



Kharazmi
University

Mathematical Research
Year 2026, Volume 11, Issue 4, pp. 168–180

Print ISSN: 2588-2546
Online ISSN: 2588-2554
DOI: xxxx

A Dual-Timeframe Deep Learning Framework Based on Ichimoku Cloud and Optimized CNN for Trend Prediction in the Forex Market

Seyedeh Zahra Hashemi⁽¹⁾ and Omid Solaymani Fard⁽²⁾ ¹

^{(1),(2)} Department of Applied Mathematics, Faculty of Mathematical Sciences, Ferdowsi University of Mashhad, Mashhad, Iran

Received: 22 December 2025 Accepted: 30 December 2025 Published online: 25 February 2026

Abstract:

As the Forex market becomes increasingly complex, accurate trend forecasting has gained critical importance for traders and researchers. Unlike most studies that focus on price prediction, this paper introduces a novel bi-timeframe framework (1-hour and 4-hour) that integrates the Ichimoku Kinko Hyo strategy with deep learning models to predict directional movements in currency pairs.

The approach employs convolutional neural networks (CNNs) and hybrid architectures (CNN-LSTM, CNN-GRU), with hyperparameters optimized using the Particle Swarm Optimization Algorithm (PSO). Models are trained on historical EURUSD data (2019–2024) from MetaTrader5 and evaluated on eight highly correlated ($\pm 80\%$) currency pairs. Due to the limitations of regression metrics (MAE, MSE, MAPE) in trading contexts, regression outputs are used solely for 4-hour trend classification, with Accuracy and F1-score as primary performance measures.

Results show that PSO-optimized models, particularly Ichimoku-CNN-GRU-PSO (ICGP), consistently outperform standard variants, achieving the highest Accuracy (up to 80.23% on USDSGD) and F1-score across most pairs.

The findings confirm that Ichimoku-based features, combined with hybrid deep learning and meta-heuristic optimization, significantly enhances trend forecasting reliability and generalization in volatile financial markets.

Keywords: Forex trend forecasting, Convolutional Neural Networks, Ichimoku strategy, Metaheuristic optimization



©2026 Kharazmi University, Tehran, Iran. This article is an open-access article distributed under the terms and conditions of the Creative Commons Attribution-NonCommercial 4.0 International (CC BY-NC 4.0 license) (<http://creativecommons.org/licenses/by-nc/4.0/>).

¹Corresponding author

E-mail addresses: (Seyedeh Zahra Hashemi) zahrahashemi@mail.um.ac.ir, (Omid Solaymani Fard) soleimani@um.ac.ir



چارچوب دو زمانه یادگیری عمیق مبتنی بر ابر ایچیموکو و CNN بهینه شده برای پیش بینی روند در بازار فارکس

سیده زهرا هاشمی^(۱) و امید سلیمانی فرد^(۲)

^(۱)،^(۲) گروه ریاضیات کاربردی، دانشکده علوم ریاضی، دانشگاه فردوسی، مشهد، ایران

تاریخ دریافت: ۱۴۰۴/۱۰/۱ تاریخ پذیرش: ۱۴۰۴/۱۰/۹ تاریخ انتشار: ۱۴۰۴/۱۲/۷

چکیده:

در این پژوهش، با توجه به پیچیدگی روزافزون بازار فارکس، یک چارچوب جدید برای پیش‌بینی روند جفت‌ارزها ارائه می‌شود که به‌جای تمرکز بر مقدار قیمت، بر پیش‌بینی جهت حرکت بازار تمرکز دارد. این چارچوب مبتنی بر دو بازه زمانی ۱ ساعته و ۴ ساعته بوده و استراتژی ایچیموکو را با مدل‌های یادگیری عمیق از جمله CNN، CNLSTM و CNNGRU ترکیب می‌کند. برای بهبود عملکرد، ابرپارامترهای مدل‌ها با بهره‌گیری از الگوریتم بهینه‌سازی ازدحام ذرات (PSO) تنظیم شده‌اند. مدل‌ها با داده‌های تاریخی EURUSD طی سال‌های ۲۰۱۹ تا ۲۰۲۴ از MetaTrader5 آموزش دیده و سپس روی هشت جفت‌ارز با همبستگی بیش از ۸۰٪ ارزیابی شده‌اند. به‌دلیل محدودیت معیارهای رگرسیونی مانند MSE، MAE و MAPE در سنجش کیفیت تصمیم‌گیری‌های معاملاتی، خروجی رگرسیون صرفاً برای تعیین روند ۴ ساعته استفاده شده و معیارهای Accuracy و F1-Score به‌عنوان شاخص‌های اصلی ارزیابی عملکرد به‌کار رفته‌اند. نتایج نشان می‌دهد مدل‌های بهینه‌شده با PSO به‌خصوص مدل ICGP، نسبت به نسخه‌های غیربهینه عملکرد برتری داشته و دقیق‌ترین نتایج را ارائه کرده‌اند؛ به‌گونه‌ای که دقت پیش‌بینی آن در جفت‌ارز USDSGD به ۸۰/۲۳٪ رسیده است. در مجموع، یافته‌ها بیانگر آن است که ترکیب ویژگی‌های مبتنی بر ایچیموکو با معماری‌های ترکیبی یادگیری عمیق و روش‌های فراابتکاری، توانایی پیش‌بینی روند و قابلیت تعمیم را در شرایط پرتلاطم بازارهای مالی به‌طور قابل‌توجهی افزایش می‌دهد.

واژه‌های کلیدی: پیش‌بینی روند فارکس، شبکه عصبی کانولوشنی، استراتژی ایچیموکو، الگوریتم فراابتکاری.

۱ مقدمه

بازار فارکس، به دلیل ویژگی‌های منحصر به فرد خود از جمله نقدینگی بالا، نوسانات قابل توجه، عدم تمرکز و اجرای سریع معاملات، به یکی از حوزه‌های کلیدی برای تحقیقات آکادمیک و کاربردی در زمینه معاملات مالی تبدیل شده است. این ویژگی‌ها بستری مناسب برای توسعه معاملات الگوریتمی فراهم کرده‌اند، که در آن مشاوران متخصص با خودکار سازی و بهینه‌سازی استراتژی‌های معاملاتی، کارایی و دقت تصمیم‌گیری را بهبود می‌بخشند. تحلیل تکنیکال، با تکیه بر داده‌های تاریخی قیمت نظیر قیمت‌های باز، بالا، پایین و بسته اغلب با اندیکاتورهای تکنیکال^۱ تکمیل می‌شود. این اندیکاتورها با تولید سیگنال‌های خرید و فروش، به معامله‌گران در شناسایی روندها، الگوها و نقاط معکوس احتمالی کمک کرده و نقش محوری در پیش‌بینی حرکات بازار فارکس ایفا می‌کند. در این میان، اندیکاتور ایچیموکو^۲ به دلیل توانایی جامع در شناسایی سطوح حمایت و مقاومت، تعیین جهت روند، ارزیابی شتاب بازار و ارائه سیگنال‌های معاملاتی، به ابزاری برجسته در تصمیم‌گیری‌های معاملاتی کوتاه‌مدت و بلندمدت تبدیل شده است. ابر ایچیموکو یکی از جامع‌ترین ابزارهای تحلیل تکنیکال است که در اواخر دهه ۱۹۳۰ میلادی توسط گویچی هوسودا (با نام مستعار ایچیموکو سانجین)، روزنامه‌نگار ژاپنی، پایه‌گذاری شد. این سیستم پس از بیش از سه دهه آزمون، بهینه‌سازی و محاسبات دستی دقیق، سرانجام در سال ۱۹۶۸ به صورت رسمی معرفی گردید. این اندیکاتور با تأکید بر تعادل و هماهنگی در حرکت قیمت‌ها طراحی شده تا نوسان‌های بازار را فیلتر کرده و سیگنال‌های شفاف‌تری ارائه دهد. همچنین با ترکیب چندین میانگین متحرک، دیدی یکپارچه از بازار را در یک نگاه فراهم می‌کند و با بهره‌گیری از بازه‌های زمانی چندگانه، درک عمیق‌تری از پویایی‌های بازار را برای تصمیم‌گیری‌های آگاهانه‌تر ممکن می‌سازد و به دلیل تطبیق‌پذیری‌اش همچنان به‌طور گسترده در معاملات استفاده می‌شود [۱].

با پیشرفت فناوری، ترکیب اندیکاتورهای تکنیکال با روش‌های یادگیری عمیق، به دلیل قابلیت تشخیص الگوهای پیچیده در داده‌های سری زمانی، به رویکردی نویدبخش تبدیل شده است. از جمله نوآوری‌های اخیر در این حوزه می‌توان به چارچوب پیش‌پردازش پیشنهادی لیوریس و همکاران [۲] اشاره کرد که با بهره‌گیری از آزمون‌های ایستایی ADF و KPSS به منظور ایستاسازی داده‌های سری زمانی، و همچنین به کارگیری معماری‌های ترکیبی CNN-LSTM و CNN-LSTM-Attention عملکرد قابل توجهی در پیش‌بینی قیمت بیت‌کوین، طلا، نقره و گاز طبیعی ارائه کردند. یا مدل ACLMC پنگ و همکاران [۳] که با برجسب‌گذاری روند پایدار و ترکیب داده‌ها از چندین ارز دیجیتال و فرکانس‌های زمانی، نوسانات ارزهای دیجیتال را مدیریت می‌کند، بر اهمیت ساختارهای ترکیبی در یادگیری عمیق تأکید دارند. همچنین، گومز [۴] با بهینه‌سازی LSTM از طریق الگوریتم ARO، دقت پیش‌بینی سهام را افزایش داده و سواستیانوف و همکاران [۵] با رویکرد چندمدلی، دقت معاملات فارکس را بهبود بخشیده‌اند. در این مطالعه [۶]، عملکرد چندین الگوریتم یادگیری ماشین از جمله مدل خطی، شبکه‌های عصبی مصنوعی، جنگل تصادفی و رگرسیون بردار پشتیبان مورد ارزیابی قرار گرفته و اندیکاتورهای نظیر میانگین متحرک نمایی سه‌گانه (TEMA) و همگرایی/واگرایی میانگین متحرک (MACD) به عنوان استراتژی‌های معاملاتی به کار گرفته شده‌اند. نتایج حاصل از آزمون این روش‌ها بر داده‌های روزانه شاخص‌های مهمی مانند DAX، IBEX و Dow Jones نشان می‌دهد که ترکیب یادگیری ماشین با تحلیل تکنیکال می‌تواند کیفیت سیگنال‌های معاملاتی و توان رقابتی استراتژی‌های معاملاتی را به‌طور معناداری بهبود بخشد. راجاشری داش و همکاران [۷]، یک رویکرد مبتنی بر شبکه عصبی CEFLANN مسئله تصمیم‌گیری معاملاتی را به صورت یک مسئله طبقه‌بندی خرید، نگهداری و فروش مدل‌سازی کرده و با تحلیل روابط غیرخطی میان اندیکاتورهای تکنیکال، سیگنال‌های معاملاتی پیوسته تولید می‌کنند. نتایج نشان می‌دهد که ادغام قابلیت یادگیری شبکه‌های عصبی با قواعد تحلیل تکنیکال می‌تواند دقت تصمیمات معاملاتی را نسبت به روش‌های کلاسیک یادگیری ماشین بهبود دهد. مطالعات بیان شده، نشان‌دهنده موفقیت رویکردهای ترکیبی یادگیری عمیق و بهینه‌سازی فراابتکاری در پیش‌بینی سری‌های زمانی مالی هستند.

این مطالعه یک چارچوب ترکیبی از اندیکاتور ایچیموکو و مدل‌های یادگیری عمیق، به‌ویژه شبکه‌های عصبی کانولوشنی (CNNها) را پیشنهاد می‌کند. CNNها به دلیل توانایی تشخیص الگوها در مجموعه داده‌های بزرگ، برای پیش‌بینی سری‌های زمانی، از جمله پیش‌بینی‌های بازار مالی، بسیار مناسب هستند. با ادغام قدرت تحلیل تکنیکال ایچیموکو با قابلیت پیش‌بینی CNN، هدف اصلی توسعه سیستمی دقیق و قوی برای پیش‌بینی حرکات قیمت در فارکس است. برای تقویت عملکرد مدل، از یک الگوریتم فرا ابتکاری^۳ به نام الگوریتم بهینه‌سازی ازدحام ذرات

¹ Technical Indicator

² Ichimoku

³ Metaheuristic Algorithm

(PSO) برای تنظیم بهینه ابرپارامترهایی^۱ نظیر نرخ یادگیری، اندازه دسته و معماری شبکه بهره می‌جویم. طراحی الگوریتم‌های فرا ابتکاری برای حل مسائل پیچیده بهینه‌سازی با تقلید از فرآیندهای طبیعی است که امکان یافتن جواب‌های بهینه یا نزدیک به بهینه را فراهم می‌کند. بهینه‌ساز PSO، که از رفتارهای اجتماعی موجودات الهام گرفته شده، به مدل‌های یادگیری عمیق کمک می‌کند تا پیکربندی مناسب را شناسایی کند و دقت پیش‌بینی را بهبود می‌بخشد [۸].

برای ارزیابی مدل‌های رگرسیون، معیارهای استاندارد مانند MAE، MSE و MAPE به کار گرفته می‌شوند. با این حال، در بسیاری از موارد، این متریک‌ها می‌توانند معامله‌گران را گمراه کنند، زیرا حتی اگر مدل نرخ خطای پایینی داشته باشد، نوسانات کوچک در قیمت‌های پیش‌بینی شده ممکن است سفارش‌های توقف ضرر را فعال کند و منجر به خروج زود هنگام از معاملات شود بنابراین تمرکز این مطالعه بر پیش‌بینی روند بازار (صعودی یا نزولی) به جای پیش‌بینی دقیق قیمت است. این رویکرد با هدف ارائه سیگنال‌های معاملاتی قابل اعتماد برای استراتژی‌های کوتاه‌مدت و بلندمدت طراحی شده است. علاوه بر این، چارچوب پیشنهادی با استفاده از داده‌های جفت‌ارزهای مختلف ارزیابی می‌شود تا قدرت تعمیم‌پذیری و کارایی آن بررسی شود. اهداف این تحقیق دوگانه است: اول، بررسی قدرت پیش‌بینی CNN‌ها در پیش‌بینی حرکات قیمت در بازار پرنوسان فارکس؛ و دوم، ارائه ابزاری قوی و مبتنی بر داده به معامله‌گران برای تصمیم‌گیری‌های معاملاتی آگاهانه.

۲ شبکه‌های عصبی کانولوشنی (CNN)

شبکه‌های عصبی کانولوشنی^۲ (CNNs) دسته‌ای از مدل‌های یادگیری عمیق هستند که به‌ویژه برای پردازش داده‌های فضایی مانند تصاویر و دنباله‌ها بسیار مؤثرند. این شبکه‌ها به دلیل توانایی خودکار و تطبیقی در یادگیری سلسله‌مراتب ویژگی‌های فضایی از داده‌ها، محبوبیت گسترده‌ای کسب کرده‌اند. کار بنیادی لکون و همکاران [۹] نشان داد که CNN‌ها ابزارهایی قدرتمند برای شناسایی و طبقه‌بندی تصاویر هستند و دقت بالایی در مجموعه داده‌های پیچیده ارائه می‌دهند.

ساختار CNN‌ها به گونه‌ای است که به طور خودکار و تطبیقی سلسله‌مراتب مکانی ویژگی‌ها را از داده‌ها از طریق سه نوع لایه اصلی یاد بگیرند: لایه‌های کانولوشن، لایه‌های تجمیع^۳ و لایه‌های کاملاً متصل^۴. لایه‌های کانولوشن با اعمال مجموعه‌ای از فیلترهای قابل یادگیری (هسته‌ها) در سراسر ورودی، مسئول استخراج ویژگی هستند. لایه‌های تجمیع، ابعاد نقشه‌های ویژگی را کاهش می‌دهند و با حفظ ویژگی‌های کلیدی و حذف اطلاعات کم‌اهمیت، نه تنها بار محاسباتی را کم می‌کنند، بلکه از بیش‌برازش جلوگیری می‌کنند [۱۰]. به عنوان مثال، تجمیع حداکثری^۵ در CNN‌های مدرن برای حفظ مهم‌ترین جنبه‌های ویژگی‌ها و کاهش نویز به کار می‌رود [۱۱]. لایه کاملاً متصل در مرحله نهایی، ویژگی‌های استخراج‌شده را ترکیب کرده و خروجی نهایی را برای وظایف طبقه‌بندی یا رگرسیون تولید می‌کند. علاوه بر پردازش تصویر، CNN‌ها با استفاده از هسته‌های کانولوشنی یک‌بعدی (1D CNN) برای داده‌های یک‌بعدی مانند سری‌های زمانی و شناسایی سیگنال بسیار مناسب هستند. در این موارد، موقعیت مطلق ویژگی‌ها کمتر اهمیت دارد. برای مثال، ترکیب 1D CNN با شبکه‌های BiLSTM در پیش‌بینی‌های پیچیده با داده‌های پرنوسان مؤثر بوده است. لاوال و همکاران یک مدل ترکیبی از 1D CNN و BiLSTM را برای پیش‌بینی کوتاه‌مدت سرعت باد توسعه دادند که با استخراج ویژگی‌های فضایی و زمانی، عملکرد بالایی در ارتفاعات مختلف نشان داد [۱۲]. به‌طور مشابه، کیم و همکاران از مدل 1D CNN-BiLSTM برای پیش‌بینی اوج تقاضای برق و قیمت حاشیه‌ای سیستم استفاده کردند، که با ثبت وابستگی‌های ترتیبی، دقت پیش‌بینی را نسبت به روش‌های سنتی بهبود دادند [۱۳].

¹Hyperparameters Optimization

²Convolutional Neural Networks

³Pooling layers Algorithm

⁴Fully connected layers

⁵Max-Pooling

۳ اندیکاتورهای برگرفته از استراتژی ایچیموکو

نمودار ایچیموکو در اصل یک نمودار شمعی ژاپنی است که با پنج اندیکاتور همپوشان از نوع میانگین متحرک تکمیل می‌شود:

- تنکان-سن^۱ (خط تبدیل): میانگین بالاترین و پایین‌ترین قیمت در ۹ دوره اخیر.
- کیجون-سن^۲ (خط پایه): میانگین بالاترین و پایین‌ترین قیمت در ۲۶ دوره اخیر.
- سنکو اسپن A^۳ (اسپن پیشرو A): میانگین تنکان-سن و کیجون-سن، ۲۶ دوره به جلو جابه‌جا شده است.
- سنکو اسپن B^۴ (اسپن پیشرو B): میانگین بالاترین و پایین‌ترین قیمت در ۵۲ دوره اخیر، ۲۶ دوره به جلو جابه‌جا شده است.
- چیکو اسپن^۵ (خط تأخیری): قیمت بسته شدن کنونی، ۲۶ دوره به عقب جابه‌جا شده است.

فضای بین سنکو اسپن A و سنکو اسپن B، معروف به ابر ایچیموکو (کومو)، مهم‌ترین بخش نمودار است. اکثر معاملات بر اساس تعامل قیمت با این ابر آغاز می‌شوند. هر پنج خط به‌عنوان سیگنال‌های صعودی یا نزولی عمل می‌کنند، اما ابر کومو نقش محوری را به‌عنوان محرک اصلی برای ورود به بازار یا خروج از آن ایفا می‌کند. به جز چیکو اسپن، سایر خطوط بر اساس بالاترین و پایین‌ترین قیمت‌ها در دوره‌های مشخص (به‌طور پیش‌فرض ۹، ۲۶ و ۵۲) محاسبه می‌شوند. با الهام از این رویکرد، این اندیکاتورها به‌عنوان ویژگی‌های جدید برای تقویت تحلیل روند و بهبود پیش‌بینی‌ها در جدول ۱ شرح داده شده‌اند.

جدول ۱: اندیکاتورهای برگرفته از استراتژی ایچیموکو

Indicator	Formula and Description
Tenkan-sen	$\frac{\text{Highest High} + \text{Lowest Low}}{2}$ (Over the last 9 periods)
Kijun-sen	$\frac{\text{Highest High} + \text{Lowest Low}}{2}$ (Over the last 26 periods)
Span A	$\frac{\text{Tenkan-sen} + \text{Kijun-sen}}{2}$ [Shifted +26]
Span B	$\frac{\text{Highest High} + \text{Lowest Low}}{2}$ (the last 52 periods) [Shifted +26]
Chikou Span	Current or Closing Price [Shifted -26]

۴ مجموعه داده

در این پژوهش، داده‌ها از طریق پلتفرم MetaTrader گردآوری شده و تمرکز اصلی بر جفت‌ارز EURUSD قرار دارد. این جفت‌ارز به دلیل حجم معاملات بالای خود در بازارهای مالی جهانی، گزینه‌ای ایده‌آل برای بررسی پویایی‌های متنوع بازار محسوب می‌شود. مجموعه داده شامل اطلاعات قیمتی OHLC (باز، بالا، پایین، بسته) در بازه زمانی پنج‌ساله (۱ سپتامبر ۲۰۱۹ تا ۱ سپتامبر ۲۰۲۴) با فواصل زمانی ۱ ساعته و ۴ ساعته است، که امکان تحلیل دقیق نوسانات کوتاه‌مدت و روندهای بلندمدت را فراهم می‌کند. بازه زمانی چهارساعته به این دلیل انتخاب شده است که هر کندل چهارساعته نیمی از یک سشن اصلی جغرافیایی (آسیایی، اروپایی یا آمریکایی) را پوشش می‌دهد و رفتارهای متمایز بازار را به‌خوبی ثبت می‌کند که معامله‌گران می‌توانند از آن‌ها برای فرصت‌های معاملاتی استفاده

¹Tenkan-sen

²Kijun-sen

³Senkou Span A

⁴Senkou Span B

⁵Chikou Span

کنند. به همین ترتیب، تایم فریم یک ساعته به دلیل کاربرد گسترده اش در معاملات الگوریتمی برگزیده شده است. این انتخاب بر پایه تجربیات معامله گران حرفه ای فارکس و مطالعات تجربی در جوامع معاملاتی این بازار صورت گرفته تا با رویه های واقعی معاملاتی هم خوانی داشته باشد. برای ارتقای دقت پیش بینی، از اندیکاتورهای برگرفته از استراتژی ایچیموکو در کنار داده های OHLC در دو بازه زمانی مختلف استفاده شد. همچنین، یک پنجره کشویی با طول ۵۰ برای ثبت وابستگی های زمانی اخیر اعمال شد، که به مدل امکان می دهد زمینه تاریخی مرتبط را با کارایی محاسباتی بالا در نظر بگیرد. داده ها به نسبت ۸۰٪ برای آموزش و ۲۰٪ برای آزمایش تقسیم شدند تا یادگیری مؤثر از داده های تاریخی و ارزیابی بی طرفانه مدل تضمین شود. تمام مراحل، از جمع آوری داده ها تا پیش پردازش و آموزش مدل، با استفاده از زبان برنامه نویسی پایتون و بهره گیری از قابلیت های آن برای مدیریت داده های بزرگ و مهندسی ویژگی های پیشرفته انجام شد. این مجموعه داده، با ساختار منسجم و ویژگی های غنی، بستری جامع برای توسعه و ارزیابی مدل های پیش بینی در بازارهای مالی فراهم می کند.

۵ چارچوب پیشنهادی برای پیش بینی سری های زمانی چندمتغیره

این بخش چارچوبی نوین برای بهبود عملکرد شبکه CNN در پیش بینی سری های زمانی چندمتغیره ارائه می دهد. تمرکز اصلی دست یابی به ویژگی های باکیفیت و مناسب برای این مدل ها از طریق اندیکاتورهای تکنیکال استراتژی ایچیموکو است. همچنین، الگوریتم PSO برای تنظیم دقیق هایپارامترها به کار گرفته شده است. مدل های تقویت شده با ایچیموکو با افزودن پیشوند Ichimoku مطابق جدول ۲ نام گذاری شده اند.

جدول ۲: نام گذاری مدل ها

Ichimoku-CNN	IC
Ichimoku-CNN-LSTM	ICL
Ichimoku-CNN-GRU	ICG
Ichimoku-CNN-PSO	ICP
Ichimoku-CNN-LSTM-PSO	ICLP
Ichimoku-CNN-GRU-PSO	ICGP

مدل IC صرفاً از لایه های کانولوشنی تشکیل شده، در حالی که ICL و ICG به ترتیب با لایه های LSTM و GRU ترکیب شده اند. همه مدل ها از تابع فعال سازی ReLU در لایه های مخفی و تابع خطی در لایه خروجی استفاده می کنند. آموزش با تابع خطای MSE و بهینه ساز Adam انجام شده و برای جلوگیری از بیش برآزش، لایه های Dropout و Batch Normalization به کار گرفته شده اند. پیاده سازی با پایتون ۳.۱۱.۳ و کتابخانه های TensorFlow و scikit-learn روی لپ تاپی با پردازنده Intel® Core™ i7-13620H (2.40 GHz) و ۱۶ گیگابایت رم انجام شد. هایپارامترهای مورد بررسی، نقش کلیدی در ظرفیت یادگیری، تعمیم پذیری و مقاومت در برابر بیش برآزش دارند. الگوریتم PSO با بهینه سازی این پارامترها، تعادل بین پیچیدگی و تعمیم پذیری مدل را بهبود می بخشد و استحکام مدل را به ویژه برای داده های سری زمانی با ابعاد بالا افزایش می دهد.

در مرحله پیش بینی چندبازه ای، عملکرد مدل ها با استفاده از معیارهای رگرسیونی MAE، MSE و MAPE ارزیابی می شود تا دقت عددی پیش بینی قیمت در افق های زمانی یک ساعته و چهار ساعته به طور دقیق سنجیده شود. در ادامه، خروجی های رگرسیونی مدل ها به یک ماژول تصمیم گیری منتقل می شوند. در این بخش، جهت حرکت بازار (صعودی یا نزولی) بر اساس هم جهتی پیش بینی های بازه های یک ساعته و چهار ساعته استخراج شده و در صورت عدم توافق، حالت «عدم اقدام» در نظر گرفته می شود. بدین ترتیب، مسئله از پیش بینی مقدار قیمت به یک مسئله طبقه بندی تبدیل می گردد که در آن برچسب های کلاسی نشان دهنده تصمیم معاملاتی نهایی هستند. در مرحله نهایی ارزیابی، با مقایسه تصمیم های پیش بینی شده با روند واقعی بازار، ماتریس درهم ریختگی تشکیل شده و معیارهای طبقه بندی Accuracy و F-Score محاسبه می شوند. شبه کد ۱ ساختار چندبازه ای و چندمدلی را با ادغام ویژگی های برگرفته از ایچیموکو، مدل های مبتنی بر CNN و بهینه سازی PSO را نشان می دهد و فرآیند گام به گام پیش بینی، ارزیابی و تصمیم گیری را برجسته می کند.

Algorithm 1 End-to-end forecasting, optimization, and decision-making framework using Ichimoku-based models and PSO.

- 1: **Input:** Historical EURUSD prices (H1 and H4), window length L , models IC, ICL, ICG and optimization algorithm PSO.
- 2: **Output:** Final performance metrics: Accuracy and F-Score.
- 3: **Step 1: Data Preparation**
- 4: Load 1-hour and 4-hour historical price data.
- 5: Compute Ichimoku indicators.
- 6: Normalize the data.
- 7: Construct sliding windows of length L .
- 8: Split data into 80% training and 20% testing sets.
- 9: **Step 2: Hyperparameter Optimization via PSO**
- 10: **for** each particle in PSO **do**
- 11: Apply the particle's hyperparameters to one of the models (IC, ICL, ICG).
- 12: Train the model and compute the MAE.
- 13: Store the MAE as the objective value.
- 14: **end for**
- 15: Extract the optimal hyperparameters after PSO convergence.
- 16: **Step 3: Final Training of Models**
- 17: **for** each model in {IC, ICL, ICG, ICP, ICLP, ICGP} **do**
- 18: Train on H1 data using optimized hyperparameters.
- 19: Train on H4 data using optimized hyperparameters.
- 20: **end for**
- 21: **Step 4: Multi-horizon Forecasting**
- 22: **for** each model **do**
- 23: Generate 1-step-ahead forecasts for H4 data.
- 24: Generate 4-step-ahead forecasts for H1 data.
- 25: Compute MSE, MAE, and MAPE for both forecasting horizons.
- 26: **end for**
- 27: **Step 5: Decision-making Module**
- 28: **if** H1 and H4 predictions indicate the same trend direction **then**
- 29: Decision = Action (Uptrend / Downtrend)
- 30: **else**
- 31: Decision = No Action
- 32: **end if**
- 33: **Step 6: Conversion to Classification Problem**
- 34: Action outputs are considered as class labels.
- 35: Compare predicted actions with real trend and compute confusion matrix.
- 36: **Step 7: Final Evaluation**
- 37: Compute Accuracy.
- 38: Compute F-Score.
- 39: **return** Accuracy and F-Score.

۶ نتایج

این مطالعه چارچوب دو زمانه نوینی برای پیش‌بینی سری‌های زمانی چندمتغیره معرفی کرد که با بهره‌گیری از پیش‌پردازش داده‌ها و ویژگی‌های برگرفته از استراتژی ایچیموکو، عملکرد مدل‌های یادگیری عمیق را بهبود می‌بخشد.

این چارچوب از مدل‌های CNN-LSTM، CNN-GRU و CNN-GRU که ابرپارامترهای آن‌ها با الگوریتم بهینه‌سازی PSO تنظیم شده، استفاده می‌کند. مدل‌ها در دو بازه زمانی ۱ ساعته و ۴ ساعته برای پیش‌بینی روند جفت‌ارز EUR/USD در بازه زمانی ۴ ساعته (داده‌های ۲۰۱۹ تا ۲۰۲۴) آموزش داده شده‌اند و برای ارزیابی از هشت جفت‌ارز دیگر با همبستگی بیش از ۸۰٪ یا کمتر از ۸۰٪- نسبت به EUR/USD مطابق جدول ۴ استفاده شده است [۱۴].

جدول ۳: معیار همبستگی با جفت‌ارز EUR/USD

	AUDUSD	EURSGD	GBPUSD	NZDUSD	USDCHF	USDCNH	USDSEK	USDSGD
EURUSD	+۸۵،۱٪	+۸۰،۱٪	-۸۴،۰٪	+۹۱،۳٪	-۸۵،۰٪	-۹۳،۵٪	-۵۲،۰٪	-۹۴،۲٪

در این بخش، عملکرد مدل‌ها با استفاده از معیارهای MAE، MSE و MAPE در دو بازه زمانی H1 و H4 برای جفت‌ارزهای AUDUSD، EURSGD، GBPUSD، NZDUSD، USDCHF، USDCNH، USDSEK و USDSGD مورد ارزیابی قرار گرفت. از آنجا که داده‌های مرحله آزمون نرمال‌سازی شده‌اند، تمامی مقادیر گزارش شده در جداول ۴، ۵ و ۶ در مقیاس نرمال‌شده ارائه شده‌اند.

نتایج جدول ۴ نشان می‌دهد که مدل‌های بهینه‌سازی شده ICP، ICLP و ICGP در اغلب جفت‌ارزها و در هر دو بازه زمانی، مقادیر کمتری از معیار MAE را نسبت به مدل‌های پایه IC، ICL و ICG به دست آورده‌اند. در این میان، مدل ICGP در اکثر سناریوها کمترین مقدار MAE را ثبت کرده و بالاترین دقت پیش‌بینی را نشان می‌دهد. به‌طور مشخص، در جفت‌ارز EURSGD این مدل با مقادیر H1: ۰/۰۰۲۸ و H4: ۰/۰۰۶۲ بهترین عملکرد را ارائه داده است که بیانگر توان بالای آن در کاهش خطای مطلق پیش‌بینی است.

بررسی نتایج معیار MSE در جدول ۵ نیز این یافته‌ها را تأیید می‌کند. مطابق این جدول، مدل ICGP در هر دو بازه زمانی H1 و H4 در اغلب جفت‌ارزها کمترین مقدار MSE را به خود اختصاص داده است. این موضوع نشان‌دهنده پایداری ساختار پیشنهادی و برتری آن در استخراج الگوهای غیرخطی و مؤثر از داده‌های بازار فارکس است. به‌عنوان نمونه، در جفت‌ارزهای AUDUSD، EURSGD، GBPUSD و NZDUSD، عملکرد مدل ICGP به‌صورت معناداری بهتر از سایر مدل‌ها بوده است. همچنین مقایسه بین دو بازه زمانی حاکی از آن است که مقادیر MSE در بازه H1 به‌طور کلی کمتر از بازه H4 هستند که نشان می‌دهد مدل‌ها در داده‌های با تفکیک زمانی بالاتر قادر به ثبت نوسانات کوتاه‌مدت بازار با دقت بیشتری می‌باشند. این رفتار به‌ویژه در جفت‌ارزهایی مانند EURSGD، USDCNH و USDSGD به‌وضوح مشاهده می‌شود.

نتایج مربوط به معیار MAPE که در جدول ۶ ارائه شده‌اند نیز با تحلیل‌های پیشین هم‌راستا بوده و برتری مدل‌های بهینه‌سازی شده را بیش از پیش تأیید می‌کنند. بر اساس این جدول، مدل ICGP به‌طور مداوم کمترین مقدار MAPE را در اکثر جفت‌ارزها ثبت کرده است که نشان‌دهنده توان بالای این مدل در کاهش خطای نسبی پیش‌بینی‌ها است. به‌طور خاص، در جفت‌ارز USDSGD این مدل با مقادیر H1: ۰/۰۰۴۲ و H4: ۰/۰۰۷۷ کمترین MAPE را به دست آورده است. علاوه بر این، مدل ICP نیز در برخی جفت‌ارزها، از جمله NZDUSD، عملکرد قابل‌توجهی از خود نشان داده است که اثربخشی آن در کاهش خطاهای نسبی را تأیید می‌کند. در مقابل، مدل‌های ICL و ICG در اغلب موارد مقادیر MAPE بالاتری تولید کرده‌اند که بیانگر قابلیت اطمینان کمتر آن‌ها در پیش‌بینی دقیق روند قیمت است.

در نهایت، نتایج ارزیابی طبقه‌بندی روند که در جدول ۷ ارائه شده‌اند، عملکرد مدل‌ها را با استفاده از معیارهای F1-Score و Accuracy مورد بررسی قرار می‌دهند. بر اساس این نتایج، مدل ICGP در اکثر جفت‌ارزها بالاترین دقت را به دست آورده است؛ به‌طوری‌که برای جفت‌ارزهای AUDUSD (۷۸،۵۲٪)، EURSGD (۷۸،۲۰٪)، GBPUSD (۷۴،۶۱٪)، NZDUSD (۷۸،۷۱٪)، USDCHF (۷۸،۷۱٪)، USDSEK (۶۴،۵۴٪) و USDSGD (۸۱،۰۵٪) عملکرد برتری را نشان می‌دهد. علاوه بر این، مقادیر بالاتر F1-Score برای مدل ICGP حاکی از توانایی بالای این مدل در حفظ تعادل میان دقت و یادآوری است که نشان‌دهنده استحکام ساختار پیشنهادی و تأثیر مثبت بهینه‌سازی مبتنی بر الگوریتم PSO در بهبود عملکرد نهایی مدل می‌باشد.

جدول ۴: ارزیابی بر اساس میانگین خطای مطلق (MAE)

	H1						H4					
	IC	ICL	ICG	ICP	ICLP	ICGP	IC	ICL	ICG	ICP	ICLP	ICGP
AUDUSD	۰/۰۱۰۲	۰/۰۱۱۰	۰/۰۱۴۷	۰/۰۰۶۵	۰/۰۱۰۰	۰/۰۰۴۷	۰/۰۲۵۵	۰/۰۱۴۰	۰/۰۱۸۹	۰/۰۱۱۸	۰/۰۱۳۳	۰/۰۰۷۹
EURSGD	۰/۰۰۷۸	۰/۰۰۷۳	۰/۰۰۹۶	۰/۰۰۵۵	۰/۰۰۶۰	۰/۰۰۲۸	۰/۰۱۶۵	۰/۰۱۲۳	۰/۰۱۵۰	۰/۰۰۶۹	۰/۰۰۷۲	۰/۰۰۶۲
GBPNZD	۰/۰۰۶۸	۰/۰۰۸۳	۰/۰۰۸۲	۰/۰۰۶۷	۰/۰۰۶۶	۰/۰۰۴۳	۰/۰۱۴۶	۰/۰۱۰۰	۰/۰۱۳۷	۰/۰۱۰۷	۰/۰۰۹۰	۰/۰۰۷۸
NZDUSD	۰/۰۱۵۵	۰/۰۱۱۹	۰/۰۰۶۵	۰/۰۱۱۵	۰/۰۱۰۲	۰/۰۰۵۵	۰/۰۲۵۸	۰/۰۱۳۷	۰/۰۱۹۱	۰/۰۱۳۰	۰/۰۱۵۷	۰/۰۰۸۴
USDCHF	۰/۰۰۷۷	۰/۰۱۰۱	۰/۰۰۷۸	۰/۰۰۷۲	۰/۰۰۶۸	۰/۰۰۴۷	۰/۰۱۵۴	۰/۰۱۰۱	۰/۰۱۴۱	۰/۰۱۰۱	۰/۰۰۷۲	۰/۰۰۸۹
USDCNH	۰/۰۱۲۱	۰/۰۱۰۷	۰/۰۰۶۸	۰/۰۰۵۶	۰/۰۰۷۹	۰/۰۰۵۹	۰/۰۱۱۸	۰/۰۱۰۹	۰/۰۱۳۵	۰/۰۱۱۴	۰/۰۰۹۵	۰/۰۰۸۸
USDSEK	۰/۰۲۰۸	۰/۰۲۲۵	۰/۰۲۲۶	۰/۰۱۵۰	۰/۰۲۰۷	۰/۰۰۶۲	۰/۰۳۰۴	۰/۰۳۰۱	۰/۰۲۳۹	۰/۰۲۰۰	۰/۰۲۴۴	۰/۰۱۷۴
USDSGD	۰/۰۰۹۶	۰/۰۱۳۸	۰/۰۰۵۲	۰/۰۰۷۱	۰/۰۰۸۱	۰/۰۰۳۸	۰/۰۱۳۳	۰/۰۱۰۰	۰/۰۱۰۲	۰/۰۱۱۸	۰/۰۰۷۸	۰/۰۰۸۳

جدول ۵: ارزیابی بر اساس میانگین مربعات خطا (MSE)

	H1						H4					
	IC	ICL	ICG	ICP	ICLP	ICGP	IC	ICL	ICG	ICP	ICLP	ICGP
AUDUSD	۳۱×۱۰^{-۴}	۱۸×۱۰^{-۴}	۱۶×۱۰^{-۴}	۲×۱۰^{-۴}	۱۵×۱۰^{-۴}	۰۵×۱۰^{-۴}	۴×۱۰^{-۴}	۳۷×۱۰^{-۴}	۱×۱۰^{-۴}	۱۴×۱۰^{-۴}	۳۴×۱۰^{-۴}	۰۷×۱۰^{-۴}
EURSGD	۱۲×۱۰^{-۴}	۰۷×۱۰^{-۴}	۰۷×۱۰^{-۴}	۰۶×۱۰^{-۴}	۰۵×۱۰^{-۴}	۰۱×۱۰^{-۴}	۳۳×۱۰^{-۴}	۱۸×۱۰^{-۴}	۲۴×۱۰^{-۴}	۰۹×۱۰^{-۴}	۰۸×۱۰^{-۴}	۰۴×۱۰^{-۴}
GBPNZD	۰۸×۱۰^{-۴}	۱×۱۰^{-۴}	۱×۱۰^{-۴}	۰۵×۱۰^{-۴}	۰۶×۱۰^{-۴}	۰۳×۱۰^{-۴}	۲۸×۱۰^{-۴}	۲۱×۱۰^{-۴}	۱۳×۱۰^{-۴}	۱۲×۱۰^{-۴}	۰۹×۱۰^{-۴}	۰۳×۱۰^{-۴}
NZDUSD	۳۳×۱۰^{-۴}	۲۱×۱۰^{-۴}	۲×۱۰^{-۴}	۱۷×۱۰^{-۴}	۱۵×۱۰^{-۴}	۰۵×۱۰^{-۴}	۸۹×۱۰^{-۴}	۴۴×۱۰^{-۴}	۴۱×۱۰^{-۴}	۱۵×۱۰^{-۴}	۳۷×۱۰^{-۴}	۰۷×۱۰^{-۴}
USDCHF	۱×۱۰^{-۴}	۱۶×۱۰^{-۴}	۱۲×۱۰^{-۴}	۰۶×۱۰^{-۴}	۰۷×۱۰^{-۴}	۰۳×۱۰^{-۴}	۳۲×۱۰^{-۴}	۱۳×۱۰^{-۴}	۲۲×۱۰^{-۴}	۱۲×۱۰^{-۴}	۰۹×۱۰^{-۴}	۰۴×۱۰^{-۴}
USDCNH	۲۲×۱۰^{-۴}	۱۵×۱۰^{-۴}	۰۹×۱۰^{-۴}	۰۵×۱۰^{-۴}	۱×۱۰^{-۴}	۰۳×۱۰^{-۴}	۲×۱۰^{-۴}	۱۲×۱۰^{-۴}	۲۴×۱۰^{-۴}	۱۸×۱۰^{-۴}	۱×۱۰^{-۴}	۰۵×۱۰^{-۴}
USDSEK	۸۴×۱۰^{-۴}	۱۰۵×۱۰^{-۴}	۹۸×۱۰^{-۴}	۶۷×۱۰^{-۴}	۱۰۱×۱۰^{-۴}	۵×۱۰^{-۴}	۱۳×۱۰^{-۴}	۱۹۴×۱۰^{-۴}	۱۰۴×۱۰^{-۴}	۶۸×۱۰^{-۴}	۱۳۶×۱۰^{-۴}	۱۴×۱۰^{-۴}
USDSGD	۱۱×۱۰^{-۴}	۲۱×۱۰^{-۴}	۰۳×۱۰^{-۴}	۰۵×۱۰^{-۴}	۰۸×۱۰^{-۴}	۰۲×۱۰^{-۴}	۱۳×۱۰^{-۴}	۱×۱۰^{-۴}	۲۱×۱۰^{-۴}	۱۲×۱۰^{-۴}	۰۷×۱۰^{-۴}	۰۶×۱۰^{-۴}

جدول ۶: ارزیابی بر اساس میانگین درصد خطای مطلق (MAPE)

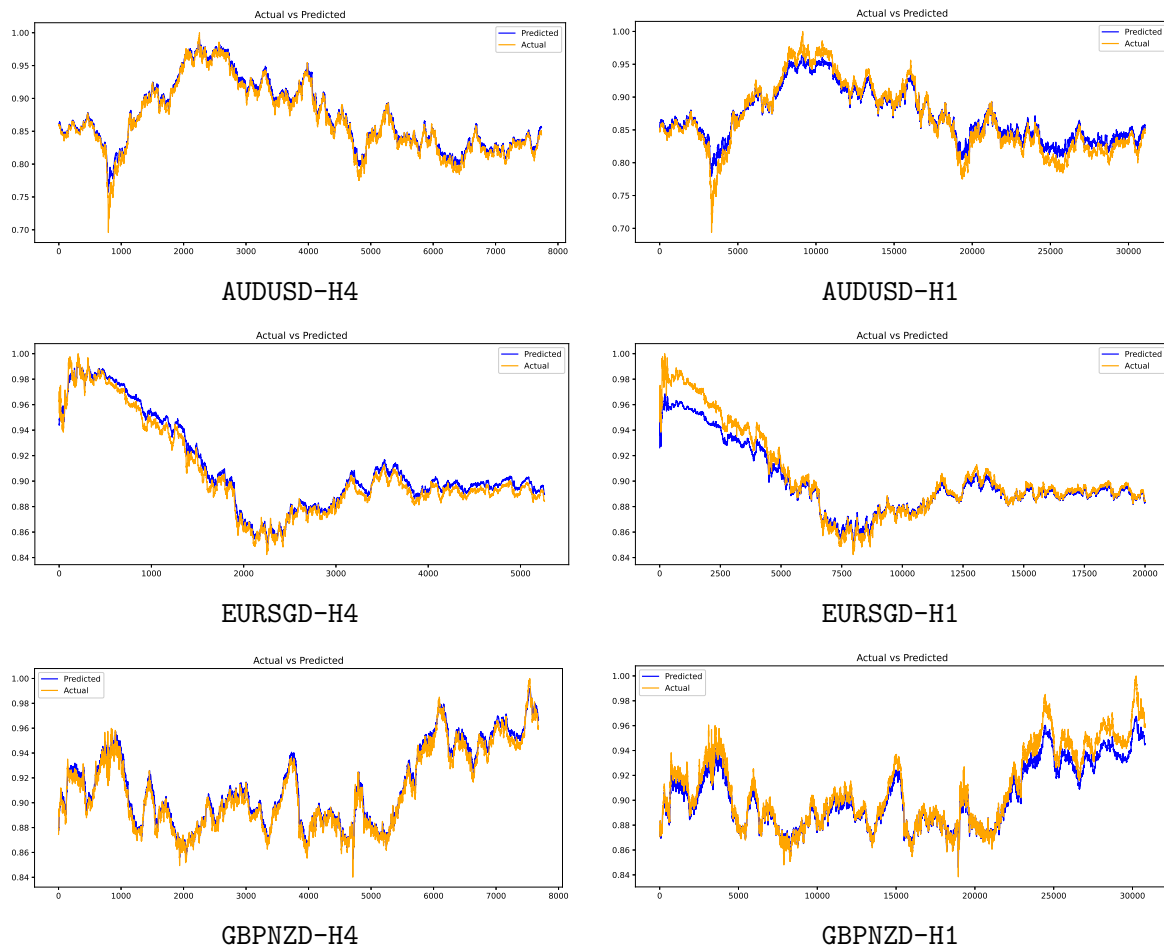
	H1						H4					
	IC	ICL	ICG	ICP	ICLP	ICGP	IC	ICL	ICG	ICP	ICLP	ICGP
AUDUSD	۰/۰۱۲۰	۰/۰۱۳۱	۰/۰۱۷۶	۰/۰۰۷۵	۰/۰۱۱۶	۰/۰۰۵۸	۰/۰۳۰۴	۰/۰۱۶۸	۰/۰۲۲۲	۰/۰۰۹۰	۰/۰۱۵۸	۰/۰۰۸۵
EURSGD	۰/۰۰۸۶	۰/۰۰۴۷	۰/۰۰۴۴	۰/۰۰۵۹	۰/۰۰۸۰	۰/۰۰۳۰	۰/۰۱۸۵	۰/۰۱۳۸	۰/۰۱۶۷	۰/۰۰۴۹	۰/۰۰۷۹	۰/۰۰۵۴
GBPNZD	۰/۰۱۶۳	۰/۰۱۱۲	۰/۰۱۵۲	۰/۰۰۷۲	۰/۰۰۹۰	۰/۰۰۵۱	۰/۰۰۷۸	۰/۰۰۷۵	۰/۰۱۱۶	۰/۰۰۹۷	۰/۰۰۵۳	۰/۰۰۴۴
NZDUSD	۰/۰۰۷۵	۰/۰۱۴۳	۰/۰۱۸۶	۰/۰۱۳۶	۰/۰۱۲۰	۰/۰۰۶۷	۰/۰۳۱۰	۰/۰۱۷۱	۰/۰۲۲۶	۰/۰۰۷۷	۰/۰۱۹۰	۰/۰۰۹۷
USDCHF	۰/۰۰۸۳	۰/۰۱۰۹	۰/۰۰۸۸	۰/۰۰۷۹	۰/۰۰۷۶	۰/۰۰۵۰	۰/۰۱۷۳	۰/۰۱۱۳	۰/۰۱۵۶	۰/۰۰۹۶	۰/۰۰۷۹	۰/۰۰۵۵
USDCNH	۰/۰۱۲۶	۰/۰۰۸۳	۰/۰۱۱۳	۰/۰۰۶۲	۰/۰۰۷۶	۰/۰۰۶۱	۰/۰۱۲۳	۰/۰۱۰۴	۰/۰۱۴۴	۰/۰۱۲۱	۰/۰۰۹۴	۰/۰۰۵۹
USDSEK	۰/۰۲۶۵	۰/۰۲۹۰	۰/۰۲۹۱	۰/۰۰۷۲	۰/۰۲۸۸	۰/۰۱۹۸	۰/۰۳۸۱	۰/۰۳۳۳	۰/۰۳۰۱	۰/۰۱۱۸	۰/۰۳۸۹	۰/۰۲۲۵
USDSGD	۰/۰۱۰۳	۰/۰۱۴۹	۰/۰۰۵۶	۰/۰۰۷۲	۰/۰۰۸۷	۰/۰۰۴۲	۰/۰۱۱۱	۰/۰۰۸۹	۰/۰۱۴۴	۰/۰۱۰۷	۰/۰۰۸۴	۰/۰۰۷۷

جدول ۷: دقت ساختار پیشنهادی


	Accuracy(%)						F1-Score					
	IC	ICL	ICG	ICP	ICLP	ICGP	IC	ICL	ICG	ICP	ICLP	ICGP
AUDUSD	٪.۷۳/۸۰	٪.۷۳/۰۰	٪.۷۴/۲۶	٪.۷۴/۲۶	٪.۷۴/۰۴	٪.۷۸/۵۲	۰/۶۱	۰/۵۴	۰/۵۹	۰/۵۹	۰/۵۸	۰/۶۵
EURSGD	٪.۷۴/۰۷	٪.۷۰/۶۰	٪.۷۵/۸۵	٪.۷۴/۴۸	٪.۷۶/۸۴	٪.۷۸/۲۰	۰/۵۸	۰/۵۵	۰/۵۳	۰/۵۶	۰/۵۹	۰/۶۱
GBPNZD	٪.۷۰/۸۹	٪.۶۹/۹۳	٪.۶۹/۷۸	٪.۷۱/۴۶	٪.۷۲/۴۰	٪.۷۴/۶۱	۰/۶۱	۰/۵۹	۰/۵۸	۰/۶۲	۰/۶۲	۰/۶۶
NZDUSD	٪.۷۳/۹۰	٪.۷۴/۱۴	٪.۷۴/۳۷	٪.۷۵/۰۱	٪.۷۳/۶۶	٪.۷۸/۱۱	۰/۵۹	۰/۵۵	۰/۵۹	۰/۶۰	۰/۵۷	۰/۶۳
USDCHF	٪.۷۶/۵۵	٪.۷۳/۶۳	٪.۷۶/۲۰	٪.۷۵/۲۵	٪.۷۵/۸۴	٪.۷۸/۷۱	۰/۵۶	۰/۵۴	۰/۵۷	۰/۵۹	۰/۵۷	۰/۶۳
USDCNH	٪.۶۶/۸۸	٪.۶۲/۸۸	٪.۶۵/۱۶	٪.۶۹/۷۱	٪.۶۷/۶۵	٪.۶۹/۴۹	۰/۶۴	۰/۵۹	۰/۶۳	۰/۶۷	۰/۶۴	۰/۶۷
USDSEK	٪.۶۲/۹۵	٪.۶۱/۱۳	٪.۶۲/۳۱	٪.۶۲/۸۵	٪.۶۱/۸۷	٪.۶۴/۵۴	۰/۶۱	۰/۶۰	۰/۶۱	۰/۶۱	۰/۶۰	۰/۶۴
USDSGD	٪.۷۹/۷۷	٪.۷۷/۵۹	٪.۷۸/۸۸	٪.۷۹/۸۲	٪.۷۸/۱۰	٪.۸۰/۲۳	۰/۵۱	۰/۵۳	۰/۵۵	۰/۵۷	۰/۵۴	۰/۵۹

نتایج حاصل از ارزیابی مدل برگزیده ICGP در دو بازه زمانی ۱ ساعته و ۴ ساعته در شکل ۱ و ۲ آمده است.


شکل ۱: نتایج پیش بینی مدل ICGP (بخش اول)




شکل ۲: نتایج پیش بینی مدل ICGP (بخش دوم)




NZDUSD-H4




NZDUSD-H1




USDCHF-H4




USDCHF-H1




USDCNH-H4




USDCNH-H1




USDSEK-H4



USDSEK-H1



USDSGD-H4



USDSGD-H1

۷ نتیجه گیری

در این پژوهش، یک چارچوب نوین و یکپارچه برای پیش‌بینی روند در بازار فارکس ارائه شد که با ادغام ویژگی‌های مبتنی بر استراتژی ایچیموکو، معماری‌های ترکیبی یادگیری عمیق شامل CNN، CNN-LSTM و CNN-GRU و الگوریتم بهینه‌سازی ازدحام ذرات (PSO)، به‌طور معناداری دقت و پایداری پیش‌بینی را بهبود می‌بخشد. ویژگی‌های استخراج‌شده از مؤلفه‌های ایچیموکو، با تقویت کیفیت نمایش داده‌های ورودی، مدل‌ها را قادر ساختند تا الگوهای غیرخطی و وابستگی‌های زمانی پنهان در سری‌های زمانی چندمتغیره را با کارایی بالاتری شناسایی کنند. علاوه بر این، طراحی یک مؤلفه تصمیم‌گیری چندبازه‌ای، امکان تلفیق پیش‌بینی‌های بازه‌های زمانی H1 و H4 را فراهم کرد و در نتیجه، صدور سیگنال روند نهایی برای بازه‌ی چهار ساعته آتی با سطح اطمینان بالاتری انجام شد.

ارزیابی جامع چارچوب پیشنهادی با استفاده از معیارهای رگرسیونی (MAE، MSE، MAPE) و معیارهای طبقه‌بندی (Accuracy، F1-Score) بر روی هشت جفت‌ارز منتخب همبسته با EUR/USD نشان داد که بهینه‌سازی هایپرپارامترها از طریق الگوریتم PSO نقش مؤثری در کاهش خطای پیش‌بینی و افزایش پایداری مدل‌ها ایفا می‌کند. در میان تمامی پیکربندی‌های بررسی‌شده، مدل Ichimoku-CNN-GRU-PSO (ICGP) به‌صورت پایدار کمترین مقادیر خطا و بالاترین مقادیر Accuracy (تا ۸۰٫۲۳٪) و F1-Score (تا ۰٫۶۷) را در اغلب جفت‌ارزها و هر دو بازه‌ی زمانی به دست آورد و به‌عنوان مدل برتر این مطالعه شناخته شد. همچنین، مدل Ichimoku-CNN-PSO (ICP) با عملکردی نزدیک به مدل برتر، به‌عنوان گزینه‌ای کارآمد و کم‌هزینه‌تر برای پیاده‌سازی‌های عملی قابل توجه است.

به‌طور کلی، نتایج این پژوهش تأیید می‌کنند که ادغام تحلیل تکنیکال مبتنی بر ایچیموکو با معماری‌های ترکیبی یادگیری عمیق و بهینه‌سازی فراابتکاری می‌تواند راهکاری مؤثر و قابل اعتماد برای غلبه بر چالش‌های پیش‌بینی روند در بازارهای پرنوسان فارکس فراهم آورد. چارچوب پیشنهادی نه‌تنها موجب افزایش دقت پیش‌بینی می‌شود، بلکه با تولید سیگنال‌های معاملاتی پایدار و قابل اعتماد، قابلیت کاربرد عملی در سیستم‌های معاملاتی خودکار و معاملات الگوریتمی را نیز داراست. در مطالعات آینده، می‌توان این چارچوب را به سایر بازارهای مالی، بازه‌های زمانی متفاوت، یا ترکیب با اندیکاتورهای تکنیکال و داده‌های بنیادی مکمل گسترش داد.

مراجع

- [1] Elliott N. Ichimoku charts: An introduction to Ichimoku kinko clouds. Harriman House Limited; 2007.
- [2] Livieris IE. A novel forecasting strategy for improving the performance of deep learning models. Expert Systems with Applications. 2023 Nov 15;230:120632.
- [3] Peng P, Chen Y, Lin W, Wang JZ. Attention-based CNN-LSTM for high-frequency multiple cryptocurrency trend prediction. Expert systems with applications. 2024 Mar 1;237:121520.
- [4] Gülmez B. Stock price prediction with optimized deep LSTM network with artificial rabbits optimization algorithm. Expert Systems with Applications. 2023 Oct 1;227:120346.
- [5] Sevastjanov P, Kaczmarek K, Rutkowski L. A multi-model approach to the development of algorithmic trading systems for the Forex market. Expert Systems with Applications. 2024 Feb 1;236:121310.
- [6] Ayala, J., García-Torres, M., Noguera, J. L. V., Gómez-Vela, F., Divina, F. (2021). Technical analysis strategy optimization using a machine learning approach in stock market indices. Knowledge-Based Systems, 225, 107119.
- [7] Dash, R., Dash, P. K. (2016). A hybrid stock trading framework integrating technical analysis with machine learning techniques. The Journal of Finance and Data Science, 2(1), 42-57.

- [8] Kennedy, J., Eberhart, R. (1995, November). Particle swarm optimization. In Proceedings of ICNN'95-international conference on neural networks (Vol. 4, pp. 1942-1948). iee.
- [9] LeCun Y, Bottou L, Bengio Y, Haffner P. Gradient-based learning applied to document recognition. Proceedings of the IEEE. 2002 Aug 6;86(11):2278-324.
- [10] Hoffmann J, Navarro O, Kastner F, Janßen B, Hubner M. A survey on CNN and RNN implementations. In PESARO 2017: The Seventh International Conference on Performance, Safety and Robustness in Complex Systems and Applications 2017 (Vol. 3).
- [11] Li Z, Liu F, Yang W, Peng S, Zhou J. A survey of convolutional neural networks: analysis, applications, and prospects. IEEE transactions on neural networks and learning systems. 2021 Jun 10;33(12):6999-7019.
- [12] Lawal A, Rehman S, Alhems LM, Alam MM. Wind speed prediction using hybrid 1D CNN and BLSTM network. IEEE Access. 2021 Nov 22;9:156672-9.
- [13] Kim J, Oh S, Kim H, Choi W. Tutorial on time series prediction using 1D-CNN and BiLSTM: A case example of peak electricity demand and system marginal price prediction. Engineering Applications of Artificial Intelligence. 2023 Nov 1;126:106817.
- [14] "Myfxbook," [Online]. Available: <https://www.myfxbook.com/>. [Accessed 08 02 2025].