



Semnan University

Journal of Econometric Modelling

Journal homepage: <https://jem.semnan.ac.ir/?lang=en>



Research Article

Quantum Artificial Intelligence and Oil Price Prediction: Evidence from the WTI Market

Younes Nademi (Corresponding Author)

Associate Professor of Economics, Department of Economics, Faculty of Humanities, Ayatollah Boroujerdi University

Younesnademi@abru.ac.ir

Reza Maaboudi

Associate Professor of Economics, Department of Economics, Faculty of Humanities, Ayatollah Boroujerdi University

maaboudi@abru.ac.ir

Arezoo Farahani

M.Sc. Student in Economics, Faculty of Humanities, Ayatollah Boroujerdi University

stuaarezoofarahani@abru.ac.ir

PAPER INFO

Paper history:

Received: 30. 09. 2025

Revised: 27. 03. 2026

Accepted: 16. 05. 2026

JEL Classification:

C46, C55, D31, D63.

Keywords:

Forecasting,

Crude oil futures price, West Texas Intermediate (WTI),

Quantum deep learning method.

ABSTRACT

This study, within the framework of the Quantum Deep Learning (QDL) approach and utilizing the Quantum Long Short Term Memory (QLSTM) model, forecasts the future price of West Texas Intermediate (WTI) crude oil. Given the strategic role of oil in the global economy and the impact of its fluctuations on macroeconomic indicators, developing accurate forecasting models is of great importance for policymakers, investors, and market participants. Daily WTI crude oil futures price data from January 2003 to June 2025 are used. The QLSTM model, which combines deep learning capabilities with quantum computing, is compared with six alternative models: classical time series models (AR, MA), machine learning algorithms (SVR), and traditional deep learning models (LSTM, GRU, MLP). Results show that QLSTM achieves the lowest forecast errors (MSE, RMSE, and Theil's U) compared to the other models, and the Diebold Mariano test statistically confirms its superiority. The findings indicate that QLSTM, by exploiting unique features of quantum computing such as superposition and entanglement, has a high ability to identify complex patterns and extreme volatility in the oil market. These results have important implications for Iranian policymakers in risk management, budgeting, and energy policy design, and also open new avenues for future research.

© 2026 Published by Semnan University Press.

How to Cite: Nademi, Y. , Maaboudi, R. and Farahani, A. (2026). Quantum Artificial Intelligence and Oil Price Forecasting: Evidence from the WTI Market. *Journal of Econometric Modelling*, 11(1), 171-215.

1. Introduction

Crude oil remains one of the most strategic commodities in the global economy. Its price fluctuations affect inflation, production costs, household expenditure, corporate profitability, government revenues, exchange-rate dynamics, and the broader stability of energy-importing and energy-exporting economies. Among the main international oil benchmarks, West Texas Intermediate (WTI) has a central role because it is widely traded through futures and options contracts and is closely linked to expectations in global energy markets. The WTI futures market is therefore not only a commodity market but also a forward-looking financial market in which information about demand, supply, geopolitical tensions, macroeconomic conditions, inventory constraints, and speculative behavior is rapidly incorporated into prices. The complex, nonlinear, and volatile nature of this market makes accurate forecasting a persistent challenge for economists, policymakers, investors, and risk managers. The objective of this study is to evaluate whether a Quantum Deep Learning (QDL) framework, implemented through a Quantum Long Short-Term Memory (QLSTM) architecture, can improve the forecasting accuracy of WTI crude oil futures prices relative to classical time-series models, machine-learning methods, and conventional deep-learning models.

The literature on crude oil price forecasting has evolved from traditional econometric and statistical models toward increasingly flexible artificial-intelligence methods. Earlier studies relied heavily on ARIMA, ARMA, GARCH-type specifications, fuzzy models, stochastic differential models, and hybrid time-series approaches. These models offer interpretability and are useful for capturing linear dependence, persistence, and volatility clustering, yet they are less effective when the price series contains strong nonlinearities, structural breaks, extreme movements, and complex temporal dependence. More recent studies have used machine-learning and deep-learning techniques such as support vector regression, multilayer perceptrons, recurrent neural networks, LSTM, GRU, CNN-LSTM, temporal convolutional networks, and ensemble or decomposition-based frameworks. These methods generally improve predictive performance because they can learn nonlinear patterns and long-memory structures from data. Nevertheless, parameter optimization, noise sensitivity, and the search for globally efficient representations remain important challenges. Quantum machine learning and quantum deep learning offer a new direction by combining neural-network architectures with quantum computational principles such as superposition, entanglement, and variational quantum circuits. The main contribution of the present study is the application of QLSTM to the WTI crude oil futures market and its systematic comparison with six competing models: AR, MA, SVR, LSTM, GRU, and MLP. This provides evidence on whether quantum-enhanced learning can add forecasting value in an important energy-finance application.

2. Methodology

The empirical analysis uses daily closing prices of WTI crude oil futures obtained through the `yfinance` library. The sample covers January 2003 to June 2025. To avoid information leakage, the data are divided chronologically before preprocessing: observations from 2003 to the end of 2022 are used for training, while observations from January 2023 to June 2025 are used for out-of-sample testing. The full sample contains 5,652 observations, including 5,027 observations in the training period and 625 observations in the testing period. Prices are normalized using the `MinMaxScaler`, which is fitted only on the training set and then applied to both the training and testing sets. The time series is converted into a supervised-learning problem through a rolling-window procedure with a 20-day window. Thus, the model predicts the price at day t using the previous 20 daily observations as inputs. The benchmark models include AR(1), MA(1), SVR with the RBF kernel, MLP, LSTM, and GRU. The deep-learning models are trained with the MSE loss function and the Adam optimizer. The batch size is 32 and the learning rate is 0.005. The MLP includes a 20-neuron input layer, a 32-neuron hidden layer with ReLU activation, and a single output neuron. LSTM and GRU each contain one recurrent layer with eight hidden units followed by a linear output layer. The QLSTM model combines a classical LSTM layer with a parameterized quantum circuit implemented using PennyLane and PyTorch. Because real quantum hardware is not used, the quantum component is simulated by the `default.qubit` state-vector simulator. The quantum circuit contains six qubits and two quantum layers. The output vector from the LSTM component is normalized, clipped, scaled by π , and encoded through angle embedding. Each quantum layer contains parameterized single-qubit rotation gates followed by CNOT gates to generate entanglement. The expectation value of the Pauli-Z operator is measured for each qubit, producing a six-dimensional quantum output vector, which is then passed through a final fully connected layer to generate the normalized price forecast. Model performance is evaluated using MSE, RMSE, and Theil's U. The Diebold-Mariano test is used to assess whether the forecast-error differences between QDL and the competing models are statistically significant.

3. Results and Discussion

The empirical results show that QLSTM provides the most accurate forecasts among all models considered. In the out-of-sample testing period, QLSTM records an RMSE of 2.2086, an MSE of 4.8778, and a Theil's U of 0.0155. These values are lower than those obtained from AR(1), MA(1), LSTM, GRU, MLP, and SVR. Among the competing models, SVR is the closest alternative, with an RMSE of 4.4872 and an MSE of 20.1351, while LSTM records an RMSE of 5.4571 and an MSE of 29.7797. The classical time-series models perform less accurately than the best machine-learning and deep-learning models, and GRU performs relatively

poorly in this application with an RMSE of 14.2130 and an MSE of 202.0088. The comparison indicates that the QLSTM model reduces forecast error substantially relative to the conventional LSTM model. In economic terms, the RMSE reduction from 5.4571 dollars in LSTM to 2.2086 dollars in QLSTM corresponds to an improvement of about 59.5 percent. For a standard WTI futures contract of 1,000 barrels, this reduction in prediction error implies a more accurate forecast equivalent to approximately 3,250 dollars per contract relative to LSTM. The Diebold-Mariano test reinforces these findings. The null hypothesis of equal predictive accuracy between QDL and each competing model is rejected at the 1 percent significance level, with reported p-values equal to 0.00 for all pairwise comparisons. Therefore, the forecasting advantage of QLSTM is not merely numerical; it is statistically significant.

The findings are consistent with the recent view that combining quantum computational structures with deep-learning architectures can enhance forecasting in complex financial and energy markets. The superior performance of QLSTM can be interpreted through its hybrid structure. The LSTM component captures temporal dependence and sequential information in WTI futures prices, while the quantum circuit adds a nonlinear representation layer based on quantum rotations and entanglement. This hybrid representation appears to improve the model's ability to identify patterns that are difficult for classical recurrent networks and traditional econometric models to capture. The results also show that stronger forecasting performance is not guaranteed simply by using a deep-learning model; model architecture and representation matter. In this study, conventional LSTM and GRU models do not match the predictive accuracy of the quantum-enhanced architecture, while SVR performs better than some deep-learning alternatives but still remains behind QLSTM. This suggests that QDL may be particularly valuable in markets characterized by abrupt shocks, nonlinear dynamics, and high uncertainty, such as crude oil futures. The robustness analysis, in which the training period is shortened to 2013-2022 while the testing period remains 2023-2025, confirms the main conclusion: QLSTM continues to outperform the competing models. This strengthens confidence in the stability of the findings.

4. Conclusion and Policy Implications

This study demonstrates that a Quantum Long Short-Term Memory model can provide highly accurate forecasts of WTI crude oil futures prices. Compared with classical time-series models, SVR, and conventional deep-learning models, QLSTM achieves the lowest MSE, RMSE, and Theil's U, and its superiority is statistically confirmed by the Diebold-Mariano test. The results have important policy and practical implications. For oil-dependent economies, including Iran, more accurate forecasts of oil futures prices can reduce uncertainty in macroeconomic planning, annual budgeting, exchange-rate management, and foreign-reserve decisions. Improved price forecasts can also support hedging strategies, risk-management

systems, and better timing of energy-sector decisions. For investors and market participants, QLSTM-based forecasts can improve the evaluation of price risk in futures markets. From a research perspective, this study opens several paths for future work. First, QDL can be combined with time-series decomposition methods such as wavelet transforms to reduce noise and extract more informative features. Second, future models can incorporate multivariate inputs, including exchange rates, global macroeconomic indicators, inventories, transportation data, geopolitical-risk measures, and financial-market uncertainty indices. Third, the approach can be extended to other energy commodities such as Brent crude oil, natural gas, and refined petroleum products. Finally, future research can compare simulated quantum models with implementations on real quantum hardware as such technology becomes more accessible.

هوش مصنوعی کوانتومی و پیش‌بینی قیمت نفت: شواهدی از بازار WTI

یونس نادمی (نویسنده مسئول)

دانشیار اقتصاد، گروه اقتصاد، دانشکده علوم انسانی، دانشگاه آیت‌الله بروجردی (ره)

Younesnademi@abru.ac.ir

رضا معبودی

دانشیار اقتصاد، گروه اقتصاد، دانشکده علوم انسانی، دانشگاه آیت‌الله بروجردی (ره)

maaboudi@abru.ac.ir

آرزو فراهانی

دانشجوی کارشناسی ارشد اقتصاد، دانشکده علوم انسانی، دانشگاه آیت‌الله بروجردی (ره)

stuarzoofarahani@abru.ac.ir

نوع مقاله: علمی - پژوهشی تاریخ دریافت: ۱۴۰۴/۰۷/۰۸ تاریخ پذیرش: ۱۴۰۵/۰۲/۲۶

چکیده:

این پژوهش در چارچوب رویکرد یادگیری عمیق کوانتومی (QDL) و با بهره‌گیری از مدل حافظه بلندمدت-کوتاه‌مدت کوانتومی (QLSTM) به پیش‌بینی قیمت آتی نفت خام وست تگزاس اینترمدیت (WTI) می‌پردازد. با توجه به جایگاه راهبردی نفت در اقتصاد جهانی و تأثیر نوسانات آن بر شاخص‌های کلان اقتصادی، دستیابی به مدل‌های دقیق پیش‌بینی اهمیت فراوانی برای سیاست‌گذاران، سرمایه‌گذاران و فعالان بازار دارد. در این مطالعه، داده‌های روزانه قیمت آتی نفت خام WTI در بازه ژانویه ۲۰۰۳ تا ژوئن ۲۰۲۵ مورد استفاده قرار گرفت. مدل QLSTM که ترکیبی از قابلیت‌های یادگیری عمیق و محاسبات کوانتومی است، با شش مدل جایگزین شامل مدل‌های کلاسیک سری زمانی AR، MA، الگوریتم‌های یادگیری ماشین (SVR) و مدل‌های یادگیری عمیق سنتی LSTM، GRU و MLP مقایسه شد. نتایج نشان داد QLSTM کمترین خطای پیش‌بینی MSE، RMSE و شاخص تایل را در مقایسه با سایر مدل‌ها دارد و آزمون دایبولد-ماریانو نیز این برتری را از نظر آماری تأیید کرد. یافته‌ها نشان می‌دهد QLSTM با بهره‌گیری از ویژگی‌های منحصر به فرد محاسبات کوانتومی مانند برهم‌نهی و درهم‌تنیدگی، توانایی بالایی در شناسایی الگوهای پیچیده و نوسانات شدید بازار نفت دارد. این نتایج پیامدهای مهمی برای سیاست‌گذاران ایران در مدیریت ریسک، بودجه‌ریزی و طراحی سیاست‌های انرژی دارد و همچنین مسیرهای تازه‌ای را برای پژوهش‌های آتی فراهم می‌آورد.

طبقه‌بندی JEL: C45، C53، G17، Q31، Q47

کلید واژه‌ها: پیش‌بینی، قیمت آتی نفت خام، وست تگزاس اینترمدیت، روش یادگیری عمیق کوانتومی

۱. مقدمه

از زمان انقلاب صنعتی تاکنون، انرژی‌های فسیلی نظیر نفت خام، گاز طبیعی و زغال‌سنگ به‌عنوان پایه‌های اصلی نظام اقتصادی جهانی شناخته شده‌اند. این منابع نه‌تنها بخش عمده‌ای از انرژی مصرفی جهان را تأمین می‌کنند، بلکه تأثیر قابل‌توجهی بر شاخص‌های کلان اقتصادی و رشد کشورها دارند؛ بنابراین، پایداری و توسعه اقتصادی بسیاری از کشورها به توسعه هم‌زمان بازار انرژی و بخش‌های تولیدی وابسته است. عملکرد هماهنگ و مؤثر اجزای مختلف بازار انرژی برای جلوگیری از شکست بازار و حفظ ثبات اقتصادی امری حیاتی است، زیرا هرگونه اختلال در این بازار، از جمله نوسانات شدید قیمت یا افزایش عدم اطمینان، پیامدهای منفی گسترده‌ای بر ساختار اقتصادی جهانی خواهد داشت (راو و همکاران^۱، ۲۰۲۵).

در میان انرژی‌های فسیلی، نفت خام به‌عنوان یکی از منابع پایه انرژی و ماده اولیه صنایع شیمیایی، جایگاهی ویژه در نظام انرژی جهانی دارد و به‌عنوان پرمعامله‌ترین و استراتژیک‌ترین منبع انرژی، نقش مهمی در توسعه اقتصادی و اجتماعی ایفا می‌کند (ژانگ و همکاران^۲، ۲۰۱۵). این منبع حیاتی سهم قابل‌توجهی در تأمین سوخت جهانی دارد و به‌طور تاریخی بیش از یک‌سوم از کل مصرف انرژی را تشکیل می‌دهد (جه‌آ و همکاران^۳، ۲۰۲۴؛ لی و همکاران^۴، ۲۰۲۴). علاوه بر این، نفت خام به‌عنوان دارایی راهبردی شناخته شده و قیمت آن معمولاً به‌عنوان شاخص کلیدی برای ارزیابی روند قیمت سایر کالاها به کار می‌رود که اهمیت آن را فراتر از حوزه انرژی گسترش داده و به معیاری اصلی در تحلیل‌های اقتصادی و بازارهای جهانی تبدیل کرده است (خو و همکاران^۵، ۲۰۲۵).

در حال حاضر، قیمت جهانی نفت خام عمدتاً بر اساس شاخص‌های سه بازار اصلی تعیین می‌شود: قیمت نفت برنت (Brent) در بورس لندن، قیمت نفت دبی (تولید منطقه خاورمیانه) در بورس کالای توکیو، و قیمت نفت وست تگزاس اینترمدیت (WTI)^۶ که در ایالات متحده تولید و در

1. Rao

2. Zhang

3. Jha

4. Li

5. Xu

6. West Texas Intermediate.

بورس نیویورک معامله می‌شود. در میان این شاخص‌ها، نفت خام WTI بیشترین تأثیر را داشته، پس از آن نفت برنت و در نهایت نفت دبی قرار دارند (یانگ^۱ و همکاران، ۲۰۲۲). طبق گزارش گروه بورس کالا و بورس معاملات آتی شیکاگو (CME Group)^۲، نفت خام وست تگزاس اینترمدیت (WTI) نوعی نفت سبک و شیرین تولیدشده در آمریکا است که از طریق قراردادهای آتی و اختیار معامله در بازارهای مالی معامله می‌شود و قیمت آن ارتباط نزدیکی با قیمت نفت خام برنت دارد. WTI یکی از بزرگ‌ترین کالاهای معامله‌شده در جهان است که این موضوع نشان‌دهنده جایگاه شاخص و کلان اقتصادی کالای WTI در بازارهای جهانی می‌باشد. همچنین نفت WTI تأثیر قابل توجه و مثبتی بر روند قیمت جهانی نفت خام از جمله نفت‌های برنت و دبی/ عمان دارد؛ بنابراین قیمت WTI می‌تواند به عنوان نماینده قیمت نفت خام در سطح جهانی مطرح باشد. تغییرات قیمت این شاخص می‌تواند تجارت بین‌المللی و اقتصاد داخلی کشورها را تحت تأثیر قرار دهد (آسیانتو^۳، ۲۰۱۹؛ ژو^۴ و همکاران، ۲۰۲۵).

در سال‌های اخیر، بازار جهانی نفت خام با نوسانات شدید قیمتی مواجه بوده است (هه^۵ و همکاران، ۲۰۲۴). این نوسانات که گاه به صورت جهش‌های ناگهانی صعودی یا نزولی بروز می‌کنند، تأثیرات قابل توجهی بر متغیرهایی چون تورم، تولید صنعتی، بودجه خانوار، سودآوری بنگاه‌ها و توازن اقتصادی کشورها داشته‌اند. ناپایداری قیمت نفت، علاوه بر پیامدهای اقتصادی، چالش‌هایی را نیز در برنامه‌ریزی‌های سیاستی و تجاری ایجاد کرده است (جه‌آ و همکاران، ۲۰۲۴). همچنین، نوسانات قیمت نفت تأثیرات عمیقی بر امنیت ملی، اقتصاد جهانی، سیاست‌های صرفه‌جویی انرژی، روابط بین‌الملل و حتی رویدادهای تاریخی برجای گذاشته است (ژانگ^۶ و همکاران، ۲۰۲۵؛ یو^۷ و همکاران ۲۰۲۵؛ لیانگ^۸ و همکاران، ۲۰۲۵).

1. Yang

2. Chicago Mercantile Exchange Group

3. Asianto.

4. Zhu

5. He

6. Zhang

7. Yu

8. Liang

گرچه تعادل میان عرضه و تقاضا عامل اصلی در تعیین قیمت نفت محسوب می‌شود، اما عوامل متعددی همچون تغییرات اقلیمی، جریان سرمایه‌گذاری، داده‌های اقتصادی با فرکانس بالا، رشد اقتصادی جهانی و رخدادهای سیاسی نیز می‌توانند بر قیمت آن اثرگذار باشند. این ترکیب از عوامل موجب شده است که بازار نفت ماهیتی بسیار پیچیده، پرنوسان و غیرخطی پیدا کند؛ به‌گونه‌ای که تحلیل و پیش‌بینی دقیق آن همواره با دشواری‌های جدی مواجه است (جه‌آ و همکاران، ۲۰۲۴).

با وجود این پیچیدگی‌ها، پیش‌بینی دقیق قیمت نفت از اهمیت راهبردی برخوردار است؛ چراکه می‌تواند سیاست‌گذاران را در تدوین برنامه‌های اقتصادی و انرژی در سطوح ملی و بین‌المللی یاری دهد (ژنگ^۱ و همکاران، ۲۰۲۴؛ لیو و همکاران^۲، ۲۰۲۴).

در این راستا، پیش‌بینی‌های دقیق قیمت نفت خام نه تنها برای بهبود عملکرد بازارهای جهانی ضروری‌اند، بلکه نقشی اساسی در طراحی سیاست‌های مؤثر انرژی ایفا می‌کنند؛ به‌ویژه آنکه تصمیم‌گیری‌های استراتژیک در زمینه تولید و مصرف انرژی و نیز ملاحظات زیست‌محیطی به شدت متأثر از نوسانات قیمتی نفت هستند. با این حال، این پیش‌بینی‌ها با چالش‌های جدی مواجه‌اند، چراکه بازار نفت تحت تأثیر شبکه‌ای از متغیرهای پیچیده شامل نوسانات عرضه و تقاضا، تغییرات نرخ ارز (به‌ویژه دلار آمریکا)، رویدادهای ژئوپولیتیکی، بلایای طبیعی، تحولات اقتصادی و رفتارهای سفته‌بازانه قرار دارد (چن و تیان^۳، ۲۰۲۵)؛ از این رو، تحقیقات فراوانی در زمینه روش‌های پیش‌بینی قیمت نفت انجام شده است. این روش‌ها از رویکردهای سنتی آماری و سری‌های زمانی تا تکنیک‌های مدرن یادگیری ماشین، از جمله روش‌های یادگیری عمیق، متنوع هستند (لی و شیا^۴، ۲۰۲۴).

بازار آتی نفت خام به‌عنوان یکی از بزرگ‌ترین بازارهای کالایی، به‌شدت متأثر از انتظارات قیمتی است و از آنجا که نوسانات آن تحت عوامل داخلی و خارجی متعددی شکل می‌گیرد، پژوهشگران برای پیش‌بینی تحولات آن از مدل‌های گوناگون سری‌زمانی استفاده کرده‌اند (جه‌آ و همکاران،

¹Zheng et al.

²Liu et al.

³Chen and Tian.

⁴Lee and Xia.

۲۰۲۴). این مدل‌ها شامل روش‌های سنتی، یادگیری ماشین (ML)^۱ و یادگیری عمیق (DL)^۲ هستند. با این حال، بهینه‌سازی پارامترها در این مدل‌ها هنوز چالش‌برانگیز است و مانع افزایش دقت پیش‌بینی می‌شود. محاسبات کوانتومی با استفاده از اصول مکانیک کوانتومی توانایی حل مسائلی را دارد که برای رایانه‌های سنتی دشوار است. ترکیب شبکه‌های عصبی کوانتومی با مدل‌های یادگیری عمیق سنتی، در قالب هوش مصنوعی کوانتومی، یکی از روش‌های نوین پژوهشی است که به بهبود دقت و کارایی پیش‌بینی‌ها کمک می‌کند (ژای و همکاران^۳، ۲۰۲۵). ویژگی‌های اصلی محاسبات کوانتومی، مانند برهم‌نهی^۴ و درهم‌تنیدگی^۵، امکان پردازش داده‌های پیچیده و نامنظم را بهبود می‌بخشند و پشتیبانی مؤثرتری از مدل‌های یادگیری عمیق فراهم می‌کنند. الگوریتم‌های شبکه عصبی کوانتومی (QNN)^۶ می‌توانند فضای پارامترهای مدل‌های یادگیری عمیق را به شکل بهینه جستجو کرده و ترکیب‌های مناسبی پیدا کنند که دقت و توانایی تعمیم مدل را افزایش دهند. قابلیت بررسی همزمان چند فضای پارامتری، شانس یافتن بهترین راه‌حل جهانی را بالا می‌برد و عملکرد و پایداری مدل را بهبود می‌بخشد. علاوه بر این، شبکه عصبی کوانتومی ساختارها و روش‌های محاسباتی جدیدی ارائه می‌کند که امکان طراحی معماری‌های پیچیده‌تر و انعطاف‌پذیرتر برای یادگیری عمیق را فراهم می‌کند و دامنه کاربردهای آن را گسترش می‌دهد (گولک^۷ و همکاران، ۲۰۲۴).

بنابراین، ترکیب مؤثر محاسبات کوانتومی و هوش مصنوعی به گونه‌ای که مزایای هر دو حوزه به کار گرفته شود و مدل‌های یادگیری عمیق سنتی بهبود یابند، یکی از مهم‌ترین محورهای پژوهشی برای افزایش دقت پیش‌بینی قیمت نفت خام محسوب می‌شود.

1. Machine Learning

2. Deep Learning

3. Zhai

^۴ Quantum Superpositio: حالتی است که در آن یک ذره کوانتومی می‌تواند به‌طور هم‌زمان در چندین وضعیت مختلف وجود داشته باشد تا زمانی که اندازه‌گیری انجام شود و یکی از آن وضعیت‌ها انتخاب شود.

^۵ Quantum Entanglement: پدیده‌ای است که در آن وضعیت‌های دو یا چند ذره به گونه‌ای به هم وابسته می‌شوند که تغییر در وضعیت یکی، بلافاصله وضعیت ذره(های) دیگر را نیز تحت تأثیر قرار می‌دهد، حتی اگر فاصله زیادی از هم داشته باشند.

6. Quantum Neural Networks

7. Golec

نوآوری اصلی این پژوهش در به‌کارگیری مدل حافظه بلندمدت-کوتاهمدت کوانتومی (QLSTM) برای پیش‌بینی قیمت آتی نفت خام وست تگزاس اینترمدیت (WTI) می‌باشد. اگرچه ادغام شبکه‌های کوانتومی با مدل‌های یادگیری عمیق سری‌های زمانی پیش‌تر مطرح شده است، اما تاکنون استفاده از این رویکرد برای پیش‌بینی قیمت آتی نفت WTI انجام نشده بود. به علاوه، این مطالعه با ارائه مقایسه‌های سیستماتیک، عملکرد مدل یادگیری عمیق کوانتومی را در مقابل مدل‌های سنتی یادگیری عمیق (LSTM¹، GRU² و MLP³)، مدل‌های کلاسیک سری‌های زمانی (AR⁴ و MA⁵) و الگوریتم‌های یادگیری ماشین (SVR⁶) ارزیابی می‌کند. این ارزیابی‌ها و کاربرد روش QDL در بازار نفت WTI، به‌عنوان نوآوری پژوهش، دقت پیش‌بینی قیمت را به‌طور قابل توجهی ارتقا می‌دهد و توسعه کاربرد هوش مصنوعی کوانتومی در حوزه پیش‌بینی مالی و انرژی را تقویت می‌کند.

ساختار باقی‌مانده این پژوهش به این شرح می‌باشد؛ بخش دوم به مرور مطالعات انجام شده در حوزه پیش‌بینی قیمت نفت خام و به خصوص روش یادگیری عمیق کوانتومی می‌انجامد. بخش سوم شامل توضیحات تکمیلی در زمینه مدل یادگیری عمیق کوانتومی و مدل‌های استفاده شده در مقایسه می‌باشد. در بخش چهارم نتایج مدل‌ها بررسی می‌شوند و مدل‌های رقیب با یکدیگر مورد مقایسه قرار می‌گیرند. در نهایت بخش پنجم به نتیجه‌گیری کلی و ارائه پیشنهادات اختصاص می‌یابد.

۲. پیشینه پژوهش

با توجه به جایگاه راهبردی نفت خام در اقتصاد جهانی و اثرگذاری نوسانات مکرر قیمت آن بر متغیرهای کلان اقتصادی، پیش‌بینی دقیق قیمت نفت همواره یکی از مسائل اساسی در حوزه اقتصاد انرژی، مدیریت ریسک و تصمیم‌گیری‌های سرمایه‌گذاری بوده است. در دهه‌های اخیر،

1. Long Short-Term Memory

2. Gated Recurrent Unit

3. Multi-Layer Perceptron

4. Auto Regressive

5. Moving Average

6. Support Vector Regression

پژوهشگران از رویکردهای متنوع سنتی و نوین برای پیش‌بینی قیمت نفت بهره‌گرفته‌اند. پیشینه مطالعات در این حوزه را می‌توان در چند محور اصلی دسته‌بندی کرد که در ادامه به تفکیک بررسی می‌شود.

۲-۱. مطالعات خارجی

۲-۱-۱. مطالعات مبتنی بر روش‌های سنتی اقتصادسنجی

الرویلی و فوزی^۱ (۲۰۲۲) با استفاده از مدل ترکیبی ARIMA-ANN و داده‌های ماهانه قیمت نفت خام (به ریال سعودی به ازای هر بشکه) در بازه زمانی جولای ۲۰۰۱ تا مه ۲۰۲۱، به پیش‌بینی سری‌های زمانی قیمت نفت پرداختند. در این پژوهش، دقت مدل ترکیبی با مدل‌های منفرد ARIMA و ANN از طریق معیارهای آماری میانگین مربع خطا (MSE)^۲، میانگین خطای مطلق (MAE)^۳ و میانگین درصد خطای مطلق (MAPE)^۴ ارزیابی شد. نتایج نشان داد که مدل ترکیبی عملکرد بهتری نسبت به مدل‌های منفرد داشته و خطاهای پیش‌بینی را به‌طور قابل توجهی کاهش داده است. یافته‌ها حاکی است استفاده از مدل‌های ترکیبی، به‌ویژه در بازارهای پیچیده و نوسانی مانند نفت، می‌تواند دقت پیش‌بینی را بهبود بخشد.

لی^۵ (۲۰۲۴) با بهره‌گیری از مدل ARIMA و مدل ترکیبی ARIMA-GARCH نوسانات ماهانه قیمت نفت خام وست تگزاس اینترمدییت (WTI) را بررسی کرد. مقایسه مدل سنتی ARIMA با مدل ترکیبی ARIMA-GARCH بیانگر آن است که مدل ترکیبی، با لحاظ کردن ناهمسانی واریانس شرطی در داده‌ها، دقت پیش‌بینی بالاتری ارائه می‌دهد و می‌تواند ابزار قابل اتکاتری برای تحلیل‌گران و سرمایه‌گذاران به شمار آید.

1. Alrweili and Fawzy

2. Mean Squared Error

3. Mean Absolute Error

4. Mean Absolute Percentage Error

5. Li.

۲-۱-۲. مطالعات مبتنی بر روش‌های یادگیری ماشین و یادگیری عمیق

الدباغ و همکاران^۱ (۲۰۲۳) با استفاده از روش یادگیری عمیق (DL)^۲، مدلی ترکیبی برای پیش‌بینی قیمت نفت ارائه کردند. در این پژوهش، از شبکه‌های عصبی کانولوشنی (CNN)^۳ و شبکه حافظه کوتاه‌مدت بلندمدت (LSTM) به صورت هم‌زمان بهره گرفته شد تا مدل شبکه عصبی کانولوشنی-حافظه بلندمدت کوتاه‌مدت (CNN-LSTM)^۴ شکل گیرد. عملکرد این مدل با شبکه‌های منفرد CNN و LSTM، مدل ماشین بردار پشتیبان (SVM)^۵ و مدل خودرگرسیون میانگین متحرک (ARIMA) مقایسه شد. داده‌ها در سه بازه زمانی کوتاه‌مدت (یک سال)، میان‌مدت (پنج سال) و بلندمدت (ده سال) مورد ارزیابی قرار گرفتند. نتایج نشان داد مدل ترکیبی CNN-LSTM در مقایسه با مدل‌های دیگر دقت بیشتری دارد و خطای کمتری تولید می‌کند. همچنین، پژوهش مذکور پیش‌بینی چندمرحله‌ای تا افق زمانی هفت روز آینده را نیز بررسی کرده است. در این مرحله، مدل CNN-LSTM با خروجی برداری^۶ با مدل رمزگذار-رمزگشا مبتنی بر شبکه LSTM^۷ مقایسه شد. هرچند دقت هر دو مدل نزدیک بود، اما مدل CNN-LSTM با خروجی برداری عملکرد بهتری از خود نشان داد. این نتایج توانمندی بالای مدل‌های ترکیبی یادگیری عمیق در پیش‌بینی دقیق قیمت نفت خام WTI را نشان می‌دهد. ژانگ و ژو^۸ (۲۰۲۴) با بهره‌گیری از مدل ترکیبی "آریم-رگرسیون بردار پشتیبان-نقاط اوج بالاتر از آستانه" (ARIMA-SVR-POT) که شامل مدل میانگین متحرک خودرگرسیون انتگرال‌شده (ARIMA)، رگرسیون بردار پشتیبان (SVR)^۹ و "روش اوج بالاتر از آستانه (POT) از نظریه مقادیر افراطی"^{۱۰} است، پیش‌بینی ارزش در معرض ریسک (VaR)^{۱۱} قراردادهای آتی نفت خام را بررسی کردند. آن‌ها عملکرد مدل خود را با سه مدل دیگر شامل-ARIMA

1. Aldabagh et al.

2. Deep Learning

3. Convolutional Neural Networks

4. Convolutional Neural Network – Long Short-Term Memory

5. Support Vector Machine

6. Vector Output

7. LSTM-based Encoder-Decoder Model

8. Zhang and Zhou.

9. Support Vector Regression

10. Peak Over Threshold (POT) method from Extreme Value Theory (EVT)

11. Value at Risk

EGARCH، ARIMA-SVR و ARIMA-EGARCH-POT مقایسه کردند و داده‌های قراردادهای آتی نفت خام وست تگزاس (WTI) در بازه زمانی ژوئن ۲۰۱۶ تا سپتامبر ۲۰۲۲ را مورد استفاده قرار دادند. نتایج نشان داد مدل ترکیبی ARIMA-SVR-POT دقت بالاتری در پیش‌بینی بازده و نوسانات قیمت ارائه می‌دهد و در شناسایی مقادیر افراطی بازده نسبت به سایر مدل‌ها عملکرد برتری دارد. همچنین، این مدل در آزمون‌های بازگشتی و به‌ویژه آزمون کوپیک^۱ در سطوح اطمینان مختلف ۹۵٪ تا ۹۹.۹٪ موفق عمل کرده است. یافته‌ها نشان می‌دهد مدل‌های سنتی اندازه‌گیری ریسک قادر به شناسایی دقیق ریسک‌های انتهایی نیستند و در برخی سطوح اطمینان از آزمون کوپیک مردود شده‌اند. در مقابل، مدل ARIMA-SVR-POT با داشتن آماره نسبت درست‌نمایی (LR) نزدیک به صفر، توانسته است احتمال وقوع زیان واقعی را به خوبی پیش‌بینی کند و برآوردهای VaR قابل اطمینانی ارائه دهد. بنابراین، می‌توان نتیجه گرفت که این مدل ترکیبی قابلیت بالایی در شناسایی ویژگی‌های توزیع انتهایی قراردادهای آتی نفت خام و تخمین دقیق ریسک بازار دارد که می‌تواند بهبود قابل توجهی در مدیریت ریسک نفت خام ایجاد کند.

سن و چودهری^۲ (2024) با هدف افزایش دقت در پیش‌بینی قیمت نفت خام، از ترکیب الگوریتم بهینه‌سازی ازدحام ذرات (PSO)^۳ با دو مدل پرکاربرد در حوزه یادگیری عمیق، یعنی شبکه حافظه بلند مدت – کوتاه مدت (LSTM) و واحد بازگشتی دروازه‌دار (GRU) استفاده کردند. نتایج تحلیل‌ها نشان داد که هر دو مدل در پیش‌بینی سری زمانی قیمت نفت خام مؤثر هستند، اما مدل GRU عملکرد دقیق‌تری از خود نشان داد. این یافته‌ها بیانگر آن است که استفاده از الگوریتم‌های بهینه‌سازی هوشمند مانند PSO در کنار مدل‌های پیشرفته یادگیری عمیق می‌تواند توان پیش‌بینی این مدل‌ها را به‌طور چشمگیری افزایش دهد. به‌طور خاص، مدل ترکیبی PSO-GRU به‌عنوان گزینه‌ای کارآمد برای پیش‌بینی قیمت نفت در بازارهای پرتلاطم و پیچیده معرفی شده است.

1. Kupiec test

2. Sen and Choudhury.

3. Particle Swarm Optimization

فروتان و لاهمیری^۱ (۲۰۲۴) در پژوهشی، توانایی مدل‌های پیشرفته یادگیری عمیق و الگوریتم‌های هوشمند در پیش‌بینی قیمت روزانه نفت خام وست تگزاس، نفت برنت، طلا و نقره را بررسی کردند. در این مطالعه، دوازده مدل یادگیری عمیق شامل انواع شبکه‌های بازگشتی (RNN)^۲، دوطرفه (Bi-directional)^۳، ترکیبی با شبکه‌های عصبی کانولوشنی (CNN) و نیز شبکه‌های کانولوشنی زمانی (TCN)^۴، به کار گرفته شدند. همچنین، عملکرد این مدل‌ها با چهار روش متداول یادگیری ماشین شامل درخت تصادفی^۵، تقویت گرادیانی سبک (LightGBM)^۶، روش بردار پشتیبان (SVR) و الگوریتم نزدیک‌ترین همسایه (KNN)^۷ مقایسه شد. نتایج نشان داد شبکه‌های کانولوشنی زمانی، بهترین عملکرد را در پیش‌بینی قیمت نفت وست تگزاس، نفت برنت و نقره داشته‌اند و کمترین خطای مطلق را ارائه کردند. در پیش‌بینی قیمت طلا نیز شبکه بازگشتی دوطرفه بر پایه واحدهای دروازه‌دار (BiGRU) با استفاده از داده‌های سی روز گذشته، دقیق‌ترین نتایج را ارائه داد. همچنین، در میان روش‌های یادگیری ماشین، الگوریتم تقویت گرادیانی سبک (LightGBM) عملکردی نزدیک به شبکه‌های کانولوشنی داشته و به‌عنوان بهترین روش غیربیولوژیکی^۸ در این حوزه معرفی شده است. یافته‌های پژوهش همچنین نشان دادند نسخه‌های دوطرفه شبکه‌های بازگشتی نسبت به نسخه‌های یک‌طرفه^۹ عملکرد بهتری دارند و مدل‌های مبتنی بر واحدهای دروازه‌دار نسبت به مدل‌های حافظه بلندمدت (LSTM) در بیشتر موارد پیش‌بینی‌های دقیق‌تری ارائه می‌کنند.

ژنگ^{۱۰} و همکاران (۲۰۲۵) مدلی ترکیبی مبتنی بر یادگیری عمیق برای پیش‌بینی قیمت نفت خام ارائه دادند. در این مدل، داده‌های خام با استفاده از تبدیل موجک تجربی (EWT)^{۱۱} به مؤلفه‌های مختلف تجزیه شدند تا پیچیدگی و رفتار غیرخطی سری زمانی کاهش یابد. سپس،

1. Foroutan and Lahmiri.

2. Recurrent Neural

3. Bi-directional Deep Learning Model

4. Temporal Convolutional Networks

5. Random Forest

6. Light Gradient Boosting

7. K-Nearest Neighbors

8. Non-Neural.

9. Unidirectional

10. Zheng

11. Empirical Wavelet Transform

پیش‌بینی‌های اولیه با سه شبکه عصبی شامل شبکه عصبی کانولوشنی زمانی (TCN)، شبکه حافظه‌دار واحد دروازه‌دار (GRU) شبکه مخزن تصادفی (ESN)^۱ تولید و در یک چارچوب یادگیری ترکیبی^۲ با عامل یادگیری تقویتی^۳ بهینه‌سازی شدند. علاوه بر این، ماژول تصحیح خطا (ECM)^۴ برای تحلیل باقی‌مانده خطاها و ارتقای عملکرد مدل افزوده شد. نتایج نشان داد مدل پیشنهادی از دقت پیش‌بینی بالاتری نسبت به شانزده روش معیار^۵ و سه مدل پیشرفته دیگر برخوردار است. در مجموع، این پژوهش نشان داد ترکیب روش‌های تجزیه سری زمانی، شبکه‌های عصبی عمیق و یادگیری تقویتی می‌تواند منجر به بهبود چشمگیر دقت پیش‌بینی در بازارهای پرنوسان همچون بازار نفت شود.

عبدالرحیم^۶ و همکاران (۲۰۲۵) روش‌های یادگیری عمیق، مدل‌های حافظه بلندمدت کوتاه‌مدت (LSTM) و پرسپترون چندلایه (MLP)^۷ را در پیش‌بینی قیمت نفت کشورهای اوپک مورد بررسی قرار دادند. آن‌ها با استفاده از شاخص‌های خطای مطلق میانگین متقارن (SMAPE)^۸، میانگین مربعات خطا (MSE) و میانگین درصد خطای مطلق (MAPE) نشان دادند که حافظه بلند مدت — کوتاه مدت (LSTM) در همه معیارها عملکرد بهتری نسبت به پرسپترون چندلایه (MLP) دارد و دقت بالاتری در پیش‌بینی قیمت نفت ارائه می‌کند. نتایج این مطالعه با پژوهش‌های قبلی همسو است که توانایی بالای LSTM را در مدل‌سازی داده‌های سری زمانی با وابستگی بلندمدت و نوسانات پیچیده تأیید می‌کنند. در مقابل، مدل پرسپترون چندلایه (MLP) به دلیل ساختار ساده‌تر، در پیش‌بینی دقیق داده‌های زمانی پیچیده ضعیف‌تر عمل می‌کند. این تحقیق نشان داد که مدل‌های LSTM برای پیش‌بینی نوسانات شدید قیمت نفت مناسب‌تر بوده و کاربرد گسترده‌تری در این زمینه دارند.

1. Echo State Network

2. Ensemble Learning

3. Reinforcement Learning Agent

4. Error Correction Module

5. Benchmark Models

6. Abdulrahim

7. Multilayer Perceptron.

8. Symmetric Mean Absolute Percentage Error

۲-۱-۳. مطالعات مبتنی بر روش‌های یادگیری کوانتومی و محاسبات کوانتومی

ژای و همکاران (۲۰۲۵) مدلی نوآورانه مبتنی بر شبکه‌های عصبی کوانتومی (QNN) در ترکیب با روش‌های یادگیری عمیق برای پیش‌بینی قیمت نفت خام ارائه کردند. در این مطالعه، شبکه عصبی کوانتومی بر پایه مفاهیم مدارها و دروازه‌های کوانتومی طراحی و در قالب مدل‌های یادگیری عمیق نظیر شبکه‌های بازگشتی (RNN)، حافظه بلندمدت کوتاه‌مدت (LSTM) و واحدهای حافظه گیت‌دار (GRU) ادغام گردید تا مدل پیش‌بینی یادگیری عمیق کوانتومی (QDL) شکل گیرد. برای ارزیابی عملکرد مدل، داده‌های قیمت آتی نفت خام بورس شانگهای به همراه عوامل مؤثر مرتبط مورد استفاده قرار گرفت. نتایج نشان داد مدل QDL نسبت به مدل‌های سنتی یادگیری عمیق دقت پیش‌بینی بالاتری دارد، به‌خصوص مدل‌های حافظه بلندمدت-کوتاه‌مدت کوانتومی (QLSTM) و واحد بازگشتی دروازه‌دار کوانتومی (QGRU) عملکرد بهتری از خود نشان دادند. این پژوهش بیانگر آن است که ادغام محاسبات کوانتومی با یادگیری عمیق می‌تواند دقت پیش‌بینی قیمت نفت و کارایی مدیریت ریسک در بازارهای مالی را به‌طور قابل توجهی افزایش دهد.

۲-۲. مطالعات داخلی

۲-۲-۱. مطالعات مبتنی بر روش‌های سنتی اقتصادسنجی

زرانژاد و همکاران (۱۳۹۱) با بهره‌گیری از داده‌های روزانه قیمت نفت اوپک، عملکرد سه مدل شامل آریمای، رگرسیون فازی و مدل ترکیبی رگرسیون خودبازگشتی میانگین متحرک انباشته فازی را در پیش‌بینی قیمت نفت خام مورد مقایسه قرار دادند. هدف اصلی این پژوهش، ارزیابی و مقایسه دقت پیش‌بینی این مدل‌ها بود که با استفاده از شاخص‌های آماری ریشه میانگین مربع خطا (RMSE)، میانگین خطای مطلق (MAE)، میانگین درصد خطای مطلق (MAPE) و ضریب نابرابری تایلر (TIC) انجام شد. یافته‌ها نشان داد مدل ترکیبی فازی نسبت به دو مدل دیگر از دقت پیش‌بینی بالاتری برخوردار است و می‌تواند به‌عنوان ابزاری مؤثر در تحلیل روند قیمت نفت به‌کار گرفته شود.

ابریشمی و همکاران (۱۳۹۲) با استفاده از رویکردی ترکیبی متشکل از تبدیل موجک^۱، مدل‌های میانگین متحرک خودرگرسیو با متغیرهای برون‌زا (ARMAX)^۲، رگرسیون هارمونیک^۳ و مدل هلت-وینترز^۴، روند پیش‌بینی قیمت نفت خام را تحلیل کردند. برای بررسی کارایی مدل پیشنهادی، نتایج آن با مدل میانگین متحرک خودرگرسیونی (ARMA) مقایسه شد. یافته‌ها نشان داد این مدل ترکیبی در مقایسه با مدل میانگین متحرک خودرگرسیونی، خطای پیش‌بینی کمتری دارد و دقت بیشتری ارائه می‌دهد.

جوانمرد و فقیدیان (۱۳۹۳) با استفاده از مدل پیش‌بینی خاکستری^۵، روند پیش‌بینی قیمت نفت خام را بررسی کردند. همچنین در این مطالعه با بهره‌گیری از معیارهای میانگین مربعات خطا (MSE) و میانگین خطای مطلق (MAE) مدل مربوطه را مورد ارزیابی قرار دادند. نتایج نشان دادند که مدل پیش‌بینی خاکستری عملکرد پیش‌بینی قیمت نفت را به طور چشمگیری بهبود می‌بخشد و دقت بالاتری نسبت به مدل‌های متداول مانند خودرگرسیون دارد.

خوچیانی و نادمی (۱۳۹۷) با بهره‌گیری از مدل‌های دیفرانسیل تصادفی^۶، و داده‌های روزانه بازه زمانی ۲۰۱۶-۱۹۸۶ دقت پیش‌بینی قیمت نفت خام وست تگزاس اینترمدیت (WTI) را مورد بررسی قرار دادند و آن را با مدل‌های خانواده آریمای (ARIMA) و گارچ (GARCH) با حافظه کوتاه‌مدت و بلندمدت مقایسه کردند. نتایج نشان دادند که مدل‌های حافظه بلندمدت آرفیما-فیگارچ^۷ و دیفرانسیل تصادفی در پیش‌بینی‌های درون‌نمونه و برون‌نمونه، به ویژه در افق‌های ۵، ۱۰ و ۲۲ روزه، دقت بیشتری نسبت به مدل‌های آریمای و گارچ حافظه کوتاه‌مدت دارند. همچنین با افزایش طول افق پیش‌بینی، عملکرد مدل‌های حافظه بلندمدت آرفیما-فیگارچ و دیفرانسیل تصادفی بهبود قابل توجهی یافت. این یافته‌ها بیانگر آن است که برای پیش‌بینی قیمت نفت خام در بازه‌های زمانی کوتاه تا میان‌مدت و بلندمدت، استفاده از این دو خانواده مدل می‌تواند نتایج دقیق‌تری ارائه دهد.

-
1. Wavelet Transform
 2. Autoregressive Moving Average with Exogenous Inputs
 3. Harmonic Regression
 4. Holt-Winters model
 5. Grey Prediction Model
 6. Stochastic Differential Models
 7. ARFIMA-FIGARCH

۲-۲-۲. مطالعات مبتنی بر روش‌های یادگیری ماشین و یادگیری عمیق

حاجی‌کرم و دارابی (۱۳۹۶) با بهره‌گیری از روش ترکیبی تحلیل مؤلفه‌های اصلی (PCA)^۱ و رگرسیون بردار پشتیبان (SVR)، و داده‌های دوره زمانی ژوئیه ۲۰۰۸ تا ژوئیه ۲۰۱۶ امکان بهبود دقت پیش‌بینی قیمت روزانه نفت خام برنت را مورد بررسی قرار دادند. در این پژوهش دقت مدل‌ها با معیارهای آماری میانگین درصد خطای مطلق (MAPE) و ریشه میانگین مربع خطا (RMSE) ارزیابی شد. نتایج حاصل از آزمون مقایسات زوجی^۲ نشان داد که "مدل ترکیبی رگرسیون بردار پشتیبان و تحلیل مؤلفه‌های اصلی" عملکرد دقیق‌تری نسبت به "مدل رگرسیون بردار پشتیبان" داشته است و پیش‌پردازش داده‌ها به کمک "تحلیل مؤلفه‌های اصلی" منجر به کاهش خطای پیش‌بینی شده است.

عبدالله‌زاده و همکاران (۲۰۲۴) با بهره‌گیری از نظریه آشوب^۳ و "روش گروهی پردازش داده‌ها همراه با الگوریتم ژنتیک (GMDH-GA)"^۴، نوسانات بلندمدت قیمت نفت خام اوپک را مورد ارزیابی قرار دادند. آن‌ها ابتدا داده‌ها را با تبدیل موجک پردازش کردند تا نویز کاهش یافته و ویژگی‌های اصلی استخراج شود. سپس با استفاده از شاخص‌هایی نظیر بُعد نهفته^۵، توان لیاپانوف^۶ و آزمون‌های مبتنی بر الگوریتم ژنتیک^۷، وجود رفتار آشوب‌گونه^۸ در داده‌های قیمتی تأیید گردید و فضای فاز برای مدلسازی دقیق‌تر بازسازی گردید. در ادامه، سه مدل شبکه عصبی شامل مدل پایه GMDH-GA^۹، نسخه ترکیب‌شده با موجک، و مدل توسعه‌یافته آن مورد استفاده قرار گرفتند. عملکرد این مدل‌ها با استفاده از شاخص‌های آماری مانند ریشه میانگین مربعات خطا (RMSE) و ضریب همبستگی مقایسه شد. نتایج نشان داد که هر سه مدل عملکرد مناسبی در پیش‌بینی دارند، اما مدل توسعه‌یافته، به دلیل ساختار پیچیده‌تر و توانایی بالاتر در تطبیق با نوسانات داده، دقت بیشتری در پیش‌بینی قیمت روزانه نفت خام اوپک از خود نشان داد. نتایج

1. Principal Component Analysis

2. Paired Comparison Test

3. Chaos Theory

4. Group Method of Data Handling - Genetic Algorithm

5. Embedding Dimension

6. Lyapunov Exponent

7. Genetic Algorithm-based Tests

8. chaotic behavior

9. Baseline GMDH-GA Model

این پژوهش تأکید می‌کند که برای درک بهتر و پیش‌بینی دقیق‌تر نوسانات بازار نفت، بهره‌گیری از ابزارهای ترکیبی و غیرخطی، به‌ویژه در محیط‌های پرتلاطم و حساس مانند بازار انرژی، ضروری است.

فتاحی و همکاران (۱۴۰۲) با استفاده از شبکه عصبی پیچشی (CNN) و رویکرد داده‌های بزرگ، به پیش‌بینی قیمت نفت خام از طریق ترکیب داده‌های متنی و رفتاری پرداختند. در این پژوهش، بیش از ۱۳,۰۰۰ عنوان خبری مرتبط با نفت خام طی سال‌های ۲۰۱۱ تا ۲۰۲۱ جمع‌آوری شد و ویژگی‌های متنی با بهره‌گیری از روش CNN استخراج گردید. همچنین داده‌های رفتاری کاربران از روندهای گوگل به مدل افزوده شد تا تأثیر متغیرهای کیفی و آماری به‌طور هم‌زمان بررسی شود. برای مقایسه عملکرد، مدل‌های مختلفی نظیر الگوریتم تقویت گرادیان^۱، ماشین بردار پشتیبان (SVM)، k نزدیک‌ترین همسایه، درخت تصمیم، جنگل تصادفی و شبکه عصبی پیچشی (CNN) مورد بررسی قرار گرفتند. نتایج حاصل از معیارهای آماری مانند میانگین مربعات خطا (MSE) و میانگین خطای مطلق (MAE) نشان دادند که مدل CNN عملکرد بهتری نسبت به سایر مدل‌ها دارد. علاوه بر این، تحلیل شاخص میانگین ارزش تأثیر (MIV) نشان داد که داده‌های متنی اخبار و روند جست‌وجوی کاربران مکمل یکدیگر هستند و ترکیب آن‌ها به‌طور قابل توجهی دقت پیش‌بینی قیمت نفت خام را افزایش می‌دهد. در مجموع، یافته‌ها تأکید کردند که اتکای صرف بر داده‌های آماری برای پیش‌بینی نوسانات بازار کافی نیست، و ادغام داده‌های متنی و رفتاری می‌تواند تصویری جامع‌تر و دقیق‌تر از تحولات قیمت نفت ارائه دهد.

۲-۳. مطالعات مبتنی بر روش‌های یادگیری کوانتومی و محاسبات کوانتومی

در بررسی مطالعات داخلی مرتبط با پیش‌بینی قیمت نفت خام، پژوهشی که به‌طور مشخص از روش‌های یادگیری کوانتومی بهره گرفته باشد، مشاهده نشد. این مسئله نشان می‌دهد که به‌کارگیری این رویکرد نوین در زمینه پیش‌بینی قیمت نفت خام، تاکنون در ادبیات داخلی مورد توجه قرار نگرفته و در نتیجه می‌تواند به‌عنوان گامی تازه در توسعه این حوزه پژوهشی تلقی شود.

^۱. Gradient Boosting Algorithm.

^۲. Mean Impact Value

مرور پیشینه نشان می‌دهد که اگرچه مدل‌های سنتی و روش‌های یادگیری ماشین در پیش‌بینی قیمت نفت عملکرد قابل توجهی داشته‌اند، اما چالش‌هایی نظیر نوسانات شدید، رفتارهای غیرخطی بازار و وجود نویز همچنان پابرجاست. در این میان، یادگیری عمیق کوانتومی به دلیل توانایی بالایی خود در پردازش داده‌های پیچیده و جست‌وجوی بهینه‌تر، به عنوان یک رویکرد نوین و آینده‌دار مطرح شده است. با این حال، استفاده از این روش در حوزه پیش‌بینی قیمت نفت WTI هنوز در مراحل ابتدایی قرار دارد و می‌تواند مسیر مناسبی برای پژوهش‌های نوآورانه فراهم سازد.

۳. روش‌شناسی پژوهش و توصیف داده

۳-۱. مدل یادگیری ماشین (ML)^۱

۳-۱-۱. مدل رگرسیون بردار پشتیبان (SVR)^۲

رگرسیون بردار پشتیبان (SVR) بر پایه اصول مشترک با ماشین بردار پشتیبان (SVM)^۳ توسعه یافته است، با این تمایز که متغیر پاسخ در این روش ماهیتی پیوسته دارد. در چارچوب SVR، به جای تعیین یک ابرصفحه، هدف اصلی شناسایی یک تابع رگرسیون خطی است که در معادله (۱) تعریف شده است. برای این منظور یک آستانه خطا (ϵ) معرفی می‌شود که در معادله (۲) کمینه‌سازی شده است و به عنوان تابع زیان مورد استفاده قرار می‌گیرد. در واقع، رویکرد SVR دنبال آن است که مقدار (ϵ) در معادله (۲) و همچنین $\|w\|^2$ در معادله (۳) به حداقل ممکن برسند.

$$f(x, w) = w^t x + b \quad (1)$$

$$|y - f(x, w)|_\epsilon = \begin{cases} 0, & \text{case } |y - f(x, w)| \leq \epsilon \\ |y - f(x, w)| - \epsilon, & \text{otherwise} \end{cases} \quad (2)$$

¹. Machine learning.

². Support vector regression.

³. Support Vector Machine.

$$R = \frac{1}{2} \|w\|^2 + c \left(\sum_{i=1}^N |y_i - f(x_i, w)|_\varepsilon \right) \quad (۳)$$

متغیر ζ_i نشان‌دهنده مقداری است که از حد ε فراتر رفته و ζ_i^* برای محدود کردن مقدار به هدف رگرسیون استفاده می‌شود. بنابراین، کمینه کردن معادله (۳) به شکل معادله (۴) انجام می‌شود، به شرط آنکه شرایط معادلات (۵) و (۶) رعایت شوند، یعنی برای هر نمونه $i = 1, 2, \dots, N$ و مقادیر ζ_i و ζ_i^* غیر منفی هستند (هنریک و همکاران^۱، ۲۰۱۸).

$$R = \frac{1}{2} \|w\|^2 + c \sum_{i=1}^N (\zeta_i + \zeta_i^*) \quad (۴)$$

$$(w^T x_i + b) - y_i \leq \varepsilon + \zeta_i \quad (۵)$$

$$y_i - (w^T x_i + b) - y_i \leq \varepsilon + \zeta_i^* \quad (۶)$$

۲-۳. مدل‌های یادگیری عمیق کلاسیک (CDL)^۲

۱-۲-۳. شبکه عصبی بازگشتی با حافظه بلندمدت (LSTM)

LSTM، که نوعی خاص از شبکه‌های عصبی بازگشتی (RNN) است، با ساختار ویژه خود قادر است مشکل وابستگی بلندمدت را به شکل موثری حل کند و در پردازش داده‌های ترتیبی عملکرد بالایی دارد. بخش مرکزی LSTM در حالت سلولی^۳ و معماری دروازه‌ای^۴ آن قرار دارد. این شبکه به طور گسترده در مسائل مرتبط با سری‌های زمانی کاربرد دارد و نتایج قابل توجهی ارائه می‌دهد. روش استخراج ویژگی‌ها در مدل LSTM در مجموع معادلات زیر نشان داده شده است.

$$I_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (۷)$$

$$F_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (۸)$$

$$O_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (۹)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (۱۰)$$

$$C_t = f_t \otimes C_{t-1} + i_t \otimes \tilde{C}_t \quad (۱۱)$$

$$h_t = o_t \otimes \tanh(C_t) \quad (۱۲)$$

^۱ Henrique

^۲ Classical Deep Learning.

^۳ Cell state.

^۴ Gate structure.

براساس معادلات (۷-۱۲)، O_t ، C_t ، \tilde{C}_t ، I_t و F_t به ترتیب دروازه خروجی، حالت سلولی، حالت سلولی پیشنهادی، دروازه ورودی و دروازه فراموشی در زمان t هستند. ماتریس‌های وزن با W_i ، W_c و W_o مشخص شده‌اند. تابع σ همان تابع سیگموئید و b_f ، b_c ، b_o و b_i نیز مقادیر بایاس را نشان می‌دهند (کریشن و میهوب^۱، ۲۰۲۵؛ آکوستا^۲ و همکاران، ۲۰۲۶).

۳-۲-۲. شبکه عصبی بازگشتی با واحد دروازه‌دار (GRU)^۳

GRU یک مدل بهبودیافته از RNN است و شامل دو دروازه اصلی، یعنی دروازه بازنشانی^۴ و دروازه به‌روزرسانی^۵ می‌باشد. فرآیند استخراج ویژگی‌ها در مجموعه معادلات زیر تشریح شده است.

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t]) \quad (۱۳)$$

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t]) \quad (۱۴)$$

$$\tilde{h}_t = \tanh(W_h \cdot [r_t * h_{t-1}, x_t]) \quad (۱۵)$$

$$h_t = (1 - z_t) * h_{t-1} + z_t * \tilde{h}_t \quad (۱۶)$$

در این مدل W_h و W_z ماتریس‌های وزن هستند و r_t ، z_t و \tilde{h}_t به ترتیب نشان‌دهنده دروازه به‌روزرسانی، دروازه بازنشانی و حالات کاندید می‌باشند (مینیه^۶ و همکاران، ۲۰۲۴).

۳-۲-۳. مدل پرسپترون چندلایه یا شبکه عصبی کاملاً متصل (MLP)^۸

شبکه‌های عصبی چندلایه‌ای (MLP) نوعی شبکه عصبی یادگیری نظارت‌شده هستند که توانایی بالایی در مدل‌سازی روابط غیرخطی و پیچیده دارند. ساختار این شبکه‌ها بر اساس اصول سیستم عصبی طبیعی طراحی شده است و برای حل مسائل پیش‌بینی غیرخطی بسیار مناسب هستند. عملکرد MLP به گونه‌ای است که ابتدا از داده‌ها برای یادگیری مراحل حل مسئله استفاده می‌کند و سپس روابط پنهان بین این مراحل را شناسایی کرده و خروجی‌های دقیق تولید می‌کند.

1. Krichen and Mihoub.

2. Akusta

3. Gated Recurrent Units.

4. Reset gate

5. Update gate

6. Candidate states

7. Mienye

8. Multi-Layer Perceptron

الگوریتم آموزش رایج در MLP، الگوریتم پسانتشار^۱ است. در این شبکه، نورون‌های هر لایه به صورت موازی عمل می‌کنند و هر لایه به طور کامل با لایه‌های قبل و بعد خود متصل است. ساختار معمول و کارآمد MLP شامل سه لایه اصلی است: یک لایه ورودی، یک یا چند لایه پنهان و یک یا چند لایه خروجی، به طوری که هر نورون با تمام نورون‌های لایه بعدی ارتباط دارد.

محاسبه متغیرهای خروجی، ورودی و بایاس به صورت زیر انجام می‌شود:

$$C_i = \sum_{i=1}^n E_{ij} IN_i + B_i \quad (17)$$

در این رابطه، E_{ij} ، IN_i و B_i به ترتیب نشان‌دهنده وزن‌ها، متغیرهای ورودی و مقدار بایاس نورون هستند.

تابع سیگموئید به عنوان یک تابع فعال‌سازی برای دو کلاس هدف، به صورت زیر محاسبه می‌شود:

$$S_i = \frac{1}{1+e^{cj}} \quad (18)$$

مقدار نهایی متغیر خروجی را می‌توان به صورت زیر محاسبه کرد: (عبدالعظیم و سلیمان^۲، ۲۰۲۳).

$$O_i = S_i(\sum_{i=1}^n E_{ij} IN_i + B_i) \quad (19)$$

۳-۳. مدل یادگیری عمیق کوانتومی (QDL)

۳-۳-۱. مبانی محاسبات کوانتومی^۳

از آنجا که محاسبات کوانتومی در برخی مفاهیم بنیادین با محاسبات کلاسیک تمایز اساسی دارند، پیش از مقایسه مدل‌ها ضروری است درک روشنی از مفاهیم پایه‌ای، از جمله کیوبیت، حالت ضربی و در هم تنیدگی حاصل شود.

(۱) حالت‌های کوانتومی و کیوبیت

کیوبیت، واحد بنیادی ذخیره‌سازی اطلاعات در رایانه‌های کوانتومی است که نقش مشابهی با بیت در رایانه‌های کلاسیک ایفا می‌کند، اما تفاوت‌های اساسی با آن دارد. برخلاف بیت کلاسیک که صرفاً می‌تواند یکی از دو حالت گسسته ۰ یا ۱ را اختیار کند، کیوبیت قادر است در حالتی به

¹. Back-Propagation

². Abd-elaziem and Soliman

³. Quantum competing basics

نام برهم‌نهی قرار گیرد؛ به این معنا که هم‌زمان ترکیبی از هر دو حالت ۰ و ۱ را شامل شود و تنها در هنگام اندازه‌گیری، با یک احتمال مشخص به یکی از این دو مقدار فرو می‌ریزد. از نظر ریاضی، حالت یک کیوبیت به صورت یک بردار ستونی متشکل از دامنه‌های احتمالی نمایش داده می‌شود که این دامنه‌ها بیانگر احتمال مشاهده هر حالت هستند. اگرچه دامنه‌ها می‌توانند مقادیر منفی یا مختلط داشته باشند، اما همواره جمع مربعات آن‌ها برابر با یک است. برای قرار دادن یک کیوبیت در برهم‌نهی یکنواخت از حالت‌های ۰ و ۱، از دروازه هادامارد استفاده می‌شود. علاوه بر این، سایر دروازه‌های واحدی نیز قادرند دامنه‌های احتمالی کیوبیت را تغییر داده و امکان ایجاد برهم‌نهی‌های متنوع را فراهم کنند که در نتیجه آن می‌توان حجم بیشتری از داده‌ها را نمایش داد.

(۲) حالت ضربی و در هم تنیدگی

زمانی که دو یا چند کیوبیت در یک مدار کوانتومی قرار می‌گیرند، حالت کلی آن‌ها به صورت یک بردار ستونی در فضای هیلبرت^۱ ترکیبی نمایش داده می‌شود. برای نمونه، در سیستم دو کیوبیتی، چهار حالت پایه وجود دارد که هر کدام با یک احتمال معین قابل اندازه‌گیری هستند. اگر حالت برهم‌نهی سیستم به گونه‌ای باشد که وضعیت هر کیوبیت به طور مستقل در حالت کلی سهم داشته و وابستگی متقابل میان آن‌ها وجود نداشته باشد، چنین حالتی به عنوان حالت ضربی شناخته می‌شود که رفتاری مشابه بیت‌های کلاسیک دارد. در مقابل، هنگامی که حالت ترکیبی را نتوان به حاصل ضرب ساده‌ای از حالت‌های منفرد تجزیه کرد، کیوبیت‌ها در وضعیت درهم‌تنیدگی قرار می‌گیرند؛ حالتی منحصربه‌فرد در مکانیک کوانتومی که ویژگی‌های غیرکلاسیک و ارتباطات پیچیده میان کیوبیت‌ها را نشان می‌دهد (آیشواریا^۲ و همکاران، ۲۰۲۵).

۳-۳-۲. حافظه بلندمدت - کوتاه‌مدت کوانتومی (QLSTM)^۳

تمایز اصلی بین معماری QLSTM و LSTM در نوع شبکه به کار رفته است. در حالی که LSTM مبتنی بر شبکه‌های عصبی بازگشتی کلاسیک عمل می‌کند، QLSTM از مدارهای

^۱. Hilbert space

^۲. Aishwarya

^۳. Quantum LSTM Hybrid

کوانتومی پارامتردهی شده (VQC)^۱ برای انجام محاسبات بهره می‌گیرد. اگر چه از منظر تئوریک، QLSTM قادر به ارائه کارایی بالاتر است، این معماری هنوز در مراحل ابتدایی توسعه قرار دارد. در طراحی QLSTM، رفتار سلول‌های LSTM از طریق گیت‌های کوانتومی مدل‌سازی می‌شود. هر واحد VQC معادل یکی از گیت‌های سلول LSTM عمل می‌کند. به طور مشخص، VQC_1 تا VQC_4 نمایانگر گیت‌های فراموشی^۲، ورودی^۳، به‌روز رسانی^۴ و خروجی^۵ هستند. VQC_5 برای نگاشت وضعیت سلول c_t به وضعیت مخفی h_t به کار گرفته می‌شود، در حالی که VQC_6 برای بهینه‌سازی بیش‌تر وضعیت سلول c_t و تولید خروجی y_t مورد استفاده قرار می‌گیرد. خروجی نهایی y_t از اندازه‌گیری انتهای هر VQC به دست می‌آید. این اندازه‌گیری‌ها مقادیر مورد انتظار اپراتور paul-Z هر کیوبیت را ارائه می‌کنند. به صورت اختیاری، این مقادیر می‌توانند در فرایند پس‌پردازش کلاسیک تحت یک تابع فعال‌سازی غیرخطی قرار گیرند تا خروجی نهایی شکل گیرد.

فرمول‌بندی QLSTM در ادامه ارائه می‌شود:

$$v_t = [h_{t-1}, x_t] \quad (20)$$

$$f_t = \sigma(VQC_1(v_t)), \quad (21)$$

$$i_t = \sigma(VQC_2(v_t)), \quad (22)$$

$$\tilde{c}_t = \tanh(VQC_3(v_t)), \quad (23)$$

$$c_t = f_t * c_{t-1} + i_t * \tilde{c}_t, \quad (24)$$

$$o_t = \sigma(VQC_4(v_t)), \quad (25)$$

$$h_t = VQC_5(o_t * \tanh(c_t)), \quad (26)$$

$$y_t = VQC_6(h_t), \quad (27)$$

که در آن v_t به عنوان ادغام وضعیت مخفی قبلی h_{t-1} و ورودی فعلی x_t تعریف شده است و y_t نشان‌دهنده خروجی تازه‌ای است که در مدل QLSTM وارد شده است.

1. Variational Quantum Circuits

2. Forget Gate.

3. Input Gate.

4. Update Gate.

5. Output Gate.

تمام VQC ها در ساختار $QLSTM$ تعریف و در سه بلوک دسته‌بندی شده‌اند. این بلوک‌ها مشابه دروازه‌ها در مدل کلاسیک $LSTM$ عمل می‌کنند. جزئیات عملکرد هر سه بلوک در ادامه ارائه می‌شود.

— گیت فراموشی

در ساختار $QLSTM$ ، جعبه VQC_1 ، حالت مخفی قبلی h_{t-1} و ورودی فعلی x_t را با هم ترکیب می‌کند و از یک تابع فعال‌سازی سیگموید برای تولید بردار f_t استفاده می‌کند. مقادیر این بردار بین ۰ و ۱ قرار دارند و مشخص می‌کنند که کدام بخش‌های حالت سلولی قبلی C_{t-1} باید حفظ شوند و کدام فراموش گردند. در عمل، مقدار ۱ نشان‌دهنده حفظ کامل و مقدار ۰ نمایانگر فراموشی کامل است.

— گیت‌های ورودی و به‌روزرسانی

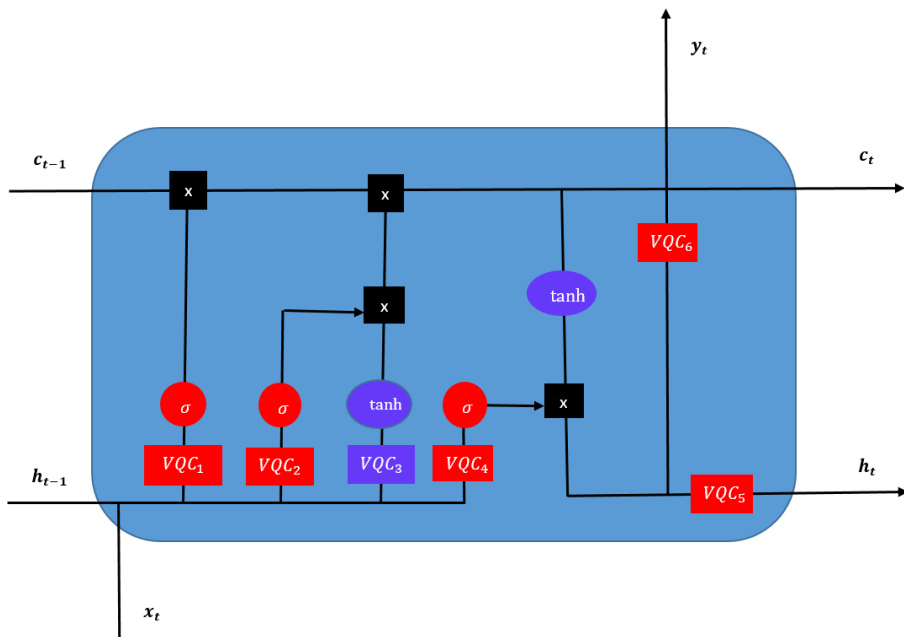
هدف این گیت‌ها تعیین اطلاعات جدیدی است که باید به حالت سلول اضافه شوند. ابتدا، VQC_2 ورودی v_t را پردازش کرده و خروجی آن را از طریق تابع سیگموید عبور می‌دهد تا مشخص شود کدام مقادیر در حالت سلول وارد شوند. به طور همزمان، VQC_3 ورودی ترکیب‌شده را پردازش کرده و از تابع تانژانت هذلولی (\tanh) برای تولید یک کاندیدای جدید حالت سلول \tilde{C}_t استفاده می‌کند. سپس، خروجی VQC_2 به صورت عنصر به عنصر در \tilde{C}_t ضرب شده و بردار حاصل برای به‌روزرسانی حالت سلول به کار گرفته می‌شود.

— گیت خروجی

ابتدا، VQC_4 ورودی v_t را پردازش کرده و آن را از طریق تابع سیگموید عبور می‌دهد تا میزان اهمیت مقادیر موجود در حالت سلول C_t مشخص شود. سپس، حالت سلول از طریق تابع تانژانت هذلولی (\tanh) تبدیل شده و در خروجی VQC_4 ضرب می‌شود. به صورت اختیاری، مقدار حاصل می‌تواند از طریق VQC_5 برای تولید حالت مخفی h_t یا از طریق VQC_6 برای بدست آوردن خروجی y_t پردازش شود. به طور کلی، ابعاد حالت سلول C_t ، حالت مخفی h_t و خروجی y_t یکسان نیستند. برای تضمین تطابق ابعاد، VQC_5 برای تبدیل C_t به h_t و از VQC_6 برای تبدیل C_t به y_t استفاده می‌شود (کیا^۱ و همکاران، ۲۰۲۴).

^۱. Kea

نمودار (۱): ساختار مدل یادگیری عمیق کوانتومی (QLSTM)



نمودار ۱ یک سلول QLSTM از مدارهای کوانتومی پارامترسازی شده (VQC_S) تشکیل شده است که به عنوان جایگزینی برای دروازه‌های LSTM عمل می‌کنند.

۳-۴. جزئیات پیاده‌سازی، پیش‌پردازش و فرآیندهای مدل‌های پژوهش

به منظور شفافیت کامل و امکان بازتولید نتایج، در این بخش تمامی جزئیات مربوط به داده‌ها، نحوه پیش‌پردازش، معماری مدل‌های استفاده‌شده و فرآیندهای هر یک تشریح می‌گردد. پیاده‌سازی با استفاده از زبان برنامه‌نویسی پایتون و کتابخانه‌های `numpy`, `pandas`, `yfinance`, `scikit-learn`, `statsmodels`, `PyTorch` و `PennyLane` انجام شده است.

۳-۴-۱. پیش‌پردازش داده‌ها و جلوگیری از نشت اطلاعات

داده‌های قیمت آتی نفت خام WTI از کتابخانه `yfinance` استخراج شدند. مجموعه داده شامل قیمت‌های پایانی روزانه می‌باشد.

داده‌ها بر اساس تاریخ به دو بخش آموزش (۲۰۰۳ تا پایان ۲۰۲۲) و آزمون (۲۰۲۳ تا ژوئن ۲۰۲۵) تقسیم شدند. این تفکیک پیش از هرگونه عملیات پیش‌پردازش وابسته به آینده انجام شده است تا از نشت اطلاعات جلوگیری شود. با توجه به ماهیت متفاوت مقیاس قیمت‌ها و نیاز مدل‌های یادگیری ماشین به ورودی‌های هم‌مقیاس، از روش MinMaxScaler برای نرمال‌سازی داده‌ها به بازه [۰, ۱] استفاده گردید. scaler تنها بر روی داده‌های آموزش برازش ('fit') شده و سپس برای تبدیل هر دو مجموعه آموزش و آزمون به کار رفت. این رویکرد تضمین می‌کند که اطلاعات مجموعه آزمون در فرآیند scaler دخالت نداشته باشد.

برای تبدیل سری زمانی به مسئله یادگیری نظارت‌شده، از روش پنجره‌لغزان با اندازه پنجره ۲۰ روز استفاده شد. بدین معنا که برای پیش‌بینی قیمت روز t ، از قیمت‌های ۲۰ روز گذشته ($t-20$ تا $t-1$) به عنوان ویژگی‌های ورودی استفاده می‌گردد. تابع 'make_windows' این عمل را جداگانه بر روی مجموعه‌های آموزش و آزمون اعمال می‌کند. در نتیجه، تعداد نمونه‌های نهایی برای آموزش برابر (طول مجموعه آموزش - ۲۰) و برای آزمون برابر (طول مجموعه آزمون - ۲۰) خواهد بود.

۳-۴-۲. فرآیند آموزش و مشخصات مدل‌ها

تمامی مدل‌های یادگیری عمیق با استفاده از تابع زیان MSE و بهینه‌ساز Adam آموزش دیده‌اند. آموزش به صورت دسته‌ای (batch) با اندازه دسته ۳۲ انجام شده است. نرخ یادگیری برای تمامی مدل‌ها ۰/۰۰۵ در نظر گرفته شد. تعداد دوره‌های آموزش برای مدل‌های LSTM، GRU و MLP برابر ۳۰ و برای مدل QLSTM (به دلیل پیچیدگی بیشتر) برابر ۷۰ تعیین گردید. در ادامه معماری دقیق هر مدل ارائه می‌شود:

مدل AR و MA: با استفاده از کتابخانه 'statsmodels' بر روی داده‌های خام (غیرنرمال) آموزش دیده و پیش‌بینی‌ها برای کل دوره آزمون تولید شدند. سپس ۲۰ روز ابتدایی پیش‌بینی‌ها (متناظر با پنجره زمانی) حذف گردید تا با پیش‌بینی سایر مدل‌ها قابل مقایسه باشد. مدل MLP: شبکه‌ای دو لایه شامل:

- لایه اول: ۲۰ نورون ورودی و ۳۲ نورون پنهان با تابع فعال‌سازی ReLU.

- لایه دوم: ۳۲ نورون و ۱ نورون خروجی (پیش‌بینی).

مدل LSTM شامل یک لایه LSTM با ۱ ویژگی ورودی و ۸ واحد پنهان و به دنبال آن یک لایه خطی برای نگاشت خروجی آخرین گام زمانی به پیش‌بینی نهایی. مدل GRU مشابه LSTM، شامل یک لایه GRU با ۱ ویژگی ورودی و ۸ واحد پنهان و لایه خطی خروجی.

مدل SVR با کرنل پیش‌فرض RBF و بدون تنظیم فرارامتر خاصی استفاده گردید.

۳-۴-۳. جزئیات پیاده‌سازی مدل یادگیری عمیق کوانتومی

مدل QLSTM بهبود یافته از ترکیب یک لایه LSTM کلاسیک و یک مدار کوانتومی پارامتری ساخته شده است. پیاده‌سازی بخش کوانتومی با استفاده از کتابخانه PennyLane و اتصال به PyTorch از طریق `qml.qnn.TorchLayer` انجام گردید. با توجه به عدم دسترسی به سخت‌افزار کوانتومی واقعی، از شبیه‌ساز `default.qubit` (شبیه‌ساز حالت-بردار) استفاده شده است.

مشخصات مدار کوانتومی:

تعداد کیوبیت‌ها: ۶ کیوبیت

عمق مدار: ۲ لایه. هر لایه شامل یک مجموعه از دروازه‌های چرخش تک‌کیوبیتی (پارامتری) و به دنبال آن دروازه‌های CNOT برای درهم‌تنیدگی کیوبیت‌ها می‌باشد. رمزگذاری داده‌ها: از روش Angle Embedding استفاده شده است. با توجه به محدودیت دامنه این رمزگذاری (معمولاً $[\pi, 0]$ یا $[-\pi, \pi]$)، پیش از اعمال به مدار، بردار خروجی LSTM (با اندازه ۶) به صورت زیر پیش‌پردازش می‌گردد:

۱. نرمال‌سازی به میانگین صفر و انحراف معیار یک (به صورت آنلاین در هر batch).

۲. برش مقادیر به بازه $[-1, 1]$ با تابع `clamp``.

۳. ضرب در عدد π تا در بازه $[-\pi, \pi]$ قرار گیرد و برای رمزگذاری زاویه‌ای مناسب باشد.

در انتهای مدار، مقدار چشم‌داشتی (expectation value) عملگر Pauli-Z برای هر یک از ۶ کیوبیت اندازه‌گیری می‌شود. خروجی اندازه‌گیری یک بردار ۶ بعدی است.

پس‌پردازش کلاسیک: بردار ۶ بعدی حاصل به یک لایه کاملاً متصل خطی با ۶ ورودی و ۱ خروجی داده می‌شود تا پیش‌بینی نهایی قیمت نرمال شده تولید گردد.

فرآیند کلی مدل QLSTM:

۱. داده‌های نرمال شده با پنجره ۲۰ روزه وارد لایه LSTM (با ۶ واحد پنهان) می‌شوند.
 ۲. خروجی آخرین گام زمانی LSTM (بردار ۶ بعدی) استخراج می‌گردد.
 ۳. این بردار با استفاده از روش توضیح داده شده (نرمال سازی، برش و مقیاس دهی) برای ورود به مدار کوانتومی آماده می‌شود.
 ۴. بردار آماده شده به مدار کوانتومی داده شده و خروجی اندازه گیری (بردار ۶ بعدی) محاسبه می‌شود.
 ۵. خروجی کوانتومی از لایه خطی نهایی عبور کرده و پیش‌بینی نهایی تولید می‌شود.
- به دلیل محدودیت‌های شبیه‌سازی، مدار کوانتومی به ازای هر نمونه به صورت مجزا فراخوانی می‌شود. این موضوع در شبیه‌ساز باعث افزایش زمان اجرا می‌گردد اما در صورت استفاده از سخت‌افزار واقعی یا شبیه‌سازهای بهینه‌تر می‌توان آن را به صورت دسته‌ای پردازش کرد.
- جدول ۱ خلاصه‌ای از فرآیندهای استفاده شده برای تمامی مدل‌ها را نشان می‌دهد:

جدول (۱): فرآیندهای مدل‌های تحقیق

مدل	اندازه پنجره	تعداد واحدهای پنهان / کیوبیت	تعداد لایه‌ها	نرخ یادگیری	اندازه دسته	تعداد دوره	بهینه‌ساز	تابع زیان
AR(1)	-	-	-	-	-	-	-	-
MA(1)	-	-	-	-	-	-	-	-
MLP	۲۰	۳۲	۲ لایه خطی	۰/۰۰۵	۳۲	۳۰	Adam	MSE
LSTM	۲۰	۸	۱ لایه LSTM	۰/۰۰۵	۳۲	۳۰	Adam	MSE
GRU	۲۰	۸	۱ لایه GRU	۰/۰۰۵	۳۲	۳۰	Adam	MSE
SVR	۲۰	-	-	-	-	-	-	MSE
QLSTM	۲۰	۶ / (LSTM) کیوبیت ۶	۱ لایه + ۲ LSTM لایه کوانتومی	۰/۰۰۵	۳۲	۷۰	Adam	MSE

اطلاعات جدول ۱ امکان بازتولید دقیق نتایج مقاله را برای سایر پژوهشگران فراهم می‌آورد.
۳-۴-۴. معیارهای ارزیابی مدل

ما از معیارهای MSE، RMSE، Theil's U برای ارزیابی نتایج استفاده می‌کنیم که به صورت زیر بیان می‌شوند (هو و لین^۱، ۲۰۲۲):

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \tilde{y}_i)^2 \quad (28)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \tilde{y}_i)^2} \quad (29)$$

$$\text{Theil's U} = \sqrt{\frac{\sum (y_i - \tilde{y}_i)^2}{\sum y_i^2}} \quad (30)$$

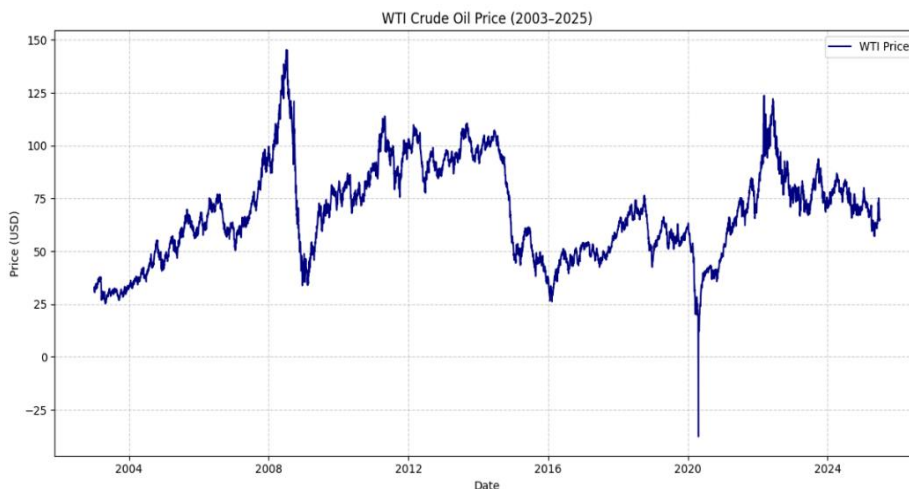
بعد از محاسبه خطاهای پیش بینی، به منظور بررسی معنی داری تفاوت خطاهای پیش بینی از آزمون دایبولد-ماریانو استفاده می‌شود.

۳-۵. توصیف داده‌ها

در این پژوهش داده‌های سری زمانی مربوط به قیمت آتی نفت خام وست تگزاس (WTI)، از کتابخانه y.finance پایتون استخراج شده‌اند. از آن، داده‌های مورد نیاز گردآوری و تحلیل می‌شوند تا با استفاده از مدل یادگیری عمیق کوانتومی، روند آینده قیمت نفت پیش‌بینی گردد. نمونه مورد مطالعه قیمت‌های روزانه آتی نفت خام WTI از ابتدای ژانویه سال ۲۰۰۳ میلادی تا انتهای ماه ژوئن ۲۰۲۵ میلادی است. بازه زمانی ۲۰۰۳ الی انتهای سال ۲۰۲۲ به منظور آموزش مدل به کار گرفته می‌شود و داده‌های مربوط به دوره ژانویه ۲۰۲۳ الی انتهای ژوئن ۲۰۲۵ به عنوان بازه آزمون مورد استفاده قرار می‌گیرند. مدل‌های یادگیری عمیق در مرحله آموزش، روند تغییرات قیمت نفت را یاد می‌گیرند و عملکرد آنها در پیش‌بینی با استفاده از بازه آزمایش سال‌های ۲۰۲۳ تا ۲۰۲۵ سنجیده می‌شود.

^۱. Ho and Lin.

نمودار (۲): روند قیمت آتی نفت خام WTI در بازه زمانی ژانویه ۲۰۰۳ الی ژوئن ۲۰۲۵



منبع: کتابخانه Python y.finance

جدول (۲): آماره‌های توصیفی قیمت آتی نفت خام WTI

در بازه زمانی ژانویه ۲۰۰۳ الی ژوئن ۲۰۲۵

دوره آزمایش (۲۰۲۵-۲۰۲۳)	دوره آموزش (۲۰۲۲-۲۰۰۳)	کل دوره (۲۰۰۳-۲۰۲۵)	آماره
۶۲۵	۵۰۲۷	۵۶۵۲	تعداد مشاهدات
۷۴/۸۷	۶۷/۸۵	۶۸/۶۳	میانگین
۷۴/۶۶	۶۴/۲۶	۶۸/۰۶	میانه
۶/۷۱	۲۳/۸۶	۲۲/۷۲	انحراف معیار
۹۳/۶۸	۱۴۵/۲۹	۱۴۵/۲۹	حداکثر
۵۷/۱۳	-۳۷/۶۳	-۳۷/۶۳	حداقل

منبع: کتابخانه Python y.finance

نمودار ۲ نشان دهنده روند حرکتی قیمت آتی نفت خام وست تگزاس در دوره ۲۰۰۳ تا ۲۰۲۵ است که بیانگر نوسانات شدید متأثر از رویدادهای کلان اقتصادی و سیاسی است. در نیمه اول این بازه، رشد سریع اقتصاد جهانی و افزایش تقاضای چین موجب شد قیمت‌ها تا رکورد تاریخی سال ۲۰۰۸ یعنی بیش از ۱۴۰ دلار افزایش یابد، اما بحران مالی جهانی همان سال باعث سقوط

ناگهانی آن تا زیر ۴۰ دلار شد. پس از این شوک، بازار در فاصله ۲۰۰۹ تا ۲۰۱۴ وارد دوره‌ای از ثبات نسبی شد و قیمت‌ها عمدتاً در محدوده ۸۰ تا ۱۰۰ دلار نوسان داشتند. با این حال، در سال‌های ۲۰۱۴ تا ۲۰۱۶ تحت تأثیر افزایش تولید نفت شیل آمریکا و جنگ قیمتی اوپک، قیمت نفت بار دیگر افت چشمگیری را تجربه کرد و به سطوح نزدیک به ۳۰ دلار رسید.

یکی از نقاط عطف تاریخی در این دوره، پاندمی کرونا در سال ۲۰۲۰ بود که موجب سقوط بی‌سابقه تقاضای جهانی شد. در نتیجه مازاد ذخایر و محدودیت شدید ظرفیت انبارش، قیمت آتی نفت خام وست تگزاس برای نخستین بار در تاریخ وارد محدوده منفی شد و در آوریل همان سال به حدود منفی ۳۷ دلار رسید. این پدیده ناشی از شرایط منحصر به فرد بازار و اجتناب معامله‌گران از تحویل فیزیکی نفت بود.

با آغاز بهبود تقاضا پس از کرونا و بروز تنش‌های ژئوپلیتیکی، به ویژه جنگ روسیه و اوکراین، قیمت‌ها در سال‌های ۲۰۲۱ و ۲۰۲۲ دوباره اوج گرفتند و به بالای ۱۲۰ دلار رسیدند. اما در دوره ۲۰۲۳ تا ۲۰۲۵ روند تعدیل عرضه و تقاضا همراه با سیاست‌های اوپک پلاس موجب شد بازار وارد فاز نوسانات محدودتر شود و عمدتاً در محدوده ۶۵ تا ۸۵ دلار نوسان کند. به طور کلی، تغییرات مشاهده شده نشان می‌دهد که بازار نفت به شدت تحت تأثیر چرخه‌های اقتصادی، شوک‌های سیاسی و بحران‌های غیرمنتظره قرار دارد و تحلیل آن برای سیاست‌گذاران و سرمایه‌گذاران اهمیت حیاتی دارد.

۴. نتایج تجربی

نتایج پیش بینی برای مدل‌های پژوهش به شرح جدول ۳ می‌باشد. نتایج نشان داده است که مدل یادگیری عمیق کوانتومی کمترین خطای پیش بینی را در بین سایر مدل‌های پژوهش داشته است. با این حال برای بررسی معنی داری تفاوت خطای های پیش بینی از آزمون دایبولد ماریانو نیز استفاده شده است که نتایج آن در جدول ۴ گزارش شده است.

جدول (۳): نتایج معیارهای خطای پیش‌بینی مدل‌های پژوهش

Model	MSE	RMSE	Theil's U
AR (1)	۴۳/۶۰۶۴	۶/۶۰۳۵	۰/۰۴۴۷
MA(1)	۹۳/۶۶۰۸	۹/۶۷۷۹	۰/۰۶۷۷
LSTM	۲۹/۷۷۹۷	۵/۴۵۷۱	۰/۰۳۶۳
GRU	۲۰۲/۰۰۸۸	۱۴/۲۱۳۰	۰/۱۰۳۹
MLP	۷۲/۲۸۶۹	۸/۵۰۲۲	۰/۰۵۹۸
SVR	۲۰/۱۳۵۱	۴/۴۸۷۲	۰/۰۲۹۳
Q LSTM	۴/۸۷۷۸	۲/۲۰۸۶	۰/۰۱۵۵

منبع: یافته‌های پژوهش با نرم افزار Python در محیط Visual Studio Code

جدول (۴): نتایج آزمون دایبولد ماریانو برای برابری خطاهای پیش‌بینی

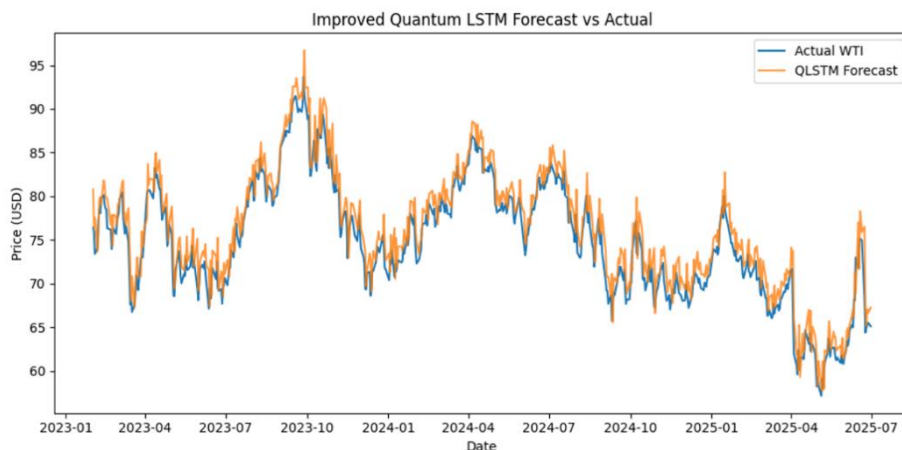
QDL vs Models	P-Value for Diebold Mariano Test
QDL vs AR	۰/۰۰
QDL vs MA	۰/۰۰
QDL vs LSTM	۰/۰۰
QDL vs GRU	۰/۰۰
QDL vs MLP	۰/۰۰
QDL vs SVR	۰/۰۰

منبع: یافته‌های پژوهش با نرم افزار Python در محیط Visual Studio Code

بنابراین نتایج آزمون دایبولد ماریانو نشان می‌دهد که فرضیه صفر برابری خطاهای پیش‌بینی مدل‌های مختلف در برابر مدل یادگیری عمیق کوانتومی در سطح معنای ۱٪ رد شده است. در نتیجه تفاوت خطاهای پیش‌بینی از نظر آماری معنی‌دار است و در نتیجه می‌توان گفت که مدل یادگیری عمیق کوانتومی از نظر دقت پیش‌بینی نسبت به سایر مدل‌های رقیب مطرح شده در مقاله حاضر عملکرد دقیق‌تری دارد.

نمودار ۳ مقادیر واقعی و پیش‌بینی شده قیمت آتی نفت خام WTI را بر اساس مدل یادگیری عمیق کوانتومی نشان می‌دهد. بر اساس این نمودار و همچنین خطای پیش‌بینی گزارش شده در جدول ۲ می‌توان به دقت عملکرد مدل یادگیری عمیق کوانتومی در پیش‌بینی دقیق قیمت آتی نفت خام WTI پی برد.

نمودار (۳): مقادیر واقعی (آبی رنگ) و پیش بینی شده قیمت آتی WTI (نارنجی رنگ) بر اساس مدل یادگیری عمیق کوانتومی



منبع: یافته‌های پژوهش با نرم افزار Python در محیط Visual Studio Code

همچنین برای بررسی استحکام نتایج بازه آموزش به دوره ۲۰۱۳-۲۰۲۲ کوتاه شد و بازه آزمایش همان بازه ۲۰۲۳-۲۰۲۵ ثابت نگه داشته شد و مجدد تمام مدلها برای این بازه کوتاه‌تر با همان ویژگی‌های قبلی برآورد شد و نتایج خطای پیش بینی در جدول ۵ در ضمیمه مقاله ارائه شد. همچنین نمودار مقادیر واقعی و پیش بینی شده برای این بازه جدید در ضمیمه تحت عنوان نمودار ۴ ارائه شد. همانطور که نتایج ضمیمه نشان می‌دهد همچنان مدل یادگیری عمیق کوانتومی نسبت به سایر مدلها عملکرد دقیق‌تری در پیش بینی قیمت آتی نفت خام داشته است لذا می‌توان گفت که نتایج از استحکام لازم برای تکرار پذیری برخوردار هستند. برتری قابل توجه مدل یادگیری عمیق کوانتومی نسبت به سایر مدل‌ها را می‌توان به چند عامل اساسی نسبت داد:

۱. **فضای ویژگی با ابعاد بالاتر:** مدار کوانتومی با ۶ کیوبیت، داده‌ها را به فضای هیلبرت با ابعاد ۶۴ نگاشت می‌کند. این افزایش ابعاد، امکان شناسایی الگوهای پیچیده‌تری را فراهم می‌آورد که در فضای کلاسیک قابل تشخیص نیستند. به عبارت دیگر، مدار کوانتومی به عنوان یک استخراج‌کننده ویژگی قدرتمند عمل کرده و بازنمایی غنی‌تری از داده‌ها ارائه می‌دهد.

۲. **ویژگی برهم‌نهی کوانتومی:** برهم‌نهی به مدار کوانتومی اجازه می‌دهد هم‌زمان چندین حالت مختلف را بررسی کند. این ویژگی در پیش‌بینی سری‌های زمانی با نوسانات شدید، مانند قیمت نفت، بسیار حیاتی است. مدل یادگیری عمیق کوانتومی می‌تواند هم‌زمان سناریوهای مختلف قیمتی (صعودی، نزولی، خنثی) را در نظر گرفته و پیش‌بینی خود را بر اساس ترکیبی وزنی از این سناریوها ارائه دهد.

۳. **درهم‌تنیدگی کوانتومی:** درهم‌تنیدگی در مدار کوانتومی از طریق دروازه‌های CNOT امکان مدل‌سازی همبستگی‌های پیچیده و غیرموضعی بین ویژگی‌های مختلف را فراهم می‌کند. در داده‌های سری زمانی، این به معنای شناسایی وابستگی‌های بلندمدت و روابط پیچیده بین نقاط زمانی دور از هم است که در مدل‌های کلاسیک به سختی قابل تشخیص هستند. به‌ویژه در بازار نفت که تحت تأثیر شوک‌های ژئوپلیتیکی و اقتصادی قرار دارد، این ویژگی اهمیت می‌یابد.

۴. **غیرخطی بودن ذاتی فضای هیلبرت:** برخلاف شبکه‌های عصبی کلاسیک که غیرخطی بودن را از طریق توابع فعال‌سازی به دست می‌آورند، فضای هیلبرت ذاتاً غیرخطی است. اندازه‌گیری در مکانیک کوانتومی یک فرآیند غیرخطی است که به مدل توانایی بیشتری در مدل‌سازی دینامیک‌های پیچیده و آشوبناک بازار نفت می‌دهد. این ویژگی توضیح می‌دهد که چرا مدل یادگیری عمیق کوانتومی در پیش‌بینی نقاط اوج و نوسانات شدید (مانند دوران کرونا) عملکرد بهتری داشته است.

۵. **پیش‌پردازش بهینه ورودی کوانتومی:** در مدل بهبودیافته مدل یادگیری عمیق کوانتومی، خروجی LSTM قبل از ورود به مدار کوانتومی نرمال‌سازی، برش داده شده و در بازه $[-\pi, \pi]$ مقیاس‌دهی می‌شود. این پیش‌پردازش باعث می‌شود داده‌ها با دامنه مؤثر رمزگذاری زاویه‌ای تطابق یافته و آموزش مدار کوانتومی پایدارتر و مؤثرتر انجام شود.

نتایج این پژوهش هم‌راستا با یافته‌های ژای و همکاران (۲۰۲۵) است که نشان دادند ادغام شبکه‌های کوانتومی با مدل‌های یادگیری عمیق، دقت پیش‌بینی قیمت نفت را به‌طور چشمگیری ارتقا می‌دهد. همچنین این یافته با پژوهش‌های پیشین مبتنی بر روش‌های یادگیری عمیق مانند CNN-LSTM (الدباغ و همکاران، ۲۰۲۳) یا ترکیب‌های پیچیده‌تر نظیر ARIMA-SVR-POT (ژانگ و ژو، ۲۰۲۴) مشابهت دارد، با این تفاوت که در مطالعه حاضر QDL حتی از این مدل‌های ترکیبی نیز عملکرد بهتری داشته است. این مسئله نشان می‌دهد که ورود ویژگی‌های

کوانتومی مانند برهم‌نهی و درهم‌تنیدگی به فضای پیش‌بینی می‌تواند توانایی مدل‌ها را در پردازش نوسانات شدید بازار نفت افزایش دهد.

در مقایسه با مدل‌های سنتی اقتصادسنجی که به دلیل محدودیت در مدل‌سازی رفتارهای غیرخطی بازار نفت عملکرد محدودتری داشتند، یافته‌های این مقاله بیانگر یک گام رو به جلو در حوزه پیش‌بینی مالی و انرژی است. همچنین، نتایج با پژوهش‌های داخلی مانند مطالعه خوچیان و نادمی (۱۳۹۷) که تأکید بر مدل‌های حافظه بلندمدت داشتند همسو است، اما نشان می‌دهد که QDL می‌تواند حتی نسبت به مدل‌های حافظه‌محور نیز عملکرد بهتری ارائه دهد. بنابراین می‌توان نتیجه گرفت که به‌کارگیری QDL یک نوآوری مهم محسوب می‌شود که با غلبه بر محدودیت‌های روش‌های سنتی و مدرن، دقت پیش‌بینی قیمت آتی نفت خام را در شرایط پرتلاطم به شکل معناداری افزایش داده است.

فراتر از بهبودهای آماری، نتایج این پژوهش از منظر معناداری اقتصادی نیز حائز اهمیت است. مدل QLSTM با RMSE برابر ۲/۲۱ دلار، نسبت به مدل LSTM با RMSE ۵/۴۶ دلار حدود ۳/۲۵ دلار به ازای هر بشکه خطای کمتری دارد. این کاهش خطا معادل ۵۹/۵ درصد بهبود دقت پیش‌بینی نسبت به مدل LSTM است. در یک قرارداد آتی استاندارد نفت خام WTI که معادل ۱۰۰۰ بشکه نفت است، این کاهش خطا به معنای پیش‌بینی دقیق‌تر به ارزش ۳۲۵۰ دلار به ازای هر قرارداد در مقایسه با LSTM می‌باشد. با توجه به اینکه حجم معاملات روزانه قراردادهای آتی WTI معمولاً بیش از ۱۰۰ هزار قرارداد است، دقت بالاتر مدل QLSTM می‌تواند در سطح کلان به صرفه‌جویی اقتصادی قابل توجهی منجر شود.

برای فعالان بازار نفت، این دقت بالاتر پیامدهای عملی زیر را به همراه دارد:

- **بهبود استراتژی‌های معاملاتی:** معامله‌گران می‌توانند با اطمینان بیشتری موقعیت‌های خرید یا فروش خود را تعیین کنند.
- **مدیریت ریسک کارآمدتر:** شرکت‌های فعال در صنعت نفت (اعم از تولیدکنندگان، پالایشگاه‌ها و مصرف‌کنندگان) می‌توانند با دقت بالاتری قراردادهای پوشش ریسک منعقد کرده و خود را در برابر نوسانات شدید قیمتی محافظت نمایند.

• **بهبود بودجه‌ریزی:** برای کشورهای صادرکننده نفت مانند ایران که بخش عمده درآمدهای ارزی آن‌ها از محل فروش نفت تأمین می‌شود، پیش‌بینی دقیق‌تر قیمت می‌تواند به تدوین بودجه‌های واقع‌بینانه‌تر و کاهش کسری بودجه کمک کند. به بیان دیگر، مدل QLSTM نه تنها از نظر آماری مدل بهتری است، بلکه از نظر اقتصادی نیز ارزش افزوده قابل توجهی ایجاد می‌کند و می‌تواند به عنوان ابزاری مؤثر در تصمیم‌گیری‌های مالی و اقتصادی مورد استفاده قرار گیرد.

۵. نتیجه‌گیری و پیشنهاد

یافته‌های این پژوهش نشان می‌دهد که مدل یادگیری عمیق کوانتومی (QDL) نسبت به سایر مدل‌های رقیب - اعم از مدل‌های کلاسیک سری‌های زمانی AR و MA، الگوریتم‌های یادگیری ماشین (SVR) و مدل‌های یادگیری عمیق سنتی LSTM، GRU و MLP دقت بالاتری در پیش‌بینی قیمت آتی نفت خام وست‌تگزاس (WTI) دارد. نتایج آزمون دایبولد-ماریانو نیز این برتری را از لحاظ آماری تأیید کرده است و نشان می‌دهد که QDL می‌تواند با بهره‌گیری از ویژگی‌های محاسبات کوانتومی مانند برهم‌نهی و درهم‌تنیدگی، الگوهای پیچیده‌تر و نوسانات شدید بازار نفت را بهتر شناسایی کند.

از منظر سیاست‌گذاری، این نتایج دارای پیامدهای مهمی برای اقتصاد ایران است. نخست، دقت بالاتر در پیش‌بینی قیمت‌های آتی نفت می‌تواند به کاهش عدم‌اطمینان در تصمیم‌گیری‌های کلان اقتصادی کمک کند. دولت ایران که بخش عمده‌ای از بودجه خود را از محل درآمدهای نفتی تأمین می‌کند، می‌تواند با استفاده از این پیش‌بینی‌ها، در زمینه تدوین بودجه‌های سالانه، سیاست‌های ارزی و مدیریت ذخایر ارزی کارآمدتر عمل کند. دوم، پیش‌بینی دقیق‌تر قیمت نفت می‌تواند ابزار مناسبی برای مدیریت ریسک و طراحی قراردادهای پوشش ریسک (Hedging) در بازارهای داخلی و خارجی فراهم سازد. این امر به‌ویژه برای شرکت ملی نفت ایران و سایر بازیگران بخش انرژی کشور، که در معرض نوسانات شدید بازار جهانی قرار دارند، اهمیت دارد. سوم، نتایج این مطالعه می‌تواند به سیاست‌گذاران حوزه انرژی در طراحی برنامه‌های متنوع‌سازی منابع انرژی

و کاهش وابستگی به نفت کمک کند؛ چراکه تحلیل دقیق نوسانات و چرخه‌های قیمتی، ضرورت تقویت منابع جایگزین و افزایش تاب‌آوری اقتصادی کشور را آشکارتر می‌سازد. از منظر پژوهشی، این تحقیق گامی نوآورانه در به‌کارگیری روش QDL در حوزه پیش‌بینی قیمت نفت است، اما می‌توان مسیرهای آتی متعددی را پیشنهاد کرد. نخست، ترکیب QDL با سایر روش‌های تجزیه سری‌های زمانی مانند موجک می‌تواند به استخراج ویژگی‌های دقیق‌تر و کاهش نویز داده‌ها کمک کند. دوم، استفاده از داده‌های چندمتغیره نظیر نرخ ارز، شاخص‌های کلان اقتصادی، داده‌های حمل‌ونقل انرژی و تنش‌های ژئوپلیتیکی در کنار داده‌های قیمتی، می‌تواند مدل را غنی‌تر سازد و دقت پیش‌بینی را افزایش دهد. سوم، توسعه این روش برای سایر بازارهای کالایی مانند گاز طبیعی، طلا و فلزات اساسی، زمینه را برای تعمیم نتایج و طراحی ابزارهای سیاست‌گذاری در حوزه‌های متنوع فراهم می‌کند.

تعارض منافع

تعارض منافع وجود ندارد.

پیوست:

جدول (۵): نتایج معیارهای خطای پیش‌بینی مدل‌های پژوهش


(بازه آموزش ۲۰۱۳-۲۰۲۲ و بازه آزمون ۲۰۲۳-۲۰۲۵)

Model	MSE	RMSE	Theil's U
AR (1)	۶۳/۰۱	۷/۹۳	۰/۰۵۴
MA (1)	۱۲۶/۴۳	۱۱/۳۴	۰/۰۷۹
LSTM	۳۶/۳۴	۶/۰۲	۰/۰۴۱
GRU	۱۴۳/۸۱	۱۱/۹۹	۰/۰۸۶
MLP	۸۶/۵۲	۹/۳۰	۰/۰۶۵
SVR	۱۳/۵۴	۳/۶۸	۰/۰۲۴
Q LSTM	۴/۴۰۹۸	۲/۰۹۹۲	۰/۰۱۴

منبع: یافته‌های پژوهش

نمودار (۴): مقادیر واقعی و پیش‌بینی شده قیمت آتی WTI

بر اساس مدل یادگیری عمیق کوانتومی (بازه آموزش ۲۰۱۳-۲۰۲۲ و بازه آزمون ۲۰۲۳-۲۰۲۵)



منبع: یافته‌های پژوهش

References

- Abd-elaziem, A. H., & Soliman, T. H. (2023). A multi-layer perceptron (mlp) neural networks for stellar classification: A review of methods and results. *International Journal of Advances in Applied Computational Intelligence*, 3(10.54216).
- Abdollahzadeh, S., Behnia, S., & Majdi, F. (2024). OPEC Crude Oil Price Prediction Based on Chaos Theory and GMDH-GA. *Petroleum Business Review (PBR)*, 8(4).
- Abdulrahim, H., Alshibani, S. M., Ibrahim, O., & Elhag, A. A. (2025). Prediction OPEC oil price utilizing long short-term memory and multi-layer perceptron models. *Alexandria Engineering Journal*, 110, 607-612.

- Abrishami, H., Behradmehr, N., & Seifi, T. (2013). Crude Oil Price Prediction Using Wavelet Transform, Nonlinear Models, and Linear Models. *Applied Economic Studies of Iran*, 2(7), 41-62. (In Persian)
- Aishwarya, C., Venkatesan, M., & Prabhavathy, P. (2025). A Scoping Survey of Quantum Machine Learning and Deep Learning for Real-World Applications. *Procedia Computer Science*, 258, 633-646.
- Akusta, A., Yıldırım, H. H., Gün, M., & Sakarya, Ş. (2026). Deep learning enhanced energy market prediction: A robust ARIMAX–LSTM fusion for crude oil pricing. *Journal of Computational and Applied Mathematics*, 474, 117006.
- Aldabagh, H., Zheng, X., & Mukkamala, R. (2023). A hybrid deep learning approach for crude oil price prediction. *Journal of Risk and Financial Management*, 16(12), 503.
- Alrweili, H., & Fawzy, H. (2022). Forecasting crude oil prices using an ARIMA-ANN hybrid model. *J Stat Appl Probab*, 11(3), 845-855.
- Asianto, A. (2019). The price determinants of West Texas Intermediate crude oil. *Jurnal Aplikasi Bisnis dan Manajemen (JABM)*, 5(1), 153-153.
- Chen, Y., & Tian, Z. (2025). A crude oil price forecasting framework based on Constraint Guarantee and Pareto Fronts Shrinking Strategy. *Applied Soft Computing*, 174, 112996.
- Fattahi, S., Kianpour, S., & Soheili, K. (2023). Crude Oil Price Prediction Using Text Mining Method and Big Data Modeling. *Natural Resources Engineering Journal*, 8(2), 83-97. (In Persian)
- Foroutan, P., & Lahmiri, S. (2024). Deep learning systems for forecasting the prices of crude oil and precious metals. *Financial Innovation*, 10(1), 111.
- Golec, M., Hatay, E. S., Golec, M., Uyar, M., Golec, M., & Gill, S. S. (2024). Quantum cloud computing: Trends and challenges. *Journal of Economy and Technology*, 2, 190-199.
- Haji Karam, E., & Darabi, R. (2017). Daily Brent Crude Oil Price Prediction by Combining Principal Component Analysis and Support Vector Regression. *Iranian Energy Economics Research Journal*, 7(25), 41-60. (In Persian)

He, K., Yu, L., & Zou, Y. (2024). Crude oil future price forecasting using pretrained Transformer model. *Procedia Computer Science*, 242, 288-293.

Henrique, B. M., Sobreiro, V. A., & Kimura, H. (2018). Stock price prediction using support vector regression on daily and up to the minute prices. *The Journal of finance and data science*, 4(3), 183-201.

Ho, T. W., & LIN, Y. C. (2022). Stock Returns Forecasting via Machine Learning with Average Windows Forecasts. *Ya-chi, Stock Returns Forecasting via Machine Learning with Average Windows Forecasts* (April 3, 2022).

Javanmard, H., & Faghidian, S. F. (2014). OPEC Crude Oil Price Prediction Using Grey Prediction Model. *Economic Modeling Quarterly*, 8(3), 91-114. (In Persian)

Jha, N., Tanneru, H. K., Palla, S., & Mafat, I. H. (2024). Multivariate analysis and forecasting of the crude oil prices: Part I—Classical machine learning approaches. *Energy*, 296, 131185.

Kea, K., Kim, D., Huot, C., Kim, T. K., & Han, Y. (2024). A Hybrid Quantum-Classical Model for Stock Price Prediction Using Quantum-Enhanced Long Short-Term Memory. *Entropy*, 26(11), 954.

Khochiani, R., & Nademi, Y. (2018). West Texas Intermediate Crude Oil Price Prediction: A Stochastic Differential Approach. *Econometric Modeling Quarterly*, 3(2), 155-177. (In Persian)

Krichen, M., & Mihoub, A. (2025). Long Short-Term Memory Networks: A Comprehensive Survey. *AI*, 6(9), 215.

Lee, J., & Xia, B. (2024). Analyzing the dynamics between crude oil spot prices and futures prices by maturity terms: Deep learning approaches to futures-based forecasting. *Results in Engineering*, 24, 103086.

Li, J., Hong, Z., Zhang, C., Wu, J., & Yu, C. (2024). A novel hybrid model for crude oil price forecasting based on MEEMD and Mix-KELM. *Expert Systems with Applications*, 246, 123104.

Li, M. (2024). Prediction of the West Texas Intermediate Crude Oil Price Using ARIMA Model and ARIMA-GARCH Model. *School of Statistics and Management*, 110-118.

- Liang, Q., Lin, Q., Guo, M., Lu, Q., & Zhang, D. (2025). Forecasting crude oil prices: A Gated Recurrent Unit-based nonlinear Granger Causality model. *International Review of Financial Analysis*, 102, 104124.
- Liu, L., Zhou, S., Jie, Q., Du, P., Xu, Y., & Wang, J. (2024). A robust time-varying weight combined model for crude oil price forecasting. *Energy*, 299, 131352.
- Mienye, I. D., Swart, T. G., & Obaido, G. (2024). Recurrent neural networks: A comprehensive review of architectures, variants, and applications. *Information*, 15(9), 517.
- Rao, A., Sharma, G. D., Tiwari, A. K., Hossain, M. R., & Dev, D. (2025). Crude oil Price forecasting: Leveraging machine learning for global economic stability. *Technological Forecasting and Social Change*, 216, 124133.
- Sen, A., & Choudhury, K. D. (2024). Forecasting the Crude Oil prices for last four decades using deep learning approach. *Resources Policy*, 88, 104438.
- Xu, Y., Liu, T., Fang, Q., Du, P., & Wang, J. (2025). Crude oil price forecasting with multivariate selection, machine learning, and a nonlinear combination strategy. *Engineering Applications of Artificial Intelligence*, 139, 109510.
- Yang, Y. T., Yang, T. Y., Chen, S. H., & Tong, C. V. (2022). Exploring the non-linearity of West Texas Intermediate crude oil price from exchange rate of US dollar and West Texas Intermediate crude oil production. *Energy Strategy Reviews*, 41, 100854.
- Yu, K., He, X. J., Han, X., Luo, X., & Lin, S. (2025). Forecasting crude oil option prices with dynamic factors using integrated machine learning models. *Communications in Nonlinear Science and Numerical Simulation*, 108879.
- Zaranejad, M., Kiani, P., Ebrahimi, S., & Raoufi, A. (2012). OPEC Crude Oil Price Prediction Using Fuzzy Autoregressive Integrated Moving Average Model. *Environmental Economics and Energy Quarterly*, 2(5), 107-127. (In Persian)
- Zhai, D., Zhang, T., Liang, G., & Liu, B. (2025). Research on crude oil futures price prediction methods: A perspective based on quantum deep learning. *Energy*, 320, 135080.
- Zhang, C., & Zhou, X. (2024). Forecasting value-at-risk of crude oil futures using a hybrid ARIMA-SVR-POT model. *Heliyon*, 10(1).

-
- Zhang, J. L., Zhang, Y. J., & Zhang, L. (2015). A novel hybrid method for crude oil price forecasting. *Energy Economics*, 49, 649-659.
- Zhang, Y., Hu, T., & Xiao, S. (2025). Forecasting crude oil price volatility with uncertainty: New modeling with multivariate selection. *Finance Research Letters*, 107442.
- Zheng, G., Li, Y., & Xia, Y. (2025). Crude Oil Price Forecasting Model Based on Neural Networks and Error Correction. *Applied Sciences*, 15(3), 1055.
- Zheng, L., Sun, Y., & Wang, S. (2024). A novel interval-based hybrid framework for crude oil price forecasting and trading. *Energy Economics*, 130, 107266.
- Zhu, S., Xu, M., Wu, J., Wang, Y., Jiang, X., Huang, Z., & Zhu, Y. (2025). A Study on Crude Oil Price Forecasting Model Integrating CEEMDAN-VMD Multiscale Decomposition with CNN-BiLSTM. *Results in Engineering*, 106391.