

Modeling of Artificial Intelligence Non-linear Algorithms in Oil Price Forecasting

Sajad Piri 

Ph.D. Student of Accounting, Department of Accounting, West Tehran Branch, Islamic Azad University, Tehran, Iran.

Zahra Farshadfar 

Assistant Professor, Department of Accounting, West Tehran Branch, Islamic Azad University, Tehran, Iran.

Abstract

High fluctuations in the price of crude oil, as the main source of energy and an important raw material of the global chemical industry, has doubled the importance of accurate estimation and forecasting of its price trend in recent years. The purpose of this applied research, is to increase the ability to predict crude oil prices using non-linear patterns by artificial intelligence. For this purpose, four artificial intelligence networks MLP, RNN, LSTM and GRU have been used and their capabilities compared to each other and the benchmark model, besides their prediction accuracy have been evaluated using the mean squared error method. The studied sample is North Sea Brent crude oil data from Aug 1st 2007 to May 31st 2024 on a daily, monthly and yearly basis.

The results of the research indicate that the network architecture in these models have several advantages in extracting information from the data in order to make more accurate predictions, and the time to obtain future prices is shorter and less error-prone. Also, among the selected non-linear models, GRU has more accurate predictions with less error in different frequencies and in a shorter time.

Introduction

As oil price fluctuations affect both oil exporting and importing countries in different ways, crude oil price is one of the most important key variables in international trade (Salik and Khorsandi, 2022), As a result, policymakers and oil market experts pay attention to its price and its fluctuations. The price of crude oil in the market is the result of many fundamental and non-fundamental factors (Shakri *et al.*, 2018). Therefore, it is not simply possible to categorize and model all the factors affecting the price of crude oil. Since all the basic and non-basic factors that affect the price formation will finally appear in the price of crude oil, it is necessary to pay attention to the price and its fluctuations (Yadgari *et al.*, 2022). Previous research indicate that the trend of oil price changes follows a non-linear pattern (Guo, 2019);

* Corresponding Author: zfarshadfar@yahoo.com

How to Cite: Piri, S., Farshadfar, Z. (2024). Modeling of Artificial Intelligence Non-linear Algorithms in Oil Price Forecasting. Iranian Energy Economics, 51 (13), 191-215.

and among the non-linear models used in predicting the price of oil, models based on artificial intelligence have shown better results (Gumus and Kiran, 2017; Zhao *et al.*, 2017; Gao *et al.*, 2022). Therefore, the purpose of this research is to improve crude oil prices out-of-sample prediction using non-linear machine learning algorithms. It is assumed that this non-linear long-short-term memory method has better performance than historical average method and multilayer perceptron network and recurrent network.

Methods and Material

The purpose of this applied research, is to increase the ability to predict crude oil prices using non-linear patterns by artificial intelligence. For this purpose, four artificial intelligence networks MLP, RNN, LSTM and GRU have been used and their capabilities compared to each other and the benchmark model, besides their prediction accuracy have been evaluated using the mean squared error method. The studied sample is North Sea Brent crude oil data from Aug 1st 2007 to May 31st 2024 on a daily, monthly and yearly basis.

Results and Discussion

The results of the research indicate that nonlinear neural network models have a better ability in predicting crude oil price in different daily, monthly and yearly frequencies with different volumes of training data compared to historical average linear model and it has less error. These findings are consistent with the results of Farshadfar and Prokopczuk (2019), Luo *et al.* (2022) and Zang *et al.* (2020).

Calculations and estimation of the studied models show that the MSFE prediction criterion in all the samples used by the GRU is better than other networks. It also indicates that with the increase in training data amount, network prediction power increases.

Conclusion

It can be concluded that the network architecture in these models have several advantages in extracting information from the data in order to make more accurate predictions, and the time to obtain future prices is shorter and less error-prone. Besides that, among the selected non-linear models, GRU has provided more accurate predictions with less errors in different frequencies and in a shorter time.

Acknowledgments

Authors would like to appreciate Eng. Behzad Alipour for his kind collaboration in program coding.

Keywords: Crude Oil, Energy, Machine learning, Neural Network, Recurrent Networks

JEL Classification: C22 , C52 , C53



مدلسازی الگوریتم‌های غیر خطی هوش مصنوعی در پیش‌بینی قیمت نفت

دانشجوی دکتری رشته حسابداری، گروه حسابداری، واحد تهران غرب، دانشگاه آزاد اسلامی، تهران، ایران.

سجاد پیری 

استادیار، گروه حسابداری، واحد تهران غرب، دانشگاه آزاد اسلامی، تهران، ایران.

زهره فرشادفر* 

چکیده

نوسانات زیاد قیمت نفت خام به عنوان منبع اصلی انرژی و ماده اولیه مهم صنعت شیمیایی جهانی، اهمیت تخمین دقیق و پیش‌بینی روند قیمت آنرا دوچندان کرده است. از اینرو هدف از انجام پژوهش کاربردی حاضر افزایش توان پیش‌بینی قیمت نفت خام با استفاده از الگوریتم‌های غیرخطی در هوش مصنوعی است. برای دستیابی به این هدف چهار شبکه پرسپترون ساده، شبکه بازگشتی، شبکه حافظه طولانی کوتاه مدت و شبکه عصبی واحدهای برگشتی گیت دار مدلسازی شده است سپس توانمندی آن‌ها نسبت به یکدیگر و مدل معیار مقایسه، و دقت پیش‌بینی آن‌ها با استفاده از روش خطای مربعات میانگین اشتباهات ارزیابی شده است. نمونه مورد مطالعه داده‌های نفت خام برنت دریای شمال از تاریخ ۲۰۰۷/۰۸/۰۱ لغایت ۲۰۲۴/۰۵/۳۱ به صورت روزانه و ماهانه و سالانه است. نتایج پژوهش نشان می‌دهد که معماری شبکه در این مدل‌ها نسبت به مدل‌های پیشین، در استخراج اطلاعات از داده‌ها توانمندتر بوده و زمان دستیابی به قیمت‌های آینده بهبود بخشیده شده است. همچنین از میان الگوهای غیرخطی، الگوی شبکه بازگشتی گیت دار در فرکانس‌های مختلف پیش‌بینی دقیق‌تر و با خطای کمتری از قیمت نفت را به دست می‌دهد.

کلیدواژه‌ها: انرژی، شبکه‌های بازگشتی، شبکه عصبی، نفت خام، یادگیری ماشین

طبقه‌بندی JEL: C22 , C52 , Q53

۱. مقدمه

قیمت نفت خام یکی از مهمترین متغیرهای کلیدی در مبادلات تجاری بین‌المللی است و به دلیل تأثیری که نوسانات قیمت آن بر ابعاد مختلف روابط سیاسی و اقتصادی کشورها گذاشته است همواره در مرکز توجه قرار داشته است (ایازی و همکاران، ۱۳۹۹)، زیرا نوسانات قیمت نفت، هر دو کشور صادرکننده و واردکننده نفت را به نوعی متأثر ساخته و متعاقباً سبب اختلال در روند عادی فعالیت‌های اقتصادی این کشورها می‌شود (سالک و خورسندی، ۱۴۰۲).

قیمت نفت خام تحت تأثیر عوامل زیادی است و روندهای حاکم بر آن پیچیده و دارای الگوهای غیرخطی است. درواقع، قیمت نفت خام در بازار حاصل برآیند عوامل بنیادین و غیر بنیادین (جنگ و عملیات تروریستی، ناآرامی، اغتشاشات ملی و منطقه‌ای، وضعیت آب و هوایی، تنش و اعتصابات در کشورهای تولیدکننده نفت خام، خط مشی نفتی اوپک، رشد اقتصادی و حتی انتظارات معامله‌گران) است (شاگری و همکاران، ۱۳۹۸) و به سادگی نمی‌توان تمام عوامل موثر بر قیمت نفت خام را دسته‌بندی و مدل‌سازی کرد. بنابراین کارشناسان بازار نفت، به قیمت و روند تغییرات آن توجه می‌کنند. زیرا تأثیر برآیند تمام عوامل بنیادین و غیربنیادین بر شکل‌گیری قیمت، نهایتاً در قیمت نفت خام بروز خواهد نمود. به عبارت بهتر این عوامل به نحوی در قیمت مستتر هستند (یادگاری و همکاران، ۱۴۰۰).

مدل‌های پیش‌بینی قیمت بیشماری ایجاد شده است و پژوهش‌های بسیاری برای یافتن یک مدل مناسب برای پیش‌بینی قیمت نفت خام انجام شده است. در پاره‌ای از این پژوهش‌ها از روش‌های تجزیه و تحلیل سنتی مانند روش میانگین متحرک، هموارسازی نمایی، مدل خودرگرسیون متوالی متغیرهای تصادفی^۱ و سایر مدل‌های اقتصادسنجی برای پیش‌بینی قیمت نفت استفاده شده است، اما این رویکردها به‌طور کلی فقط برای سیستم‌های خطی مناسب هستند این در حالیست که شواهد گویای آن است که بازار قیمت نفت خام دارای الگوی غیرخطی و با فرکانس بالا است و الگوهای خطی برای این بازار چندان قابل اعتماد نیستند (دفاریا و همکاران^۲ (۲۰۰۶)، فونگ و یونگ^۳ (۲۰۰۵)،

1. Autoregressive Integrated Moving Average (ARIMA)

2. De Faria et al.

3. Fong and Yong

گوا^۱ (۲۰۱۹)). در پژوهش‌های جدید تلاش شده است تا از یادگیری ماشین و تکنیک‌های یادگیری عمیق برای پیش‌بینی قیمت نفت خام استفاده شود (گائو و همکاران^۲ (۲۰۲۲)، گوموس و کران^۳ (۲۰۱۷)، ژائو و همکاران^۴ (۲۰۱۷)). با این حال بررسی پژوهش‌های صورت گرفته در زمینه کاربرد الگوهای غیرخطی شبکه عصبی در پیش‌بینی قیمت نفت نشان می‌دهد که اولاً استفاده از الگوهای غیرخطی در پیش‌بینی قیمت نفت خام به صورت روند تکامل این شبکه‌ها از ساده به عمیق در پیش‌بینی قیمت است. اما پژوهشی مبنی بر مقایسه توان پیش‌بینی شبکه‌های غیرخطی با ساختار متفاوت یافت نشد. از نوآوری‌های این پژوهش آن است که به مقایسه توان پیش‌بینی شبکه‌های غیرخطی به‌طور هم‌زمان می‌پردازد.

ثانیاً در این پژوهش‌ها برای بررسی توان شبکه در پیش‌بینی داده‌های خارج از نمونه ابتدا داده‌ها به دو بخش آموزش و تست تقسیم شده‌اند و معمولاً از یک نسبت تست که به صورت ۵۰ درصد آموزش و ۵۰ درصد تست است استفاده شده است. در این پژوهش از سه نسبت آموزش به تست برای ارزیابی توان شبکه در پیش‌بینی داده‌های خارج از نمونه استفاده شده است که این از نوآوری‌های دیگر این پژوهش است.

نکته سوم آن است که پژوهش‌های صورت گرفته در زمینه پیش‌بینی قیمت نفت معمولاً در یک افق زمانی سالانه یا ماهانه و یا روزانه به پیش‌بینی قیمت می‌پردازند از نوآوری‌های دیگر این پژوهش آن است که به مقایسه توانایی پیش‌بینی این شبکه‌ها در سه دوره کوتاه‌مدت و میان‌مدت و بلندمدت پرداخته است.

در این پژوهش تلاش شده است تا با استفاده از چهار شبکه غیرخطی پرسپترون^۵، شبکه بازگشتی^۶، شبکه حافظه طولانی کوتاه‌مدت^۷ و شبکه عصبی واحدهای برگشتی گیت‌دار^۸ به پیش‌بینی قیمت نفت خام در افق‌های کوتاه‌مدت (روزانه)، میان‌مدت (ماهانه) و بلندمدت (سالانه) پرداخته و دقت پیش‌بینی قیمت‌های خارج از نمونه در فرکانس‌های

1. Guo

2. Gao et al.

3. Gumus and Kiran

4. Zhao and et al.

5. Multilayer perceptron (MLP)

6. Recurrent Neural Network (RNN)

7. Long short-term memory (LSTM)

8. Gate Recurrent Unit (GRU)

مختلف ۱ و ۳ و ۶ و ۹ دوره جلوتر را بهبود بخشد، همچنین نکات سه گانه فوق را نیز مدنظر قرار داده و به محاسبه آن‌ها پردازد. از این‌رو هدف از انجام این پژوهش بهبود پیش‌بینی خارج از نمونه قیمت نفت خام با استفاده از الگوریتم‌های غیرخطی یادگیری ماشین است. فرض بر آن است که این روش غیرخطی حافظه طولانی کوتاه مدت عملکرد بهتری نسبت به روش میانگین تاریخی و شبکه پرسپترون چندلایه و شبکه بازگشتی دارد. در ادامه مروری بر پژوهش‌های صورت گرفته در زمینه پیش‌بینی قیمت خواهیم داشت سپس روش پژوهش توضیح داده خواهد شد و نهایتاً نتایج و بحث ارائه می‌شود.

۲. ادبیات نظری و پیشینه پژوهش

افزایش قیمت نفت خام در دهه ۷۰ میلادی به دلایل سیاسی و اقتصادی در فعالان بازار نفت این باور را به وجود آورد که روند صعودی قیمت نفت ادامه خواهد داشت از این‌رو اندیشمندان اقتصادی در محافل علمی بر آن شدند تا الگوها و نظریه‌هایی را در ارتباط با تعیین قیمت نفت خام تنظیم نمایند تا از آن طریق بتوانند نوسانات قیمت نفت خام را توضیح دهند که از آن جمله می‌توان به نظریه حق مالکیت، نظریه عرضه باقیمانده، نظریه هتلینگ، نظریه بازی‌ها، نظریه رقابتی، نظریه هدف درآمدی و قانون والراس و مارشال اشاره کرد (امامی میدی، ۱۳۸۵).

بررسی عوامل مؤثر بر نوسانات قیمت نفت خام براساس نظریه هتلینگ (نظریه اقتصادی نحوه بهره‌برداری از منابع طبیعی پایان‌پذیر) در پژوهش حاضر قابل توضیح خواهد بود. هارولد هتلینگ، در سال ۱۹۳۱ در مقاله‌ای به نام «اقتصاد منابع پایان‌پذیر» در مورد استخراج و یا عدم استخراج نفت خام بحث نموده است. وی در سال ۱۹۳۱ نظریه اقتصادی نحوه بهره‌برداری از منابع طبیعی پایان‌پذیر را ارائه کرد و این نظریه به تدریج توسعه یافت. چارچوب نظری هتلینگ، بازار آزاد و بدون دخالت دولت است. در نظریه هتلینگ فرض بر این است که هزینه نهایی استخراج ثابت بوده و با در نظر گرفتن نرخ تنزیل استدلال می‌شود که در شرایط رقابت کامل، بایستی اختلاف قیمت منبع طبیعی و هزینه نهایی استخراج متناسب با نرخ تنزیل افزایش یابد و در شرایط انحصاری، اختلاف درآمد نهایی و هزینه نهایی استخراج بایستی متناسب با نرخ تنزیل افزایش یابد. صاحب منبع طبیعی (میدان نفتی) دو سناریو در پیش‌رو دارد: او می‌تواند نفت را استخراج کرده و بفروشد و یا این کار را در آینده انجام دهد. اگر این کار را اکنون انجام دهد، می‌تواند درآمد حاصل از فروش

نفت را در بانک قرار داده و از بانک سود دریافت کند. همچنین می‌تواند نفت را در آینده استخراج نماید. در آن صورت او فقط درآمدی معادل فروش نفت به قیمت بازار را خواهد داشت که مقدار آن با فرض قیمت ثابت نفت در بازار به اندازه نرخ بازگشت سالیانه سرمایه از مقدار قبلی کمتر است. تنها عاملی که باعث می‌شود صاحب مخزن نفت را در آینده استخراج کند، آن است که حداقل قیمت نفت با نرخ تنزیل و یا نرخ بازگشت سرمایه افزایش یابد. درواقع براساس نظریه هتلینگ صاحب منبع طبیعی به دنبال حداکثرسازی ارزش حال منافع آینده است.

بر این اساس، شناخت بازار نفت و عوامل مؤثر بر قیمت نفت خام به منظور تحلیل وضعیت حال و آتی درآمدهای نفتی بسیار ضروری است و از اهمیت بالایی در سیاستگذاری و توسعه اقتصادی برخوردار است. از این رو، پیش‌بینی قیمت نفت نه تنها نقش مؤثری در سیاست دولت‌ها ایفاء می‌کند، بلکه بر بهینه‌سازی میزان تولید در بلندمدت نیز بسیار مؤثر خواهد بود. بنابراین پیش‌بینی ابزار مهمی در جهت اخذ تصمیمات استراتژیک و آینده پژوهی است، چرا که اطلاعات بسترهای لازم برای فرآیند تصمیم‌سازی و سناریوسازی را فراهم می‌کند. اهمیت نفت خام در مبادلات تجاری و تأمین امنیت عرضه انرژی در کشورهای صنعتی و همچنین اهمیت آن در تأمین امنیت تقاضا و امنیت درآمدی کشورهای تولیدکننده، سبب شده است تا پژوهش‌های زیادی در داخل و خارج از کشور در ارتباط با پیش‌بینی قیمت نفت خام صورت پذیرد. در ادامه به پاره‌ای از مطالعات صورت گرفته در داخل و خارج از کشور پرداخته شده است.

لئو و همکاران^۱ (۲۰۲۲) به پیش‌بینی قیمت نفت با استفاده از روش شبکه‌های عصبی عمیق و مقایسه دقت آن با روش‌های سنتی اقتصادسنجی پرداخته و نتیجه می‌گیرد که روش‌های یادگیری ماشین دقت بهتری در پیش‌بینی دارند.

زانگ و همکاران^۲ (۲۰۲۰) به پیش‌بینی قیمت نفت با استفاده از روش شبکه‌های عصبی عمیق پرداخته و نتیجه آن را با مدل خطی خودرگرسیون متوالی متغیرهای تصادفی مقایسه می‌کند و نتیجه می‌گیرد که مدل غیرخطی توان پیش‌بینی بهتری در پیش‌بینی قیمت نفت دارد.

1. Luo et al.

2. Zhang et al.

ژانگ و همکاران^۱ (۲۰۱۹) به پیش‌بینی قیمت نفت با استفاده از روش‌های سنتی خودرگرسیون متوالی متغیرهای تصادفی و گارچ^۲ پرداخته‌اند و نتیجه می‌گیرند که الگوسازی و پیش‌بینی با این روش‌ها ساده است.

فرشادفر و پروکوپچوک (۲۰۱۹) به پیش‌بینی قیمت نفت با استفاده از روش شبکه‌های عصبی عمیق ساده پرداخته و به مقایسه قدرت پیش‌بینی این مدل با مدل‌های اقتصاد سنجی خطی پرداخته‌اند و نتیجه می‌گیرند که شبکه عمیق قدرت پیش‌بینی بهتری دارد.

وانگ، سانگ و لی^۳ (۲۰۱۸) به پیش‌بینی قیمت نفت با استفاده از روش شبکه‌های عصبی عمیق ساده پرداخته و به مقایسه قدرت پیش‌بینی این مدل با مدل سنتی میانگین متحرک خودهمبسته یکپارچه^۴ (آریما) پرداخته‌اند آن‌ها نتیجه می‌گیرند که الگوهای غیرخطی دقت بهتری در پیش‌بینی دارند.

سالک و خرسندی (۱۴۰۲) برای پیش‌بینی قیمت نفت از سه روش تلفیقی شامل شبکه عصبی و سیستم معادلات همزمان، آریما و سیستم معادلات همزمان، شبکه عصبی و میانگین متحرک خودهمبسته یکپارچه (آریما) و سیستم معادلات همزمان با روش‌های مرسوم و تک متغیره شبکه عصبی و میانگین متحرک خودهمبسته یکپارچه (آریما) پرداخته است. نتایج آن‌ها نشان می‌دهد که روش تلفیقی میانگین متحرک خودهمبسته یکپارچه (آریما) و سیستم معادلات همزمان در پیش‌بینی ۵ ساله و روش تلفیقی شبکه عصبی، میانگین متحرک خودهمبسته یکپارچه (آریما) و سیستم معادلات همزمان در پیش‌بینی ده ساله از قدرت پیش‌بینی‌کنندگی بهتری نسبت به روش‌های مرسوم و تک متغیره شبکه عصبی و میانگین متحرک خودهمبسته یکپارچه (آریما) برخوردار است.

یادگاری و همکاران (۱۴۰۱) به پیش‌بینی قیمت نفت با استفاده از الگوی خاکستری در بازه زمانی سال‌های ۲۰۱۵ تا ۲۰۲۱ می‌پردازند آن‌ها نتیجه می‌گیرند که مدل ترکیبی توانایی بالاتری جهت توضیح و پوشش نوسانات قیمت در بازه‌های مختلف زمانی را داشته و قابل اطمینان‌تر از مدل منفرد است. لذا می‌توان از مدل ترکیبی به جای مدل‌های مبتنی بر نظریه منفرد برای پیش‌بینی دقیق‌تر استفاده کرد.

1. Zhang et al.

2. Generalized autoregressive conditional heteroscedasticity (GARCH)

3. Wang and Song and Li.

4. ARIMA

عباسی‌نامی (۱۴۰۰) از انواع مدل‌های گارچ جهت پیش‌بینی قیمت نفت خام استفاده کرده است و نتیجه می‌گیرد که این مدل‌ها توان پیش‌بینی درون نمونه‌ای خوبی دارند. لاری خلیلی و سمنانی (۱۳۹۷) به پیش‌بینی قیمت نفت با استفاده از درخت دوتایی و شبکه‌های عصبی و توابع سری زمانی پرداخته است و نتیجه می‌گیرد شبکه‌های عصبی دقت خوبی در پیش‌بینی دارند.

مطالعه پژوهش‌های پیشین نشان می‌دهد که این پژوهش‌ها با افزایش یا تغییر تعداد عوامل اثرگذار بر قیمت نفت خام یا تغییر مدل‌های خطی و در نهایت استفاده از الگوهای غیرخطی سعی در بهبود پیش‌بینی قیمت نفت خام داشته‌اند. همچنین تمرکز این پژوهش‌ها بیشتر بر پیش‌بینی‌های درون نمونه‌ای است و در صورت پرداختن به پیش‌بینی‌های خارج از نمونه از فرکانس‌های مختلف استفاده نشده است. اما پژوهش حاضر کوشیده است تا به مقایسه توانمندی مدل‌های غیرخطی در پیش‌بینی دقیق‌تر قیمت نفت، به صورت مقایسه توانمندی پیش‌بینی داده‌های خارج از نمونه در دوره‌های یک و سه و شش و نه دوره جلوتر پردازد و این از نوآوری‌های این پژوهش است. با توجه به مطالعات صورت گرفته در زمینه پیش‌بینی قیمت نفت خام، فرضیه اصلی این پژوهش آن است که شبکه عصبی واحدهای برگشتی گیت‌دار توان بهتری در پیش‌بینی قیمت نفت خام نسبت به سایر شبکه‌های غیرخطی و مدل میانگین تاریخی دارد.

۳. روش پژوهش

پژوهش حاضر پژوهشی کاربردی است که به پیش‌بینی قیمت نفت خام براساس الگوهای غیرخطی شبکه عصبی می‌پردازد. برای این منظور از چهار شبکه عصبی پرسپترون چند لایه و شبکه عصبی بازگشتی حافظه طولانی کوتاه‌مدت و شبکه عصبی واحدهای برگشتی گیت‌دار استفاده شده و توانایی پیش‌بینی قیمت نفت آن نسبت به یکدیگر در سه افق کوتاه‌مدت (روزانه) و میان‌مدت (ماهانه) و بلندمدت (سالانه) و در فرکانس ۱، ۳، ۶ و ۹ دوره جلوتر با یکدیگر مقایسه شده است. به این منظور از داده‌های نفت خام برنت دریای شمال از تاریخ ۲۰۰۷/۰۸/۰۱ لغایت ۲۰۲۴/۰۵/۳۱ به صورت روزانه، ماهانه و سالانه استفاده شده است.

برای بررسی توان شبکه در پیش‌بینی داده‌های خارج از نمونه ابتدا داده‌ها به دو بخش آموزش و تست تقسیم می‌شوند. نسبت تقسیم به گونه‌ای انتخاب می‌شود که بخش

آموزش سهم کافی برای یادگیری مدل را داشته باشد و بخش تست برای ارزیابی عملکرد آن به کار رود. در این پژوهش از سه نسبت آموزشی استفاده شده است ابتدا شبکه با ۷۰ درصد داده‌ها آموزش داده شده و خروجی گرفته شده است، سپس با ۵۰ درصد داده‌ها و در انتها با ۳۰ درصد داده‌ها این فرآیند تکرار شده و خروجی گرفته شده است (به این صورت که نخست ۷۰ درصد از داده‌ها برای تخمین و ۳۰ درصد برای پیش‌بینی کنار گذاشته شدند، در مرحله دوم ۵۰ درصد از داده‌ها برای تخمین و ۵۰ درصد برای پیش‌بینی کنار گذاشته شدند و در مرحله سوم ۳۰ درصد از داده‌های نمونه برای تخمین و ۷۰ درصد برای پیش‌بینی کنار گذاشته شدند).

۴. مدل پژوهش

در این پژوهش به منظور پیش‌بینی قیمت نفت خام خارج از نمونه از چهار شبکه متفاوت هوش مصنوعی استفاده شده که هر یک نسخه توسعه یافته از شبکه قبلی است، در مطالعات قبلی در زمینه پیش‌بینی قیمت در بازارهای مالی مانند ریچ^۱ (۲۰۱۰) و نارایان و وسترلند^۲ (۲۰۱۲)، پیش‌بینی‌پذیری قیمت براساس مدل رگرسیون زیر آزمون شده است:

$$P_{t+h} = \alpha + \beta x_t + \epsilon_{t+h} \quad (1)$$

که در آن P_{t+h} قیمت نفت خام است و x_t متغیر پیش‌بینی کننده (در این مطالعه قیمت نفت خام دوره قبل) است.

در این پژوهش با فرض وجود ویژگی‌های^۳ (باقیمانده‌ها) u_t که از اطلاعات زمان t استخراج شده است به دنبال یک تابع پیش‌بینی کننده f برای پیش‌بینی قیمت نفت خام در زمان $t+1$ هستیم. فرض بر آن است که P_{t+1} از دو بخش تشکیل شده است: خروجی قابل پیش‌بینی $f(u_t) = I_{t+1}$ و بخش غیر قابل پیش‌بینی γ یا نویز گوسی که دارای میانگین صفر و واریانس β است:

$$P_{t+1} = \hat{P}_{t+1} + \gamma, \quad \gamma \sim N(0, \beta) \quad (2)$$

u_t می‌تواند یک تبدیل خطی یا غیرخطی از اطلاعات خام (R_t) باشد. اگر تابع تبدیل را با ϕ نشان دهیم داریم:

1. Rapach
2. Narayan and Westerlund
3. Features (Representation)

$$u_t = \varphi(R_t) \quad (۳)$$

$$\hat{P}_{t+1} = f \circ \varphi(R_t) \quad (۴)$$

بخشی از این اطلاعات خام در متغیر پیش‌بینی‌کننده که در این پژوهش مقادیر با یک وقفه نفت خام (h) است وجود دارد از این رو می‌توان رابطه ۴ را به صورت زیر بازنویسی کرد:

$$R_{t+1} = \delta(W h_1 + b) \quad (۵)$$

δ تابع فعال‌سازی نامیده می‌شود و ماتریس W و بردار b پارامترهای مدل‌اند. زمانی که تنها یک لایه وجود داشته باشد این رابطه نمایانگر یک شبکه عصبی تک لایه است. در شبکه‌های عصبی چندلایه، لایه‌ها با روش‌های پیشرفته یادگیری افزوده می‌شوند شبکه چندلایه برای عملکرد پیش‌بینی شده، $y = f(u)$ ، می‌تواند توسط جمع کردن سریالی توابع شبکه به صورت زیر ساخته شود:

$$\begin{aligned} h_1 &= \delta_1(W_{1u} + b_1) \\ h_2 &= \delta_2(W_{2h_1} + b_2) \\ y &= \delta_L(W_L h_{L-1} + b_L) \end{aligned} \quad (۶)$$

L که در آن تعداد لایه‌ها است. با توجه به یک مجموعه مشخص از ورودی‌ها و خروجی $\{u^n, \tau^n\}_{n=1}^N$ و یک تابع خطا $\varepsilon(y^n, \tau^n)$ که اختلاف بین خروجی $y^n = f(u^n)$ و هدف τ^n را اندازه‌گیری می‌کند، پارامترهای مدل $\theta = \{W_1, \dots, W_L, b_1, \dots, b_L\}$ برای کل شبکه می‌تواند به گونه‌ای انتخاب شود که مجموع خطاهای زیر را به حداقل برساند:

$$\min_0 [J = \sum_{n=1}^N \varepsilon(y^n, \tau^n)] \quad (۷)$$

با توجه به انتخاب مناسب $\varepsilon(\cdot)$ ، گرادینان آن را می‌توان از طریق تجزیه و تحلیل خطا به دست آورد (بیشاپ^۱، ۲۰۰۶). در مورد رابطه (۷)، مسئله حداقل‌سازی را می‌توان با روش گرادینان کاهش‌ی شبیه‌سازی و حل کرد. در این پژوهش تابع هدف به صورت زیر انتخاب شده است:

$$J = \frac{1}{N} \sum_{n=1}^N \|y^n - \tau^n\|^2 + \lambda \cdot \sum_{l=1}^L \|W_l\|_2 \quad (۸)$$

که در آن $\|\cdot\|_2$ و $\|\cdot\|_2$ به ترتیب فرم اقلیدسی ماتریس L_2 را مشخص می‌کنند. جمله دوم یک «تنظیم‌کننده»^۲ است که برای جلوگیری از بیش‌برازش^۳ اضافه می‌شود، در حالی که λ یک ضریب تعریف شده توسط کاربر است.

1. Bishop

برای آموزش شبکه تابع پیش‌بینی $\hat{f}_{i,t+1} = f_i(u_t), i = 1, \dots, M$ را با استفاده از شبکه چندلایه ایجاد می‌کنیم، به صورت زیر:

$$\begin{aligned} h_1 &= \text{ReLU}(W_1 u_t + b_1) \\ h_2 &= \text{ReLU}(W_2 h_1 + b_2) \\ \hat{f}_{i,t+1} &= W_3 h_2 + b_3 \quad \text{and} \quad \text{ReLU}(x) = \max(x, 0) \end{aligned} \quad (9)$$

تابع فعال‌سازی یکسوکننده خطی تصحیح شده^۳ دارای سرعت یادگیری بسیار سریعتر از تابع فعال‌سازی زیگموئید^۴ است، که این سبب بهبود عملکرد در شبکه‌های عصبی چندلایه می‌شود (نایر و هینتون^۵، ۲۰۱۰). با یک مجموعه از ویژگی‌ها (داده‌های خام) به‌عنوان ورودی، شبکه عصبی از طریق به حداقل رساندن تابع هدف تعریف شده در معادله (۹) آموزش می‌بیند.

تعداد تکرار ۱۰۰۰ و ضریب تنظیم، $\lambda = 0.001$ است. به این ترتیب چهار شبکه عصبی پرسپترون چندلایه^۶، شبکه بازگشتی ساده^۷ و شبکه حافظه طولانی کوتاه‌مدت و شبکه بازگشتی گیت‌دار طراحی شده‌اند. معماری شبکه‌های عصبی مختلف بدین صورت است که شبکه پرسپترون چندلایه دارای ۵ لایه پنهان بوده و تعداد نورون‌ها در هر لایه پنهان به ترتیب برابر با ۱۰۰، ۶۰، ۴۰، ۴۰ می‌باشد. توابع فعال‌سازی یکسوکننده خطی تصحیح شده در تمام لایه‌های پنهان به جز لایه خروجی استفاده شده است. در لایه خروجی از تابع یکسوکننده خطی تصحیح شده با شیب صاف^۸ استفاده شده است. برای شبکه بازگشتی ساده از ۲ لایه میانی، ۵۰ نورون در هر لایه و تابع فعال‌سازی یکسوکننده خطی تصحیح شده در تمام لایه‌ها استفاده شده است.

در شبکه حافظه بلندمدت کوتاه از ۳ لایه میانی و ۵۰ نورون در هر لایه و تابع فعال‌سازی یکسوکننده خطی تصحیح شده در تمام لایه‌ها استفاده شده است. به دلیل توانایی در حفظ اطلاعات بلندمدت در این شبکه از لایه‌های بیشتری نسبت به شبکه بازگشتی ساده استفاده

-
1. Regularizer
 2. Over fitting
 3. Rectified linear Unit (ReLU)
 4. Sigmoid
 5. Nair and Hinton
 6. MLP
 7. RNN
 8. Scaled Exponential linear Unit (SeLU)

شده است. وجود ۵۰ نورون در هر لایه ظرفیت کافی برای یادگیری الگوهای پیچیده در داده‌های سری زمانی را فراهم می‌کند و در نهایت انتخاب ۲ لایه میانی و ۵۰ نورون در هر لایه و تابع فعالسازی یکسوکننده خطی تصحیح شده در تمام لایه‌ها انتخاب خوبی برای شبکه واحد بازگشتی گیت‌دار است. برای طراحی شبکه از کتابخانه کراس^۱ و کتابخانه تسورفلو^۲ در پایتون ۳/۶ آناکوندا^۳ استفاده شده است.

در این پژوهش نیز به تبعیت از ریچ و همکاران^۵ (۲۰۱۰) و ولش و گوئیال^۶ (۲۰۰۸) از مدل میانگین تاریخی به عنوان مدل معیار یا مبنای مقایسه استفاده شده که به صورت زیر محاسبه می‌شود:

$$\hat{p}_{T_0+1} = \frac{1}{T_0} \sum_{j=1}^{T_0} p_j \quad (10)$$

به پیروی از ادبیات اقتصادی، متداولترین معیار برای ارزیابی دقت پیش‌بینی بین مدل‌ها، خطای مربعات میانگین اشتباهات^۷ پیش‌بینی‌ها است که در این پژوهش نیز مورد استفاده قرار گرفته است و به صورت زیر محاسبه می‌شود:

$$MSFE = \frac{1}{n} \sum_{j=1}^n (p_{T_0+j} - \hat{p}_{T_0+j})^2 \quad (11)$$

که در آن $\hat{p}_{T_0+j}$ قیمت تخمینی، p_{T_0+j} قیمت واقعی T_0 و n تعداد مشاهدات در نمونه و خارج از نمونه است.

۵. یافته‌ها

جهت پیش‌بینی قیمت نفت خام نخست داده‌های پژوهش به دو دسته تقسیم شدند که دسته اول داده‌ها به منظور تخمین مدل و دسته دوم به منظور پیش‌بینی مورد استفاده قرار گرفتند. برای این منظور داده‌ها سه بار دسته‌بندی شده‌اند به این صورت که نخست ۷۰ درصد از داده‌ها برای تخمین و ۳۰ درصد برای پیش‌بینی کنار گذاشته شدند، در مرحله دوم ۵۰ درصد از داده‌ها برای تخمین و ۵۰ درصد برای پیش‌بینی کنار گذاشته شدند و در مرحله

-
1. Keras
 2. Tensor Flow
 3. Python 3.6
 4. Anaconda 3
 5. Rapach et al.
 6. Welch and Goyal
 7. Mean Square False Error (MSFE)

سوم ۳۰ درصد از داده‌های نمونه برای تخمین و ۷۰ درصد برای پیش‌بینی کنار گذاشته شدند. پس از تخمین مدل با دسته اول داده‌ها، دسته دوم داده‌ها برای پیش‌بینی بازده در سه افق زمانی روزانه (فرکانس‌های یک روز، سه روز، شش روز و نه روز جلوتر)، هفتگی (فرکانس‌های یک هفته، سه هفته، شش هفته و نه هفته جلوتر) و ماهانه (فرکانس‌های یک ماه، سه ماه، شش ماه و نه ماه جلوتر) مورد استفاده قرار گرفتند.

جدول ۱. MSFE محاسبه شده حاصل از روش میانگین تاریخی

داده‌های روزانه				
فرکانس	۱ روز	۳ روز	۶ روز	۹ روز
درصد آموزش				
۳۰ درصد	۰/۳۳۷۸	۰/۳۳۷۷	۰/۳۳۷۴	۰/۳۳۷۱
۵۰ درصد	۰/۰۰۴۱	۰/۰۰۴۱	۰/۰۰۴۱	۰/۰۰۴۱
۷۰ درصد	۰/۰۰۵۱	۰/۰۰۵۱	۰/۰۰۵۱	۰/۰۰۵۱
داده‌های ماهانه				
فرکانس	۱ ماه	۳ ماه	۶ ماه	۹ ماه
درصد آموزش				
۳۰ درصد	۰/۰۳۸۸	۰/۰۳۹۳	۰/۰۴۰۱	۰/۰۴۰۹
۵۰ درصد	۰/۰۳۱۰	۰/۰۳۱۵	۰/۰۳۲۴	۰/۰۳۳
۷۰ درصد	۰/۰۲۵	۰/۰۲۶۷	۰/۰۲۸۰	۰/۰۲۹۶
داده‌های سالانه				
فرکانس	۱ سال	۳ سال	۶ سال	۹ سال
درصد آموزش				
۳۰ درصد	۰/۴۰۰	۰/۴۲۸	۰/۶۱۸	–
۵۰ درصد	۰/۱۳۲	۰/۰۷۴	۰/۰۵۲۷	–
۷۰ درصد	۰/۰۹۱۸	۰/۰۳۵۲	–	–

منبع: محاسبات پژوهش

در ابتدا به تبعیت از ریچ و همکاران (۲۰۱۰) و ولش و گویال (۲۰۰۸) این تخمین‌ها برای مدل میانگین تاریخی به‌عنوان مدل معیار در سه دوره زمانی روزانه و ماهانه و سالانه و در چهار فرکانس گفته شده محاسبه شده و براساس میانگین مجذور اشتباه خطا هر دوره مقایسه شده است.

همان‌طور که در جدول ۱ مشاهده می‌شود توانایی پیش‌بینی قیمت نفت در این مدل در داده‌های روزانه نسبت به داده‌های ماهانه و سالانه بیشتر است همچنین در داده‌های روزانه

همراه با آموزش مدل با ۵۰ درصد از داده‌ها مدل، خطای کمتری از خود نشان می‌دهد. این نتیجه در داده‌های ماهانه صادق نیست و در این دوره زمانی با ۷۰ درصد داده‌های آموزشی نتیجه بهتری کسب شده است. این نتیجه در داده‌های سالانه نیز مشهود است. نتایج به دست آمده در افق‌های زمانی متفاوت یکسان بوده و تفاوت چشمگیری در نتایج این مدل دیده نمی‌شود.

جدول ۲. MSFE محاسبه شده حاصل از شبکه MLP

داده‌های روزانه				
فرکانس	روز ۱	روز ۳	روز ۶	روز ۹
درصد آموزش				
۳۰ درصد	۰/۱۵۰	۰/۳۳۷	۱/۹۵۴	۱/۶۱۱
۵۰ درصد	۰/۰۰۰۵	۰/۰۰۲	۰/۰۰۸۵	۰/۰۲۳۸
۷۰ درصد	۰/۰۰۰۴۱	۰/۰۰۲۳	۰/۰۰۷۱	۰/۰۱۲۸
داده‌های ماهانه				
فرکانس	ماه ۱	ماه ۳	ماه ۶	ماه ۹
درصد آموزش				
۳۰ درصد	۰/۰۰۷۳	۰/۰۸۳۳	۰/۲۷۹	۰/۵۹۲
۵۰ درصد	۰/۰۰۴۸	۰/۰۳۹	۰/۲۳	۰/۴۲۲
۷۰ درصد	۰/۰۰۵۳	۰/۰۴۴۲	۰/۱۰۴	۰/۲۳۳
داده‌های سالانه				
فرکانس	سال ۱	سال ۳	سال ۶	سال ۹
درصد آموزش				
۳۰ درصد	۰/۷۰۶	۸/۷۶۶	۱۲/۸۲	-
۵۰ درصد	۰/۰۹۸	۰/۳۲۳	۰/۰۱۰	-
۷۰ درصد	۰/۱۴۳	۰/۱۶۵	-	-

منبع: محاسبات پژوهش

در ادامه دقت پیش‌بینی‌های خارج از نمونه با استفاده از شبکه‌های عصبی بررسی شده است. ابتدا شبکه پرسپترون مورد ارزیابی قرار گرفته است این رویه برای هر سه شبکه بازگشتی و شبکه حافظه طولانی کوتاه‌مدت و شبکه عصبی واحدهای برگشتی گیت‌دار

مدلسازی الگوریتم‌های غیرخطی هوش مصنوعی در پیش‌بینی قیمت نفت | پیری و فرشادفر | ۲۰۷

تکرار شده و مقادیر تخمینی و مقادیر واقعی مقایسه و مقدار میانگین مجذور خطای اشتباه آن محاسبه شده است که نتایج آن در جدول‌های بعدی ارائه شده است. همان‌طور که در جدول ۲ دیده می‌شود پیش‌بینی‌های مدل پرسپترون چند لایه از قیمت نفت خام در داده‌های روزانه با ۵۰ درصد داده‌های آموزش دیده و فرکانس‌های ۱ تا ۹ ماه جلوتر از دقت خوبی برخوردار است در داده‌های ماهانه نیز با ۵۰ و ۷۰ درصد از داده‌های آموزش پیش‌بینی خوبی با فرکانس ۱ و ۳ و ۶ ماه جلوتر دیده می‌شود. این روند در داده‌های سالانه با ۵۰ و ۷۰ درصد داده‌های آموزش تا فرکانس یکسال جلوتر دیده می‌شود.

جدول ۳. MSFE محاسبه شده حاصل از شبکه RNN

داده‌های روزانه				
فرکانس	روز ۱	روز ۳	روز ۶	روز ۹
درصد آموزش				
۳۰ درصد	۰/۰۴۸	۰/۸۶۱	۴/۳۰	۳/۰۲۲
۵۰ درصد	۰/۰۰۰	۰/۰۰۱	۰/۰۰۷۷	۰/۰۱۳۲
۷۰ درصد	۰/۰۰۰۳۴	۰/۰۰۲	۰/۰۰۶	۰/۰۱۲۴
داده‌های ماهانه				
فرکانس	ماه ۱	ماه ۳	ماه ۶	ماه ۹
درصد آموزش				
۳۰ درصد	۰/۰۰۵۹	۰/۰۷۳۳	۰/۲۳۵	۰/۵۲۰
۵۰ درصد	۰/۰۰۴۲	۰/۰۳۹۷	۰/۱۸۸	۰/۳۷۰
۷۰ درصد	۰/۰۰۵۲	۰/۰۴۲۵	۰/۱۰۹	۰/۲۰۹
داده‌های سالانه				
فرکانس	سال ۱	سال ۳	سال ۶	سال ۹
درصد آموزش				
۳۰ درصد	۰/۱۰۲	۷/۹۴۰	۱۲/۰۱۱	—
۵۰ درصد	۰/۰۴۰	۰/۴۸۱	۰/۹۹۹	—
۷۰ درصد	۰/۰۶۸	۰/۱۴۸	—	—

منبع: محاسبات پژوهش

برای بررسی توانایی مدل شبکه عصبی بازگشتی در پیش‌بینی قیمت نفت خام از جدول ۳ استفاده شده است. همان‌طور که در این جدول مشاهده می‌شود این مدل در تمام

پیش‌بینی‌های خارج از نمونه روزانه در فرکانس‌های یک تا ۹ روز جلوتر با ۵۰ و ۷۰ درصد از داده‌های آموزشی عملکرد خوبی دارد در داده‌های ماهانه با ۳۰ و ۵۰ و ۷۰ درصد از داده‌های آموزش با فرکانس یک ماه و ۳ ماه جلوتر عملکرد خوبی دیده می‌شود. در داده‌های سالانه با ۵۰ و ۷۰ درصد از داده‌های آموزش با فرکانس یکسال جلوتر توان خوبی در پیش‌بینی قیمت نفت خام دیده می‌شود.

جدول ۴. MSFE محاسبه شده حاصل از شبکه LSTM

داده‌های روزانه				
فرکانس	روز ۱	روز ۳	روز ۶	روز ۹
درصد آموزش				
۳۰ درصد	۰/۱۸۳	۰/۱۰۳	۰/۳۴۰	۰/۱۳۶
۵۰ درصد	۰/۰۰۰۳	۰/۰۰۲۲	۰/۰۰۸۱	۰/۰۱۸۴
۷۰ درصد	۰/۰۰۰۴۲	۰/۰۰۱۹	۰/۰۰۶۴	۰/۰۱۷۸
داده‌های ماهانه				
فرکانس	ماه ۱	ماه ۳	ماه ۶	ماه ۹
درصد آموزش				
۳۰ درصد	۰/۰۰۷	۰/۱۳۵	۰/۱۸۱	۰/۶۲۳
۵۰ درصد	۰/۰۰۷	۰/۱۰۲	۰/۰۹۶	۰/۴۲۸
۷۰ درصد	۰/۰۰۰۴۹	۰/۰۳۶۲	۰/۱۱۷	۰/۲۳
داده‌های سالانه				
فرکانس	سال ۱	سال ۳	سال ۶	سال ۹
درصد آموزش				
۳۰ درصد	۰/۱۲۸	۸/۷۸۹	۱۳/۵۱۹	—
۵۰ درصد	۰/۰۲۸	۰/۱۰۱	۰/۳۱۹	—
۷۰ درصد	۰/۰۴۱	۰/۱۴۹	—	—

منبع: محاسبات پژوهش

همان‌طور که در جدول ۴ دیده می‌شود شبکه حافظه طولانی کوتاه‌مدت تمام پیش‌بینی‌های خارج از نمونه روزانه در فرکانس‌های یک تا ۹ روز جلوتر با ۵۰ و ۷۰ درصد از داده‌های آموزشی عملکرد خوبی دارد در داده‌های ماهانه با ۳۰ و ۵۰ و ۷۰ درصد از

مدلسازی الگوریتم‌های غیرخطی هوش مصنوعی در پیش‌بینی قیمت نفت | پیری و فرشادفر | ۲۰۹

داده‌های آموزش با فرکانس یک ماه جلوتر عملکرد خوبی دیده می‌شود. در داده‌های سالانه با ۵۰ و ۷۰ درصد از داده‌های آموزش با فرکانس یک سال جلوتر توان خوبی در پیش‌بینی قیمت نفت خام دیده می‌شود.

جدول ۵. MSFE محاسبه شده حاصل از شبکه GRU

داده‌های روزانه				
فرکانس	روز ۱	روز ۳	روز ۶	روز ۹
درصد آموزش				
۳۰ درصد	۰/۰۰۶۱	۰/۲۴۳	۴/۵۲۷	۲/۹۲۳
۵۰ درصد	۰/۰۰۰۲	۰/۰۰۱۵	۰/۰۰۶۲	۰/۰۱۵۷
۷۰ درصد	۰/۰۰۰۳۱	۰/۰۰۱۸	۰/۰۰۰۷	۰/۰۱۴۶
داده‌های ماهانه				
فرکانس	ماه ۱	ماه ۳	ماه ۶	ماه ۹
درصد آموزش				
۳۰ درصد	۰/۰۰۵۹	۰/۰۵۱۵	۰/۱۹۰	۰/۵۲۹
۵۰ درصد	۰/۰۰۴۶	۰/۰۶۳۳	۰/۱۰۵	۰/۴۱۴
۷۰ درصد	۰/۰۰۵۲	۰/۰۳۲۷	۰/۱۰۸	۰/۲۱۴
داده‌های سالانه				
فرکانس	سال ۱	سال ۳	سال ۶	سال ۹
درصد آموزش				
۳۰ درصد	۰/۱۰۷	۸/۶۵۰	۱۱/۹۷۱	—
۵۰ درصد	۰/۰۲۷۰	۰/۰۸۹	۰/۳۶۷	—
۷۰ درصد	۰/۰۴۴	۰/۱۲۷	—	—

منبع: محاسبات پژوهش

و در نهایت از مدل شبکه عصبی واحدهای برگشتی گیت‌دار برای پیش‌بینی قیمت خام در دوره‌های روزانه و ماهانه و سالانه استفاده شده و دقت پیش‌بینی آن محاسبه شده است.

همان‌طور که در جدول ۵ دیده می‌شود این مدل در تمام پیش‌بینی‌های خارج از نمونه روزانه در فرکانس‌های یک تا ۹ روز جلوتر با ۵۰ و ۷۰ درصد از داده‌های آموزشی عملکرد بسیار خوبی داشته و خطای پیش‌بینی قیمت نفت خام آن در قیمت‌های ماهانه با ۳۰

و ۵۰ و ۷۰ درصد از داده‌های آموزش با فرکانس یک ماه جلوتر بسیار کم است. در داده‌های سالانه با ۵۰ و ۷۰ درصد از داده‌های آموزش با فرکانس یک سال جلوتر توان خوبی در پیش‌بینی قیمت نفت خام دیده می‌شود.

۶. بحث و نتیجه‌گیری

نوسانات قابل توجه قیمت نفت خام در سال‌های اخیر، برآورد دقیق قیمت آن را به امری حیاتی تبدیل کرده است. تلاش‌های قابل توجهی برای یافتن یک مدل مناسب برای قیمت نفت انجام شده است. استفاده از الگوهای غیرخطی یادگیری ماشین در پیش‌بینی قیمت نفت همواره در حال تکامل است. در این پژوهش تلاش شد تا از سه شبکه غیر خطی هوش مصنوعی در پیش‌بینی قیمت نفت خام استفاده شده و توان آن با یکی از جدیدترین شبکه‌های یعنی شبکه واحدهای «بازگشتی گیت‌دار» در بهبود پیش‌بینی قیمت نفت خام در فرکانس‌های متفاوت (۱ و ۳ و ۶ و ۹) در افق‌های مختلف روزانه و ماهانه و سالانه استفاده شود و نتایج حاصل مورد مقایسه قرار گیرد.

شکل ۱. مقایسه پیش‌بینی روند روزانه قیمت نفت مدل‌های مختلف با ۷ و ۵۰ و ۳۰ درصد داده‌های آموزشی



منبع: یافته‌های پژوهش

همان‌طور که نتایج نشان می‌دهد توان پیش‌بینی قیمت نفت خام در فرکانس‌های مختلف روزانه و ماهانه و سالانه با حجم‌های متفاوت داده‌های آموزش در الگوهای غیرخطی شبکه

عصبی بهتر از الگوی خطی میانگین تاریخی بوده و دارای خطای کمتری است که این یافته‌ها با نتایج لئو و همکاران (۲۰۲۲)، زانگ و همکاران (۲۰۲۰) و فرشادفر و پروکوپچوک (۲۰۱۹) همخوانی دارد. نتایج محاسبات انجام شده و برآورد مدل‌ها نشان می‌دهد که معیار خطای مربعات میانگین پیش‌بینی در همه نمونه‌های استفاده شده، توسط شبکه واحدهای بازگشتی گیت‌دار از سایر شبکه‌ها بهتر بوده و با افزایش حجم داده‌های آموزش قدرت پیش‌بینی شبکه افزایش می‌یابد.


شکل ۲. مقایسه پیش‌بینی روند ماهانه قیمت نفت مدل‌های مختلف با ۷۰ و ۵۰ و ۳۰ درصد داده‌های آموزشی



منبع: یافته‌های پژوهش

به عبارت دیگر این شبکه قدرت یادگیری بهتری نسبت به سایر شبکه‌ها داشته و خطای آن در پیش‌بینی قیمت نفت خام آینده کمتر است. در این مدل دقت پیش‌بینی نسبت به مدل منفرد براساس معیارهای ارزیابی معرفی شده بهبود یافته است. همچنین شبکه واحدهای بازگشتی گیت‌دار، توانایی بالاتری جهت پوشش نوسانات قیمت نفت خام را داشته و قابل اطمینان‌تر از شبکه چندلایه ساده و بازگشتی ساده و حافظه طولانی کوتاه‌مدت است. از این‌رو فرض اصلی پژوهش مبنی بر عملکرد بهتر شبکه واحدهای بازگشتی گیت‌دار در پیش‌بینی قیمت نفت خام نسبت به سایر شبکه‌های هوش مصنوعی مورد تأیید قرار می‌گیرد.

شکل ۳. مقایسه پیش‌بینی روند سالانه قیمت نفت مدل‌های مختلف با ۷۰ و ۵۰ و ۳۰ درصد داده‌های آموزشی



منبع: یافته‌های پژوهش

بنابراین شبکه واحدهای بازگشتی گیت‌دار عملکرد پیش‌بینی بهتری را نسبت به شبکه‌های تکامل‌یافته پیش از خود داشته و پیش‌بینی آن برای قیمت نفت خام نیز بسیار قابل اعتماد خواهد بود.

براساس شرایط جدید ایجادشده در بازار نفت ازجمله افزایش عرضه از منابع نامتعارف و کاهش هزینه تولید از این منابع، وقوع پیک تقاضا و شرایط برای تولیدکنندگان سستی، ازجمله بازار نفت و عوامل تأثیرگذار بر قیمت نفت خام به منظور تحلیل وضعیت حال و آتی بسیار ضروری است. لذا پیشنهاد می‌گردد که مطالعات در زمینه پیش‌بینی قیمت نفت خام با استفاده از روش‌های جدید و بروز ازجمله ترکیب مدل‌های غیرخطی بازگشتی با سایر مدل‌ها ازجمله مدل‌های یادگیری عمیق تداوم داشته باشد تا به مدل‌های دقیق‌تر و با خطای کمتر دست یابیم.

۷. تعارض منافع

این اثر دارای تعارض منافع نمی‌باشد.

۸. سپاسگزاری

نویسندگان بر خود لازم می‌دانند تا از جناب آقای مهندس بهزاد علیپور که ما را در پیشبرد این پژوهش یاری نمودند، تشکر نمایند.

ORCID

Zahra Farshadfar  <http://orcid.org/0000-0003-4953-4882>

Sajad Piri  <http://orcid.org/0009-0004-6896-8357>

۹. منابع

امامی میدی، علی. (۱۳۸۵). تحلیل عوامل مؤثر بر قیمت نفت خام. فصلنامه پژوهش‌های اقتصاد ایران، ۲۸، ۱۲۶-۱۱۱.

سالک، نوید؛ خرسندی، مرتضی. (۱۴۰۱). طراحی الگوی بازار نفت و مقایسه پیش‌بینی‌های قیمت نفت خام. فصلنامه تحقیقات مدلسازی اقتصادی، ۱۳(۴۷)، ۱۱۴-۷۳.

عباسی نامی، حامد. (۱۴۰۰). مدلسازی و پیش‌بینی نوسانات قیمت نفت خام و ارزش معرض ریسک با استفاده از مدل‌های تغییر رژیم GARCH و تک رژیمی. فصلنامه مطالعات اقتصاد انرژی، ۱۷(۶۸)، ۱۷۴-۱۴۱.

لاری سمنانی، بهروز و خلیلی، سیمین. (۱۳۹۷). تخمین قیمت نفت خام اوپک با استفاده از روش‌های درخت دوتایی، سری زمانی و شبکه‌های عصبی مصنوعی. مهندسی منابع معدنی، ۳(۳)، ۴۱-۳۱.

شاکری، عباس؛ محمدی، تیمور و جعفری، محمد. (۱۳۹۸). تأثیر نوسانات مالی جهانی بر بازار نفت با تأکید بر بحران مالی ۲۰۰۸. فصلنامه پژوهش‌نامه اقتصادی، ۷۴، ۳۸-۱.

DOI: <https://doi.org/10.22054/joer.2019.11245>

یادگاری، حسین؛ محمدی، تیمور؛ آماده، حمید؛ قاسمی، عبدالرسول و مصطفائی، حمیدرضا. (۱۴۰۱). پیش‌بینی قیمت نفت خام برنت با الگوی ترکیبی مدل خاکستری غیرخطی و تصحیح پسماند آریمای خطی. فصلنامه مطالعات اقتصاد انرژی، ۱۸(۷۲)، ۲۵-۱.

DOI: <http://dx.doi.org/10.22054/jiee.2022.62826.1862>

References

- Abbasi Nami, Hamed. (2021). Modeling and Forecasting Crude Oil Price Volatility and Value at Risk Using GARCH and Single Regime Switching Models. *Energy Economics Quarterly*, 17(68), 141-174. [In Persian]
- Ayazi, A., Amiri, M., Fartukzadeh, HR., and Azar, A. (2020). Strategic analysis of international oil market suppliers based on graph model. *Scientific quarterly of interdisciplinary studies on strategic knowledge*, 10(39): 179-206. [In Persian]
- De Faria, E., Albuquerque, M. P., Gonzalez, J., Cavalcante, J., & Albuquerque, M.P. (2009). Predicting the Brazilian stock market through neural networks and adaptive exponential smoothing methods. *Expert*

- Systems with Applications*, 36(10), 12506-12509. DOI: 10.1016/j.eswa.2009.04.032
- Emami, A. (2006). Analysis of factors affecting the price of crude oil, *Iranian Economic Research Quarterly*, 28, 111-126. [In Persian]
- Farshadfar, Z., Prokopczuk, M., (2019). Nonlinear Model Improves Stock Return Out of Sample Forecasting (Case Study: United State Stock Market). *International Journal of Finance and Managerial Accounting*, 3(12), 1-13.
- Farshadfar, Z., Prokopczuk, M., (2019). Improving Stock Return Forecasting by Deep Learning Algorithm, *Advances in mathematical finance& applications*, 4 (3), 1-13. DOI: 10.22034/amfa.2019.584494.1173
- Fong, W. M. and Yong, L. H. M. (2005). Chasing trends: Recursive moving average trading rules and internet stocks. *Journal of Empirical Finance*, 12(1), 43–76. DOI: 10.1016/j.jempfin.2003.07.002
- Guo, J. (2019). Oil price forecast using deep learning and ARIMA. In 2019 international conference on machine learning, big data and business intelligence (pp. 241–247). IEEE.
DOI:10.1109/MLBDBI48998.2019.00054
- Gao, R., Liu, J., Zhou, Q., Duru, O. and Yuen, K. F. (2022). Newbuilding ship price forecasting by parsimonious intelligent model search engine. *Expert Systems with Applications*, 201, Article 117119. DOI:10.1016/j.eswa.2022.117119
- Gumus, M., and Kiran, M. S. (2017). Crude oil price forecasting using XGBoost. In *2017 international conference on computer science and engineering* (pp. 1100–1103). DOI:10.1109/UBMK.2017.8093500
- Lari Semnani, Behrouz, Khalili, Simin. (2018). OPEC crude oil price estimation using binary tree, time series and artificial neural networks methods. *Journal of Mineral Resources Engineering*, 3(3), 31-41. [In Persian]
- Luo, S., Ni, Z., Zhu, X., Xia, P., & Wu, H. (2022). A novel methanol futures price prediction method based on multicycle CNN-GRU and attention mechanism. *Arabian Journal for Science and Engineering*, 1–15. DOI:10.1109/ICCAE56788.2023.10111233
- Narayan, P., Sharma, S., Poon, W, Westerlund, J. (2014). Do oil prices predict economic growth? New global evidence. *Energy Economics*, 41: 137-146. DOI:10.1016/j.eneco.2013.11.003
- Rapach, D., Strauss, J., Zhou, G. (2010). Out-of-sample equity premium prediction: Combination forecast and links to the real economy. *Review of Financial Studies*, 23: 821-862. DOI:10.2139/ssrn.1257858
- Salik, Navid, Khorsandi, Morteza. (2022). Designing an oil market model and comparing crude oil price forecasts. *Economic Modeling Research Quarterly*, 13(47), 73-114. [In Persian]

- Shakri, Abbas, Mohammadi, Taimur, Jafari, Mohammad. (2019). The effect of global financial fluctuations on the oil market with an emphasis on the 2008 financial crisis. *Economic Research Quarterly*, 74, 1-38. DOI:https://doi.org/10.22054/joer.2019.11245 . [In Persian]
- Wang, Q., Song, X. and Li, R. (2018). A novel hybridization of nonlinear grey model and linear ARIMA residual correction for forecasting US shale oil production. *Energy*, 165, 1320–1331. DOI:10.1016/j.energy.2018.10.032
- Welch, I., Goyal, A. (2008). A comprehensive look at the empirical performance of equity premium prediction. *Review of Financial Studies*, 21: 1455-1508. DOI:10.1093/rfs/hhm014
- Yadegari H, Mohammadi T, Amadeh H, Qasemi A, Mostafaei H (2022). Brent crude oil Price Forecast with Hybrid Model of Nonlinear Grey Model and Linear Arima Waste Correction, *Quarterly Energy Economics Review*, 18(72): 1-25. DOI: http://dx.doi.org/10.22054/jiee.2022.62826.1862. [In Persian]
- Zang, H., Liu, L., Sun, L., Cheng, L., Wei, Z., and Sun, G. (2020). Short-term global horizontal irradiance forecasting based on a hybrid CNN-LSTM model with spatiotemporal correlations. *Renewable Energy*, 160, 26-41. DOI:10.1016/j.renene.2020.05.150
- Zhao, Y., Li, J., and Yu, L. (2017). A deep learning ensemble approach for crude oil price forecasting. *Energy Economics*, 66, 9–16. DOI:10.1016/j.eneco.2017.05.023

استناد به این مقاله: پیری، سجاد؛ فرشادفر، زهرا. (۱۴۰۲). مدلسازی الگوریتم‌های غیرخطی هوش مصنوعی در پیش‌بینی قیمت نفت، پژوهشنامه اقتصاد انرژی ایران، ۵۲ (۱۳)، ۱۹۱–۲۱۵.



Iranian Energy Economics is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License.