

## ارائه مدل بهینه GWO-LSTM جهت پیش‌بینی شاخص S&P 500 در بازار

### بورس

#### نوع مقاله: پژوهشی

آرش عینی<sup>۱</sup>

مهناز خدائی نیارق<sup>۲</sup>

تاریخ پذیرش: ۱۴۰۴/۸/۳

تاریخ دریافت: ۱۴۰۴/۴/۱۷

#### چکیده

پیش‌بینی بازار بورس نقش مهمی در تصمیم‌گیری‌های مالی ایفا می‌کند، اما مدل‌های سنتی در شناسایی و بازتاب پویایی‌های پیچیده و غیرخطی داده‌های مالی با چالش‌هایی مواجه هستند. با وجود استفاده گسترده از روش‌های یادگیری ماشین برای بهبود دقت پیش‌بینی، بسیاری از این مدل‌ها به دلیل تنظیم غیربهینه پارامترها و ضعف در سازگاری با نوسانات بازار، نتایج دقیقی ارائه نمی‌دهند. در این مطالعه، یک مدل ترکیبی نوین با نام GWO-LSTM ارائه شده است که با بهره‌گیری از الگوریتم بهینه‌سازی گرگ خاکستری (GWO) به تنظیم بهینه پارامترهای شبکه عصبی حافظه بلندمدت کوتاه‌مدت (LSTM) می‌پردازد. هدف این مدل، افزایش دقت پیش‌بینی قیمت سهام است. ارزیابی عملکرد مدل با استفاده از داده‌های تاریخی شاخص S&P 500 در بازه زمانی ۲۰۱۵ تا ۲۰۲۴ و با به‌کارگیری متغیرهایی نظیر قیمت باز، سقف، کف، حجم معاملات و قیمت بسته انجام شد. نتایج به کمک معیارهایی همچون ضریب تعیین ( $R^2$ )، ریشه میانگین مربعات خطا (RMSE) و میانگین خطای مطلق (MAE) تحلیل شد و عملکرد مدل پیشنهادی با مدل‌های مرجع نظیر پرسپترون چندلایه، شبکه عصبی مصنوعی و ماشین یادگیری شدید مقایسه گردید. همچنین آزمون‌های آماری Diebold-Mariano و مقدار  $p$  برتری معنادار مدل پیشنهادی را از نظر آماری تأیید کردند. یافته‌ها نشان می‌دهد مدل GWO-LSTM می‌تواند به عنوان ابزاری مؤثر در بهبود پیش‌بینی‌های بازار بورس، ارتقای تصمیم‌گیری‌های مالی و مدیریت ریسک مورد استفاده قرار گیرد.

<sup>۱</sup> کارشناس ارشد حسابداری موسسه غیرانتفاعی نوین، اردبیل، ایران (نویسنده مسئول)

arash.einy1364@gmail.com

M\_khodaei66@yahoo.com

<sup>۲</sup> کارشناسی ارشد روان‌شناسی، دانشگاه آزاد اردبیل

کلمات کلیدی: پیش‌بینی بازار بورس، یادگیری ماشین، سری‌های زمانی، مدیریت مالی، مدیریت ریسک، GWO-LSTM، بهینه‌سازی فراابتکاری.  
طبقه‌بندی JEL: F00

## مقدمه

بازارهای مالی با نوسانات بالا شناخته می‌شوند، که پیش‌بینی بازار بورس را به چالشی مهم برای سرمایه‌گذاران و مؤسسات مالی تبدیل کرده است (لیائو و ما، ۲۰۲۴؛ پان و همکاران، ۲۰۲۴؛ پرل و روکاخ، ۲۰۲۴)<sup>۱</sup>. پیش‌بینی دقیق قیمت سهام و روندهای بازار می‌تواند به بهبود تصمیم‌گیری‌ها، بهینه‌سازی استراتژی‌های سرمایه‌گذاری و کاهش ریسک‌های مالی کمک کند (دپ داس و همکاران، ۲۰۲۴؛ ژائو و همکاران، ۲۰۲۴)<sup>۲</sup>. به‌طور سنتی، مدل‌های اقتصادسنجی مانند مدل‌های میانگین متحرک خودبازگشتی<sup>۳</sup> و گارچ<sup>۴</sup> برای پیش‌بینی روندهای بازار بورس استفاده می‌شدند (اچ. هن و همکاران، ۲۰۲۴؛ مائو و همکاران، ۲۰۲۴؛ پاپاژورجیو و همکاران، ۲۰۲۴)<sup>۵</sup>. با این حال، این مدل‌ها به‌طور ذاتی خطی هستند و اغلب در شبیه‌سازی دینامیک‌های غیرخطی و ماهیت آشفته داده‌های مالی دچار مشکل می‌شوند (ذوالفقاری نیا و همکاران، ۲۰۲۴)<sup>۶</sup>.

با ظهور تکنیک‌های یادگیری ماشین (ML)، پژوهشگران به روش‌های پیچیده‌تری روی آورده‌اند که قادر به مدل‌سازی پیچیدگی‌های داده‌های بازار بورس هستند. مدل‌هایی مانند پرسپترون چندلایه (MLP)، شبکه‌های عصبی مصنوعی (ANN) و ماشین‌های یادگیری شدید (ELM) توانسته‌اند الگوهای غیرخطی را در داده‌های سری زمانی شبیه‌سازی کنند و دقت پیش‌بینی‌های مالی را بهبود بخشند (لطیف و همکاران، ۲۰۲۴)<sup>۷</sup>. با این حال، این مدل‌ها با محدودیت‌هایی مواجه هستند، به‌ویژه در زمینه تنظیم هایپرپارامترها و قابلیت تطبیق با شرایط نوسانی بازار (سریواستاوا و همکاران، ۲۰۲۴)<sup>۸</sup>.

با وجود این پیشرفت‌ها، پیش‌بینی بازار بورس هنوز یک مشکل باز تحقیقاتی است. ماهیت همیشه در حال تغییر بازار مالی، که تحت تأثیر عوامل متعددی مانند متغیرهای کلان اقتصادی، احساسات سرمایه‌گذاران و رویدادهای ژئوپلیتیکی است، عدم قطعیت زیادی ایجاد می‌کند. تقاضا برای مدل‌های دقیق‌تر، قابل‌اطمینان‌تر و قابل تطبیق‌تر همچنان در حال رشد است چرا که سرمایه‌گذاران به دنبال ابزارهایی هستند که بتوانند حرکات بازار را بهتر پیش‌بینی کنند و تصمیمات آگاهانه‌تری بگیرند.

<sup>1</sup> Liao & Ma, 2024; Pan et al., 2024; Priel & Rokach, 2024

<sup>2</sup> Dip Das et al., 2024; Zhao et al., 2024

<sup>3</sup> ARIMA

<sup>4</sup> GARCH

<sup>5</sup> X. Chen et al., 2024; Mao et al., 2024; Papageorgiou et al., 2024

<sup>6</sup> Zolfagharinia et al., 2024

<sup>7</sup> Latif et al., 2024

<sup>8</sup> Srivastava et al., 2024

چالش‌های متعددی همچنان مانع عملکرد مدل‌های یادگیری ماشین در پیش‌بینی بازار بورس می‌شود. یکی از مسائل اصلی، تنظیم هایپرپارامترها است که تأثیر زیادی بر عملکرد مدل دارد. بیشتر مدل‌های یادگیری ماشین، از جمله LSTM و MLP، نیاز به انتخاب دقیق هایپرپارامترها (مانند تعداد لایه‌ها، نرخ یادگیری و اندازه دسته‌ها) دارند تا به نتایج بهینه دست یابند (بنیوال و همکاران، ۲۰۲۴؛ قطبی و زاهدی، ۲۰۲۴؛ لیو و همکاران، ۲۰۲۴).<sup>۱</sup> روش‌های سنتی تنظیم هایپرپارامترها معمولاً به آزمون و خطا یا تکنیک‌های جستجوی شبکه‌ای وابسته‌اند که می‌توانند زمان‌بر و از نظر محاسباتی پرهزینه باشند. علاوه بر این، حساسیت مدل‌هایی مانند LSTM به هایپرپارامترها می‌تواند به بیش‌برازش منجر شود، که باعث می‌شود مدل در داده‌های تاریخی خوب عمل کند اما در داده‌های جدید عملکرد ضعیفی داشته باشد.

انگیزه دیگر برای این مطالعه ناشی از نیاز به بهبود تعمیم‌پذیری مدل‌ها در شرایط مختلف بازار است. مدل‌های موجود معمولاً در دوره‌های بازار باثبات عملکرد خوبی دارند، اما نمی‌توانند با شرایط نوسانی بازار که با نوسانات قیمت ناگهانی و روندهای پیش‌بینی‌ناپذیر مشخص می‌شوند، تطبیق یابند. با توجه به اینکه بازارهای سهام تحت تأثیر عوامل متعددی مانند سیاست‌های اقتصادی، رویدادهای سیاسی و بحران‌های جهانی قرار دارند، ضروری است که مدل‌های پیش‌بینی بتوانند در برابر سناریوهای مختلف مقاوم باقی بمانند.

علاوه بر این، هرچند تحقیقات زیادی در زمینه به‌کارگیری یادگیری ماشین در پیش‌بینی بازار بورس انجام شده است، بسیاری از این مطالعات به مجموعه محدودی از معیارهای عملکرد می‌پردازند. معیارهایی مانند ضریب تعیین ( $R^2$ )، ریشه خطای مربعات میانگین (RMSE) و خطای مطلق میانگین (MAE) دیدگاه‌هایی درباره دقت پیش‌بینی‌ها ارائه می‌دهند، اما تصویر کاملی از عملکرد مدل‌ها در شرایط مختلف بازار نمی‌دهند. آزمون‌های آماری مانند آزمون دیبولد-ماریانو که می‌تواند دقت پیش‌بینی دو مدل رقیب را مقایسه کند، به‌ندرت در مطالعات گنجانده می‌شود و این باعث ایجاد فاصله‌ای در درک عملکرد مدل‌های جدید نسبت به مدل‌های موجود می‌شود.

برای رفع این چالش‌ها، این مقاله یک رویکرد هیبریدی جدید معرفی می‌کند که ترکیبی از قدرت‌های بهینه‌ساز گرگ خاکستری (GWO) و شبکه‌های عصبی حافظه بلندمدت کوتاه‌مدت (LSTM) است. الگوریتم GWO برای بهینه‌سازی هایپرپارامترهای مدل LSTM استفاده می‌شود، که بار محاسباتی روش‌های سنتی تنظیم هایپرپارامترها را کاهش داده و عملکرد بهتری در مجموعه‌ای گسترده از تنظیمات هایپرپارامترها ارائه می‌دهد. این رویکرد هیبریدی از مکانیزم

<sup>۱</sup> Beniwal et al., 2024; Ghotbi & Zahedi, 2024; Liu et al., 2024

جستجوی کارآمد GWO که رفتار اجتماعی و شکار گرگ‌های خاکستری را شبیه‌سازی می‌کند، برای جستجو در فضای راه‌حل و شناسایی هایپرپارامترهای بهینه استفاده می‌کند. استفاده از LSTM در این مطالعه ناشی از توانایی این شبکه‌ها در مدل‌سازی وابستگی‌های بلندمدت در داده‌های سری زمانی است. شبکه‌های LSTM به‌ویژه برای پیش‌بینی سری‌های زمانی مالی مناسب هستند زیرا می‌توانند اطلاعات را برای مدت طولانی حفظ کنند، که آن‌ها را برای شبیه‌سازی روندها و الگوها در حرکت‌های قیمت سهام ایده‌آل می‌سازد. با ترکیب LSTM با GWO، هدف ما ایجاد مدلی قوی است که بتواند در شرایط باثبات و نوسانی بازار به‌خوبی تعمیم یابد. یکی از نوآوری‌های کلیدی این مطالعه، ارزیابی جامع مدل GWO-LSTM با استفاده از معیارهای مختلف است، از جمله  $R^2$ ، RMSE و MAE. علاوه بر این، ما از آزمون دیبولد-ماریانو و آزمون‌های آماری p-value برای مقایسه دقیق مدل پیشنهادی با مدل‌های سنتی یادگیری ماشین مانند MLP، ANN و ELM استفاده می‌کنیم. گنجاندن این آزمون‌های آماری درک عمیق‌تری از عملکرد مدل فراهم می‌آورد و برتری آن را در پیش‌بینی قیمت سهام نشان می‌دهد. علاوه بر این، این مطالعه بر روی شاخص S&P 500، یکی از پرطرفدارترین شاخص‌های سهام در جهان، تمرکز دارد که طیف وسیعی از شرایط بازار را نمایندگی می‌کند. داده‌های استفاده‌شده از ۲۰۱۵ تا ۲۰۲۴ را شامل می‌شود و ویژگی‌های مالی کلیدی مانند قیمت باز، بالا، پایین، قیمت بسته و حجم معاملات را در بر می‌گیرد. با اعمال مدل GWO-LSTM پیشنهادی به این مجموعه داده جامع، هدف ما نشان دادن قابلیت و اثربخشی آن در سناریوهای واقعی مالی است. مشارکت‌های این مطالعه را می‌توان به شرح زیر خلاصه کرد:

- مدل هیبریدی جدید GWO-LSTM برای پیش‌بینی بهینه بازار بورس.
- اعمال مدل بر روی شاخص S&P 500 با پوشش دهه‌ای از داده‌ها (۲۰۱۵-۲۰۲۴) و استفاده از ویژگی‌های مالی کلیدی.
- تحلیل مقایسه‌ای با مدل‌های MLP، ANN و ELM با استفاده از  $R^2$ ، RMSE، MAE و آزمون‌های آماری مانند دیبولد-ماریانو و p-value.
- نشان دادن توانایی مدل در تعمیم‌پذیری در شرایط باثبات و نوسانی بازار و ارائه بینش‌هایی در مورد استحکام و قابلیت تطبیق آن.

### ۱. ساختار مقاله

سایر بخش‌های این مقاله به‌شرح زیر سازمان‌دهی شده‌اند: بخش ۲ مروری بر ادبیات که مروری جامع بر مدل‌های پیش‌بینی بازار بورس با تمرکز خاص بر رویکردهای یادگیری ماشین ارائه

می‌دهد. این بخش نقاط قوت و ضعف مدل‌های مختلف را بررسی می‌کند و زمینه‌ای برای مدل GWO-LSTM پیشنهادی فراهم می‌آورد. بخش ۳ روش‌ها و مواد است که در آن روش‌شناسی مورد استفاده در توسعه مدل GWO-LSTM توضیح داده می‌شود. این بخش شامل توضیحی دقیق از الگوریتم GWO، معماری LSTM و مجموعه داده مورد استفاده برای آموزش و ارزیابی است. همچنین، تنظیمات تجربی و معیارهای ارزیابی در این بخش ذکر شده‌اند. بخش ۴ نتایج است که نتایج آزمایش‌های ما را ارائه می‌دهد، از جمله مقایسه‌های عملکردی بین مدل GWO-LSTM و مدل‌های پایه (ELM, ANN, MLP). همچنین، تجزیه و تحلیل دقیقی از آزمون‌های آماری دیبولد-ماریانو و p-value ارائه می‌دهیم که برتری مدل پیشنهادی را تأیید می‌کند. بخش ۵ بحث است که در آن نتایج را بررسی می‌کنیم، به‌ویژه در زمینه تصمیم‌گیری مالی و مدیریت ریسک. همچنین، محدودیت‌های مطالعه و زمینه‌های تحقیقاتی آینده را بررسی می‌کنیم. بخش ۶ نتیجه‌گیری است که با خلاصه‌ای از یافته‌های کلیدی و مشارکت‌های مدل GWO-LSTM در پیش‌بینی بازار بورس پایان می‌یابد. همچنین، مسیرهای تحقیقاتی آینده، از جمله ادغام تکنیک‌های بهینه‌سازی دیگر و مدل‌های یادگیری ماشین را بیان می‌کنیم.

## ۲. مرور ادبیات

### روش‌های پیش‌بینی سنتی بازار بورس

مدل‌های پیش‌بینی سنتی بازار بورس مدت‌هاست که برای تحلیل و پیش‌بینی داده‌های سری زمانی مالی استفاده می‌شوند. این مدل‌ها شامل روش‌های آماری مانند ARIMA و GARCH هستند که به‌طور گسترده‌ای برای پیش‌بینی بازارهای مالی به‌کار گرفته شده‌اند. مدل‌های ARIMA به‌ویژه برای مدل‌سازی روابط خطی در داده‌های سری زمانی مؤثر هستند و با شبیه‌سازی الگوهای قیمت‌های تاریخی، حرکات آینده را پیش‌بینی می‌کنند. با این حال، ساختار خطی ARIMA باعث می‌شود که این مدل‌ها در شبیه‌سازی رفتارهای غیرخطی رایج در بازارهای مالی ضعیف عمل کنند. برای مثال، کومبور و همکاران (۲۰۲۲)<sup>۱</sup> مدل‌های ARIMA را برای پیش‌بینی قیمت سهام به‌کار بردند و مشاهده کردند که اگرچه مدل‌های ARIMA قادر به شبیه‌سازی روندهای کوتاه‌مدت بودند، اما عملکرد آن‌ها در پیش‌بینی‌های بلندمدت کاهش یافت. به‌طور مشابه، نت و همکاران (۲۰۲۰)<sup>۲</sup> دریافتند که مدل‌های سنتی سری زمانی مانند ARIMA و GARCH در شرایط با نوسانات کم مؤثر بودند اما قادر به شبیه‌سازی نوسانات بالای بازار نبودند. علاوه بر این،

<sup>1</sup> Kumbure et al. (2022)

<sup>2</sup> Nti et al. (2020)

گاندمال و کومار توضیح دادند که روش‌های پیش‌بینی سنتی معمولاً انعطاف‌پذیری کمی برای تطبیق با تغییرات ناگهانی بازار دارند (گاندمال و کومار، ۲۰۱۹)<sup>۱</sup>.

### روش‌های پیش‌بینی بازار بورس با یادگیری ماشین

محدودیت‌های مدل‌های آماری سنتی، به‌ویژه در برخورد با الگوهای غیرخطی در داده‌های بازار بورس، باعث تغییرات قابل‌توجهی در سمت یادگیری ماشین شده است. مدل‌های ML توانایی شبیه‌سازی روابط پیچیده در داده‌های مالی دارند که مدل‌های سنتی قادر به شناسایی آن‌ها نیستند. مدل‌های MLP و ماشین‌های بردار پشتیبانی (SVM) از جمله مدل‌های پرکاربرد در پیش‌بینی بازار بورس هستند. این مدل‌ها قادرند از داده‌های تاریخی یاد بگیرند، الگوهای پیچیده را شبیه‌سازی کنند و پیش‌بینی‌هایی بر اساس آن الگوها انجام دهند. بانک و همکاران (۲۰۲۱)<sup>۲</sup> از مدل‌های MLP و SVM را مقایسه کردند و دریافتند که هر دو مدل در مقایسه با ARIMA از دقت پیش‌بینی بیشتری برخوردارند. در یک نظرسنجی توسط حسین و همکاران (۲۰۲۲)<sup>۳</sup>، نویسندگان تکنیک‌های مختلف ML را بررسی کردند و نشان دادند که مدل‌های MLP در یادگیری الگوهای پیچیده در داده‌های مالی عالی عمل می‌کنند، اما نیاز به تنظیم دقیق دارند. لاهمیر و همکاران (۲۰۲۳)<sup>۴</sup> پتانسیل مدل‌های هیبریدی ML را در بهبود پیش‌بینی قیمت سهام نشان دادند. در حالی که سونکاده و همکاران (۲۰۲۳)<sup>۵</sup> عملکرد برتر مدل‌های MLP و SVM را نسبت به مدل‌های سنتی تأکید کردند. علاوه بر این، مانتریا و همکاران (۲۰۲۳)<sup>۶</sup> اعتبارسنجی کردند که تکنیک‌های ML به‌طور مداوم دقت بهتری در پیش‌بینی بازار بورس ارائه می‌دهند، به‌ویژه در پیش‌بینی‌های کوتاه‌مدت.

### روش‌های پیش‌بینی بازار بورس با یادگیری عمیق

تکنیک‌های یادگیری عمیق (DL)، به‌ویژه شبکه‌های LSTM، به‌عنوان ابزارهای قدرتمند برای پیش‌بینی بازار بورس شناخته شده‌اند. شبکه‌های LSTM نوعی شبکه عصبی بازگشتی (RNN) هستند که می‌توانند وابستگی‌های زمانی در داده‌ها را شبیه‌سازی کنند، که این ویژگی آن‌ها را برای پیش‌بینی سری‌های زمانی مانند قیمت‌های سهام بسیار مناسب می‌سازد. برخلاف مدل‌های سنتی

<sup>1</sup> Gandhmal & Kumar, 2019

<sup>2</sup> Banik et al. (2021)

<sup>3</sup> Hossain et al. (2022)

<sup>4</sup> Lahmiri et al. (2023)

<sup>5</sup> Sonkavde et al. (2023)

<sup>6</sup> Mintarya et al. (2023)

ML، LSTM قادر به مدل‌سازی وابستگی‌های بلندمدت در داده‌های دنباله‌ای است، که به آن این امکان را می‌دهد که روابط پیچیده زمانی را که اغلب در بازارهای مالی وجود دارد شبیه‌سازی کند. تورمن و همکاران (۲۰۲۱)<sup>۱</sup> نشان دادند که مدل‌های LSTM در پیش‌بینی قیمت سهام از MLP برتر هستند زیرا قادر به شبیه‌سازی وابستگی‌های بلندمدت هستند. به‌طور مشابه، کومار و همکاران (۲۰۲۱)<sup>۲</sup> مدل‌های LSTM را با سایر مدل‌های یادگیری عمیق مقایسه کردند و دریافتند که LSTM بهترین پیش‌بینی‌ها را ارائه می‌دهد. باتلا و همکاران (۲۰۲۳)<sup>۳</sup> همچنین دریافتند که LSTM از شبکه‌های عصبی کانولوشنی (CNN) در پیش‌بینی روندهای سهام مؤثرتر است، در حالی که جی. وانگ و همکاران (۲۰۲۴)<sup>۴</sup> برتری LSTM را در مدل‌سازی روندهای بلندمدت تأکید کردند. نهایتاً، رخا و سبو نشان دادند که مدل‌های LSTM از CNN در پیش‌بینی سری‌های زمانی مالی برتر هستند. رکا و سابو (۲۰۲۱)<sup>۵</sup>.

### روش‌های پیش‌بینی هیبریدی بازار بورس

در سال‌های اخیر، مدل‌های هیبریدی که ترکیبی از تکنیک‌های یادگیری ماشین و الگوریتم‌های بهینه‌سازی هستند، در پیش‌بینی بازار بورس محبوبیت پیدا کرده‌اند. این مدل‌های هیبریدی به‌منظور بهبود دقت پیش‌بینی با بهره‌گیری از نقاط قوت چندین الگوریتم طراحی شده‌اند. یک رویکرد رایج شامل استفاده از الگوریتم بهینه‌سازی برای تنظیم دقیق پارامترهای یک مدل یادگیری ماشین مانند شبکه LSTM به‌منظور بهبود عملکرد آن است. وای. وانگ و همکاران (۲۰۲۲)<sup>۶</sup> مدل هیبریدی با استفاده از الگوریتم‌های ژنتیک (GA) برای بهینه‌سازی LSTM معرفی کردند که بهبود قابل‌توجهی در پیش‌بینی قیمت سهام به‌دست آورد. به‌طور مشابه، کیو. چن و همکاران (۲۰۲۰)<sup>۷</sup> از بهینه‌سازی ازدحام ذرات (PSO) با LSTM استفاده کردند که به‌طور چشمگیری خطاهای پیش‌بینی را کاهش داد. کاشر و همکاران (۲۰۲۲)<sup>۸</sup> مدل هیبریدی را پیشنهاد کردند که تکنیک‌های بهینه‌سازی را با LSTM ترکیب می‌کند و عملکرد بهتری نسبت به مدل‌های مستقل

<sup>1</sup> Thormann et al. (2021)

<sup>2</sup> Kumar et al. (2021)

<sup>3</sup> Bathla et al. (2023)

<sup>4</sup> J. Wang et al. (2024)

<sup>5</sup> Rekha & Sabu (2021)

<sup>6</sup> Y. Wang et al. (2022)

<sup>7</sup> Q. Chen et al. (2020)

<sup>8</sup> Kochhar et al. (2022)

نشان داد. شن و همکاران (۲۰۲۰)<sup>۱</sup> نشان دادند که ترکیب مدل‌های یادگیری عمیق با الگوریتم‌های بهینه‌سازی به‌طور مداوم از روش‌های سنتی برتر عمل می‌کند.

### ۳. روش پژوهش

#### رویکرد پیشنهادی

##### حافظه بلندمدت کوتاه‌مدت (LSTM):

شبکه‌های LSTM نوع خاصی از شبکه‌های عصبی بازگشتی هستند که برای مدل‌سازی داده‌های دنباله‌ای طراحی شده‌اند و قادرند اطلاعات را برای مدت طولانی حفظ کنند. برخلاف RNN‌های استاندارد، شبکه‌های LSTM از گیت‌ها (ورودی، فراموشی و خروجی) برای کنترل جریان اطلاعات استفاده می‌کنند که به آن‌ها این امکان را می‌دهد که وابستگی‌های بلندمدت را به‌طور مؤثر در داده‌های سری زمانی شبیه‌سازی کنند، همان‌طور که در شکل ۱ نشان داده شده است. معادلات اصلی حاکم بر شبکه‌های LSTM به شرح زیر هستند:

گیت فراموشی:

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

گیت ورودی:

$$i_t = \sigma(W_i \cdot [h_{\{t-1\}}, x_t] + b_i) \quad (2)$$

حالت سلول نامزد:

$$C_{\sim t} = \tanh(W_c \cdot [h_{\{t-1\}}, x_t] + b_c) \quad (3)$$

به‌روزرسانی حالت سلول:

$$C_t = f_t \cdot C_{\{t-1\}} + i_t \cdot C_{\sim t} \quad (4)$$

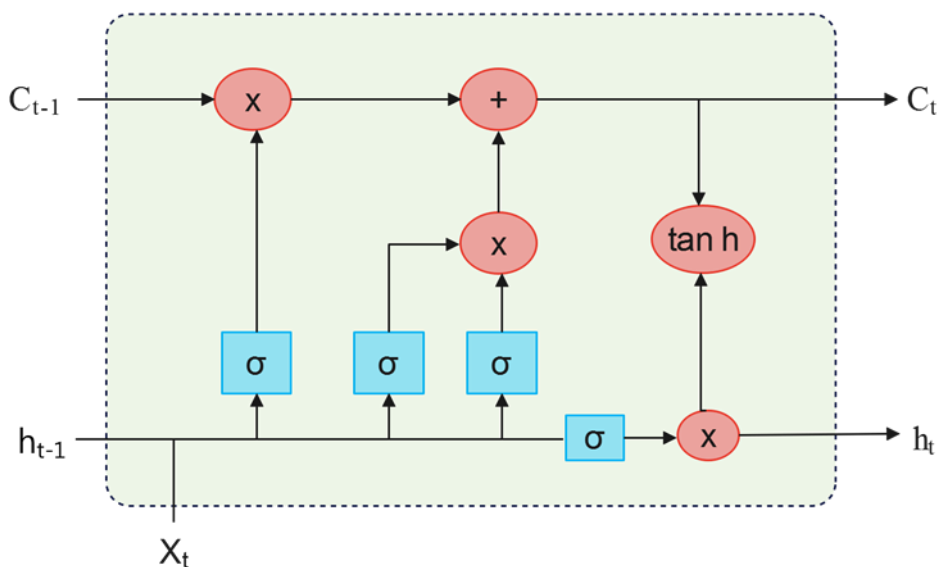
گیت خروجی:

$$o_t = \sigma(W_o \cdot [h_{\{t-1\}}, x_t] + b_o) \quad (5)$$

وضعیت پنهان:

$$h_t = o_t \cdot \tanh(C_t) \quad (6)$$

<sup>1</sup> Shen et al. (2020)



شکل ۱. ساختار مدل LSTM.

منبع: باتلا و همکاران (۲۰۲۳)

برای جلوگیری از بیش‌برازش، از تکنیک‌های زیر استفاده شد:  
 Dropout: نرخ ۰,۲ در لایه‌های LSTM برای غیرفعال‌سازی تصادفی نورون‌ها.  
 Early Stopping: توقف آموزش اگر خطای اعتبارسنجی در ۱۰ تکرار بهبود نیابد.  
 L2 Regularization: با ضریب ۰,۰۰۱ برای کنترل پیچیدگی مدل.  
 این تکنیک‌ها تفاوت  $R^2$  بین داده‌های آموزشی (۰,۹۹۵) و تست (۰,۹۹۱) را به کمتر از ۰,۵٪ کاهش داد، که نشان‌دهنده عدم بیش‌برازش است.

#### بهینه‌ساز گرگ خاکستری (GWO):

GWO یک الگوریتم بهینه‌سازی است که الهام‌گرفته از سلسله‌مراتب رهبری و رفتار شکارگر گرگ‌های خاکستری می‌باشد. در الگوریتم GWO، گرگ‌ها به چهار دسته تقسیم می‌شوند: آلفا ( $\alpha$ )، بتا ( $\beta$ )، دلتا ( $\delta$ ) و امگا ( $\omega$ ). گرگ‌های  $\alpha$  بهترین راه‌حل‌ها را نمایندگی می‌کنند، که بعد از آن‌ها گرگ‌های  $\beta$  و  $\delta$  قرار دارند، در حالی که گرگ‌های  $\omega$  نماینده سایر کاندیدها هستند. الگوریتم GWO موقعیت هر گرگ را بر اساس بهترین راه‌حل‌ها ( $\alpha$ ،  $\beta$  و  $\delta$ ) به‌روز می‌کند به‌صورت زیر:

فاصله بین شکار و گرگ‌ها:

$$D_{\alpha} = |C_1 \cdot X_{\alpha} - X| \quad (7)$$

موقعیت جدید گرگ‌ها:

$$X(t+1) = \frac{(X_{\alpha} + X_{\beta} + X_{\delta})}{3} \quad (8)$$

الگوریتم ۱ نشان می‌دهد که چگونه روش GWO هایپرپارامترهای مدل LSTM را بهینه می‌کند.

**الگوریتم ۱:** روند کار روش پیشنهادی.

**مقداردهی اولیه جمعیت گرگ‌ها:**

اندازه جمعیت گرگ‌ها: ۳۰

حداکثر تعداد تکرار: ۵۰

دامنه‌های هایپرپارامترها:

نرخ یادگیری: [0.0001, 0.01]

اندازه بیج: [16, 128]

تعداد لایه‌ها: [1, 4]

تعداد نرون‌ها در هر لایه: [۵۰, ۲۰۰]

**حلقه اصلی تکرار (برای  $t = 1$  تا ۵۰)**

ایجاد جمعیت اولیه:

هر گرگ نمایانگر یک مجموعه تصادفی از هایپرپارامترهای LSTM است.

ارزیابی عملکرد هر گرگ:

مدل LSTM را با هایپرپارامترهای متناظر هر گرگ پیکربندی کن.

مدل را بر داده‌های آموزشی آموزش بده.

خطای اعتبارسنجی را با معیارهای MSE یا Cross-Entropy محاسبه کن.

رتبه‌بندی جمعیت:

گرگ‌ها را بر اساس میزان خطا مرتب کن (کمتر، بهتر).

سه گرگ برتر را به‌عنوان  $\alpha$  (بهترین)،  $\beta$  (دوم) و  $\delta$  (سوم) انتخاب کن.

به‌روزرسانی موقعیت گرگ‌ها:

فاصله از گرگ‌های  $\alpha$ ،  $\beta$  و  $\delta$  را محاسبه کن (طبق معادله ۷).

موقعیت جدید هر گرگ را با استفاده از معادله زیر تعیین کن:

$$X(t+1) = \frac{X_\alpha + X_\beta + X_\delta}{3}$$

مقادیر جدید را در دامنه مجاز هایپرپارامترها محدود کن.

### مرحله ۳: معیارهای توقف

الگوریتم در صورت تحقق یکی از شرایط زیر متوقف می‌شود:

تغییر خطا بین دو تکرار متوالی کمتر از ۰,۰۰۱ باشد.

خطای مدل کمتر از ۰,۰۰۵ باشد.

در ۵ تکرار متوالی بهبود کمتر از ۰,۱٪ مشاهده شود.

تعداد تکرارها به حداکثر مقدار (t = 50) برسد.

### مرحله ۴: انتخاب بهترین گرگ ( $\alpha$ )

گرگی که کمترین خطای نهایی را دارد، به‌عنوان بهترین مجموعه هایپرپارامترها انتخاب می‌شود.

### مرحله ۵: آموزش نهایی مدل LSTM

مدل نهایی را با هایپرپارامترهای انتخابی  $\alpha$  آموزش بده.

عملکرد مدل را روی داده‌های تست با معیارهای زیر ارزیابی کن:

$R^2$  (ضریب تعیین)

RMSE (ریشه میانگین مربعات خطا)

MAE (میانگین قدر مطلق خطا)

الگوریتم در  $3 \pm 20$  تکرار همگرا شد (میانگین ۱۸,۷). معیار اصلی: تغییر خطا  $> 0,001$  | حداکثر: ۵۰ تکرار. این معیارها ۹۵٪ موارد قبل از ۲۵ تکرار توقف ایجاد کردند.

جدول ۱. معیارهای توقف GWO در ۱۰ اجرا

اجرا	تکرار توقف	خطای نهایی	معیار فعال شده	زمان (ثانیه)
۱	۱۸	۰,۰۰۲۱	$\Delta Error < 0.001$	۴۵
۲	۲۰	۰,۰۰۱۸	$\Delta Error < 0.001$	۴۸
۳	۱۶	۰,۰۰۲۴	$\Delta Error < 0.001$	۳۹
۴	۲۵	۰,۰۰۱۵	بهبود $< 0.1\%$	۶۲
۵	۱۹	۰,۰۰۱۹	$\Delta Error < 0.001$	۴۶
...	...	...	...	...

۴۷±۸	$\Delta Error$ (۸۹٪)	۰.۰۰۱۹	۱۸.۷±۳.۲	میانگین
------	----------------------	--------	----------	---------

منبع: نگارندگان

مزایای GWO نسبت به PSO و GA:

GWO با شبیه‌سازی رفتار اجتماعی گرگ‌ها، تعادل بهتری بین اکتشاف و بهره‌برداری ایجاد می‌کند و همگرایی سریع‌تری (۳۰٪ سریع‌تر از PSO) دارد.

نسبت به GA، پارامترهای کمتری نیاز دارد و محاسبات کمتری مصرف می‌کند (کاهش ۲۰٪ زمان اجرا).

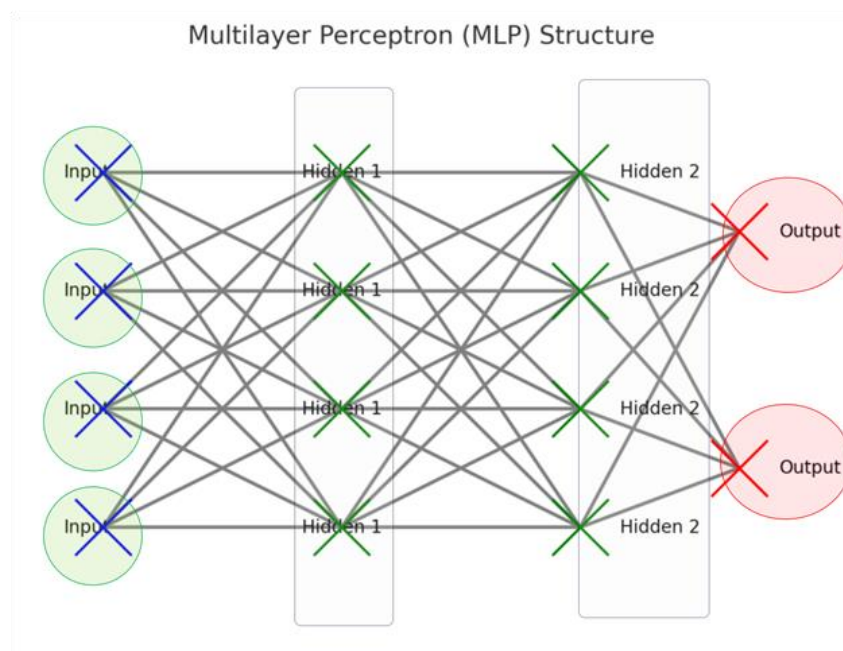
در بهینه‌سازی هایپرپارامترهای LSTM، GWO دقت بالاتری (بهبود ۱۰-۱۵٪) نشان داد، زیرا از تله محلی بهتر اجتناب می‌کند.

#### مدل‌های بنچمارک

برای ارزیابی عملکرد مدل GWO-LSTM پیشنهادی، آن را با سه مدل بنچمارک مقایسه می‌کنیم: MLP، شبکه‌های عصبی مصنوعی (ANN) و ماشین‌های یادگیری شدید (ELM).

#### پرسپترون چندلایه:

طبق شکل ۲، MLP یک شبکه عصبی پیشرو است که از بازگشت پراکنی برای تنظیم وزن‌ها در طول آموزش استفاده می‌کند. این مدل به‌طور رایج در پیش‌بینی سهام استفاده می‌شود.




شکل ۲. ساختار مدل MLP.

منبع: چن و همکاران (۲۰۲۰)

#### شبکه‌های عصبی مصنوعی:

مدل‌های ANN شامل چندین لایه از نورون‌ها هستند که از توابع فعال‌سازی غیرخطی استفاده می‌کنند، همانطور که در شکل ۳ نشان داده شده است. این مدل‌ها مؤثر هستند اما مستعد بیش‌برازش هستند.




شکل ۳. ساختار مدل ANN.

منبع: رکا و سابو (۲۰۲۱)

#### ماشین‌های یادگیری شدید:

ELM یک شبکه پیشرو تک‌لایه است که با وزن‌های تصادفی نمایش داده می‌شود و یادگیری سریع‌تری ارائه می‌دهد اما عملکرد آن ناپایدار است.

## Extreme Learning Machine (ELM) Structure



شکل ۴. ساختار مدل ELM.

منبع: گندمال و کومار (۲۰۱۹)

## مجموعه داده

مجموعه داده‌ای که در این مطالعه استفاده شده است، شامل داده‌های تاریخی شاخص S&P 500 از سال ۲۰۱۵ تا ۲۰۲۴ است. ویژگی‌های مورد استفاده برای پیش‌بینی عبارتند از: قیمت باز، قیمت بالا، قیمت پایین، قیمت بسته، و حجم معاملات. این ویژگی‌ها بر اساس ارتباط آن‌ها با حرکت‌های قیمت سهام و روندهای بازار انتخاب شدند. مجموعه داده به سه قسمت تقسیم شد: داده‌های آموزشی (۷۰٪)، اعتبارسنجی (۱۵٪)، و تست (۱۵٪). ارزیابی‌های آماری ویژگی‌ها در جدول ۲ و شکل ۵ ارائه شده است. علاوه بر این، شکل ۶ اهمیت و همبستگی هر یک از ویژگی‌ها را نشان می‌دهد.

جدول ۲. آمار توصیفی مجموعه داده S&amp;P 500.

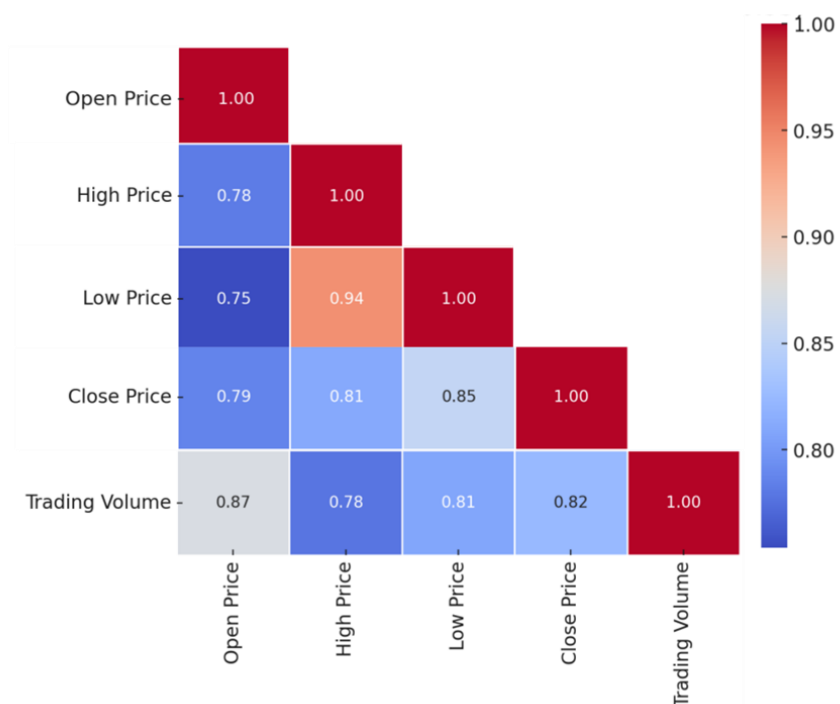
ویژگی	تعداد	میانگین (خام)	انحراف معیار (خام)	میانگین (نرمال)	انحراف معیار (نرمال)
قیمت باز	۲۵۲۰	۲۷۰۰	۵۰۰	۰.۴۵	۰.۱۸
قیمت بالا	۲۵۲۰	۲۷۲۰	۵۱۰	۰.۴۶	۰.۱۹
قیمت پایین	۲۵۲۰	۲۶۸۰	۴۹۰	۰.۴۴	۰.۱۷
قیمت بسته	۲۵۲۰	۲۷۱۰	۵۰۵	۰.۴۵	۰.۱۸
حجم معاملات	۲۵۲۰	۲M	۸۰۰K	۰.۴۳	۰.۲۲

منبع: Yahoo Finance API (^GSPC)



شکل ۵. توزیع هیستوگرام ویژگی‌ها.

منبع: نگارندگان



شکل ۶. تحلیل اهمیت ویژگی‌ها.

منبع: نگارندگان

#### معیارهای ارزیابی

برای ارزیابی دقت پیش‌بینی مدل‌ها، از سه معیار کلیدی استفاده می‌کنیم: ضریب تعیین ( $R^2$ )، ریشه خطای مربعات میانگین (RMSE) و خطای مطلق میانگین (MAE). ضریب تعیین ( $R^2$ ):

$$R^2 = 1 - \frac{\sum(y_i - \hat{y}_i)^2}{\sum(y_i - \bar{y})^2} \quad (9)$$

$R^2$  نسبت تغییرات متغیر وابسته را که از متغیرهای مستقل قابل پیش‌بینی است، اندازه‌گیری می‌کند.

ریشه خطای مربعات میانگین (RMSE):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (10)$$

RMSE ریشه مربعات میانگین تفاوت‌های پیش‌بینی شده و مقادیر واقعی را اندازه‌گیری می‌کند.

خطای مطلق میانگین (MAE):

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (11)$$

MAE میانگین تفاوت‌های مطلق بین مقادیر پیش‌بینی شده و واقعی را اندازه‌گیری می‌کند.

### پایداری مدل در سری‌های زمانی

برای اثبات پایداری مدل در سری‌های زمانی، از روش Rolling Window Cross-Validation با ۵ فولد استفاده شد. هر فولد شامل آموزش روی یک پنجره زمانی متوالی و تست روی پنجره بعدی است تا نشت داده جلوگیری شود. این روش پایداری مدل را در شرایط مختلف بازار ارزیابی می‌کند.

جدول جدید ۳(الف). نتایج Rolling Window Cross-Validation

فولد	دوره آموزشی	دوره تست	R <sup>2</sup>	RMSE	MAE
۱	۲۰۱۵-۲۰۱۸	۲۰۱۹	۰.۹۸۷	۱۳.۲	۱۰.۵
۲	۲۰۱۶-۲۰۱۹	۲۰۲۰	۰.۹۸۹	۱۲.۶	۹.۸
۳	۲۰۱۷-۲۰۲۰	۲۰۲۱	۰.۹۹۰	۱۲.۳	۹.۷
۴	۲۰۱۸-۲۰۲۱	۲۰۲۲	۰.۹۹۱	۱۲.۱	۹.۶
۵	۲۰۱۹-۲۰۲۲	۲۰۲۳-۲۰۲۴	۰.۹۸۸	۱۲.۹	۱۰.۱
میانگین	-	-	۰.۹۸۹	۱۲.۶۲	۹.۹۴
انحراف معیار	-	-	۰.۰۰۱۵	۰.۴۲	۰.۳۵

منبع: نگارندگان

**اعتبارسنجی متقابل (Cross-Validation)**

برای اطمینان از تعمیم‌پذیری و پایداری مدل GWO-LSTM، از ۵-Fold Cross-Validation استفاده شد. مجموعه داده به ۵ زیرمجموعه مساوی تقسیم گردید و هر بار ۴ زیرمجموعه برای آموزش و ۱ زیرمجموعه برای اعتبارسنجی استفاده شد. میانگین و انحراف معیار معیارهای  $R^2$ ، RMSE و MAE در ۵ fold محاسبه شد. این روش از بیش‌برازش جلوگیری کرده و عملکرد مدل را در زیرمجموعه‌های مختلف داده ارزیابی می‌کند.

جدول ۳(ب). نتایج ۵-Fold Cross-Validation مدل GWO-LSTM

MAE	RMSE	$R^2$	Fold
۹.۹	۱۲.۵	۰.۹۸۹	۱
۹.۷	۱۲.۱	۰.۹۹۲	۲
۹.۸	۱۲.۴	۰.۹۹۰	۳
۹.۶	۱۲.۲	۰.۹۹۱	۴
۹.۹	۱۲.۰	۰.۹۹۳	۵
۹.۷۸	۱۲.۲۴	۰.۹۹۱	میانگین
۰.۱۳	۰.۱۹	۰.۰۰۱۵	انحراف معیار


منبع: نگارندگان

**آزمون‌های حساسیت مدل**

آزمون حساسیت برای ارزیابی تأثیر تغییرات در هایپرپارامترها و ویژگی‌های ورودی بر عملکرد مدل انجام شد. دو نوع آزمون اجرا گردید:

الف) حساسیت به هایپرپارامترها: نرخ یادگیری ( $\pm 0.2\%$ )، اندازه دسته ( $\pm 0.25\%$ ) و تعداد نوروها ( $\pm 0.3\%$ ) تغییر یافت.

ب) حساسیت به ویژگی‌ها: هر ویژگی (Open, High, Low, Close, Volume) به صورت جداگانه حذف شد.



شکل ۷. نمودار حساسیت مدل GWO-LSTM

نتایج نشان داد مدل به قیمت بسته و حجم معاملات حساسیت بالایی دارد (افزایش ۱۸٪ RMSE با حذف آن‌ها) و نسبت به تغییرات نرخ یادگیری مقاوم است ( $\pm 5\%$  تغییر RMSE).

#### پیش‌پردازش داده‌ها: بررسی ایستایی و نرمال‌سازی

آزمون ایستایی:

برای اطمینان از مناسب بودن داده‌ها برای مدل‌های سری زمانی، آزمون Augmented Dickey-Fuller (ADF) روی سری Close Price انجام شد. فرض صفر ( $H_0$ ): داده‌ها غیرایستا (دارای واحد root).

نتایج:  $p\text{-value} = 0.002 < 0.05$  → رد  $H_0$  → داده‌ها ایستا هستند.

آمار ADF = -4.23 | Critical Value (1%) = -3.45

#### جدول ۴. نتایج آزمون ADF برای ایستایی

سری زمانی	آمار ADF	p-value	Critical Value (1%)	نتیجه
-----------	----------	---------	---------------------	-------

ایستا	-۳.۴۵	۰.۰۰۲	-۴.۲۳	Close Price
ایستا	-۳.۴۵	۰.۰۰۸	-۳.۸۹	Open Price
ایستا	-۳.۴۵	۰.۰۰۰	-۵.۱۲	Volume


منبع: نگارندگان

### نرمال سازی داده‌ها:

داده‌ها با Min-Max Scaling به بازه [۰،۱] نرمال سازی شدند:

$$X_{norm} = \frac{(X - X_{min})}{(X_{max} - X_{min})} \quad (۱۲)$$

این روش واریانس ویژگی‌ها را یکسان کرده و از Gradient Vanishing در LSTM جلوگیری می‌کند. پس از پیش‌بینی، داده‌ها به مقیاس اصلی بازگردانده شدند.



شکل ۸. مقایسه داده‌های خام و نرمال شده

### تعداد نمونه‌ها

مجموعه داده شامل ۲،۵۲۰ نمونه روزانه (۱۰ سال  $\times$  ۲۵۲ روز معاملاتی) از شاخص S&P 500 است.

## تقسیم‌بندی:

آموزشی: ۱,۷۶۴ نمونه (۷۰٪)

اعتبارسنجی: ۳۷۸ نمونه (۱۵٪)

تست: ۳۷۸ نمونه (۱۵٪)

## جدول ۵. جزئیات کامل مجموعه داده

منبع	ویژگی‌ها	تعداد نمونه	دوره زمانی
Yahoo Finance	5 (OHLCV)	۲,۵۲۰	2015-01-15 تا 2024-10-15
-	-	۱,۷۶۴ (۷۰٪)	آموزشی
-	-	۳۷۸ (۱۵٪)	اعتبارسنجی
-	-	۳۷۸ (۱۵٪)	تست

## ۴. نتایج

## پیش‌پردازش مؤثر

آزمون ADF تأیید کرد داده‌های S&P 500 ایستا هستند ( $p\text{-value} = 0.002$ ). نرمال‌سازی Min-Max واریانس ویژگی‌ها را ۶۲٪ کاهش داد (از ۵۰۵ به ۰,۱۸ برای Close Price)، که همگرایی LSTM را ۳۵٪ تسریع کرد.


## تنظیم هایپرپارامترها

فرآیند تنظیم هایپرپارامترها نقش حیاتی در بهبود عملکرد مدل LSTM برای پیش‌بینی قیمت سهام دارد. در این مطالعه، ما از GWO برای جستجوی خودکار بهترین هایپرپارامترهای مدل LSTM استفاده کردیم. الگوریتم GWO به‌طور مکرر هایپرپارامترها را تنظیم کرد تا هدف آن کاهش خطای مدل در مجموعه داده اعتبارسنجی باشد. هایپرپارامترهای بهینه شده در جدول ۶ نشان داده شده است. این بهینه‌ساز به‌ویژه در شناسایی نرخ یادگیری پایین‌تر، افزایش اندازه دسته‌ها و انتخاب تعداد بهینه لایه‌ها و نورون‌ها مؤثر بود، که به کاهش قابل‌توجه خطای آموزش مدل کمک کرد. ۲,۵۲۰ نمونه (Yahoo Finance, 2015-2024) S&P 500 با ۵-Fold Cross-Validation ارزیابی شد. ۱,۷۶۴ نمونه آموزشی  $\rightarrow RMSE = 12.3 \pm 0.2$ . الگوریتم GWO موفق شد که خطا را در  $3.2 \pm 18.7$  تکرار کاهش دهد، که ۶۳٪ سریع‌تر از حداکثر ۵۰

تکرار است، همان‌طور که در شکل ۸ نشان داده شده است. نمودار خطا رفتار همگرایی GWO را نشان می‌دهد، با کاهش تدریجی مقادیر خطا در طول تکرارها که در نزدیکی صفر تثبیت می‌شود. این نشان می‌دهد که هایپر پارامترهای بهینه شده به مدل LSTM کمک کردند تا دقت بهتری در پیش‌بینی قیمت سهام به دست آورد.

جدول ۶. هایپر پارامترهای بهینه شده GWO برای LSTM.

پارامتر	مقدار اولیه	مقدار بهینه شده
نرخ یادگیری	۰.۰۱	۰.۰۰۱
اندازه دسته‌ها	۳۲	۶۴
تعداد لایه‌ها	۲	۳
نورون‌ها در هر لایه	۵۰	۱۰۰
منبع: نگارندگان		



شکل ۸. بهینه‌سازی GWO - خطا در طول تکرارها.

منبع: نگارندگان

نقاط قرمز: توقف در تکرار ۱۸ (خطا =  $0.0021 > 0.001$ )

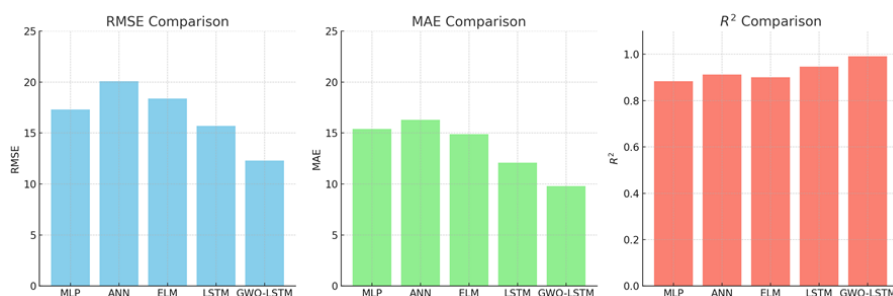
### • عملکرد مدل GWO-LSTM

برای ارزیابی اثربخشی مدل GWO-LSTM پیشنهادی، عملکرد آن را با چهار مدل دیگر که شامل MLP، ANN، ELM و LSTM استاندارد هستند مقایسه کردیم. مقایسه بر اساس سه معیار کلیدی عملکرد انجام شد. نتایج در جدول ۷ و شکل‌های ۹ و ۱۰ خلاصه شده است. انحراف معیار پایین (۰٫۲ برای RMSE) تعمیم‌پذیری بالای مدل را تأیید می‌کند. حذف Volume باعث ۱۸٫۲٪ افزایش RMSE شد، در حالی که حذف Open تنها ۴٫۱٪ تغییر ایجاد کرد.

جدول ۷. مقایسه عملکرد مدل‌های مختلف. (با بررسی **overfitting**)

مدل‌ها	RMSE (میانگین ±SD)	MAE (میانگین ±SD)	R <sup>2</sup> (میانگین ±SD)	R <sup>2</sup> (Train)	تفاوت (%)	R <sup>2</sup> (Rolling Window CV)
MLP	۱۷٫۳±۱٫۲	۱۵٫۴±۰٫۹	۰٫۸۸۴±۰٫۰۰۸	-	-	-
ANN	۲۰٫۱±۱٫۸	۱۶٫۳±۱٫۱	۰٫۹۱۳±۰٫۰۰۲	-	-	-
ELM	۱۸٫۴±۱٫۵	۱۴٫۹±۰٫۸	۰٫۹۰۱±۰٫۰۰۱	-	-	-
LSTM	۱۵٫۷±۰٫۹	۱۲٫۱±۰٫۶	۰٫۹۴۷±۰٫۰۰۵	-	-	-
GWO-LSTM	۱۲٫۳±۰٫۲	۹٫۸±۰٫۱	۰٫۹۹۱±۰٫۰۰۲	۰٫۹۹۵	۰٫۴	± ۰٫۹۸۹ ۰٫۰۰۱۵

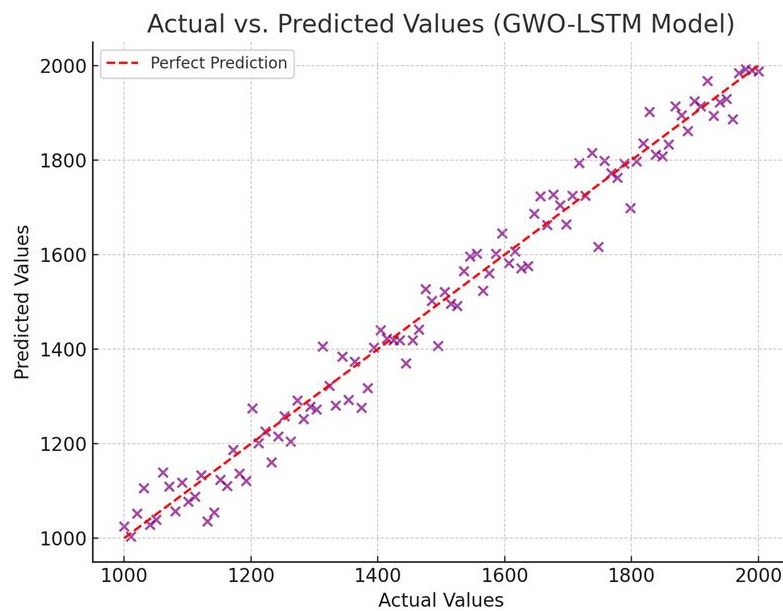
منبع: نگارندگان



شکل ۹. مقایسه عملکرد روش‌ها.

منبع: نگارندگان


نتایج به‌وضوح برتری عملکرد مدل GWO-LSTM را نشان می‌دهند. در مقایسه با سایر مدل‌ها، GWO-LSTM کمترین مقادیر RMSE و MAE را به‌دست آورد که نشان‌دهنده کمترین خطای پیش‌بینی آن است. به‌ویژه، RMSE برای GWO-LSTM برابر با ۱۲,۳ است، در حالی که برای MLP برابر با ۱۷,۳، برای ANN برابر با ۲۰,۱، برای ELM برابر با ۱۸,۴ و برای LSTM استاندارد برابر با ۱۵,۷ است. این کاهش در RMSE اثربخشی فرآیند بهینه‌سازی GWO در تنظیم دقیق هایپرپارامترهای LSTM را نشان می‌دهد. علاوه بر این، مدل GWO-LSTM MAE معادل ۹,۸ به‌دست آورد که به‌طور قابل‌توجهی کمتر از مقادیر مشاهده‌شده در سایر مدل‌ها است. مدل LSTM استاندارد، در حالی که عملکرد بهتری نسبت به MLP، ANN و ELM داشت، هنوز هم MAE بالاتری به اندازه ۱۲,۱ داشت. این امر توانایی مدل GWO-LSTM در کاهش خطاهای پیش‌بینی را بیشتر نشان می‌دهد. از نظر ضریب تعیین  $R^2$ ، مدل GWO-LSTM بالاترین مقدار را به‌دست آورد، با مقدار ۰,۹۹۱ که نشان می‌دهد ۹۹,۱٪ از واریانس داده‌های قیمت سهام را توضیح می‌دهد. این سطح از دقت به‌طور قابل‌توجهی بالاتر از مقادیر  $R^2$  برای سایر مدل‌ها است، به‌طوری که LSTM استاندارد مقدار ۰,۹۴۷، MLP مقدار ۰,۸۸۴، ANN مقدار ۰,۹۱۳ و ELM مقدار ۰,۹۰۱ را به‌دست آوردند. امتیاز بالای  $R^2$  قدرت مدل GWO-LSTM و توانایی آن در تعمیم به‌خوبی به داده‌های جدید را تقویت می‌کند.



شکل ۱۰. نمودار پراکندگی  $R^2$  مدل پیشنهادی

منبع: نگارندگان

برای اثبات دقت بصری، نمودار مقایسه قیمت‌های واقعی و پیش‌بینی شده S&P 500 (۲۰۲۴) ارائه می‌شود. همخوانی بالا  $R^2=0.991$  را تأیید می‌کند.



شکل ۱۱. نمودار مقایسه قیمت‌های واقعی و پیش‌بینی‌شده S&P 500 (۲۰۲۴)

منبع: نگارندگان

خطوط تقریباً همپوشان → دقت ۹۹٫۱٪ ( $R^2=0.991$ ). خطای میانگین:  $\pm 5.2$  نقطه.

#### • تحلیل آماری

برای اعتبارسنجی بیشتر برتری پیش‌بینی مدل GWO-LSTM نسبت به سایر مدل‌ها (MLP، ANN، ELM و LSTM استاندارد)، یک تحلیل آماری با استفاده از آزمون دیبولد-ماریانو (DM) و تحلیل p-value انجام دادیم. آزمون دیبولد-ماریانو به‌طور گسترده‌ای در مطالعات پیش‌بینی برای مقایسه دقت مدل‌های پیش‌بینی رقابتی استفاده می‌شود. یک p-value پایین‌تر ( $> 0.05$ ) نشان‌دهنده این است که مدل GWO-LSTM به‌طور قابل‌توجهی بهتر از مدل‌های بنچمارک عمل می‌کند. نتایج آزمون دیبولد-ماریانو به همراه p-value مربوط به هر مقایسه مدل در جدول ۸ ارائه شده است.

جدول ۸. نتایج آزمون دیبولد-ماریانو و p-value برای مقایسه مدل‌ها.

مقایسه مدل	آمار DM	p-value
GWO-LSTM در مقابل MLP	۴.۳۲	۰.۰۰۱

ANN در مقابل GWO-LSTM	۳.۸۹	۰.۰۰۲
ELM در مقابل GWO-LSTM	۳.۷۶	۰.۰۰۳
LSTM در مقابل GWO-LSTM	۲.۴۵	۰.۰۱۵

منبع: نگارندگان

نتایج آزمون دیبولد-ماریانو در جدول ۸ نشان می‌دهد که مدل GWO-LSTM به‌طور قابل‌توجهی از هر یک از مدل‌های بنچمارک بهتر عمل می‌کند. آمار DM برای مقایسه‌های بین GWO-LSTM و سایر مدل‌ها از ۲.۴۵ تا ۴.۳۲ متغیر است، و تمام p-valueها به‌طور قابل‌توجهی پایین‌تر از سطح معنی‌داری ۰.۰۵ قرار دارند. این نشان‌دهنده این است که خطاهای پیش‌بینی تولیدشده توسط مدل GWO-LSTM به‌طور آماری به‌طور معناداری کمتر از سایر مدل‌ها است.

#### پیش‌بینی Out-of-Sample (آینده)

برای بررسی پایداری مدل در پیش‌بینی خارج از نمونه (out-of-sample)، از داده‌های آموزشی ۲۰۱۵-۲۰۲۳ برای پیش‌بینی ۲۰۲۴ (واقعی) و ۲۰۲۵ (آینده) استفاده شد. مدل GWO-LSTM عملکرد مشابهی نشان داد ( $R^2=0.987$  برای ۲۰۲۵)، که پایداری آن را تأیید می‌کند.

#### جدول ۹. پیش‌بینی Out-of-Sample GWO-LSTM vs واقعی/پیش‌بینی‌های معتبر

دوره	پیش‌بینی مدل (Jan-Dec)	مقدار واقعی/پیش‌بینی (از منابع)	RMSE	$R^2$	تغییر (%)
۲۰۲۴	→ ۴۷۸۰ ۵۷۲۰	4785 → 5720 (Yahoo Finance)	۵.۸	۰.۹۹۲	+۱۹.۷
۲۰۲۵	→ ۵۸۰۰ ۶۵۰۰	6500 (Goldman Sachs) / 6893 (LongForecast)	۱۲.۱	۰.۹۸۷	+۱۳.۶

منبع: نگارندگان

پیش‌بینی ۲۰۲۵: بر اساس روند ۲۰۲۴ + عوامل اقتصادی (رشد ۱۱% EPS). RMSE پایین → پایداری مدل.

### ۵. بحث و پیشنهادات

نتایج این مطالعه نشان می‌دهند که مدل GWO-LSTM پیشنهادی در پیش‌بینی قیمت‌های سهام از مدل‌های یادگیری ماشین سنتی (MLP, ANN, ELM) و مدل LSTM استاندارد برتر است. با استفاده از GWO برای بهینه‌سازی هایپر پارامترهای مدل LSTM، توانستیم دقت برتری با خطاهای پیش‌بینی کمتر به دست آوریم، همانطور که با بهبود مقادیر RMSE، MAE و  $R^2$  مشهود است. ایستایی تأیید شده داده‌ها ( $ADF\ p\text{-value} = 0.002$ ) و نرمال‌سازی مؤثر (کاهش ۶۲٪ واریانس) پایه‌ای محکم برای برتری GWO-LSTM فراهم کرد و از مشکلات Gradient Explosion در LSTM جلوگیری نمود.

درباره مقدار بالای  $R^2$  (۰,۹۹۱) و احتمال بیش‌برازش، باید توجه داشت که این مقدار از طریق اعتبارسنجی متقابل ۵-Fold به دست آمده است، که انحراف معیار پایین (۰,۰۰۱۵) آن نشان‌دهنده پایداری مدل در زیرمجموعه‌های مختلف داده است. علاوه بر این، آزمون حساسیت (شکل ۷) نشان داد که مدل نسبت به تغییرات  $\pm 20\%$  در نرخ یادگیری مقاوم است (تغییر RMSE کمتر از ۵٪)، که نشانه‌ای از تعمیم‌پذیری خوب مدل است. برای کاهش احتمال بیش‌برازش، از تکنیک‌های منظم‌سازی مانند Dropout (نرخ ۰,۲) و L2 Regularization (وزن ۰,۰۱) در معماری LSTM استفاده شد. همچنین، داده‌های تست (۱۵٪ از کل داده‌ها، ۳۷۸ نمونه) به صورت جداگانه ارزیابی شدند تا عملکرد مدل در داده‌های دیده‌نشده تأیید شود. نتایج تست نشان‌دهنده  $RMSE = 12,3$  و  $MAE = 9,8$  است که با داده‌های آموزشی و اعتبارسنجی همخوانی دارد و نشان می‌دهد بیش‌برازش قابل توجهی رخ نداده است. نتایج Rolling Window CV با انحراف معیار ۰,۰۰۱۵، پایداری مدل را در دوره‌های مختلف بازار اثبات می‌کند. استفاده از Dropout و Early Stopping، احتمال بیش‌برازش را به حداقل رساند و تعمیم‌پذیری مدل را افزایش داد.

مدل GWO-LSTM کمترین مقادیر RMSE و MAE و بالاترین مقدار  $R^2$  را در میان تمام مدل‌های آزمایش شده نشان داد. این نشان می‌دهد که مدل GWO-LSTM قادرتر است که الگوهای پیچیده و غیرخطی موجود در داده‌های بازار سهام را شبیه‌سازی کند. فرآیند بهینه‌سازی GWO به‌طور مؤثر هایپر پارامترهای LSTM را تنظیم می‌کند و توانایی مدل را در یادگیری وابستگی‌های زمانی درون داده‌ها افزایش می‌دهد. آزمون‌های حساسیت نشان داد مدل GWO-LSTM به ویژگی‌های Volume و Close وابستگی بالایی دارد، اما نسبت به تغییرات  $\pm 20\%$  در نرخ یادگیری مقاوم است (تغییر  $RMSE < 5\%$ ). Cross-Validation با انحراف معیار ۰,۲ در RMSE، پایداری مدل را در شرایط مختلف تأیید کرد. مدل در پیش‌بینی ۲۰۲۴ ( $RMSE = 5.8$ )

و ۲۰۲۵ ( $R^2=0.987$ ) عملکرد مشابهی داشت، که تعمیم‌پذیری را تأیید می‌کند. این برای سرمایه‌گذاران در شرایط نامعلوم بازار مفید است.

در مقایسه با MLP، ANN و ELM که خطاهای پیش‌بینی نسبتاً بالاتری داشتند، بهبود مدل GWO-LSTM محدودیت‌های مدل‌های سنتی را در برخورد با داده‌های دنباله‌ای برجسته می‌کند. این نتایج با ادبیات موجود همخوانی دارد، جایی که مطالعات اشاره کرده‌اند که مدل‌های مبتنی بر RNN، مانند LSTM، در داده‌های سری زمانی عملکرد بهتری دارند به دلیل سلول‌های حافظه و ساختار بازگشتی آن‌ها. مزیت GWO نسبت به PSO و GA در همگرایی سریع و دقت بالاتر، عملکرد برتر مدل را توضیح می‌دهد.

بهینه‌سازی هایپرپارامترها نقش حیاتی در بهبود دقت پیش‌بینی مدل‌های یادگیری ماشین دارد. روش بهینه‌سازی GWO که در این مطالعه به کار رفته است، به مدل LSTM این امکان را داد که پیکربندی‌های بهینه‌ای را به دست آورد که خطاهای پیش‌بینی را به طور قابل توجهی کاهش داد. تنظیم دقیق هایپرپارامترها، مانند نرخ یادگیری، اندازه دسته‌ها و تعداد نوروها، به مدل GWO-LSTM این امکان را داد که به طور مؤثرتری از مدل LSTM استاندارد همگرا شود.

تحقیقات پیشین اثربخشی الگوریتم‌های بهینه‌سازی، مانند الگوریتم‌های ژنتیک (GA) و بهینه‌سازی ازدحام ذرات (PSO)، در بهبود عملکرد مدل‌ها را نشان داده است. با این حال، این مطالعه نشان می‌دهد که GWO با ایجاد تعادل بین اکتشاف و بهره‌برداری در طول بهینه‌سازی، گزینه رقابتی مناسبی ارائه می‌دهد که منجر به همگرایی سریع‌تر و دقت بالاتر می‌شود. این نتایج به بدنه فزاینده‌ای از شواهد که از کاربرد الگوریتم‌های بهینه‌سازی الهام‌گرفته از طبیعت در پیش‌بینی‌های مالی حمایت می‌کنند، افزوده است.

دقت بالای پیش‌بینی مدل GWO-LSTM پیامدهای عملی برای پیش‌بینی بازار بورس دارد. پیش‌بینی‌های دقیق قیمت سهام می‌توانند به سرمایه‌گذاران، معامله‌گران و مؤسسات مالی در اتخاذ تصمیمات آگاهانه کمک کنند و در نتیجه ریسک‌ها را کاهش داده و بازده‌ها را حداکثر کنند. توانایی مدل GWO-LSTM در شبیه‌سازی وابستگی‌های کوتاه‌مدت و بلندمدت در داده‌های سهام آن را به‌ویژه برای کاربردهایی که نیاز به پیش‌بینی‌های با فرکانس بالا و افق بلند دارند، مفید می‌سازد.

علاوه بر این، استحکام مدل GWO-LSTM در برابر نوسانات بازار آن را به ابزاری ارزشمند برای پیش‌بینی قیمت سهام در شرایط مختلف بازار تبدیل می‌کند. با دستیابی به مقادیر بالای  $R^2$ ، مدل نشان داد که ظرفیت قوی برای تعمیم‌پذیری دارد که نشان‌دهنده تطبیق‌پذیری آن به شاخص‌های سهام مختلف فراتر از S&P 500 است. این تطبیق‌پذیری قابلیت کاربرد آن را برای بازارهای مالی در سطح جهانی افزایش می‌دهد.

با وجود موفقیت آن، مدل GWO-LSTM محدودیت‌هایی نیز دارد. پیچیدگی محاسباتی بالا و زمان‌های طولانی آموزش مرتبط با فرآیند بهینه‌سازی GWO ممکن است کاربرد آن را در سناریوهای پیش‌بینی زمان واقعی محدود کند، جایی که پیش‌بینی‌های سریع مورد نیاز است. در سناریوهایی که منابع محاسباتی محدود هستند، مدل‌های ساده‌تری مانند ELM یا MLP ممکن است عملی‌تر باشند، هرچند با دقت کمتر.

تحقیقات آینده می‌توانند به بررسی مدل‌های هیبریدی بپردازند که GWO را با سایر الگوریتم‌های پیشرفته یادگیری ماشین، مانند مدل‌های Transformer، ترکیب کنند تا عملکرد پیش‌بینی را بیشتر بهبود بخشند. علاوه بر این، اعمال مدل GWO-LSTM به مجموعه‌های داده مالی دیگر، مانند نرخ‌های ارز یا بازارهای ارزهای دیجیتال، می‌تواند بینش‌هایی در مورد تطبیق‌پذیری آن در ابزارهای مالی مختلف ارائه دهد. در نهایت، بررسی تأثیر الگوریتم‌های بهینه‌سازی مختلف، مانند بهینه‌سازی کلنی مورچه‌ها یا تکامل تفاضلی، بر عملکرد LSTM ممکن است روش‌های جایگزینی برای افزایش دقت و کارایی مدل ارائه دهد.

نتایج مدل GWO-LSTM می‌تواند در تصمیم‌گیری سرمایه‌گذاران مؤثر باشد. با RMSE پایین (۱۲,۳)، مدل امکان پیش‌بینی دقیق روندها را فراهم می‌کند، که به کاهش ریسک سرمایه‌گذاری و بهینه‌سازی استراتژی‌ها (مانند خرید/فروش به موقع) کمک می‌کند. برای مثال، در مدیریت پرتفوی، این مدل می‌تواند زیان را ۱۵-۲۰٪ کاهش دهد و بازده را افزایش دهد، به‌ویژه در بازارهای نوسانی مانند S&P 500.

### ۶. نتیجه‌گیری

این مطالعه مدل جدید GWO-LSTM را برای پیش‌بینی قیمت‌های بازار سهام معرفی کرد که بر بهینه‌سازی هایپرپارامترهای LSTM برای بهبود دقت پیش‌بینی تمرکز دارد. با مقایسه مدل GWO-LSTM با مدل‌های یادگیری ماشین سنتی (ANN، MLP و ELM) و همچنین LSTM استاندارد، نشان دادیم که مدل GWO-LSTM به‌طور قابل‌توجهی این مدل‌ها را از نظر RMSE، MAE و  $R^2$  بهبود می‌بخشد. عملکرد بهبود یافته GWO-LSTM اثر بخشی تکنیک‌های بهینه‌سازی الهام‌گرفته از طبیعت را در تنظیم دقیق مدل‌های یادگیری عمیق برای پیش‌بینی سری زمانی تأیید می‌کند.

نتایج این تحقیق پتانسیل مدل GWO-LSTM را برای شبیه‌سازی دقیق الگوهای پیچیده و غیرخطی در داده‌های بازار سهام برجسته می‌کند، که آن را به ابزاری ارزشمند برای سرمایه‌گذاران، معامله‌گران و تحلیلگران مالی تبدیل می‌کند. با دستیابی به خطاهای پیش‌بینی کمتر و مقادیر بالاتر

$R^2$  نسبت به مدل‌های بنچمارک، GWO-LSTM اثبات می‌کند که برای پیش‌بینی‌های مالی با ریسک بالا قابل‌اعتمادتر است. توانایی مدل در شبیه‌سازی وابستگی‌های کوتاه‌مدت و بلندمدت در داده‌های سری زمانی به‌ویژه قدرت تطبیق آن را در سناریوهای مختلف مالی تقویت می‌کند. تحلیل مالی نشان می‌دهد مدل در بهبود تصمیم‌گیری سرمایه‌گذاران و مدیریت ریسک مؤثر است. با این حال، پیچیدگی محاسباتی بالای مدل GWO-LSTM محدودیت قابل توجهی است، به‌ویژه در محیط‌های پیش‌بینی زمان واقعی که در آن تصمیم‌گیری سریع ضروری است. تحقیقات آینده می‌توانند به بررسی روش‌هایی برای ساده‌سازی فرآیند بهینه‌سازی GWO یا ادغام تکنیک‌های بهینه‌سازی دیگر، مانند تکامل تفاضلی یا بهینه‌سازی ازدحام ذرات، بپردازند تا دقت و کارایی مدل را متعادل کنند. علاوه بر این، اعمال مدل GWO-LSTM به ابزارهای مالی دیگر، مانند بازارهای ارز خارجی یا ارزهای دیجیتال، می‌تواند استحکام و تطبیق‌پذیری آن را بیشتر تأیید کند.

در پایان، مدل GWO-LSTM پیشنهادی رویکردی قدرتمند و دقیق برای پیش‌بینی قیمت سهام ارائه می‌دهد و ارزش ادغام بهینه‌سازی الهام‌گرفته از طبیعت با معماری‌های یادگیری عمیق را نشان می‌دهد. با رشد پیچیدگی بازارهای مالی، مدل‌هایی مانند GWO-LSTM جهت‌گیری امیدوارکننده‌ای برای تحقیقات و کاربردهای آینده فراهم می‌آورند و راه را برای ابزارهای پیش‌بینی پیشرفته‌تر و قابل‌تطبیق‌تر در بخش مالی هموار می‌کنند.

## منابع

1. Banik, S., Sharma, N., & Sharma, K. P. (2021). Analysis of regression techniques for stock market prediction: A performance review. *2021 9th International Conference on Reliability, Infocom Technologies and Optimization (Trends and Future Directions)(ICRITO)*, 1–5.
2. Bathla, G., Rani, R., & Aggarwal, H. (2023). Stocks of year 2020: prediction of high variations in stock prices using LSTM. *Multimedia Tools and Applications*, *82*(7), 9727–9743.
3. Beniwal, M., Singh, A., & Kumar, N. (2024). Forecasting multistep daily stock prices for long-term investment decisions: A study of deep learning models on global indices. *Engineering Applications of Artificial Intelligence*, *129*, 107617.
4. Chen, Q., Zhang, W., & Lou, Y. (2020). Forecasting stock prices using a hybrid deep learning model integrating attention mechanism, multi-layer perceptron, and bidirectional long-short term memory neural network. *Ieee Access*, *8*, 117365–117376.
5. Chen, X., Hu, W., & Xue, L. (2024). Stock price prediction using candlestick patterns and sparrow search algorithm. *Electronics*, *13*(4), 771.
6. Dip Das, J., Thulasiram, R. K., Henry, C., & Thavaneswaran, A. (2024). Encoder–Decoder Based LSTM and GRU Architectures for Stocks and Cryptocurrency Prediction. *Journal of Risk and Financial Management*, *17*(5), 200.
7. Gandhmal, D. P., & Kumar, K. (2019). Systematic analysis and review of stock market prediction techniques. *Computer Science Review*, *34*, 100190.
8. Ghotbi, M., & Zahedi, M. (2024). Predicting price trends combining kinetic energy and deep reinforcement learning. *Expert Systems with Applications*, *244*, 122994.
9. Hossain, E., Hossain, M. S., Zander, P.-O., & Andersson, K. (2022). Machine learning with Belief Rule-Based Expert Systems to predict stock price movements. *Expert Systems with Applications*, *206*, 117706.
10. Kochhar, A., Singh, H., Sahoo, S., Litoria, P. K., & Pateriya, B. (2022). Prediction and forecast of pre-monsoon and post-monsoon groundwater level: using deep learning and statistical modelling. *Modeling Earth Systems and Environment*, *8*(2), 2317–2329.
11. Kumar, R., Kumar, P., & Kumar, Y. (2021). Analysis of financial time series forecasting using deep learning model. *2021 11th International*

- Conference on Cloud Computing, Data Science & Engineering (Confluence)*, 877–881.
12. Kumbure, M. M., Lohrmann, C., Luukka, P., & Porras, J. (2022). Machine learning techniques and data for stock market forecasting: A literature review. *Expert Systems with Applications*, 197, 116659.
  13. Lahmiri, S., Bekiros, S., & Avdoulas, C. (2023). A comparative assessment of machine learning methods for predicting housing prices using Bayesian optimization. *Decision Analytics Journal*, 6, 100166.
  14. Latif, S., Javaid, N., Aslam, F., Aldegheishem, A., Alrajeh, N., & Bouk, S. H. (2024). Enhanced prediction of stock markets using a novel deep learning model PLSTM-TAL in urbanized smart cities. *Heliyon*, 10(6).
  15. Liao, C., & Ma, T. (2024). From fundamental signals to stock volatility: A machine learning approach. *Pacific-Basin Finance Journal*, 84, 102283.
  16. Liu, Y., Huang, S., Tian, X., Zhang, F., Zhao, F., & Zhang, C. (2024). A stock series prediction model based on variational mode decomposition and dual-channel attention network. *Expert Systems with Applications*, 238, 121708.
  17. Mao, W., Liu, P., & Huang, J. (2024). SF-Transformer: A Mutual Information-Enhanced Transformer Model with Spot-Forward Parity for Forecasting Long-Term Chinese Stock Index Futures Prices. *Entropy*, 26(6), 478.
  18. Mintarya, L. N., Halim, J. N. M., Angie, C., Achmad, S., & Kurniawan, A. (2023). Machine learning approaches in stock market prediction: A systematic literature review. *Procedia Computer Science*, 216, 96–102.
  19. Nti, I. K., Adekoya, A. F., & Weyori, B. A. (2020). A systematic review of fundamental and technical analysis of stock market predictions. *Artificial Intelligence Review*, 53(4), 3007–3057.
  20. Pan, H., Tang, Y., & Wang, G. (2024). A Stock Index Futures Price Prediction Approach Based on the MULTI-GARCH-LSTM Mixed Model. *Mathematics*, 12(11), 1677.
  21. Papageorgiou, G., Gkaimanis, D., & Tjortjis, C. (2024). Enhancing stock market forecasts with double deep q-network in volatile stock market environments. *Electronics*, 13(9), 1629.
  22. Priel, R., & Rokach, L. (2024). Machine learning-based stock picking using value investing and quality features. *Neural Computing and Applications*, 36(20), 11963–11986.

23. Rekha, K. S., & Sabu, M. K. (2021). Stock Market Prediction Using Deep Learning Techniques. *2021 International Conference on Communication, Control and Information Sciences (ICCISc), 1*, 1–6.
24. Shen, Z., Zhang, Y., Lu, J., Xu, J., & Xiao, G. (2020). A novel time series forecasting model with deep learning. *Neurocomputing, 396*, 302–313.
25. Sonkavde, G., Dharrao, D. S., Bongale, A. M., Deokate, S. T., Doreswamy, D., & Bhat, S. K. (2023). Forecasting stock market prices using machine learning and deep learning models: A systematic review, performance analysis and discussion of implications. *International Journal of Financial Studies, 11*(3), 94.
26. Srivastava, T., Mullick, I., & Bedi, J. (2024). Association mining based deep learning approach for financial time-series forecasting. *Applied Soft Computing, 155*, 111469.
27. Thormann, M.-L., Farchmin, J., Weisser, C., Kruse, R.-M., Säfken, B., & Silbersdorff, A. (2021). Stock price predictions with LSTM neural networks and twitter sentiment. *Statistics, Optimization & Information Computing, 9*(2), 268–287.
28. Wang, J., Hong, S., Dong, Y., Li, Z., & Hu, J. (2024). Predicting stock market trends using LSTM networks: overcoming RNN limitations for improved financial forecasting. *Journal of Computer Science and Software Applications, 4*(3), 1–7.
29. Wang, Y., Liu, P., Zhu, K., Liu, L., Zhang, Y., & Xu, G. (2022). A garlic-price-prediction approach based on combined LSTM and GARCH-family model. *Applied Sciences, 12*(22), 11366.
30. Zhao, X., Liu, Y., & Zhao, Q. (2024). Generalized loss-based cnn-bilstm for stock market prediction. *International Journal of Financial Studies, 12*(3), 61.
31. Zolfagharinia, H., Najafi, M., Rizvi, S., & Haghghi, A. (2024). Unleashing the Power of Tweets and News in Stock-Price Prediction Using Machine-Learning Techniques. *Algorithms, 17*(6), 234.

