022).

در ادامه این پیشرفت‌ها، در دهه ۱۹۸۰، مدل‌های انعطاف‌پذیرتری برای تجزیه‌وتحلیل نوسان‌ها در بازارهای مختلف مالی گسترش یافتند. معرفی مدل ناهمسانی شرطی خودرگرسیونی (ARCH)[2] توسط Engel (1982) و تعمیم آن به مدل GARCH[3] توسط Bollerslev (1986) نقطه عطفی در این زمینه به‌شمار می‌آیند (Cheteni, 2017). در حالی که مدل‌های سنتی سری زمانی و اقتصادسنجی بر فرض واریانس ثابت استوار بودند، مدل ARCH امکان تغییر واریانس شرطی را به‌عنوان تابعی از خطاهای گذشته فراهم کرد. این پیشرفت، زمینه‌ساز توسعه مدل‌های دقیق‌تری برای تحلیل ریسک و نوسان‌های آن شد. به‌ویژه، شناسایی ساختاری مدل GARCH به بهبود برآورد معیارهای کلاسیک ریسک پرتفوی و بررسی تغییرپذیری‌های آن کمک کرده است (Shapiro, 2022).

[1] AutoRegressive Integrated Moving Average
[2] Autoregressive Conditional Heteroskedasticity
[3] Generalized Autoregressive Conditional Heteroskedasticity

هم‌زمان با گسترش این مدل‌ها، پیشرفت‌های فناورانه و افزایش دسترسی به داده‌های گوناگون، زمینه را برای دگرگونی بزرگ در تجزیه‌وتحلیل بازارهای مالی فراهم کردند. اختراع صفحه گسترده برای تحلیل داده‌ها، گردآوری خودکار اطلاعات و افزایش توان محاسباتی موجب شدند که بررسی پویایی‌های بازار و تأثیرگذاری متغیرهای مختلف بر یکدیگر بادقت بیشتری انجام شود. علاوه بر این، ظهور روش‌های نوین در تحلیل داده‌ها، مانند شبکه‌های عصبی مصنوعی و یادگیری عمیق، امکان بررسی رابطه‌های غیرخطی میان متغیرهای اقتصادی و مالی را فراهم کرده است. این پیشرفت‌ها، همراه با مدل‌های نوسان‌های مالی، به پژوهشگران کمک می‌کنند تا تأثیرپذیری بازار از تکانه‌های مختلف و رفتار متغیرهای کلیدی را به طور جامع‌تری بررسی و ارزیابی کنند (Bhandari et al., 2022).

در سال‌های اخیر، یادگیری ماشینی از جمله مهم‌ترین پیشرفت‌های فناوری در زمینه تجزیه‌وتحلیل مالی مطرح شده است. یادگیری ماشینی شاخه‌ای از هوش مصنوعی است که در آن الگوریتم‌هایی گسترش داده می‌شوند تا کامپیوترها بدون نیاز به برنامه‌ریزی صریح قادر به یادگیری باشند. در این میان، روش‌های یادگیری عمیق به دلیل توانایی آن‌ها در تحلیل داده‌های پیچیده و کشف الگوهای نهفته، اهمیت شایان توجهی یافته‌اند. افزایش شمار محققان و سازمان‌هایی که به توسعه این روش‌ها می‌پردازند، همراه با پیشرفت منابع محاسباتی، دسترسی به این فن و روش‌ها را آسان کرده است (García Medina & Moreno, 2023). یکی از زمینه‌هایی که یادگیری عمیق تأثیر بسزایی در آن داشته، تجزیه‌وتحلیل داده‌های مالی و پیش‌بینی ریسک‌های مرتبط با بازارهای مالی است. مدل‌های سنتی اقتصادسنجی و آماری، به‌ویژه هنگام مدل‌سازی متغیرهای غیرثابت یا وابستگی‌های پیچیده، با چالش‌های بسیاری روبه‌رو هستند. در مقابل، الگوریتم‌های یادگیری عمیق می‌توانند این ساختارهای پیچیده را شناسایی کرده و بادقت بیشتری تجزیه‌وتحلیل کنند. این الگوریتم‌ها با یادگیری از داده‌های حجیم، ابزارهای توانمندی برای مدل‌سازی رفتارهای مالی و پیش‌بینی نوسان‌های بازار فراهم می‌کنند. برخلاف روش‌های سنتی که به طور معمول مبتنی بر فرضیه‌های ساده‌سازی شده هستند، مدل‌های یادگیری عمیق توانایی شناسایی رابطه‌های غیرخطی و پیچیده بین متغیرها را دارند و به همین دلیل نقش مهمی در درک الگوهای نوسان‌های مالی و رفتار بازار ایفا می‌کنند (Rezaei & Ahmadi, 2024).

شبکه‌های عصبی مصنوعی[1]، از جمله مهم‌ترین تکنیک‌های یادگیری ماشینی هستند که برای برآورد و تجزیه‌وتحلیل داده‌های پیچیده به کار می‌روند. این شبکه‌ها از سیستم عصبی زیستی الهام‌گرفته شده‌اند و همانند مغز انسان، اطلاعات را پردازش می‌کنند. ساختار شبکه‌های عصبی شامل مجموعه‌ای از نورون‌های مصنوعی به‌هم‌پیوسته است که برای حل یک مسئله خاص، به‌صورت هماهنگ عمل می‌کنند. عنصر کلیدی این سامانه، توانایی یادگیری از راه تجربه است، به این معنا که شبکه در طول فرایند یادگیری، قوانین نهفته در داده‌ها را استخراج کرده و در ساختار خود اعمال می‌کند (Shahrabi Ameri & Taiebysani, 2025).

از جمله ویژگی‌های برجسته شبکه‌های عصبی، قابلیت پردازش موازی داده‌ها که باعث افزایش سرعت تجزیه‌وتحلیل اطلاعات می‌شود (Ziyadi et al., 2023). این ویژگی، به‌ویژه در تجزیه‌وتحلیل داده‌های حجیم مالی، یک برتری کلیدی به شمار می‌آیند. شبکه‌های عصبی مصنوعی، افزون بر توانایی یادگیری الگوها، برای شناسایی و تجزیه‌وتحلیل روندها در داده‌های مالی استفاده می‌شوند. دلیل اصلی که این شبکه‌ها را توانمند و متمایز می‌کند، قابلیت یافتن الگوهای پنهان در داده‌ها بوده که با روش‌های سنتی قابل‌شناسایی نیستند (Shahrabi Ameri & Taiebysani, 2025). این ویژگی به پژوهشگران اجازه می‌دهد تا رابطه‌های پیچیده میان متغیرهای اقتصادی را بهتر درک کرده و رفتارهای نوسانی بازارهای مالی را تحلیل کنند.

شبکه عصبی بازگشتی (RNN)[2]، نوعی از شبکه‌های عصبی مصنوعی است که برای پردازش داده‌های تابلویی یا ترتیبی مانند تشخیص گفتار، پردازش زبان طبیعی و تجزیه‌وتحلیل سری‌های زمانی بهره‌گیری می‌شوند. برخلاف شبکه‌های عصبی پیشرو[3] که داده‌ها را تنها در یک‌جهت پردازش می‌کنند، RNN دارای حلقه بازخوردی است که خروجی هر مرحله را به همراه ورودی جدید به شبکه بازمی‌گرداند. این ویژگی به شبکه امکان می‌دهد اطلاعات گذشته را حفظ کرده و از آن‌ها برای پردازش داده‌های جدید استفاده کند. به بیان ساده، این معماری باعث می‌شود که رابطه‌های زمانی بین داده‌ها حفظ شود و شبکه بتواند وابستگی‌های دنباله‌دار را درک کند (Selvin et al., 2017).

---

[1] Artificial Neural Network (ANN)
[2] Recurrent Neural Network (RNN)
[3] Feed Forward Neural Networks

مفهوم RNN در دهه ۱۹۸۰ معرفی شد و به طور ویژه برای تجزیه‌وتحلیل داده‌های سری‌مانی و دنباله‌دار گسترش یافت. در این شبکه‌ها، هر نورون قادر است وضعیت داخلی خود را حفظ کرده و اطلاعات مربوط به ورودی‌های گذشته را ذخیره کند. این ویژگی، امکان مدل‌سازی وابستگی‌های دوره زمانی در داده‌ها را فراهم کرده و باعث شده است که RNN در تجزیه‌وتحلیل روندهای مالی و بررسی نوسان‌های بازار کاربرد گسترده‌ای داشته باشد (Zaremba et al., 2014; Shahrabi Ameri &Taiebysani, 2025).

شبکه‌های عصبی بازگشتی (RNN) در نسخه‌های اولیه خود با مسئله حفظ اطلاعات مرتبط با ورودی‌های گذشته در بازه‌های زمانی درازمدت روبه‌رو بودند. این محدودیت موجب کاهش توانایی آن‌ها در مدل‌سازی ساختارهای بلندمدت شده و در نتیجه باعث بروز نوسان‌ها و ناپایداری در تولید دنباله‌های داده‌ای می‌شود. یکی از چالش‌های بنیادین در این شبکه‌ها این است که اگر پیش‌بینی‌ها تنها بر مبنای چند ورودی اخیر انجام شود و این ورودی‌ها نیز توسط خود شبکه تولید شده باشند، احتمال اصلاح خطاهای گذشته بسیار کاهش می‌یابد. در نتیجه، این شبکه‌ها به یک سازوکار مؤثر برای حفظ اطلاعات بلندمدت نیاز دارند تا بتوانند داده‌های گذشته را به‌درستی به کار گیرند و وابستگی‌های بلندمدت را بهتر مدل‌سازی کنند. برای حل این مسئله، مدل حافظه طولانی کوتاه‌مدت (LSTM) به‌عنوان یک معماری پیشرفته شبکه عصبی بازگشتی طراحی شد که امکان ذخیره‌سازی و دسترسی به اطلاعات گذشته را به شکل مؤثرتری فراهم می‌کند. برخلاف RNNهای سنتی که در آن‌ها اطلاعات در هر گام زمانی به‌مرور از بین می‌رود، LSTM با بهره‌گیری از یک ساختار حافظه‌ای ویژه، قادر به حفظ اطلاعات مهم در طول زمان است. این ویژگی باعث شده است که LSTM در حل مسئله‌ها مبتنی بر دنباله‌های زمانی، از جمله پیش‌بینی دوره‌های مالی؛ مانند قیمت سهام و نرخ ارز، عملکرد بسیار بهتری نسبت به مدل‌های سنتی داشته باشد. به دلیل توانایی بالای این مدل در پردازش داده‌های متوالی، از آن در زمینه‌هایی همچون تجزیه‌وتحلیل بازارهای مالی، پردازش زبان طبیعی و پیش‌بینی داده‌های سری زمانی به طور گسترده استفاده می‌شود (Selvin et al., 2017).

در تجزیه‌وتحلیل داده‌های سری زمانی مالی، به دلیل نوسان‌های شدید و تأثیرپذیری از عامل‌های خارجی مانند شاخص‌های اقتصاد کلان، رویدادهای ژئوپلیتیکی و احساس‌های مختلف بازار، مدل‌سازی وابستگی‌های بلندمدت چالش‌برانگیز است. روش‌های سنتی مانند مدل‌های خطی و

سری‌های زمانی کلاسیک به طور معمول توانایی کافی برای شناسایی الگوهای پیچیده و وابستگی‌های بلندمدت را ندارند. در این میان، مدل LSTM باقابلیت ویژه خود در حفظ اطلاعات و تشخیص الگوهای پنهان، ابزار توانمندی برای تجزیه‌وتحلیل و پیش‌بینی روندهای مالی به شمار می‌آیند (Botunac et al., 2024). این مدل می‌تواند نوسان‌های بازار را بهتر درک کرده و ارتباطات غیرخطی میان داده‌ها را شناسایی کند، در نتیجه دقت پیش‌بینی در زمینه‌هایی مانند قیمت سهام، نرخ ارز و دیگر شاخص‌های مالی را افزایش می‌دهد. باتوجه‌به توانایی این مدل در ثبت رابطه‌های پیچیده میان متغیرهای مالی، استفاده از آن در پژوهش و ارزیابی‌های مربوط به نوسان‌های بازارهای مالی و بررسی رابطه‌های متقابل آن‌ها، می‌تواند منجر به بینش‌های دقیق‌تر و پیش‌بینی‌های قابل‌اعتمادتری شود.

مدل‌سازی و پیش‌بینی نوسان‌های بازارهای مالی همواره از جمله موضوع‌های کلیدی در پژوهش و ارزیابی‌های اقتصادی و مالی بوده است. روش‌های مختلفی برای این منظور پیشنهاد شده‌اند که شامل مدل‌های سنتی آماری، ترکیب این مدل‌ها با الگوریتم‌های یادگیری ماشین و استفاده از شبکه‌های عصبی عمیق است. در این بخش، پژوهش و ارزیابی‌های مختلفی که از این روش‌ها بهره گرفته‌اند مرور می‌شوند تا جایگاه روش انتخابی این پژوهش مشخص شود.

مدل‌های GARCH و انواع آن در تجزیه‌وتحلیل نوسان‌های بازارهای مالی موردتوجه بسیاری از پژوهشگران و محققان قرار گرفته‌اند. به‌عنوان‌مثال، Tule et al (2018) با استفاده از مدل VARMA-AGARCH به بررسی سرریز بازده و تکانه‌ها بین بازار سهام و ارز پرداختند و نشان دادند که تکانه‌ها بیشتر از بازار سهام به بازار ارز منتقل می‌شوند. همچنین، Taheri et al (2023) با استفاده از مدل‌های ARCH و GARCH، تأثیر نوسان‌های بازار ارز و طلا بر نوسان‌های بازار سرمایه ایران را بررسی کردند و نتایج نشان داد که نوسان‌های بازارهای ارز و طلا تأثیر معناداری بر نوسان‌های بازار سهام دارند. افزون بر این، Aghaei et al (2024) با استفاده از مدل EGARCH به بررسی رابطه میان بازارهای فارکس، رمزارز، ارز و بازار سهام ایران پرداخته و نشان دادند که نوسانات این بازارها به بازار سهام منتقل می‌شود. نتایج این پژوهش‌ها نشان می‌دهند که مدل‌های GARCH ابزار توانمندی برای تحلیل نوسانات و سرریز آن‌ها در بازارهای مالی هستند.

در سال‌های اخیر، استفاده از روش‌های یادگیری عمیق به‌عنوان رویکردی نوین در تجزیه‌وتحلیل و مدل‌سازی بازارهای مالی رشد چشمگیری داشته است. Kim & Won (2018) در پژوهشی باهدف

بهبود دقت در تجزیه‌وتحلیل رفتار قیمت سهام، مدلی ترکیبی به نام GEW-LSTM ارائه دادند که شبکه عصبی LSTM را با سه مدل متفاوت از خانواده GARCH ترکیب می‌کند. نتایج این پژوهش نشان داد که مدلGEW-LSTM عملکرد بهتری نسبت به دیگر مدل‌های منفرد و ترکیبی در معیارهایی همچون MAE، MSE، HMAE و HMSE دارد.

به طور همانند، Liu (2019) با بهره‌گیری از الگوریتم‌های یادگیری عمیق به تجزیه‌وتحلیل نوسان‌های شاخص S&P500 در دوره زمانی سال‌های ۲۰۰۰ تا ۲۰۱۴ پرداخت و نشان داد که این روش‌ها نسبت به مدل‌های سنتی GARCH از دقت بالاتری برخوردار هستند. Nikou et al (2019) نیز در پژوهشی با هدف بررسی قابلیت‌های مدل LSTM در برآورد قیمت پایانی صندوق EWU در انگلستان، عملکرد آن را با مدل‌هایی مانند ANN، SVM و RF مقایسه کردند. نتایج نشان‌دهنده برتری LSTM در تجزیه‌وتحلیل داده‌های مالی بود. همچنین، Qu & Zhao (2019) در پژوهشی دیگر، با بهره‌گیری از مدل‌های LSTM و RNN، به پیش‌بینی قیمت بازار ارز پرداختند و نشان دادند که مدل LSTM نسبت به RNN خطای کمتری در معیارهای RMSE و MAE دارد و از دقت بالاتری برخوردار بوده است.

در ادامه، Bhanuse et al (2023) در پژوهش خود مدلی مبتنی بر شبکه عصبی LSTM برای پیش‌بینی قیمت سهام توسعه دادند. این مدل با استفاده از داده‌های تاریخی شامل قیمت، حجم معامله‌ها و شاخص‌های بازار، در قالب معماری شامل لایه‌های LSTM، Dense و Dropout طراحی شد. این مدل توانست عملکرد بهتری نسبت به راهبرد استراتژی‌های سنتی مانند "خرید و نگهداری" نشان دهد و نقش یادگیری عمیق در تصمیم‌سازی‌های مالی را برجسته سازد.

در پژوهشی دیگر، Adams and Uchema (2024) باهدف ارزیابی توان پیش‌بینی نوسان‌های نرخ ارز در نیجریه، مدل‌های EGARCH و LSTM را مقایسه و دریافتند که مدلEGARCH (1,1) در تجزیه‌وتحلیل نوسان‌ها بهتر از LSTM عمل می‌کند.

در میان پژوهش‌های داخلی، Shariffar et al (2021) عملکرد معماری LSTM را در بررسی رفتار قیمتی سهام ارزیابی کردند. آنان با ترکیب داده‌های قیمتی، شاخص‌های تکنیکال و اطلاعات معاملاتی سهام‌داران، مدلی عمیق ارائه دادند که با بهره‌گیری از لایه Dropout، عملکرد بهتری نسبت به نسخه‌های ساده‌تر داشت و توانست ویژگی‌های تأثیرگذار را به طور خودکار استخراج کند.

Zoghi et al (2022) چارچوبی نوین برای تجزیه‌وتحلیل جهت حرکت بازار در قراردادهای آتی سکه طلا ارائه کردند. آنان از ترکیب روش‌هایی چون تبدیل موجک، خود رمزنگار انباشته و شبکه LSTM بهره گرفتند. یافته‌ها گویای از آن بود که مدل ترکیبی آنان عملکرد دقیق‌تری نسبت به روش‌های دیگر داشته و بازدهی بالاتری ایجاد کرده است.

Rameh et al (2022) نیز مدلی ترکیبی مبتنی بر LSTM و تجزیه‌وتحلیل متون خبری ارائه دادند که با درنظرگرفتن هم‌زمان داده‌های سری زمانی و اطلاعات روانی بازار، توانست عملکرد بهتری نسبت به روش‌های کلاسیک مانند Prophet و ARIMA ارائه کند و خطای پیش‌بینی را کاهش دهد.

Beheshti Masalegou et al (2023) نیز با طراحی مدلی ترکیبی بر پایه شبکه LSTM و استفاده هم‌زمان از داده‌های قیمتی، شاخص‌های فنی و اخبار منتشرشده در کانال Reddit، به بررسی توانایی مدل در تجزیه‌وتحلیل قیمت روز آیندهٔ سهام پرداختند. یافته‌ها نشان داد که مدل ترکیبی آنان دقت بالاتری نسبت به استفاده جداگانه از داده‌های عددی یا متنی داشته و در مقایسه با مدل‌های MLP، SVM و RNN نیز برتری عملکردی داشته است.

در نهایت، Shahrabi Ameri &Taiebysani (2025) نیز به بررسی بازده سهام با استفاده از شبکه LSTM پرداختند. آنان با انتخاب شرکت‌هایی با داده‌های بدون شکاف و تعدیل‌شده از بورس تهران، نشان دادند که این مدل قابلیت تجزیه‌وتحلیل شایان توجهی در تبیین رفتار قیمتی بازار دارد و می‌تواند به‌خوبی عامل‌های مؤثر مانند زمان، ریسک و بازده را در نظر بگیرد.

مرور نتایج ادبیات‌پژوهش نشان می‌دهد که مدل‌های سنتی مانند GARCH و مشتقات آن همچنان در تجزیه‌وتحلیل نوسانات بازارهای مالی کاربرد دارند، اما محدودیت آن‌ها در شناسایی الگوهای غیرخطی و پیچیده، پژوهشگران را به‌سوی بهره‌گیری از روش‌های پیشرفته‌تر سوق داده است. در این میان، مدل‌های یادگیری عمیق به‌ویژه شبکه عصبی LSTM به دلیل قابلیت درک وابستگی‌های زمانی بلندمدت، توانسته‌اند عملکرد شایان توجهی در تجزیه‌وتحلیل داده‌های مالی از خود نشان دهند. مرور نتایج پژوهش‌های بسیاری با تمرکز بر LSTM نشان داده‌اند که این مدل، چه در ترکیب با داده‌های عددی و چه متنی، می‌تواند نسبت به مدل‌های سنتی و حتی دیگر الگوریتم‌های یادگیری ماشین، دقت و پایداری بالاتری داشته باشد. در راستای این روند پژوهشی، این پژوهش باهدف تجزیه‌وتحلیل پویا و جامع‌تر، از مدلLSTM برای بررسی هم‌زمان رابطه‌های میان شاخص صنایع غذایی، شاخص

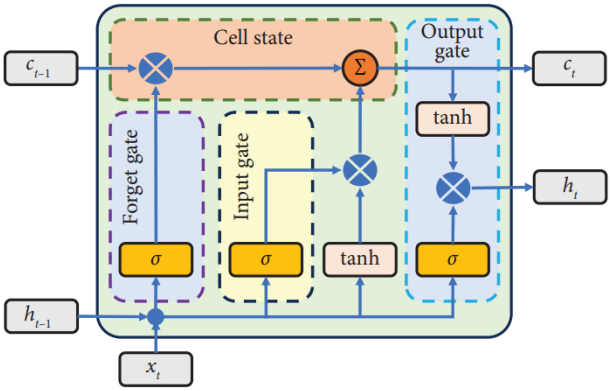
کل بورس، نرخ ارز و قیمت سکه بهره می‌برد؛ به‌طوری‌که نه‌تنها خود متغیرها، بلکه رفتار نوسانی آن‌ها نیز در قالب الگویی غیرخطی و مبتنی بر یادگیری عمیق مدل‌سازی خواهد شد. این رویکرد می‌تواند درک دقیق‌تری از تعامل‌های میان بازارهای مالی ارائه دهد و بستری مناسب برای تصمیم‌گیری‌های داده‌محور فراهم کند.

روش‌شناسی

در این پژوهش، از مدل حافظه طولانی کوتاه‌مدت (LSTM) برای تجزیه‌وتحلیل و پیش‌بینی نوسان‌های بازارهای مالی استفاده شده است. مجموعه‌داده‌ها شامل سری‌های زمانی روزانه شاخص صنایع غذایی (به‌جز قند و شکر)، شاخص کل بورس، نرخ ارز (دلار آزاد) و قیمت سکه در بازه زمانی فروردین ۱۳۹۶ تا اسفند ۱۴۰۲ است که به ترتیب از وب‌سایت شرکت بورس اوراق بهادار تهران و منابع معتبر اعلام نرخ ارز و سکه گردآوری شده‌اند. مدل LSTM نخستین‌بار توسط Schmidhuber & Hochreiter (1997) معرفی شد و به‌عنوان یک نسخهٔ بهبودیافته از شبکه‌های عصبی بازگشتی (RNN) توسعه یافت. این مدل با استفاده از یک ساختار حافظه‌ای خاص، قادر به حفظ وابستگی‌های بلندمدت در داده‌های سری‌مانی است، درحالی‌که RNNهای سنتی با مسئله محوشدن گرادیان روبه‌رو هستند.

واحد LSTM شامل یک سلول حافظه است که مسئول ذخیره اطلاعات است. فرایند ذخیره‌سازی توسط سه دروازه مجزا آسان گری می‌شود: دروازه ورودی[1]، دروازه فراموشی[2] و دروازه خروجی[3]. ساختار واحد LSTM در شکل ۱ نشان داده شده است.

[1] Input gate
[2] Forget gate
[3] Output gate



شکل (۱) ساختار واحد LSTM

Figure 1. Structure of an LSTM Unit

منبع: Agarwal et al., 2025

Source: Agarwal et al., 2025

سلول LSTM در لحظهٔ t دادهٔ ورودی X_t و خروجی لحظه‌ی قبلی $h(t-1)$ را به‌عنوان ورودی دریافت می‌کند. همچنین، این سلول دارای مقدار حافظه‌ای $c(t)$ است و خروجی $h(t)$ را تولید می‌کند. فرآیند ارزیابی واحد LSTM را می‌توان به چند مرحله تقسیم کرد که به شرح زیر است (Agarwal et al., 2025):

۱. مرحلهٔ اولیه شامل محاسبهٔ مقدار حافظهٔ پیشنهادی $\tilde{c}_t$ با استفاده از یک ماتریس وزن W_c و مقدار انحراف b_c مطابق رابطهٔ (۱) است:

$$\tilde{c}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c). \quad (۱)$$

در رابطه (۱)، W_cماتریس وزن و b_c مقدار انحراف هستند که به‌صورت پیش‌فرض با مقدارهای اولیه‌ی تصادفی کنترل‌شده مقداردهی می‌شوند. این مقداردهی اولیه به‌طور معمول با استفاده از توزیع‌های آماری استاندارد مانند نرمال یا یکنواخت انجام می‌شود تا از بروز مسئله‌هایی مانند ناپایداری گرادیان جلوگیری شود. در طول فرایند آموزش، مقدارهای وزن و انحراف با استفاده از الگوریتم‌های بهینه‌سازی

به‌روزرسانی می‌شوند. عبارت tanh در این رابطه به تابع تانژانت هایپربولیک[1] اشاره دارد که یک تابع فعال‌سازی غیرخطی با دامنه خروجی [۱،۱-] است.

۲. دروازه ورودی i_t نقش مهمی در تعیین تأثیر داده‌های ورودی کنونی بر به‌روزرسانی مقدار حالت سلول حافظه دارد. مقدار آن با استفاده از ماتریس وزن W_i، مقدار انحراف b_i و تابع سیگموئید[2] σ با رابطهٔ (۲) محاسبه می‌شود:

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (۲)$$

۳. مقدار دروازه فراموشی f_t که وظیفهٔ کنترل به‌روزرسانی داده‌های گذشته در ارتباط با حالت سلول حافظه را دارد، با توجه به ماتریس وزن W_fو مقدار انحراف b_fبا رابطهٔ (۳) به‌دست می‌آید:

$$f_t = \sigma\big(W_f \cdot [h_{t-1}, x_t] + b_f\big) \quad (۳)$$

۴. مقدار سلول حافظه c_t در زمان t تعیین می‌شود که در آن tنشان‌دهنده‌ی لحظه‌ی کنونی و c_{t-1} مقدار حالت گذشته واحد LSTM است. این مقدار به‌صورت رابطهٔ (۴) محاسبه می‌شود:

$$c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}_t, \quad (۴)$$

که در آن $\odot$ نشان‌دهندهٔ حاصل‌ضرب نقطه‌ای است. فرایند به‌روزرسانی سلول حافظه بر مبنای مقدار حالت سلول گذشته و مقدار پیشنهادی جدید تعیین می‌شود که این مقدارها توسط دروازه ورودی و دروازه فراموشی کنترل می‌شوند.

۵. مقدار دروازه خروجی o_t که وظیفه‌ی تنظیم خروجی مرتبط با حالت ذخیره‌شده در سلول حافظه را بر عهده دارد، با استفاده از ماتریس وزن W_oو مقدار انحراف b_oبا رابطهٔ (۵) محاسبه می‌شود:

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (۵)$$

۶. در نهایت، مقدار خروجی واحد LSTM یعنی h_tبر مبنای رابطهٔ (۶) تعیین می‌شود:

$$h_t = o_t \odot \tanh(c_t) \quad (۶)$$

---

[1] Hyperbolic Tangent
[2] Sigmoid Function

استفاده از سه دروازه کنترلی و یک سلول حافظه این امکان را برای LSTM فراهم می‌کند که اطلاعات بلندمدت را به طور مؤثر حفظ، دسترسی، بازنشانی و به‌روزرسانی کند. شایان یادآوری است که با تنظیم ابعاد ماتریس وزن در این سازوکار پارامترهای مشترک، می‌توان ابعاد خروجی را بر مبنای نیاز تنظیم کرد. افزون بر این، LSTM یک تأخیر زمانی شایان توجه بین سیگنال‌های ورودی و بازخوردی ایجاد می‌کند. برتری اصلی آن در توانایی حفظ جریان پیوسته خطا نهفته است، زیرا حالت درونی پایدار در معماری سلول حافظهٔ آن، بازدارنده از انفجار یا محوشدن گرادیان‌ها در طول زمان می‌شود (Cao et al., 2018).

به‌منظور ارزیابی عملکرد مدل، میانگین مربعات خطا (MSE)[1]، میانگین قدرمطلق خطا (MAE)[2] و مجموع مربعات باقی‌مانده (RSS)[3] به‌عنوان معیارهای سنجش دقت استفاده شده‌اند. ترکیب‌بندی محاسبه هر شاخص به ترتیب در رابطه‌های (۷) تا (۹) ارائه شده است:

$$MSE = \frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2 \quad (۷)$$

$$MAE = \frac{1}{n}\sum_{i=1}^{n}|y_i - \hat{y}_i| \quad (۸)$$

$$RSS = \sum_{i=1}^{n}(y_i - \hat{y}_i)^2 \quad (۹)$$

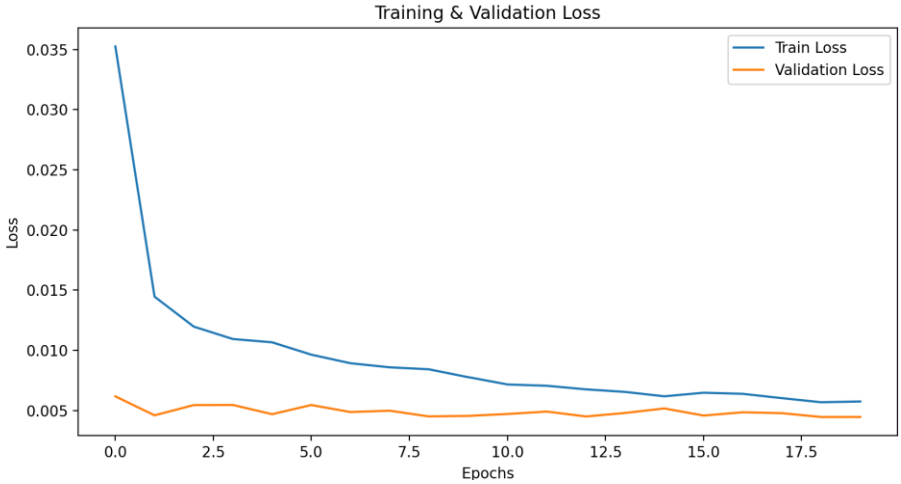
در این رابطه‌ها، y_i مقدارهای واقعی، $\hat{y}_i$ مقدارهای پیش‌بینی‌شده توسط مدل و n شمار مشاهده‌ها بوده است (Praneeth et al., 2024).

داده‌های مورداستفاده در این پژوهش به‌صورت روزانه و از منابع معتبر شامل وب‌سایت رسمی شرکت بورس اوراق بهادار تهران (برای شاخص‌های بورسی) و پایگاه‌های رسمی اعلام نرخ ارز و قیمت سکه گردآوری شده‌اند. پردازش، پیش‌پردازش و تجزیه‌وتحلیل داده‌ها با استفاده از نرم‌افزار پایتون[4] و کتابخانه‌های تخصصی آن صورت‌گرفته است.

نتایج و بحث

[1] Mean Squared Error
[2] Mean Absolute Error
[3] Residual Sum of Squares
[4] Python

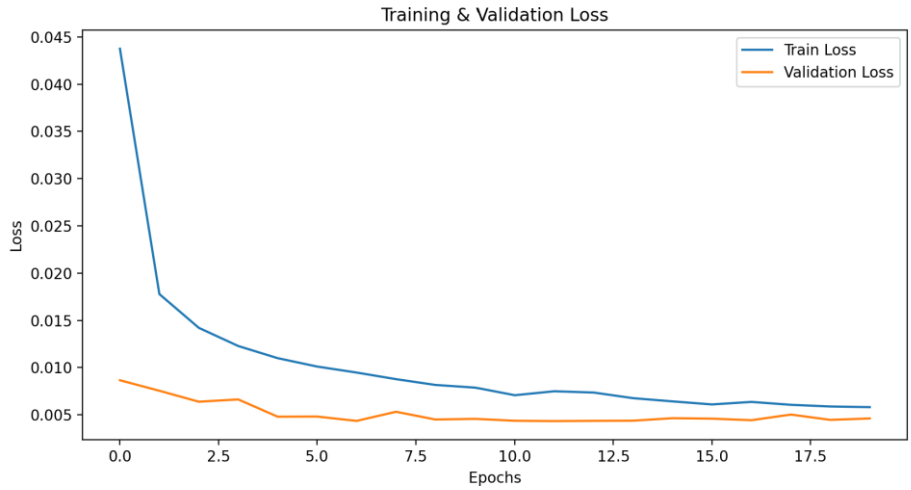
در راستای ارزیابی عملکرد مدل LSTM، نمودارهای ۱ و ۲ به ترتیب روند تغییرپذیری‌های خطای آموزش[1] و خطای اعتبارسنجی[2] را در پیش‌بینی مقدارهای اصلی و نوسان متغیرهای شاخص صنایع غذایی، شاخص کل بورس، نرخ ارز (دلار) و قیمت سکه نشان می‌دهند. هر دو نمودار بیانگر روند کاهشی خطاها طی مرحله‌های آموزش هستند. این روند کاهشی، به‌ویژه در دوره‌های ابتدایی، نشان‌دهنده فرایند یادگیری مؤثر مدل و بهبود تدریجی دقت پیش‌بینی آن است. ازسوی‌دیگر، نزدیکی شایان توجه میان منحنی‌های آموزش و اعتبارسنجی و تثبیت آن‌ها در سطح‌های پایین، گویای عدم بروز بیش برازش[3] و برخورداری مدل از قابلیت تعمیم‌پذیری مناسب است. بر این مبنا، می‌توان نتیجه گرفت که مدل LSTM در هر دو سطح داده‌های اصلی و نوسان آن‌ها، قادر به شناسایی و یادگیری الگوهای نهفته بوده و عملکرد رضایت‌بخشی در پیش‌بینی رفتار متغیرهای اقتصادی مورد بررسی ارائه می‌دهد.



نمودار (۱) روند تغییرپذیری خطای آموزش و اعتبارسنجی مدل LSTM در پیش‌بینی مقدارهای اصلی متغیرها

Figure 1- Training and Validation Loss Curves of the LSTM Model for Predicting the Original Variable Values

[1] Train Loss
[2] Validation Loss
[3] Overfitting



نمودار (۲) روند تغییرپذیری خطای آموزش و اعتبارسنجی مدل LSTM در پیش‌بینی نوسان متغیرها

Figure 2- Training and Validation Loss Curves of the LSTM Model for Predicting Variable Volatility

در ادامه این ارزیابی، جدول ۱ به‌منظور بررسی دقیق‌تر عملکرد مدل، مقدارهای شاخص‌های آماری خطا شامل میانگین مربعات خطا (MSE)، میانگین قدرمطلق خطا (MAE) و مجموع مربعات باقیمانده (RSS) را در دو حالت «پیش‌بینی مقدارهای اصلی متغیرها» و «پیش‌بینی نوسان‌های آن‌ها» نمایش می‌دهد. این شاخص‌ها، معیارهای استانداردی برای سنجش دقت مدل‌های سری زمانی هستند. مشاهده اعداد این جدول نشان می‌دهد که هرچند مقدار MSE در پیش‌بینی نوسانات به طور محسوسی کمتر از پیش‌بینی مقادیر اصلی است (که بیانگر دقت بالاتر مدل در شناسایی شوک‌هاست)، اما مقدار MAE در هر دو حالت به‌صورت نسبتاً مشابه باقی‌مانده و این موضوع، ثبات عملکرد مدل را در تخمین میانگین خطاها تأیید می‌کند.

جدول (۱) جدول شاخص‌های خطای مدل در پیش‌بینی مقدارها و نوسان‌ها

Table 1- Model Error Metrics for Predicting Values and Volatility

RSS	MAE	MSE	نوع داده Data Type
6.344145745208	0.035744589645	0.004467708271	مقدارهای اصلی Original Values
6.552409129207	0.038773810499	0.000461437263	نوسان‌ها Volatility

منبع: یافته‌های تحقیق Source: Research Findings

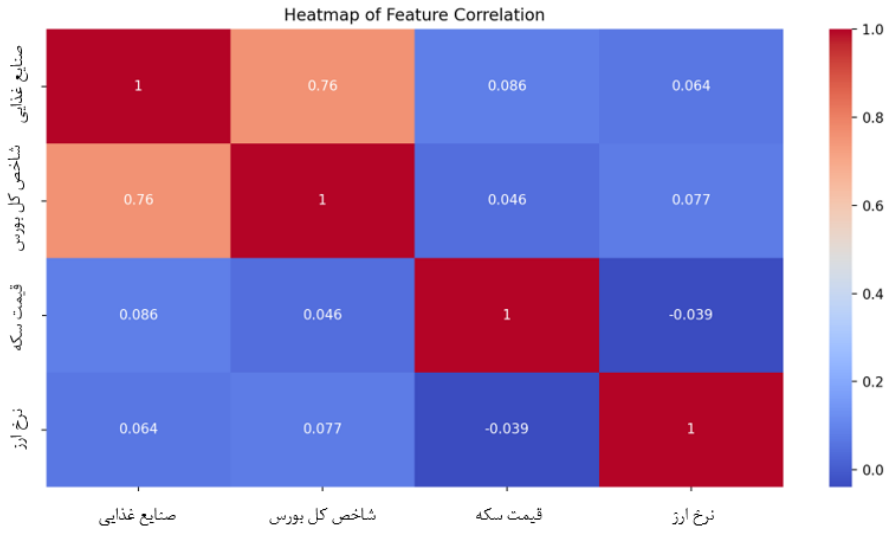
برای تجزیه‌وتحلیل دقیق‌تر رابطه‌های میان متغیرهای موردپژوهش، نمودارهای ۳ و ۴ به ترتیب ماتریس همبستگی بین سطح‌های قیمتی و نوسان‌های شاخص صنایع غذایی، شاخص کل بورس، قیمت سکه و نرخ ارز را نمایش می‌دهند. در هر دو نمودار، مقدارهای قطری برابر با عدد یک‌اند که بیانگر همبستگی کامل هر متغیر با خودش است. در نمودار سوم، همبستگی میان سطح شاخص صنایع غذایی و شاخص کل برابر با ۰/۷۶ است که نشان‌دهنده‌ی همراهی و هم‌راستایی این دو شاخص در سطح قیمت‌هاست. دیگر همبستگی‌ها به‌نسبت ضعیف هستند؛ به‌عنوان مثال، همبستگی میان شاخص کل و نرخ ارز (۰/۰۷۷)، شاخص کل و قیمت سکه (۰/۰۴۶) و نیز میان سکه و دلار (۰/۰۳۹-) همگی در سطوح بسیار پایین قرار دارند. این امر بیانگر آن است که بازارهای طلا و ارز رفتار مستقلی نسبت به بازار سرمایه در سطح قیمت‌ها دارند. همچنین، مقدار منفی میان سکه و دلار نشان‌دهنده‌ی هم‌حرکتی ضعیف و خلاف‌جهت در سطح قیمت‌هاست، گرچه مقدار آن ناچیز است.

در مقابل، نمودار ۴ که همبستگی میان نوسان متغیرها را نشان می‌دهد، الگوی متفاوتی را نمایان می‌سازد. باردیگر نوسان‌های شاخص صنایع غذایی و نوسان‌های شاخص کل بیشترین همبستگی مثبت را دارند (۰/۷۶) که بیانگر واکنش همانند این دو بازار به تکانه‌های کوتاه‌مدت است. همچنین، همبستگی بین نوسان‌های سکه و نوسان‌های دلار به عدد شایان توجه ۰/۶۸ رسیده است که نسبت به همبستگی قیمتی آن‌ها (۰/۰۳۹-) جهش شایان توجهی دارد و نشان می‌دهد که هرچند در بلندمدت ممکن است روند متفاوتی داشته باشند، اما در نوسان‌های کوتاه‌مدت به‌شدت هم‌جهت هستند. همچنین، همبستگی نوسان‌های میان شاخص کل و نرخ ارز (۰/۱۲) بیشتر از همبستگی قیمتی آن‌ها (۰/۰۷۷) بوده است، که به‌طور ضمنی گویای حساسیت بیشتر بازار سرمایه به نوسان‌های

نرخ ارز در دوره‌های کوتاه‌مدت است. همین الگو در مورد شاخص کل و قیمت سکه نیز مشاهده می‌شود.

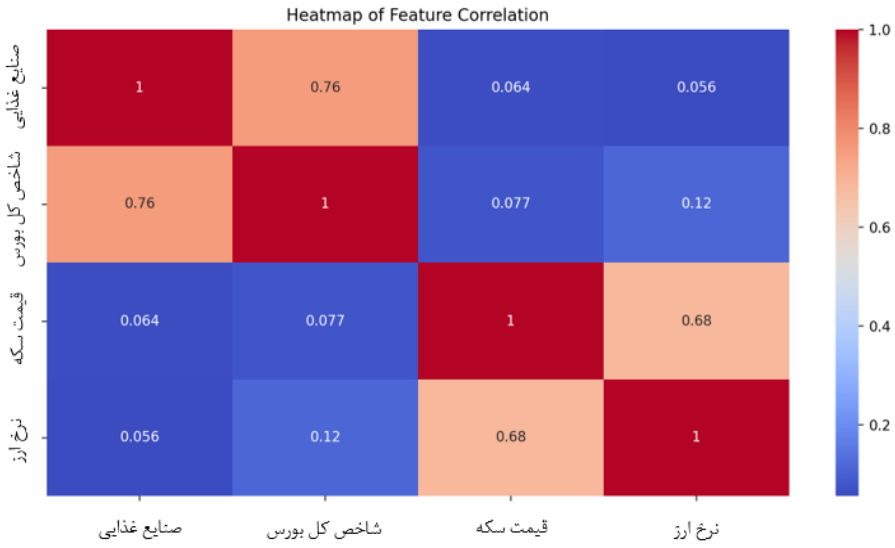
این تفاوت محسوس در الگوهای همبستگی میان سطح قیمت‌ها و نوسان‌های آن‌ها نشان می‌دهد که رابطه‌های میان بازارها در افق‌های زمانی کوتاه‌مدت و بلندمدت یکسان نیست. شواهد پژوهشی نیز این نتیجه را تأیید می‌کنند و نشان می‌دهند که تغییرپذیری‌های کوتاه‌مدت بیشتر بازتاب واکنش سریع بازار به تکانه‌ها و اطلاعات جدید است، درحالی‌که تغییرپذیری‌های بلندمدت بیشتر تحت‌تأثیر عوامل ساختاری و پایدار قرار دارند. بر اساس فرضیه ترکیب توزیع‌ها[1]، نوسان‌های بازار ترکیبی از مؤلفه‌هایی با پایداری کوتاه‌مدت و بلندمدت هستند و بسته به افق زمانی تجزیه‌وتحلیل، وزن و اثر هر یک از این مؤلفه‌ها تغییر می‌کند (Andersen et al., 1997; Mohammadi et al., 2021). از این منظر، تغییر نشانهٔ همبستگی میان برخی متغیرها مانند رابطه منفی سطح قیمت سکه و دلار در مقابل همبستگی مثبت نوسان آن‌ها می‌تواند ناشی از تفاوت در ماهیت محرک‌های کوتاه‌مدت و بلندمدت باشد. این موضوع، ضرورت تحلیل هم‌زمان داده‌های قیمتی و نوسانی را در مدل‌سازی‌های پیش‌بینی و تصمیم‌گیری‌های اقتصادی دوچندان می‌سازد.

[1] Mixture-of-Distributions Hypothesis



نمودار (۳) ماتریس همبستگی بین سطح‌های قیمتی متغیرها

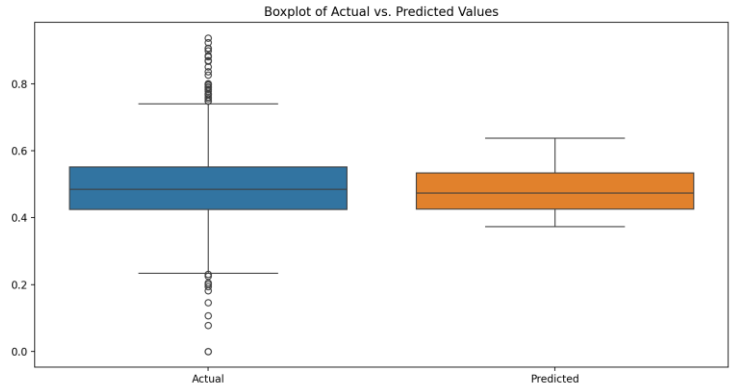
Figure 3- Correlation Matrix of the Variables' Price Levels



نمودار (۴) ماتریس همبستگی بین نوسان‌های متغیرها

Figure 4- Correlation Matrix of Variable Volatilities

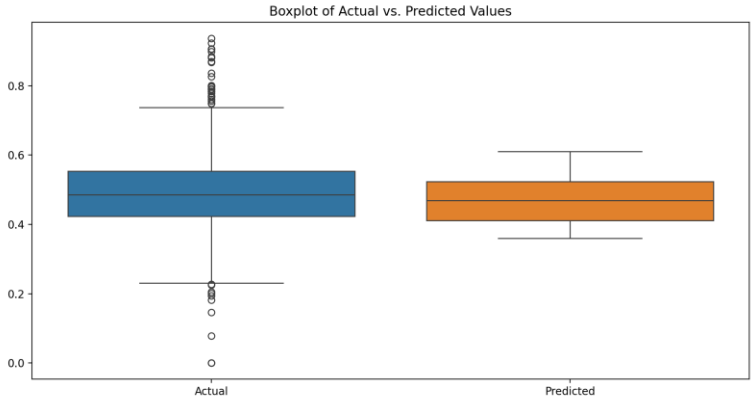
در نهایت، جهت بررسی میزان همخوانی میان مقدارهای واقعی و مقدارهای پیش‌بینی‌شده توسط مدل LSTM، نمودارهای ۵ و ۶ جعبه‌ای[1] از این دو سری داده را به‌صورت مقایسه‌ای نمایش می‌دهند. نمودار ۵ به مقدارهای واقعی متغیرها مربوط است و نمودار ۶ نوسان آن‌ها را در برمی‌گیرد. در نمودار مربوط به مقدارهای اصلی، توزیع مقدارهای پیش‌بینی‌شده تا حد زیادی با داده‌های واقعی هم‌راستاست، هرچند اندکی انقباض در بازهٔ پیش‌بینی‌شده دیده می‌شود که می‌تواند ناشی از رفتار محافظه‌کارانهٔ مدل در رویارویی با مقدارهای پرت باشد. بااین‌حال، نزدیکی میانه‌ها و مرکز توزیع‌ها، گویای دقت مناسب مدل در بازتولید مقدارهای اصلی متغیرهاست. در نمودار مربوط به نوسان‌های نیز الگوی همانندی مشاهده می‌شود. پراکندگی داده‌های واقعی بیشتر است که طبیعی بوده، اما مدل توانسته محدوده و مرکز توزیع نوسان‌ها را به‌خوبی بازسازی کند. این مسئله به‌ویژه در مدل‌سازی تکانه‌ها و رفتار کوتاه‌مدت بازار دارای اهمیت بالایی بوده است.



نمودار (۵) مقایسه مقدارهای واقعی و پیش‌بینی‌شده در سطح متغیرها

Figure 5- Comparison of Actual and Predicted Values at the Variable Level

[1] Boxplot



نمودار (۶) مقایسه مقدارهای واقعی و پیش‌بینی‌شده در سطح نوسان‌ها

Figure 6- Comparison of Actual and Predicted Values at the Volatility Level

در جمع‌بندی یافته‌ها، می‌توان نتیجه گرفت که شاخص صنایع غذایی، به‌ویژه در سطح نوسان‌ها، بیشترین همبستگی را با شاخص کل بورس دارد و از دگرگونی‌های کلی بازار سرمایه بیشترین تأثیر را می‌پذیرد. این موضوع نشان‌دهندهٔ آن است که صنعت غذا، به‌عنوان یکی از صنایع داخلی محور، نسبت به رفتار کلی سرمایه‌گذاران در بازار بورس واکنش‌پذیر است. در مقابل، همبستگی این شاخص باقیمت طلا و نرخ ارز، چه در سطح قیمت و چه در سطح نوسان‌ها، بسیار محدود و در برخی موارد ناچیز بوده است. این الگو بیانگر آن است که بازارهای دارایی جایگزین مانند ارز و طلا نقش کم‌رنگ‌تری در جهت‌دهی به رفتار شاخص صنایع غذایی دارند. از منظر اقتصادی، می‌توان این الگو را ناشی از ساختار تولید و بازار مصرف صنعت غذا دانست که وابستگی بیشتری به عامل‌های داخلی مانند هزینه‌های تولید، سیاست‌های حمایتی دولت و تغییرپذیری‌های تقاضای داخلی دارد و کمتر تحت‌تأثیر نوسان‌های بازارهای جهانی طلا و ارز قرار می‌گیرد. همچنین، در سال‌های مورد بررسی، نوسان‌های عمده نرخ ارز و طلا بیشتر ناشی از تکانه‌های بیرونی و عوامل کلان اقتصادی بوده که اثر مستقیم محدودی بر بخش غذا گذاشته‌اند. هرچند در سطح نوسان‌های کوتاه‌مدت، همبستگی میان برخی بازارها افزایش‌یافته است، اما همچنان شاخص کل بورس، به دلیل بازتاب کلی شرایط اقتصادی و انتظارات سرمایه‌گذاران، عامل اصلی تأثیرگذار بر نوسان‌های شاخص صنایع غذایی باقی‌مانده است.

این نتایج تا حدودی با یافته‌های برخی پژوهش‌های پیشین مانند Taheri et al (2023) و Aghaei et al (2024) تفاوت دارد؛ آنان تأثیر معنادار نوسان‌های بازار ارز و طلا بر بازار سهام ایران را گزارش کرده‌اند، اما تمرکز آنان بر تجزیه‌وتحلیل شاخص کل بورس بوده و صنایع خاص را به طور جداگانه بررسی نکرده‌اند. پژوهش حاضر با تمرکز بر تجزیه‌وتحلیل بخشی و شاخص صنایع غذایی، نشان می‌دهد که اثرگذاری متغیرهای کلان مالی بر این صنعت، به‌مراتب محدودتر است و متغیرهای درون‌زای بازار سرمایه نقش پررنگ‌تری ایفا می‌کنند.

همچنین یافته‌های این پژوهش در زمینه توان مدل LSTM در پیش‌بینی دقیق رفتار متغیرها و شناسایی الگوهای غیرخطی، با نتایج پژوهش‌هایی مانند Shariffar et al (2021) و Shahrabi Ameri &Taiebysani (2025) هم‌راستاست؛ آنان نیز بر کارایی LSTM در تبیین رفتار بازار سرمایه با بهره‌گیری از داده‌های داخلی و ساختارهای پیچیده تأکید داشتند. این پژوهش با توسعه این رویکرد، از مدل LSTM نه‌تنها برای تجزیه‌وتحلیل یک بازار خاص، بلکه برای مدل‌سازی تعامل‌های بین بازاری نیز بهره برده است.

افزون بر این، یافته‌های مربوط به‌دقت پیش‌بینی مدل در سطح نوسان‌های، با نتایج پژوهش‌های بین‌المللی مانند Nikou et al (2019) و Bhanuse et al (2023) همخوانی دارد؛ نتایج بررسی و ارزیابی‌هایی که نشان داده‌اند مدل LSTM در مقایسه با روش‌های سنتی مانند GARCH یا الگوریتم‌های SVM و RF، از عملکرد دقیق‌تر و پایدارتری برخوردار بوده‌اند.

بر مبنای یافته‌های این پژوهش، می‌توان پیشنهادهای سیاستی زیر را ارائه کرد:

۱. سیاست‌گذاری در سطح کلان بازار سرمایه: باتوجه‌به وابستگی شدید شاخص صنایع غذایی به نوسان‌های شاخص کل بورس، به‌کارگیری ابزارهای تثبیت بازار همچون دامنه نوسان پویا، تقویت بازارگردانی و توسعه صندوق‌های تثبیت، می‌تواند از انتقال سریع تکانه‌های کلان بازار به این صنعت جلوگیری کند.

۲. تمرکز بر سیاست‌های داخلی مانند بهبود زنجیره تأمین مواد اولیه، کنترل هزینه‌های تولید و ارائه مشوق‌های صادراتی می‌تواند تاب‌آوری این بخش را در برابر نوسان‌های اقتصادی افزایش دهد.

۳. ایجاد سامانه‌های هشدار زودهنگام مبتنی بر مدل‌های پیش‌بینانه مانند LSTM، می‌تواند توان تصمیم‌گیری‌های سریع را برای سیاست‌گذاران و فعالان بازار افزایش دهد.

باتوجه‌به نتایج به‌دست‌آمده، پیشنهاد می‌شود در پژوهش‌های آینده، دیگر صنایع با استفاده از همین رویکرد تجزیه‌وتحلیل شوند و متغیرهای مکملی مانند شاخص‌های جهانی، تکانه‌های خبری یا عامل‌های کلان اقتصادی به مدل اضافه شود تا توان پیش‌بینی آن ارتقا یابد. همچنین توسعه ابزار کاربردی بر پایه این مدل می‌تواند به تصمیم‌سازی‌های دقیق‌تری برای سرمایه‌گذاران و سیاست‌گذاران کمک کند.

منبع‌ها:

Adams, S. and Uchema, J. (2024) Nigeria Exchange Rate Volatility: A Comparative Study of Recurrent Neural Network LSTM and Exponential Generalized Autoregressive Conditional Heteroskedasticity Models. *Journal of Artificial Intelligence and Big Data, 4: 61-73.*

Adibpour, M. (2017) Measuring the Effect of Exchange Rate Uncertainty on Industrial Corporates Stock Price Index of Tehran Stock Exchange. Macroeconomics Research Letter, 11(22): 105-131. (In Persian)

Agarwal, S., Sharma, S., Faisal, K. and Sharma, R. (2025) Time-Series Forecasting Using SVMD-LSTM: A Hybrid Approach for Stock Market Prediction. Journal of Probability and Statistics, 2025: 1-14.

Aghaei, M., Rezagholizadeh, M. and Chawshany, S. (2024) Investigation the Spillover of Volatility and Return Between Cross-Border Markets (Forex and Cryptocurrencies) and Stock Market in Iran. *Journal of Economics and Modelling, 14(4): 113-160*. (In Persian)

Andersen, T. G., and Bollerslev, T. (1997) Heterogeneous Information Arrivals and Return Volatility Dynamics: Uncovering the Long-run in High Frequency Returns. *Journal of Finance, 52: 975-1005*.

Azarm, H., Farajzadeh, Z. (2022) Challenges and opportunities of investment and financing to improve agricultural production. *Journal of Agricultural Production and Marketing Economics, 1(1): 5-24*. (In Persian)

Beheshti Masalegou, M., Afshar Kazemi, M. A., Haghighat Monfared, J. and Rezaeian, A. (2023) Deep learning for stock market forecasting using numerical and textual information (Long-Short Term Memory approach). *Quarterly Financial Engineering and Securities Management, 14(55): 65-87.* (In Persian)

Bhandari, H., Rimal, B., Pokhrel, N., Rimal, R., Dahal, K. and K C Khatri, R. (2022) Predicting stock market index using LSTM. *Machine Learning with Applications, 9: 1-15.*

Bhanuse, P., Bansode, P. and Pukale, P. (2023) Stock Market Prediction Model using LSTM. *International Journal for Research in Applied Science and Engineering Technology, 11: 503-507*.

Bollerslev, T. (1986) Generalized Autoregressive Conditional Heteroskedasticity. *Journal of Econometrics, 31(3): 307-327*.

Botunac, I., Bosna, J. and Matetic, M. (2024) Optimization of Traditional Stock Market *Strategies Using the LSTM Hybrid Approach. Information, 15:1-17*.

Cao, J., Li, Z. and Li, J. (2018) Financial time series forecasting model based on CEEMDAN and LSTM. hysica A: *Statistical Mechanics and its Applications, 519: 127-139.*

Cheteni., P. (2017) Stock market volatility using GARCH models: Evidence from South Africa and China stock markets. *Journal of Economics and Behavioral Studies, 8: 237-245.*

Chkili, W. and Nguyen, D.K. (2014) Exchange rate movements and stock market returns in a regime-switching environment: Evidence for BRICS countries. *Research in International Business and Finance, 31: 46-56.*

Doostian, R. and Mirashrafi, Z. (2025) Evaluating volatility of markets parallel to the money market on return of the capital market banking industry. *International Journal of Finance & Managerial Accounting, 10(39): 233-243.*

Dourandish, A., Shariat, E. and Arzande, N. (2014) The Study of Volatility Spillover Effects of The Exchange Rate on Agricultural Industry Index Listed on The Stock Exchange. *Journal of Agricultural Economics and Development, 28(2): 177-184.* (In Persian)

Engle, R.F. (1982) Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation. Econometrica, 50(4): 987-1007.

García-Medina, A. and Moreno, E. (2023) STM–GARCH Hybrid Model for the Prediction of Volatility in Cryptocurrency Portfolios. *Computational Economics, 63: 1511-1542.*

Hansen, J. V., McDonald, J. B. and Nelson, R. D. (1999) Time series prediction with genetic-algorithm designed neural networks: An empirical comparison with modern *statistical models. Computational Intelligence, 15(3): 171-184*.

Hochreiter, S. and Schmidhuber, J. (1997) Long Short-Term Memory. *Neural Computation, 9(8): 1735-1780.*

Jahangiri, K. and Hoseini Ebrahimabad, A. (2017) The Study of Monetary Policy, Exchange Rate and Gold Effects on the Stock Market in Iran Using MS-VAR-EGARCH Model. *Financial Research Journal, 19(3): 389-414*. (In Persian)

Kazemi, S. (2012) A review of econometric methods and applications. First International Conference on Econometrics, Methods and Applications, 1-23. (In Persian)

Keshavarzhaddad, G., Ebrahimi, B. and Jafar Abdi, A. (2011) Investigating the contagion of volatility between stock returns of the cement industry and its related industries in Iran. *Iranian Quarterly Journal of Economic Research, 16(47): 129-162*. (In Persian)

Kim, H. and Won, C. (2018) Forecasting the Volatility of Stock Price Index: A Hybrid Model Integrating LSTM with Multiple GARCH-Type Models. Expert Systems with Applications, 103: 25-37.

Liu, Y. (2019) Novel Volatility Forecasting Using Deep Learning – Long ShortTerm Memory Recurrent Neural Networks. *Expert Systems with Applications,132: 99- 109*.

Mohammadi, T., Ghasemi, A. Taklif, A. and Sadeghin, A. (2021) The analysis of permanent and temporary fluctuations of Brent Oil & Relative Industries Index With Gold, Currency Index: *Network Approach. Financial Economics, 15(56): 89-115*. (In Persian)

Nikou, M., Mansourfar, G. and Bagherzadeh, J. (2019) Stock price prediction using DEEP learning algorithm and its comparison with machine learning algorithms. *Intelligent Systems in Accounting, Finance and Management, 26: 164-174*.

Praneeth, M.V., Rahman, M.U. and Sharma, K.V. (2024) Adaptive Stock Market Prediction Using LSTM and Sentiment Analysis for Volatile Market Conditions. Frontiers in Collaborative Research, *2*(2): 14-24.

Qu, Y. and Zhao, X. (2019) Application of LSTM Neural Network in Forecasting Foreign Exchange Price. Journal of Physics: Conference Series, 1237: 1-5.

Rameh, T., Abbasi, R. and Sanai, M. R. (2022) Forecasting the stock market using LSTM neural network hybrid model. Knowledge publishing platform, 1-21. (In Persian)

Rezaei, M. and Ahmadi, A. (2024) Analyzing Financial Risk Prediction Using Deep Learning Algorithms: A Comparative Study of LSTM and CNN Models. Accounting, Finance and Computational Intelligence, 1(1): 1-12. (In Persian)

Sadeghi shahdani, M, and Mohseni, H. (2018) Spillover and transfers of gold coin price fluctuations on the capital market. Financial Economics, 12(44): 103-121. (In Persian)

Securities & Exchange Organization. (2019) <www.seo.ir>.

Selvin, S., Ravi, V., Gopalakrishnan, E. A., Menon, V. K. and Soman, K. P. (2017) Stock price prediction using LSTM, RNN and CNN-sliding window model. Proc. Int. Conf. Advances in Computing, Communications and Informatics (ICACCI), Udupi, India.

Shahrabi Ameri, H. and Taiebysani, E. (2025) Evaluation of the performance of recursive neural network (RNN) Long-Short Term Memory (LSTM) method in stock price forecasting. Journal of Investment Knowledge, 14(55): 93-117. (In Persian)

Shaki, S. and Tofighi, H. (2012) The effect of exchange rate fluctuations on Iranian stock market returns. The Second National Conference on Regionally Oriented Economic Development Strategies, 1-18. (In Persian)

Shapiro, D. (2022) Identification of structural multivariate GARCH models. Journal of Econometrics, 227(1): 212-227.

Shariffar, A., Khalili Araghi, M., Raeesi Vanani, I. and Fallah, M. (2021) The Assessment of the optimal Deep Learning Algorithm on Stock Price Prediction (Long Short-Term Memory Approach). Financial Engineering, 12(48): 348-370. (In Persian)

Shinagawa, Y. (2014) Determinants of Financial Market Spillovers: The Role of Portfolio Diversification, Trade, Home Bias, and Concentration. IMF Working Papers, 14:1-24.

Taheri, S., Abdul Baqi Attaabadi, A. M., Waziri Sarshak, M. and Arman, M. H. (2023) The Effect of Gold and Exchange Rate Volatility on Capital Market Volatility. Financial Economics, 17(63): 95-116. (In Persian)

Tule, M., Dogo, M. and Uzonwanne, G. (2018) Volatility of stock market returns and the naira exchange rate. Global Finance Journal, 35: 97-105.

Zaremba, W., Sutskever, I. and Vinyals, O. (2014) Recurrent neural network regularization. arXiv preprint arXiv:1409.2329.

Ziyadi, H., Salavati, E. and Lotfi Heravi, M. (2023) Housing Price Forecasting Using AI (LSTM). Financial Research Journal, 25(4): 557-576. (In Persian)

Zoghi, S., Raei, R. and Falahpor, S. (2022) Presenting a market direction prediction model for gold coin trades in Iran's Commodity Exchange market using Long Short-Term Memory (LSTM) algorithm. Financial Engineering and Portfolio Management, 13(53): 34-53. (In Persian)

Doi: 10.22034/IAES.2025.2058957.2124

Agricultural Economics/Volume 20/Issue 2/1405

Applied Machine Learning to Food Industry Index Effectiveness Analysis: A Long Short-Term Memory (LSTM) Neural Network Approach

Masoume Mohamadnasab Chemazi, Foad Eshghi, Seyed Mojtaba Mojaverian, Seyedeh Samira KamalMousavi[1]

Received:26 April 2025 **Accepted:23 September 2025**

Extended Abstract

Introduction

The food industry is one of the key sectors of the Iranian economy and plays a vital role in food security, employment, foreign exchange earnings, and sustainable economic development. Due to its extensive linkages with agriculture, production, trade, and exports, the performance of this industry can be affected by developments in financial and macroeconomic markets. In particular, changes in the overall stock market, exchange rate, and gold coin prices may influence the behavior and risk structure of food-industry firms. Therefore, identifying the interactions between the Food Industry Index and major financial markets can provide useful information for investors, policymakers, and economic analysts.

Traditional econometric approaches have been widely used to investigate financial market relationships; however, their ability to capture nonlinear relationships and complex temporal dependencies may be limited. In recent years, machine-learning and deep-learning approaches have provided new opportunities for modeling complex financial time series. Among these methods, the Long Short-Term Memory (LSTM) neural network is particularly suitable for sequential data because of its ability to retain long-term information and identify nonlinear temporal patterns. Accordingly, this study aims to analyze the dynamic relationships among the Food Industry Index, the overall stock market index, the exchange rate, and gold coin prices in Iran using an LSTM neural network. The study considers both the original values of the variables and their volatility to provide a more comprehensive assessment of inter-market relationships.

[1]Respectively: PhD Student, Assistant Professor (Corresponding Author), Professor and PhD Student, Department of Agricultural Economics, Sari University of Agricultural Sciences and Natural Resources
Email: fesh.foad@gmail.com

Methodology

This study employs a Long Short-Term Memory (LSTM) neural network to analyze the dynamic behavior and interrelationships among selected Iranian financial markets. The dataset consists of daily observations of the Food Industry Index (excluding sugar and sugarcane), the overall stock market index, the free-market exchange rate (US dollar), and gold coin prices over the period from Farvardin 1396 to Esfand 1402 (approximately March 2017 to March 2024). The stock market indicators were obtained from the Tehran Stock Exchange, while exchange-rate and gold coin price data were collected from reliable sources. Data processing and analysis were conducted using Python and its specialized libraries.

The LSTM architecture, as an advanced form of recurrent neural network, was employed because of its ability to retain and utilize long-term temporal information through its memory cell and input, forget, and output gates. The model was applied to both the original values and the volatility of the variables. Model performance was evaluated using three statistical error measures: Mean Squared Error (MSE), Mean Absolute Error (MAE), and Residual Sum of Squares (RSS). In addition, correlation matrices were used to examine the relationships among the variables at both the price-level and volatility levels. Training and validation loss curves, as well as boxplots of actual and predicted observations, were used to assess the learning process, generalization capability, and consistency between actual and predicted values.

Results and Discussion

The results indicate that the LSTM model was able to learn the underlying patterns of both the original values and the volatility of the financial variables. The training and validation loss curves showed a declining pattern and converged at relatively low levels, suggesting satisfactory model learning and relatively stable generalization performance. The model also demonstrated an acceptable ability to reproduce the observed patterns in both the original series and their volatility.

The error measures further confirmed the predictive performance of the model. For the original values, the MSE, MAE, and RSS were 0.004467708, 0.035744590, and 6.344145745, respectively. For volatility, the corresponding values were 0.000461437, 0.038773810, and 6.552409129. The considerably lower MSE obtained for volatility indicates the model's ability to capture variations in the series, while the relatively similar MAE values in the two cases suggest a comparatively stable average prediction error.

The correlation analysis revealed important differences between relationships at the price level and at the volatility level. At the price level, the Food Industry Index had its strongest correlation with the overall stock market index, with a correlation coefficient of 0.76, indicating considerable comovement between the two stock-market indicators.

In contrast, the correlations between the overall stock market index and the exchange rate (0.077), the overall stock market index and gold coin prices (0.046), and gold coin prices and the exchange rate (-0.039) were weak.

At the volatility level, the correlation between food-industry volatility and overall stock-market volatility remained relatively high at 0.76. Moreover, the correlation between gold coin price volatility and exchange-rate volatility increased substantially to 0.68, while the correlation between overall stock-market volatility and exchange-rate volatility reached 0.12. These findings indicate that inter-market relationships can differ considerably depending on whether price levels or short-term fluctuations are considered. In particular, some relationships become more pronounced when volatility rather than price levels is considered.

The comparison of actual and predicted distributions also showed considerable similarity between the two series. Although a slight contraction in the predicted range was observed, particularly in the presence of extreme observations, the proximity of the medians and central distributions indicated that the LSTM model was able to reproduce the general behavior of the variables. Similar patterns were observed for volatility, where the model successfully captured the central range and distribution of fluctuations.

Overall, the findings suggest that the Food Industry Index is more closely associated with the overall stock market than with the exchange-rate and gold coin markets. This result highlights the important role of domestic stock-market conditions in shaping the behavior of the Food Industry Index during the study period. The findings also differ to some extent from studies focusing on the overall Iranian stock market that reported significant effects from exchange-rate and gold-market volatility, suggesting that inter-market relationships may vary across specific sectors.

Suggestion

Based on the findings, several practical and research-oriented suggestions can be proposed. First, given the relatively strong association between the Food Industry Index and the overall stock market, policymakers and market authorities should pay particular attention to mechanisms that can reduce the rapid transmission of broad stock-market fluctuations to food-industry firms. Measures such as strengthening market-making mechanisms, developing stabilization funds, and improving market-stabilization instruments may contribute to greater resilience of the sector.

Second, greater attention should be given to domestic factors affecting the food industry, including the improvement of raw-material supply chains, management of production costs, and the development of export incentives. Such measures can strengthen the industry's resilience to financial and economic fluctuations.

Third, the development of early-warning systems based on predictive models such as LSTM can assist policymakers, investors, and other market participants in identifying emerging fluctuations and responding more rapidly.
Finally, future studies are encouraged to apply similar approaches to other sectoral stock indices and incorporate complementary variables such as global market indicators, news shocks, and macroeconomic factors. Combining these additional information sources with deep-learning models may improve predictive performance and provide a more comprehensive understanding of inter-market volatility relationships.
JEL Classification: C45, C53, G14, E37
Keywords: Deep Learning, Parallel Markets, Coin, Exchange Rate, Market Volatility