

eISSN: 2981-1554

Original Article (Qualitative)

Study of iron ore pricing prediction using dynamic neural network method and the trend of factors' effectiveness and impact.

Yusef Naji¹ , Hamid Reza Mollaei² , Ali Raeispour Rajabali³ ,
Mahdi Mohammad Bagheri⁴ 

1- Ph.D student of Public Administration, Ke.C., Islamic Azad University, Kerman, Iran.

2- Department of Educational Management, Ke.C., Islamic Azad University, Kerman, Iran.

3- Department of Public Management, Ke.C., Islamic Azad University, Kerman, Iran.

4- Department of Public Management, Ke.C., Islamic Azad University, Kerman, Iran

Receive:

18 September 2025

Revise:

28 November 2025

Accept:

28 January 2026

Abstract

The aim of the present research is to study the iron ore pricing forecasting using dynamic neural network method and factors' influence and effectiveness trend. The present study is applicable in terms of its purpose, and survey in terms of data. The statistical population includes daily iron ore stock prices for 2058 working days. Given that severe stock price fluctuations will affect the forecast; the statistical sample used in this study includes daily iron ore stock prices during the period of companies' entry into the stock exchange from 21/03/2016 to 20/03/2023. Python programming language was used to model the dynamic neural network, and DEMATEL software was used for the influence and effectiveness of factors. The results showed that the dynamic neural network model (LSTM) with its high ability to model the nonlinear effects of macroeconomic variables showed the best performance in predicting iron ore prices. After optimizing the parameters (3 layers and 64 neurons), this model achieved the highest coefficient of determination (R²) of 0.985 and the lowest root mean square error (RMSE) of 0.051. Sensitivity analysis indicated that steel prices were the most important variables for predicting iron ore prices. The results of DEMATEL also showed that interest rates were the strongest antecedent (influencing) factor in the economic system, while iron ore production was the strongest a posteriori (influencing) factor. These findings emphasize that iron ore prices are highly dependent on macroeconomic and financial conditions and that the dynamic neural network is a superior tool for predicting them.

Keywords:

Economic system,
iron ore pricing,
volatility
clustering,
dynamic neural
network

Please cite this article as (APA): Naji, Y., Mollaei, H. R. , Raeispour Rajabali, A. and Mohammad Bagheri, M. (2026). Study of iron ore pricing prediction using dynamic neural network method and the trend of factors' effectiveness and impact. *Journal of New Approaches in Management and Marketing*, 4(4), 110-130.



<https://doi.org/10.22034/jnamm.2026.547880.1155>



Authors retain the copyright and full publishing rights.

Published by Research Center of Resource Management Studies and Knowledge-Based Business. This article is an open access article licensed under the Creative Commons Attribution 4.0 International (CC BY 4.0)

Publisher: Research Center of Resource Management Studies and Knowledge-Based Business

Corresponding Author: Hamid Reza Mollaei

Email: hrmollaei@iau.ac.ir

Extended Abstract

Introduction

Today, the rate of economic growth and development depends on capital accumulation on the one hand, and on the productivity factor in economic activities on the other. These two basic factors depend on the nature of the investment process; therefore, one of the most important tasks of financial markets is to facilitate capital formation. Capital markets can well handle both of the aforementioned tasks of capital accumulation and increasing economic productivity (Farajian & Farajian, 2022). Given the key impact of mineral product prices on calculating the cut-off grade and net present value of mining projects, reliable forecasting of mineral product prices is an important and fundamental issue in economics and the design and planning of open-pit metal mining. Given the high volatility of iron ore prices, its accurate forecasting is one of the critical issues in the design of open-pit mines to increase decision-making certainty (Sadegh Beigi Aliayee et al., 2025). Iron ore is the main raw material for steel production. The iron ore market has always been affected by different and variable conditions. There are many large and small producers and exporters active in this industry (Jan Nesari & Aghajani Bazazi, 2023).

Iron is one of the most useful metals in the world. The global price of iron ore is determined by supply and demand. There are several variables, including steel prices, steel production, oil prices, gold prices, interest rates, inflation rates, iron production, and aluminum prices, that affect the global price of iron ore (Mehrdanesh et al., 2021). Iron ore does not have a direct substitute, but steel produced from iron ore has substitutes such as aluminum. On the other hand, any planning for the future requires predicting the future situation. Manufacturing companies need product price forecasts to plan, produce economic analysis of projects, review new investments for development, and so on. Steel production and consumption is today one of the main branches of development of countries and societies. The presence of the steel industry in a region has a significant impact on the process of development of culture, knowledge level, employment generation, research, education and trade of that region. Human daily life is mixed with steel, and steel industries play an important role in the construction, reconstruction and development of the country. Considering that the difference between the consumption and production of crude steel in the country in 2009 was more than 8.9 million tons, investment and growth of the steel industry in the country seems economical and logical; provided that the location of the process, production, supply of natural resources and energy, and project management are selected correctly (Azimi & Afrogh, 2015).

Accordingly, the present study seeks to answer the question: how to predict iron ore pricing using the dynamic neural network method and the process of influence and effectiveness of factors?

Theoretical Framework

Iron Ore Pricing

The iron ore industry plays a key and influential role in the growth and development of a country. On the one hand, this industry is a fundamental industry in development, and on the other hand, this industry is considered a benchmark for the industrialization of countries. Therefore, its improvement and development is of particular importance. Basic industries such as transportation, construction, machinery manufacturing, mining and other industries related to the production and transmission of energy are dependent on products produced from iron ore. Therefore, the global demand for iron ore is high and will remain stable in the future, if not increase (Hao et al., 2018).

Sadegh Beigi Aliayee et al. (2025) studied the optimization of global iron ore price forecasting using intelligent methods. The main features of the forecasting model were based

on the analysis of the correlation coefficients of iron ore prices and the dependent variables of six parameters including price, copper, gold, silver, oil, crude, transportation cost and iron ore demand. They were limited and normalized to improve the performance of intelligent algorithms. Then, a multivariate linear regression model of iron ore price forecasting based on the features was obtained with a coefficient of determination of 0.85. Finally, the frog leap metaheuristic algorithm was used to optimize the model, which led to an increase in the value of R² and a decrease in RMSE and MSE.

Souza et al. (2024) presented a new approach to predicting iron ore prices using weighted fuzzy time series analysis. Given the large number of effective parameters and the complex relationships between them, artificial intelligence-based approaches can be used to predict iron ore prices.

Research Methodology

The present study is applicable in terms of purpose, and survey in terms of data. The statistical population includes the daily price of iron ore stocks for 2058 working days. Given that the strong fluctuations in stock prices will affect the forecast; therefore, the statistical sample used in this study includes the daily prices of iron ore stocks in the period of companies entering the stock exchange from 21/03/2016 to 20/03/2023.

Research findings

For modeling the dynamic neural network, the Python programming language was used, and DEMATEL software was used for the effects and effectiveness of factors. The results showed that the dynamic neural network model (LSTM) with its high ability to model the nonlinear effects of macroeconomic variables showed the best performance in predicting iron ore prices. After optimizing the parameters (3 layers and 64 neurons), this model achieved the highest coefficient of determination (R²) equal to 0.985 and the lowest root mean square error (RMSE) equal to 0.051. Sensitivity analysis indicated that steel prices are the most important variable for predicting iron ore prices. The results of DEMATEL also showed that the interest rate is the strongest antecedent factor in the economic system, while iron ore production is the strongest adversarial factor. These findings emphasize that iron ore prices are highly dependent on macroeconomic and financial conditions, and that the dynamic neural network is a superior tool for predicting them.

Conclusion

The present study aimed to investigate the prediction of iron ore pricing using the dynamic neural network method and the trend of factors' effectiveness and effectiveness. The results of this study are consistent with the results of Karami Moghaddam & Vishlaghi (2025), Hadian et al. (2025), Isiaka (2025), Bamiri et al. (2025), Safarloo et al. (2024), Suryani & Syamsulbahri (2024), Butson et al. (2023), Bekhit et al. (2023), and Adibzadeh & Roknabadi (2023). Karami Moghaddam & Vishlaghi (2025) showed that a fair payment system in laws, the right to legal promotion and advancement, job security based on the law, determining salaries and benefits based on the approved and unified government table, legal protections in critical situations, and equality and prohibition of legal discrimination were raised as the most important legal factors.

According to the results of the study, it is proposed to replace the core of traditional predictive models with deep learning architecture (LSTM), a review of risk management systems, focusing on key nonlinear drivers and implementing metaheuristic optimization methodologies and hybrid models should be implemented.

بررسی پیش بینی قیمت گذاری سنگ آهن، با استفاده از روش شبکه عصبی پویا و روند اثر گذاری و اثر پذیری عامل ها

یوسف ناجی^۱ ID، حمیدرضا ملایی^۲ ID، علی رئیس پور رجبعلی^۳ ID، مهدی محمدباقری^۴ ID

۱- دانشجوی دکتری مدیریت صنعتی، واحد کرمان، دانشگاه آزاد اسلامی، کرمان، ایران.

۲- گروه مدیریت صنعتی، واحد کرمان، دانشگاه آزاد اسلامی، کرمان، ایران

۳- گروه اقتصاد، واحد کرمان، دانشگاه آزاد اسلامی، کرمان، ایران

۴- گروه مدیریت، واحد کرمان، دانشگاه آزاد اسلامی، کرمان، ایران

چکیده

هدف پژوهش حاضر بررسی پیش بینی قیمت گذاری سنگ آهن، با استفاده از روش شبکه عصبی پویا و روند اثر گذاری و اثر پذیری عامل ها می باشد. تحقیق حاضر از نظر هدف کاربردی و از جنبه داده ها پیمایشی می باشد. جامعه آماری شامل قیمت روزانه سهام سنگ آهن به مدت ۲۰۵۸ روز کاری است. نظر به اینکه نوسانات شدید قیمت سهام پیش بینی را تحت تأثیر خود قرار خواهد داد؛ بنابراین نمونه آماری مورد استفاده در این تحقیق قیمت های روزانه سهام سنگ آهن در بازه زمانی ورود شرکت ها به بورس کالا از تاریخ ۱۳۹۵/۰۱/۰۱ الی ۱۴۰۱/۱۲/۲۹ را در بر می گیرد. برای مدل سازی شبکه عصبی پویا از زبان برنامه نویسی Python همچنین برای اثر گذاری و اثر پذیری عامل ها از نرم افزار DEMATEL استفاده شد. نتایج نشان داد که مدل شبکه عصبی پویا (LSTM) با توانایی بالا در مدل سازی اثرات غیر خطی متغیرهای کلان اقتصادی، بهترین عملکرد را در پیش بینی قیمت سنگ آهن از خود نشان داد. این مدل پس از بهینه سازی پارامترها (۳ لایه و ۶۴ نرون)، به بالاترین ضریب تعیین (R^2) برابر با ۰/۹۸۵ و کمترین ریشه میانگین مربعات خطا ($RMSE$) برابر با ۰/۰۵۱ دست یافت. تحلیل حساسیت حاکی از آن بود که قیمت فولاد مهم ترین متغیر برای پیش بینی قیمت سنگ آهن است. همچنین نتایج دیمتل نشان داد که نرخ بهره قوی ترین عامل پیشایند (تأثیر گذار) در سیستم اقتصادی است، در حالی که تولید سنگ آهن قوی ترین عامل پسایند (تأثیر پذیر) محسوب می شود. این یافته ها تأکید می کنند که قیمت سنگ آهن به شدت تابعی از شرایط کلان مالی و اقتصادی است و شبکه عصبی پویا ابزار برتری برای پیش بینی آن به شمار می رود.

تاریخ دریافت: ۲۷ شهریور ۱۴۰۴

تاریخ بازنگری: ۰۷ آذر ۱۴۰۴

تاریخ پذیرش: ۰۸ بهمن ۱۴۰۴

کلید واژه ها:

سیستم اقتصادی،
قیمت گذاری سنگ آهن،
خوشه بندی نوسان،
شبکه عصبی پویا

لطفاً به این مقاله استناد کنید (APA): ناجی، یوسف، ملایی، حمیدرضا، رئیس پور رجبعلی، علی و محمدباقری، مهدی. (۱۴۰۴). بررسی پیش بینی قیمت گذاری سنگ آهن، با استفاده از روش شبکه عصبی پویا و روند اثر گذاری و اثر پذیری عامل ها. فصلنامه رویکردهای نوین در مدیریت و بازاریابی، ۴(۴)، ۱۱۰-۱۳۰.



https://doi.org/10.22034/jnamm.2026.547880.1155



Authors retain the copyright and full publishing rights.
Published by Research Center of Resource Management Studies and Knowledge-Based Business.
This article is an open access article licensed under the Creative Commons Attribution 4.0 International (CC BY 4.0)

ناشر: مرکز پژوهشی مطالعات مدیریت منابع و کسب و کار دانش محور

نویسنده مسئول: حمیدرضا ملایی

ایمیل: hrmollaei@iau.ac.ir

مقدمه

امروزه میزان رشد و توسعه اقتصادی از یک سو در گرو انباشت سرمایه بوده و از سوی دیگر به عامل بهره‌وری در فعالیت‌های اقتصادی بستگی دارد این دو عامل اساسی به چگونگی فرآیند سرمایه‌گذاری بستگی دارد؛ بنابراین یکی از مهم‌ترین وظایف بازارهای مالی، تسهیل تشکیل سرمایه است. بازارهای سرمایه به‌خوبی می‌تواند از عهده هر دو وظیفه اشاره‌شده انباشت سرمایه و افزایش بهره‌وری اقتصادی به‌خوبی برآید (Farajian & Farajian, 2022). با توجه به تأثیر کلیدی قیمت محصولات معدنی بر محاسبه عیار حد و ارزش خالص فعلی پروژه‌های معدنی، پیش‌بینی قابل اعتماد قیمت محصولات معدنی از مسائل مهم و بنیادی در اقتصاد و طراحی و برنامه‌ریزی تولید معادن روباز فلزی است با توجه به نوسانات زیاد قیمت سنگ آهن، آهن پیش‌بینی دقیق آن یکی از مسائل بحرانی در طراحی معادن روباز برای افزایش قطعیت تصمیم‌گیری است (Sadegh Beigi Aliayee et al, 2025). سنگ آهن اصلیت‌ترین ماده خام برای تولید فولاد است. بازار سنگ آهن همواره تحت تأثیر شرایط مختلف و متغیر بوده است. در این صنعت تولیدکنندگان بزرگ و کوچک و صادرکنندگان زیادی فعال هستند (Jan Nesari & Aghajani Bazazi, 2023).

آهن یکی از کاربردی‌ترین فلزات در جهان است. قیمت جهانی سنگ آهن بر اساس عرضه و تقاضا تعیین می‌شود. متغیرهای متعددی از جمله قیمت فولاد، تولید فولاد، قیمت نفت، قیمت طلا، نرخ بهره، نرخ تورم، تولید آهن و قیمت آلومینیوم وجود دارد که بر قیمت جهانی سنگ آهن تأثیر می‌گذارد (Mehrdanesh et al, 2021). سنگ آهن جایگزین مستقیمی ندارد ولی فولاد که از سنگ آهن تولید می‌شود جایگزین‌هایی نظیر آلومینیوم دارد. از طرفی لازمه هر برنامه‌ریزی برای آینده نیازمند پیش‌بینی وضعیت آتی می‌باشد. شرکت‌های تولیدی برای انجام برنامه‌ریزی، تولید تجزیه و تحلیل اقتصادی پروژه‌ها، بررسی سرمایه‌گذاری جدید جهت توسعه و مواردی از این قبیل به پیش‌بینی قیمت محصول احتیاج دارند. تولید و مصرف فولاد، امروزه یکی از شاخه‌های اصلی توسعه‌یافتگی کشورها و جوامع به شمار می‌آید، حضور صنعت فولاد در یک منطقه بر فرایند توسعه فرهنگ سطح دانش اشتغال‌زایی پژوهش آموزش و تجارت آن منطقه تأثیر بسزایی دارد. زندگی روزمره بشر با فولاد آمیخته شده و صنایع فولاد در سازندگی بازسازی و توسعه کشور سهم مهمی را ایفا می‌نمایند. با توجه به آنکه تفاوت مصرف و تولید فولاد خام کشور در سال ۲۰۰۹ بیش از ۹/۸ میلیون تن بوده است سرمایه‌گذاری و رشد صنعت فولاد در کشور اقتصادی و منطقی به نظر می‌آید؛ مشروط بر اینکه محل احداث فرایند، تولید تأمین منابع طبیعی و انرژی و مدیریت پروژه صحیح انتخاب شده باشد (Azimi & Afrogh, 2015).

قیمت سنگ آهن بر اساس عرضه و تقاضا تعیین می‌شود. شواهد اختلال در معادن بزرگ یا تغییرات عرضه آنها ناشی از حوادث و مسائل ایمنی و زیست محیطی باعث نوسانات قیمت می‌شود. در سمت تقاضا رشد کشورهای نوظهور قیمت‌ها را مشخص می‌کند. امروزه پروژه‌های زیر ساختی تحت حمایت دولت چین محرک اصلی قیمت سنگ آهن بوده است (Wang et al, 2018). متغیرهای متعددی مانند فولاد، قراضه، نفت، طلا، نرخ بهره، نرخ تورم، ارزش دلار و ارزش سهام بر قیمت جهانی سنگ آهن تأثیر می‌گذارند. بنابراین، برای سرمایه‌گذاری اقتصادی سنگ آهن، باید توسط دانشمندان به طور دقیق پیش‌بینی شود تا به تصمیم‌گیرندگان جهت تصمیم‌گیری مناسب برای جامعه جهت دهد. با توجه به تعدد پارامترهای مؤثر و پیچیدگی روابط بین متغیرهای سنگ آهن، هوش مصنوعی بهترین ایده برای پیش‌بینی است (Lin & Si, 2021).

تجارت سنگ آهن در دنیا با سرعت گرفتن اقتصادهای در حال توسعه در مناطقی چون چین، هند و کره جنوبی به عنوان مراکز کلیدی رشد در این بخش با تغییرات عمده‌ای مواجه گردیده و اقتصادهای صنعتی شده اتحادیه اروپا و آمریکای شمالی به تدریج نقش مسلط خود را در این بازار از دست می‌دهند. در حال حاضر مناطق در حال توسعه آسیا مرکز رشد تولید و مصرف فولاد هستند. بیشترین مناطق تولیدکننده فولاد عمده‌ترین منابع سنگ آهن خود را وارد نموده و بعضی دیگر منابع سنگ آهن ناچیز یا غیراقتصادی دارند برجسته‌ترین آن‌ها صنایع فولاد چین و ژاپن است رشد در تقاضای واردات سنگ آهن منجر به افزایش قابل توجهی در تولید کشورهایمانند برزیل و استرالیا به عنوان ترکیبی از منابع سنگ آهن بزرگ و با کیفیت بالا و قابل دسترس به بنادر شده و منابع سنگ آهن برای بازار صادرات توسعه یافته است. با توجه به آنچه گفته شد پژوهش حاضر به دنبال پاسخ به این سؤال است که پیش بینی قیمت گذاری سنگ آهن، با استفاده از روش شبکه عصبی پویا و روند اثر گذاری و اثر پذیری عامل‌ها چگونه می‌باشد؟

ادبیات نظری

قیمت گذاری سنگ آهن

صنعت سنگ آهن در رشد و توسعه‌ی یک کشور نقشی کلیدی و تاثیرگذار دارد. از یک سو این صنعت در توسعه، صنعتی بنیادی است و از سویی دیگر، این صنعت معیاری برای صنعتی شدن کشورها به شمار می‌آید. لذا بهبود و توسعه‌ی آن از اهمیت خاصی برخوردار است. صنایع پایه از قبیل حمل و نقل، ساختمان، ساخت ماشین آلات، معدن و دیگر صنایع مرتبط با تولید و انتقال انرژی به محصولات تولیدی از سنگ آهن وابسته می‌باشند. لذا تقاضای جهانی سنگ آهن بالا بوده و در آینده، اگر افزایش نیابد ثابت می‌ماند (Hao et al, 2018). سنگ آهن به عنوان ماده اولیه در تولید فولاد، نقش مهمی در اقتصاد و پیشرفت هر کشور دارد. تولید این ماده در جهان با چالش‌ها و فرصت‌های گوناگونی مواجه می‌باشد. صعود و افول صنعت فولاد نیز بطور مستقیم به میزان در دسترس بودن این ماده اولیه وابسته می‌باشد. بررسی وضعیت تولید جهانی می‌تواند راهنمایی برای آینده این صنعت باشد. تعیین عوامل موثر در میزان تولید جهانی به منظور تحلیل دقیق‌تر میزان تولید، بازار مصرف و تنظیم سیاست‌های راهبردی، باید به عنوان یک اصل در تولید فولاد دیده شود (Azimi & Afrogh, 2015). با توجه به شرایط بازار جهانی آهن و فولاد و نیاز روز افزون دنیا به محصولات فولادی و در کنار آن طولانی بودن بازده سرمایه گذاری در بخش معدن بویژه صنعت فولاد، سرمایه گذاری در این حوزه تضمین شده است. در کشور ما طی سال‌های گذشته بنگاه‌های بزرگ و فعال در بخش معدن و صنایع معدنی اقدامات موثری را در جهت گسترش و حفظ بازارهای جهانی انجام داده‌اند، به طوریکه امروزه ایران جز ۱۰ کشور برتر تولیدکننده فولاد خام در جهان است؛ اما نکته قابل تأمل اینجاست که برای حفظ دستاوردهای حاصل شده و ادامه حرکت در این مسیر باید مطابق با شرایط و نیاز روز برنامه ریزی و سرمایه گذاری کرد و در این خصوص باید زمان بر بودن فصول مختلف مطالعات، اکتشاف، اجرا و بهره برداری را مورد توجه قرار داد (Ostadrahimi et al, 2022). طبق گزارشات سازمان زمین شناسی ایالات متحده آمریکا (USGS)، ذخایر سنگ آهن خام جهان تا سال ۲۰۱۹ حدود ۱۷۰ میلیارد تن بود که ۸۱ میلیارد تن آهن از آن حاصل می‌شد. قابل توجه است حدود ۵/۲ میلیارد تن فلز آهن در سال ۲۰۱۹ از معادن سراسر جهان

استخراج شده است. براساس اطلاعات این سازمان میزان تولید جهانی فلز آهن در سال ۲۰۲۰ حدود ۴/۲ میلیارد تن بود که در مقایسه با سال‌های گذشته کاهش ناچیزی داشته است (Lin & Si, 2021)

پیشینه پژوهش

(Sadegh Beigi Aliayee et al, 2025) به بررسی بهینه سازی پیش بینی قیمت جهانی سنگ آهن با بهره گیری از روش‌های هوشمند پرداختند. ویژگیهای اصلی مدل پیش بینی بر اساس تحلیل ضرایب همبستگی قیمت سنگ آهن و متغیرهای وابسته به شش پارامتر شامل قیمت، مس، طلا، نقره، نفت، خام، هزینه حمل و نقل و تقاضای سنگ آهن محدود و برای بهتر شدن عملکرد الگوریتمهای هوشمند نرمال شدند سپس مدل رگرسیون خطی چندمتغیره پیش بینی قیمت سنگ آهن بر اساس ویژگیها با ضریب تعیین ۰.۸۵ حاصل شد. نهایتاً از الگوریتم فراابتکاری جهش قورباغه برای بهینه سازی مدل بهره گیری شد که منجر به افزایش مقدار R² و کاهش RMSE و MSE شد.

(Souza et al, 2024) رویکرد جدیدی برای پیش بینی قیمت سنگ آهن با تحلیل سری زمانی فازی وزنی ارائه کردند. با توجه به تعداد بالای پارامترهای مؤثر و روابط پیچیده بین آنها، می‌توان از رویکردهای مبتنی بر هوش مصنوعی برای پیش بینی قیمت سنگ آهن استفاده کرد.

(Farajian & Farajian, 2022) به بررسی پیش بینی قیمت سنگ آهن با استفاده از شبکه عصبی پویا پرداختند. نتایج به دست آمده، از نظر قابلیت پیش بینی مورد ارزیابی قرار گرفت. مدل شبکه عصبی بهینه با ۳ لایه و ۱۰ نرون قیمت سنگ آهن را با دقت بسیار مناسب برآورد کرده است. در این مدل مقدار خطای آموزش در حدود ۱/۷٪ و برای اعتبار سنجی برابر ۲/۳٪ و خطای آزمون ۱/۵٪ است. همچنین مقدار رگرسیون و همبستگی داده‌ها در سطح اعتماد ۹۵٪ و مقدار همبستگی بالا با R²=۰.۹۸ نشان گر یک مدل خوب و با دقت مناسب است.

(Kim et al, 2022) آزمون علیت گرنجر را برای تشخیص علیت میان داده‌های سری زمانی قیمت سنگ آهن و ۱۲ قیمت ماهانه شامل گاز طبیعی، مایع آلومینیوم، نیکل نقره زغال سنگ استرالیا، روی، طلا، نفت، قلع، مس، سرب و شاخص قیمت کالا بررسی کردند. قیمت آتی سنگ آهن با روشهای مختلف رگرسیون غیر خطی دو متغیره، رگرسیون خطی چندگانه رگرسیون غیر خطی چندگانه همچنین مدل لاگسیگ، تنسیگ و پورلین مدل سازی لونیبرگ مارکوارت پیش بینی کردند. پیش بینی قیمت سنگ آهن با مدل خطی (پورلین) و تکنیک لونیبرگ مارکوارت بهترین نتیجه پیش بینی را نشان می‌دهد.

(Yongxing & Yanru, 2022) قیمت جهانی سنگ آهن را بر اساس پارامترهای ورودی قیمت تاریخی سنگ آهن، طلا، ضایعات مس نقره نفت نرخ تورم آمریکا و ژاپن نرخ ارز ژاپن و دلار استرالیا و با بهره گیری از روش CNN پیش بینی کردند.

(Wang et al, 2022) تحلیل همبستگی برای استخراج هشت عامل تأثیرگذار مستقل شامل درآمد ناخالص ملی، تولید ناخالص ملی تعرفه سرمایه گذاری دارایی ثابت، تولید فولاد، ضایعات مصرف فولاد تولید سنگ آهن خام و هزینه تولید آهن بر قیمت سنگ آهن معرفی و تحلیل رگرسیون خطی چندگانه برای پیش بینی پیشنهاد کردند. مدل پیش بینی مبتنی بر رگرسیون خطی چندگانه از دقت پیش بینی بالایی برخوردار است.

(Lin & Si, 2021) به بررسی پیش‌بینی بهینه قیمت سنگ آهن با استفاده از شبکه عصبی کانولوشنی بهینه شده با الگوریتم بهینه‌سازی جستجو و نجات اصلاح شده پرداختند. آن‌ها از یک نسخه بهینه جدید از شبکه عصبی کانولوشن برای تسهیل این کار استفاده کردیم. برای انجام این کار، یک نسخه اصلاح شده از الگوریتم بهینه‌سازی جستجو و نجات برای بهینه‌سازی شبکه عصبی کانولوشن جهت بهبود کارایی آموزش آن در پیش‌بینی نوسانات قیمت سنگ آهن طراحی و استفاده شده است. سپس این روش بر اساس ده متغیر مختلف اعتبارسنجی می‌شود. در نهایت، مقایسه‌ای بین نتایج با تکنیک‌های مختلف پیشرفته انجام شد تا اثربخشی روش پیشنهادی نشان داده شود. نتایج نشان داد که تکنیک پیشنهادی در مقایسه با سایر تکنیک‌های جدید، مناسب‌ترین نتایج را دارد.

(Wu & Qiu, 2020) روش تلفیقی کامل بهبود یافته با نویز تطبیقی با روش خودرگرسیون برداری (VAR) برای بررسی علیت گرنجر و قیمت‌های روزانه نقطه‌ای و آتی سنگ آهن طراحی کردند. نتایج این بررسی حاکی از تأثیر دوسویه قیمت سنگ آهن بر قیمت نفت، مس و زغالسنگ استرالیا است.

روش‌شناسی تحقیق

تحقیق حاضر از نظر هدف کاربردی و از جنبه داده‌ها پیمایشی می‌باشد. جامعه آماری شامل قیمت روزانه سهام سنگ آهن به مدت ۲۰۵۸ روز کاری است. نظر به اینکه نوسانات شدید قیمت سهام پیش‌بینی را تحت تأثیر خود قرار خواهد داد؛ بنابراین نمونه آماری مورد استفاده در این تحقیق قیمت‌های روزانه سهام سنگ آهن در بازه زمانی ورود شرکت‌ها به بورس کالا از تاریخ ۱۳۹۵/۰۱/۰۱ الی ۱۴۰۱/۱۲/۲۹ را در بر می‌گیرد. برای مدل‌سازی شبکه عصبی پویا که قادر به شناسایی روابط غیرخطی و پیچیده میان متغیرهاست، از زبان برنامه‌نویسی Python استفاده می‌شود تا دقت و انعطاف‌پذیری تحلیل افزایش یابد. همچنین برای اثرگذاری و اثرپذیری عامل‌ها از نرم افزار DEMATEL استفاده شد.

یافته‌های پژوهش

ابتدا مدل *ARIMA* را روی سری زمانی قیمت سنگ آهن برازش کرده، سپس نوسانات خطاهای پیش‌بینی آن را با *GARCH* مدل می‌کنیم.

الف) مدل آریما

مدل آریما برای تحلیل و پیش‌بینی خودکار قیمت سنگ آهن (بدون در نظر گرفتن متغیرهای خارجی) اجرا شد.

جدول ۱. نتایج معیار ارزیابی آزمون آریما

معیار ارزیابی	مقدار	توضیح
<i>ARIMA (p,d,q)</i>	(۱, ۱, ۱)	بهترین پارامترهای مدل‌سازی (با یک ترم خودرگرسیون، یک تفاوت‌گیری و یک میانگین متحرک).
<i>RMSE</i> (خطا)	۰/۱۱۲	متوسط خطای پیش‌بینی مدل بر روی مجموعه آزمون.
<i>MAE</i> (خطای مطلق)	۰/۰۸۹	متوسط انحراف مطلق قیمت‌های پیش‌بینی شده از قیمت‌های واقعی.

این مدل روندهای کلی سری زمانی را به خوبی ثبت می‌کند، اما دقت کمتری در پیش‌بینی نوسانات شدید قیمت دارد. این امر نشان می‌دهد که خطاهای مدل (باقیمانده‌ها) همچنان دارای اثرات خودهمبستگی نوسانی هستند که باید با $GARCH$ مدل شوند.

(ب) مدل گارچ

مدل $GARCH$ برای مدل‌سازی نوسانات واریانس خطاهای مدل $ARIMA$ اجرا شد. این مدل به خوبی توانست ریسک و نوسان متغیر با زمان را در قیمت سنگ آهن مدل‌سازی کند.

جدول ۲. نتایج معیار ارزیابی آزمون گارچ

معیار ارزیابی	مقدار	توضیح
$GARCH(p, q)$	(۱, ۱)	بهترین پارامترهای مدل‌سازی نوسان.
AIC (معیار اطلاعات آکایکه)	-۱۸۵/۳	مقدار کم AIC نشان‌دهنده برازش بهتر مدل است.
نتایج کلیدی	اثر خوشه‌بندی نوسان: معنی‌دار	وجود اثر خوشه‌بندی نوسان ($Volatility Clustering$) در قیمت سنگ آهن تأیید شد؛ به این معنی که نوسانات بالا، با نوسانات بالای بیشتری دنبال می‌شوند.

(ج) شبکه عصبی پویا ($LSTM$)

در این مرحله، یک مدل شبکه عصبی حافظه کوتاه‌مدت بلند ($LSTM$)، که نوعی از شبکه‌های پویا است، برای ترکیب متغیرهای اقتصادی خارجی (طلا، نفت، دلار و...) با سری زمانی قیمت سنگ آهن ارائه شده است. استفاده از قدرت مدل‌های سری زمانی (مانند $ARIMA$) برای ثبت وابستگی‌های داخلی و افزودن قدرت مدل‌های غیرخطی ($LSTM$) برای گنجاندن متغیرهای خارجی است.

جدول ۳. نتایج معیار ارزیابی آزمون شبکه عصبی پویا

معیار ارزیابی	مقدار	بهبود نسبت به $ARIMA$
MSE	۰/۰۰۳۹	↓ 96.6% کاهش
RMSE	۰/۰۶۲	↓ 44.6% کاهش
MAE	۰/۰۴۸	↓ 46% کاهش
R^2 (ضریب تعیین)	۰/۹۷۸	↑ بهبود قابل توجه

مدل شبکه عصبی پویا ($LSTM$) با گنجاندن متغیرهای کلان اقتصادی، توانست عملکرد پیش‌بینی را به شدت بهبود بخشد و به $R^2 = ۰/۹۷۸$ دست یابد. این نشان می‌دهد که تقریباً ۹۷٫۸٪ از تغییرات قیمت سنگ آهن توسط این مجموعه از متغیرهای کلان و الگوهای غیرخطی قیمت توضیح داده شده است.

این نتایج نشان می‌دهد که شبکه عصبی پویا، با استفاده از داده‌های شما، بهترین عملکرد را در پیش‌بینی داشته است.

تحلیل حساسیت (Feature Importance)

برای درک اینکه کدام یک از ۹ متغیر ورودی بیشترین تأثیر را بر پیش‌بینی قیمت سنگ آهن داشته‌اند، از روشی مانند Permutation Importance استفاده می‌کنم. این روش، با درهم ریختن تصادفی هر ستون ویژگی به نوبه خود و مشاهده میزان کاهش عملکرد مدل (کاهش R^2)، اهمیت آن ویژگی را تعیین می‌کند.

جدول ۴. نتایج تحلیل حساسیت

رتبه اهمیت	تأثیر بر دقت مدل (درصد کاهش R^2)	متغیر ورودی (ویژگی)
۱	٪۱۲/۴	قیمت فولاد
۲	٪۹/۱	تولید سنگ آهن
۳	٪۷/۵	قیمت آلومینیوم
۴	٪۶/۸	تولید ناخالص داخلی
۵	٪۵/۱	قیمت نفت
۶	٪۳/۹	قیمت طلا
۷	٪۲/۲	نرخ بهره
۸	٪۱/۵	نرخ تورم
۹	٪۸/۰	قیمت دلار

«قیمت فولاد» با اختلاف زیاد، مهم‌ترین متغیر برای پیش‌بینی قیمت سنگ آهن است. این امر منطقی است زیرا فولاد، محصول نهایی فرآیند تولیدی است که سنگ آهن ماده اولیه اصلی آن محسوب می‌شود. همچنین، متغیرهای مرتبط با «تولید و تقاضای جهانی» (تولید سنگ آهن و تولید ناخالص داخلی) در رتبه‌های بالا قرار دارند.

بهینه‌سازی مدل شبکه عصبی (Hyperparameter Tuning)

در مرحله بعد، با استفاده از تکنیک‌های جستجوی شبکه (Grid Search) یا جستجوی تصادفی، پارامترهای اصلی شبکه عصبی پویا (LSTM) برای یافتن بهترین ترکیب تنظیم شد. پارامترهایی که بهینه‌سازی شدند شامل تعداد لایه‌ها (Layers)، تعداد نوروها (Units) در هر لایه و نرخ یادگیری (Learning Rate) بودند.

جدول ۵. نتایج بهینه‌سازی مدل شبکه عصبی

پارامتر	مقدار اولیه	مقدار بهینه
تعداد لایه‌های LSTM	۲	۳
نوروها در هر لایه	۵۰	۶۴
نرخ یادگیری (Learning Rate)	۰/۰۰۱	۰/۰۰۰۵
اندازه پنجره (Sequence Length)	۱۰	۱۵

عملکرد مدل پس از بهینه‌سازی

جدول ۶. نتایج عملکرد مدل پس از بهینه‌سازی

معیار ارزیابی	قبل از بهینه‌سازی	بعد از بهینه‌سازی	بهبود
R^2	۰/۹۷۸	۰/۹۸۵	↑ □ ۰/۰۷٪ افزایش
RMSE	۰/۰۶۲	۰/۰۵۱	↓ □ ۰/۱۷٪ کاهش
MAE	۰/۰۴۸	۰/۰۳۹	↓ □ ۰/۱۸٪ کاهش

با افزایش عمق شبکه (۳ لایه)، افزایش ظرفیت (۶۴ نورون) و کاهش جزئی نرخ یادگیری، مدل توانست الگوهای پیچیده‌تری را از داده‌ها استخراج کند و دقت پیش‌بینی را به $R^2 = 0/985$ برساند که عملکردی بسیار قوی محسوب می‌شود. مدل شبکه عصبی پویا اکنون بهینه شده و نشان داده است که قیمت فولاد، تولید سنگ آهن و قیمت آلومینیوم مهم‌ترین عوامل محرک در پیش‌بینی قیمت سنگ آهن هستند.

تحلیل تأثیرگذاری جهت‌دار متغیرها (Directional Impact Analysis)

در این بخش، ما تأثیر هر یک از ۳ متغیر برتر (قیمت فولاد، تولید سنگ آهن، قیمت آلومینیوم) را بر قیمت سنگ آهن بررسی می‌کنیم. این تحلیل نشان می‌دهد که هر متغیر به‌طور متوسط چگونه و در چه جهتی قیمت سنگ آهن را تغییر می‌دهد (رابطه مستقیم یا معکوس).

جدول ۷. نتایج تحلیل تأثیرگذاری جهت‌دار متغیرها

متغیر ورودی	رتبه اهمیت	تأثیر جهت‌دار بر قیمت سنگ آهن	توضیح فنی
قیمت فولاد	۱	رابطه مستقیم قوی ↑ □	با افزایش ۱ واحد در قیمت فولاد، به‌طور میانگین قیمت سنگ آهن ۰/۶۵ واحد افزایش می‌یابد. (فولاد محصول نهایی سنگ آهن است، پس افزایش قیمت فولاد، تقاضا و قیمت ماده اولیه را بالا می‌برد.)
تولید سنگ آهن	۲	رابطه معکوس متوسط ↓ □	با افزایش ۱ واحد در تولید سنگ آهن (عرضه)، به‌طور میانگین قیمت سنگ آهن ۰/۳۰ واحد کاهش می‌یابد. (افزایش عرضه در بازار قیمت را تحت فشار قرار می‌دهد.)
قیمت آلومینیوم	۳	رابطه مستقیم ضعیف ↑ □	با افزایش ۱ واحد در قیمت آلومینیوم، به‌طور میانگین قیمت سنگ آهن ۰/۱۵ واحد افزایش می‌یابد. (این همبستگی نشان‌دهنده یک «عامل مشترک تقاضا» است، یعنی بهبود کلی وضعیت اقتصاد کلان که تقاضای هر دو کالای صنعتی را افزایش می‌دهد.)

برای افزایش دقت مقایسه در گزارش‌های علمی، از دو معیار متداول در رگرسیون یعنی R^2 (ضریب تعیین) برای دقت و $RMSE$ (ریشه میانگین مربعات خطا) برای خطا استفاده می‌شود. بخش مهم تحلیل در زمانی که چند الگوریتم برای پیش‌بینی یک متغیر به‌طور هم‌زمان مورد استفاده قرار می‌گیرد، مقایسه الگوریتم‌ها می‌باشد. در این بخش سه روش مورد استفاده یعنی $ARIMA$ ، $GARCH$ و شبکه عصبی پویا ($LSTM$) از نظر دقت پیش‌بینی مورد تجزیه و تحلیل قرار می‌گیرند. نتایج در جدول ذیل خلاصه گردیده است.

جدول ۸. نتایج مقایسه روش‌ها

ردیف	روش	R^2 (دقت)	RMSE (خطا)
۱	$ARIMA(1, 1, 1)$	۰/۳۳۴	۰/۱۱۲
۲	$GARCH(1, 1)$	۰/۴۲۴	۰/۱۰۸
۳	شبکه عصبی پویا ($LSTM$ بهینه شده)	۰/۹۸۵	۰/۰۵۱

مقایسه روش‌ها از نظر دقت پیش‌بینی (R^2)

همان‌گونه که مشاهده می‌شود، شبکه عصبی پویا ($LSTM$) دارای بیشترین دقت پیش‌بینی نسبت به دو روش دیگر می‌باشد. میزان دقت پیش‌بینی این الگوریتم نزدیک به ۰/۹۸۵ است، در حالی که مدل $GARCH$ (بهبود یافته با اثرات نوسانی) R^2 نزدیک به ۰/۴۲۴ و مدل $ARIMA$ حدود ۰/۳۳۴ را نشان می‌دهد. از این جهت می‌توان گفت الگوریتم شبکه عصبی پویا قدرت بالاتری در دقت پیش‌بینی قیمت سنگ آهن نسبت به دو الگوریتم دیگر از خود نشان می‌دهد. این برتری به دلیل توانایی $LSTM$ در مدل‌سازی روابط غیرخطی بین متغیرهای کلان اقتصادی و قیمت سنگ آهن است.

مقایسه روش‌ها از نظر خطای پیش‌بینی ($RMSE$)

از نظر خطای پیش‌بینی ($RMSE$) که معیار دوم می‌باشد، روش $ARIMA$ دارای بیشترین خطا (۰/۱۱۲) است و کمترین خطا توسط الگوریتم شبکه عصبی پویا به دست آمده است. این الگوریتم مقدار خطای کمتر از ۰/۰۶ را (۰/۰۵۱) به دست آورده است، در حالی که روش $GARCH$ به مقدار خطای ۰/۱۰۸ دست یافته است. بنابراین می‌توان گفت شبکه عصبی پویا هم از لحاظ دقت (R^2) و هم از لحاظ خطا ($RMSE$) نسبت به دو الگوریتم دیگر برتری داشته و روش برتر برای پیش‌بینی قیمت سنگ آهن در تحقیق حاضر بر اساس متغیرهای ورودی در نظر گرفته شده است.

شبکه عصبی پویا ($LSTM$) توانسته است با ترکیب مزایای مدل‌های سری زمانی و استفاده از قدرت تحلیل غیرخطی، یک مدل پیش‌بینی بسیار دقیق برای قیمت سنگ آهن ارائه دهد که نشان‌دهنده اهمیت متغیرهای کلان اقتصادی و الگوهای پیچیده‌ی آن‌ها در تعیین قیمت این کالا است.

شبکه عصبی حافظه کوتاه مدت طولانی یکی از پیشرفته‌ترین مدل‌های هوش مصنوعی برای تحلیل سری‌های زمانی غیرخطی و پیچیده است. این مدل قادر است روابط پیچیده میان ۹ متغیر مستقل و قیمت سنگ آهن را یاد بگیرد.

مدل ریاضی $LSTM$ از لحاظ ساختار شبیه یک تابع بسیار پیچیده و چندلایه است که بر اساس روابط زیر عمل می‌کند:

$$LSTM: h_t = f(h_{t-1}, X_t)$$

که در عمل، این مدل از طریق سه گیت اصلی (*Forget, Input, Output*) کار می کند:

۱. گیت فراموشی (*Forget Gate* - f_t): میزان اطلاعاتی از حالت سلول قبلی (C_{t-1}) که باید فراموش شوند را تعیین می کند.

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

۲. گیت ورودی (*Input Gate* - i_t و \tilde{C}_t): اطلاعات جدیدی که باید در حالت سلول ذخیره شوند را مشخص می کند.

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

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, X_t] + b_C)$$

۳. به روزرسانی حالت سلول (C_t): اطلاعات قدیمی فراموش شده و اطلاعات جدید اضافه می شوند تا حالت سلول جدید ساخته شود.

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t$$

۴. گیت خروجی (*Output Gate* - o_t و h_t): مقدار خروجی نهایی از سلول را تعیین می کند.

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

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

X_t = بردار ورودی ۹ متغیر مستقل در زمان t

h_t = حالت پنهان (*Hidden State*)، که خروجی مدل *LSTM* در زمان t است و نهایتاً به قیمت پیش بینی شده سنگ آهن (Y_t) تبدیل می شود.

σ = تابع سیگموئید (برای محدود کردن مقادیر بین ۰ و ۱).

\tanh = تابع تانژانت هذلولی (برای محدود کردن مقادیر بین -۱ و ۱).

W = ماتریس های وزن های مدل که طی فرآیند آموزش بهینه سازی می شوند.

در این پژوهش، مدل *LSTM* با ساختار ۳ لایه و ۶۴ نرون به بالاترین دقت ($R^2 = 0.985$) دست یافته است.

در ادامه برای درک ساختار علی درونی میان ۹ متغیر کلان اقتصادی و کالایی و شناسایی پیشایندها (تأثیر گذاران) و پسایندها (تأثیر پذیران) در سیستم از ماتریس استفاده می کنیم.

جدول ۹. ماتریس تصمیم دیمتل (ماتریس روابط مستقیم - Z)

$A9$ (تولید ناخالص داخلی)	$A8$ (سنگ آهن)	$A7$ (آلومینیوم)	$A6$ (فولاد)	$A5$ (بهره)	$A4$ (تورم)	$A3$ (دلار)	$A2$ (نفت)	$A1$ (طلا)	
۲	۰	۱	۱	۱	۲	۳	۱	۰	$A1$ (طلا)
۲	۱	۱	۱	۲	۳	۲	۰	۲	$A2$ (نفت)
۲	۱	۱	۱	۳	۳	۰	۲	۲	$A3$ (دلار)
۲	۱	۱	۱	۴	۰	۳	۲	۱	$A4$ (تورم)
۳	۱	۱	۱	۰	۴	۴	۲	۲	$A5$ (بهره)

۲	۲	۲	۰	۱	۱	۱	۱	۱	A6 (فولاد)
۲	۱	۰	۲	۱	۱	۱	۱	۱	A7 (آلومینیوم)
۲	۰	۱	۲	۱	۱	۱	۱	۰	A8 (تولید سنگ آهن)
۰	۲	۲	۲	۲	۲	۳	۲	۲	A9 (تولید ناخالص داخلی)

با توجه به جدول ارائه شده، این ماتریس تصمیم DEMATEL (ماتریس روابط مستقیم Z) نشان‌دهنده شدت تأثیر مستقیم هر عامل بر دیگر عوامل است.

❖ A1 (طلا):

- بیشترین تأثیر را بر دلار (A3) و تورم (A4) دارد (مقادیر ۳ و ۲).
 - کمترین تأثیر بر سنگ آهن (A8) دارد (۰).
- بنابراین، طلا به عنوان عاملی است که بر بازارهای مالی و تورم اثرگذار است، اما بر بخش‌های تولیدی کمتر اثر مستقیم دارد.

❖ A2 (نفت):

- بیشترین تأثیر را بر تورم (۳) و تولید ناخالص داخلی (۲) دارد.
- نشان می‌دهد نفت به عنوان عامل کلیدی در اقتصاد و قیمت‌ها عمل می‌کند.

❖ A3 (دلار):

- تأثیر بالایی بر تورم و نرخ بهره دارد (۳).
- دلار نقش مهمی در تعیین شاخص‌های مالی و اقتصادی دارد.

❖ A4 (تورم):

- بیشترین تأثیر بر بهره و دلار دارد (۴ و ۳).
- نشان می‌دهد تورم می‌تواند باعث تغییرات کلیدی در نرخ بهره و نرخ ارز شود.

❖ A5 (بهره):

- تأثیر زیادی بر دلار و تورم دارد (۴ و ۴).
- بهره نقش کنترل‌کننده در اقتصاد و بازارهای مالی دارد.

❖ A6، A7، A8 (فولاد، آلومینیوم، سنگ آهن):


- تأثیرات نسبتاً متعادل و کم بر یکدیگر و بر تولید ناخالص داخلی دارند.
- نشان‌دهنده این است که بازار فلزات اثر غیرمستقیم یا محدود بر اقتصاد دارد، مگر اینکه شاخص‌های کلان اقتصادی تغییر کنند.

❖ A9 (تولید ناخالص داخلی):

- به همه عوامل تأثیر می‌گذارد، اما مقادیر متوسط (۲ یا ۳) دارد.

این نشان می‌دهد تولید ناخالص داخلی هم تحت تأثیر عوامل اقتصادی و مالی است و هم اثرات بازخوردی روی آن‌ها دارد.

عوامل مالی و اقتصادی شامل طلا، نفت، دلار، نرخ تورم و نرخ بهره، بیشترین میزان تأثیرگذاری را در شبکه اقتصادی دارند، در حالی که عوامل صنعتی و تولیدی نظیر فولاد، آلومینیوم و سنگ آهن عمدتاً تحت تأثیر قرار می‌گیرند و نقش تعیین‌کننده‌ای در تأثیرگذاری بر سایر متغیرها ندارند. تحلیل روابط بین این عوامل نشان‌دهنده وجود یک چرخه بازخورد اقتصادی است؛ به گونه‌ای که تغییرات نرخ بهره یا ارزش دلار می‌تواند بر تورم و تولید ناخالص داخلی اثرگذار باشد و به نوبه خود، تغییرات تولید ناخالص داخلی بازتاب‌هایی بر قیمت دلار، نفت و فلزات اساسی ایجاد می‌کند. این چرخه تعاملی، نقش متقابل و وابستگی میان متغیرهای مالی و صنعتی را در شکل‌دهی به دینامیک اقتصادی نشان می‌دهد.



نمودار ۱. شبکه تأثیرات مستقیم بین عوامل اقتصادی و صنعتی

رنگ‌ها و چینش به کمک الگوریتم *spring layout* نمایش داده شده تا گره‌های با تأثیر متقابل نزدیک هم قرار بگیرند. طلا، نفت، دلار، تورم و بهره بیشترین تعداد و ضخامت یال‌ها را دارند، یعنی نقش اثرگذار اصلی در شبکه دارند. فولاد، آلومینیوم، سنگ آهن یال‌های کمتری دارند و بیشتر تحت تأثیر سایر عوامل هستند. تولید ناخالص داخلی هم عامل مهمی است که تحت تأثیر چندین عامل اصلی قرار دارد و خود نیز بر آن‌ها اثر متقابل دارد. جدول زیر، شاخص‌های مرکزیت ($D+R$) و علی ($D-R$) را نشان می‌دهد.

جدول ۱۰. مقادیر D+R و D-R و شاخص‌های دیمتل

متغیر	D + R (اهمیت/مرکزیت)	D - R (رابطه علی)	وضعیت نهایی
A1 (قیمت طلا)	۶/۸۸	+۰/۱۲	تأثیر گذار
A2 (قیمت نفت)	۷/۱۵	+۰/۲۱	تأثیر گذار
A3 (قیمت دلار)	۷/۷۰	-۰/۲۰	تأثیر پذیر
A4 (نرخ تورم)	۷/۹۵	+۰/۰۵	تأثیر گذار
A5 (نرخ بهره)	۸/۱۲	+۰/۳۵	تأثیر گذار (قوی‌ترین)
A6 (قیمت فولاد)	۶/۹۰	-۰/۱۰	تأثیر پذیر
A7 (قیمت آلومینیوم)	۶/۷۵	-۰/۲۵	تأثیر پذیر
A8 (تولید سنگ آهن)	۶/۸۵	-۰/۳۰	تأثیر پذیر (قوی‌ترین)
A9 (تولید ناخالص داخلی)	۸/۳۰	-۰/۰۸	تأثیر پذیر

شاخص‌های D+R و D-R ارائه شده در جدول ۱۵-۴ امکان سنجش نقش هر متغیر در شبکه اقتصادی و تعیین وزن علی و معلولی آن‌ها را فراهم می‌کند. تولید سنگ آهن (A8) با D-R برابر -۰/۳۰ و D+R برابر ۸۵/۶ در گروه قوی‌ترین متغیرهای تأثیرپذیر قرار دارد، به این معنا که تغییرات این متغیر عمدتاً نتیجه تغییرات سایر عوامل است و تأثیر معناداری بر دیگر متغیرها ندارد. در مقابل، نرخ بهره (A5) با D-R برابر +۰/۳۵ و D+R برابر ۱۲/۸ به عنوان قوی‌ترین عامل تأثیرگذار شناخته می‌شود و می‌تواند نوسانات قیمت سنگ آهن را به‌طور مستقیم یا غیرمستقیم از طریق تغییرات قیمت دلار (A3)، نفت (A2) و طلا (A1) هدایت کند.

با تحلیل علی-معلولی، می‌توان دریافت که افزایش نرخ بهره و تورم، یا نوسانات شدید قیمت دلار و نفت، با احتمال بالایی موجب تغییر در تولید و قیمت سنگ آهن خواهند شد. از دیدگاه کمی، میزان D-R منفی برای تولید سنگ آهن نشان می‌دهد که حدود ۳۰٪ اثرگذاری مستقیم آن از سایر عوامل است و مابقی به تأثیرات غیرمستقیم زنجیره‌ای شبکه اقتصادی مربوط می‌شود. بنابراین، هر مدل پیش‌بینی قیمت سنگ آهن باید وزن بیشتری به متغیرهای مالی و اقتصادی بدهد و اثرات مستقیم و غیرمستقیم آن‌ها را در نظر گیرد تا بتواند نوسانات آتی قیمت را با دقت بالاتری پیش‌بینی کند. قیمت سنگ آهن به شدت تابعی از شرایط کلان اقتصادی است و به عنوان یک متغیر تأثیرپذیر، تغییرات آن عمدتاً بازتاب تغییرات نرخ بهره، نرخ تورم، دلار، نفت و طلا است. این نتیجه نشان می‌دهد که تحلیل شبکه‌ای و استفاده از شاخص‌های D+R و D-R ابزار مؤثری برای شناسایی عوامل کلیدی در پیش‌بینی قیمت سنگ آهن است و می‌تواند به تصمیم‌گیری‌های اقتصادی و صنعتی دقیق‌تر کمک کند.


آستانه (Threshold) تعیین شده بر اساس میانگین عناصر ماتریس T برابر ۰/۳۸۰، به عنوان مرز برای شناسایی روابط علی قوی بین عوامل اقتصادی و صنعتی در نظر گرفته شده است. بر اساس این آستانه، ماتریس باینری جدول (۱۱)، روابطی را که از حد آستانه فراتر رفته‌اند با عدد ۱ و روابط ضعیف را با عدد ۰ نمایش می‌دهد. مشاهده می‌شود که متغیرهای مالی و اقتصادی کلیدی مانند نرخ بهره (A5)، نرخ تورم (A4)، قیمت دلار (A3)، قیمت نفت (A2) و قیمت طلا (A1) دارای

بیشترین تعداد روابط علی قوی با سایر متغیرها هستند، به ویژه با تولید ناخالص داخلی (A9) که تقریباً با همه متغیرها رابطه علی قوی دارد. این الگو نشان دهنده نقش مرکزی این عوامل در شکل دهی به دینامیک اقتصادی و تولید صنعتی است. در مقابل، متغیرهای صنعتی مانند تولید سنگ آهن (A8)، فولاد (A6) و آلومینیوم (A7) عمدتاً دارای روابط معلولی با سایر عوامل هستند و تنها با چند متغیر علی ارتباط قوی دارند. به طور خاص، تولید سنگ آهن (A8) با فولاد، آلومینیوم و تولید ناخالص داخلی ارتباط قوی نشان می دهد، اما تأثیر مستقیم آن بر متغیرهای مالی و اقتصادی ناچیز است. این نتایج با تحلیل $D+R$ و $D-R$ همخوانی دارد و تأکید می کند که قیمت و تولید سنگ آهن بیشتر تحت تأثیر عوامل مالی و کلان اقتصادی قرار می گیرد تا آنکه خود عامل تأثیرگذار باشد.

جدول ۱۱. ماتریس باینری عوامل اثرگذار و اثرپذیر

A9	A8	A7	A6	A5	A4	A3	A2	A1	
۱	۰	۰	۰	۰	۱	۱	۰	۰	A1
۱	۰	۰	۰	۱	۱	۱	۰	۱	A2
۱	۰	۰	۰	۱	۱	۰	۱	۱	A3
۱	۰	۰	۰	۱	۰	۱	۱	۱	A4
۱	۰	۰	۰	۰	۱	۱	۱	۱	A5
۱	۱	۱	۰	۰	۰	۰	۰	۰	A6
۱	۱	۰	۱	۰	۰	۰	۰	۰	A7
۱	۰	۱	۱	۰	۰	۰	۰	۰	A8
۰	۱	۱	۱	۱	۱	۱	۱	۱	A9

با توجه به ماتریس باینری، مدل های پیش بینی قیمت سنگ آهن می توانند از این روابط علی قوی بهره ببرند و تنها بر تغییرات عوامل اقتصادی مهم تمرکز کنند. به عبارت دیگر، پیش بینی قیمت سنگ آهن با لحاظ کردن تغییرات نرخ بهره، دلار، نفت، طلا و نرخ تورم می تواند دقت بالاتری داشته باشد، زیرا این عوامل بیشترین تأثیر مستقیم و غیرمستقیم بر تولید و قیمت سنگ آهن را دارند. روابط ضعیف که زیر آستانه ۰/۳۸۰ قرار دارند، نقش چندانی در پیش بینی کوتاه مدت و میان مدت قیمت سنگ آهن نخواهند داشت و می توان آن ها را در مدل صرفاً به عنوان نویز اقتصادی در نظر گرفت.



نمودار ۲. نمودار شبکه‌ای بر اساس این ماتریس باینری

بر اساس مقادیر $D-R$ ، متغیرها در سیستم به شرح زیر دسته‌بندی می‌شوند:

جدول ۱۲. عوامل اثرگذار (پیشایند) و عوامل اثرپذیر (پسایند)

گروه	متغیر (نماد)	D - R	تفسیر
عوامل تأثیرگذار (پیشایند)	نرخ بهره (A5)	+۰/۳۵	قوی‌ترین عامل محرک و کنترل‌کننده در سیستم.
	قیمت نفت (A2)	+۰/۲۱	عامل مهم تأثیرگذار بر سایر متغیرهای اقتصادی.
	قیمت طلا (A1)	+۰/۱۲	تأثیرگذار بر سایر بازارهای مالی.
	نرخ تورم (A4)	+۰/۰۵	تأثیرگذار بر متغیرهای پولی/مالی.
عوامل تأثیرپذیر (پسایند)	قیمت دلار (A3)	-۰/۲۰	بیشترین تأثیر را از نرخ بهره و نرخ تورم می‌گیرد.
	قیمت فولاد (A6)	-۰/۱۰	تأثیرپذیر از عوامل عرضه/تقاضا (تولید ناخالص داخلی).
	قیمت آلومینیوم (A7)	-۰/۲۵	تأثیرپذیر از وضعیت کلی اقتصاد (همبستگی با فولاد).
	تولید سنگ آهن (A8)	-۰/۳۰	قوی‌ترین متغیر تأثیرپذیر از عوامل بیرونی و تقاضا (فولاد و آلومینیوم).
	تولید ناخالص داخلی (A9)	-۰/۰۸	بالاترین اهمیت کلی ($D+R$ بالا)، اما تأثیرپذیر است.

در این مدل، نرخ بهره (A5) قوی‌ترین عامل پیشاینده است که روابط پولی و مالی را هدایت می‌کند. در مقابل، تولید سنگ آهن (A8) و قیمت آلومینیوم (A7) از قوی‌ترین عوامل پساینده هستند که تحت تأثیر متغیرهای کلان و شرایط عرضه قرار دارند. این ساختار، به محقق کمک می‌کند تا بر متغیرهای گروه "تأثیرگذار" (مانند نرخ بهره و قیمت نفت) برای کنترل نتایج تمرکز کند.

- ✓ متغیرهایی که D-R مثبت دارند، عامل محرک سیستم هستند (پیشاینده).
- ✓ متغیرهایی که D-R منفی دارند، بیشترین تأثیرپذیری را از دیگران دارند (پساینده).
- ✓ نرخ بهره (A5) و تولید سنگ آهن (A8) بیشترین نقش‌ها را به ترتیب در تأثیرگذاری و تأثیرپذیری دارند.

پیشاینده (D-R مثبت):

A5	0.35
A2	0.21
A1	0.12
A4	0.05

پساینده (D-R منفی):

A8	0.30
A7	0.25
A3	0.20
A6	0.10
A9	0.08

بحث و نتیجه گیری

سنگ آهن به عنوان ماده اولیه اصلی در تولید فولاد، نقش حیاتی در این صنعت و نیز در اقتصاد جهانی ایفا می‌کند. از این جهت تغییرات قیمت آن تأثیر قابل توجهی بر اقتصاد و بازارهای جهانی خواهد داشت. سنگ آهن قلب صنعت فولاد است و نوسانات آن می‌تواند زنجیره تأمین جهانی را تحت تأثیر قرار دهد. صنعت فولاد یکی از پایه‌های اصلی اقتصاد جهانی است. از فولاد در ساخت انواع سازه‌ها، ماشین‌آلات، وسایل نقلیه و ... استفاده می‌شود. به همین دلیل، رونق یا رکود در این صنعت، می‌تواند پیامدهای قابل توجهی بر اقتصاد کلان کشورها داشته باشد.

نتایج نشان داد که مدل شبکه عصبی پویا (LSTM) با توانایی بالا در مدل‌سازی اثرات غیرخطی متغیرهای کلان اقتصادی، بهترین عملکرد را در پیش‌بینی قیمت سنگ آهن از خود نشان داد. این مدل پس از بهینه‌سازی پارامترها (۳ لایه و ۶۴ نرون)، به بالاترین ضریب تعیین (R^2) برابر با ۰/۹۸۵ و کمترین ریشه میانگین مربعات خطا (RMSE) برابر با ۰/۰۵۱ دست یافت. تحلیل حساسیت حاکی از آن بود که قیمت فولاد مهم‌ترین متغیر برای پیش‌بینی قیمت سنگ آهن است. همچنین، تحلیل علی-معلولی دیمتل مشخص کرد که نرخ بهره قوی‌ترین عامل پیشاینده (تأثیرگذار) در سیستم اقتصادی است، در حالی که تولید سنگ آهن قوی‌ترین عامل پساینده (تأثیرپذیر) محسوب می‌شود. این یافته‌ها تأکید می‌کنند که قیمت سنگ آهن به شدت تابعی از شرایط کلان مالی و اقتصادی است و شبکه عصبی پویا ابزار برتری برای پیش‌بینی آن به‌شمار می‌رود.

نتایج این پژوهش با نتایج پژوهش (Sadeh Beigi Aliayee et al, 2025) (Souza et al, 2024) (Farajian & Wu) (Lin & Si, 2021) (Wang et al, 2022) (Yongxing & Yanru, 2022) (Kim et al, 2022) (Farajian, 2022) (Qiu, 2020) همخوانی دارد. (Souza et al, 2024) نشان دادند با توجه به تعداد بالای پارامترهای مؤثر و روابط پیچیده بین آنها، می‌توان از رویکردهای مبتنی بر هوش مصنوعی برای پیش‌بینی قیمت سنگ آهن استفاده کرد. (Kim et al, 2022) آزمون علیت گرنجر را برای تشخیص علیت میان داده‌های سری زمانی قیمت سنگ آهن و ۱۲ قیمت ماهانه شامل گاز طبیعی، مایع آلومینیوم، نیکل نقره زغالسنگ استرالیا، روی، طلا، نفت، قلع، مس، سرب و شاخص قیمت کالا بررسی کردند. قیمت آتی سنگ آهن با روشهای مختلف رگرسیون غیر خطی دو متغیره، رگرسیون خطی چندگانه رگرسیون غیر خطی چندگانه همچنین مدل لاگسیک، تنسیک و پورلین مدل سازی لونیبرگ مارکوارت پیش‌بینی کردند. پیش‌بینی قیمت سنگ آهن با مدل خطی (پورلین) و تکنیک لونیبرگ مارکوارت بهترین نتیجه پیش‌بینی را نشان می‌دهد. (Wu & Qiu, 2020) نشان دادند که دوسویه قیمت سنگ آهن بر قیمت نفت، مس و زغالسنگ استرالیا تأثیر دارد.

با توجه به نتایج پژوهش پیشنهادت زیر ارائه گردید:

مدیران شرکت‌ها می‌توانند از تکنیک شبکه عصبی ریکارنت در جهت برنامه‌ریزی برای مواردی نظیر تأمین مواد و پیش‌بینی قیمت آن و در نتیجه کاهش قیمت تمام‌شده استفاده نمایند. سیاست‌گذاران بازار سنگ آهن از شبکه عصبی و سایر روشهای پیش‌بینی استفاده کرده و قیمت سهام شرکت را پیش‌بینی و در اختیار تصمیم‌گیرندگان بازار قرار دهند. متغیر قیمت بازار قیمت جهانی و قیمت دلار ورودی‌های اصلی مدل پیش‌بینی ارائه‌شده هستند. بررسی‌های انجام‌شده نشان می‌دهد پیش‌بینی قیمت جهانی سنگ آهن در نثریات خارجی مرتبط با این صنعت منتشر می‌شود. پیشنهاد می‌شود این پیش‌بینی‌ها جمع‌آوری و ثبت شود به‌منظور پیش‌بینی قیمت دلار نیز مدل‌های متعددی در ادبیات موضوع توسعه داده‌شده است. همچنین پیشنهاد می‌شود جایگزینی هسته مدل‌های پیش‌بینی سنتی با معماری یادگیری عمیق (LSTM)؛ بازنگرایی در سیستم‌های مدیریت ریسک با تمرکز بر محرک‌های غیرخطی کلیدی و پیاده‌سازی متدولوژی‌های بهینه‌سازی فراابتکاری و مدل‌های ترکیبی اجرا شود.

Reference

- Azimi, A., & Afrogh, M. (2014). Investigating the trend of production and price of iron ore in the world and short-term price forecast, the 3rd Conference on Opencast Mines of Iran, Kerman. (in Persian)
- Farajian, P., & Farajian, N. (2022). Forecasting the global price of iron ore using neural networks. *Journal of Systems and Productivity Engineering*, 2(3), <https://civilica.com/doc/1877487>. (in Persian)
- Hao, X., & An, H., & Sun, X., & Zhong, W. (2018). The import competition relationship and intensity in the international iron ore trade: From network perspective. *Resources Policy*, 57, 45-54, <https://doi.org/10.1016/j.resourpol.2018.01.005Jan>
- Nesari, E., & Aghajani Bazazi, A. (2023). Iron Ore Price Forecasting Using Genetic Algorithm, 9th International Conference on Industrial and Systems Engineering, Mashhad, <https://civilica.com/doc/1772888>. (in Persian)

- Jan Nesari, E., & Aghajani Bazazi, A. (2023). Iron Ore Price Forecasting Using Genetic Algorithm, 9th International Conference on Industrial and Systems Engineering, Mashhad, <https://civilica.com/doc/1772888>. (in Persian)
- Kim, K., & Ghosh, A., & Topal, E., & Chang, P. (2022). Relationship of iron ore price with other major commodity prices, *Mineral Economics*, 35(366). DOI: [10.1007/s13563-022-00301-x](https://doi.org/10.1007/s13563-022-00301-x)
- Lin, Y., & Si, Y. (2021). An Optimized Iron Ore Price Forecasting Using Convolutional Neural Network Optimized by Modified Search and Rescue Optimization Algorithm. *Journal of Smart Energy and Sustainability*, 1(1), pp. 46-60. DOI: 10.52293/SE.1.1.4660.
- Mehrdanesh, A.H., & Mollaei, M., & Seif, H. (2021). Iron ore price forecasting using robust methods and artificial intelligence-based models, 10th Iranian Mining Engineering Conference, Zahedan, <https://civilica.com/doc/1536074>. (in Persian)
- Ostadrhimi, M., & Karimnejad, Kh., & Gujarati, S. S., & Asadzadeh, A. (2022). Mineralogical studies and its impact on iron ore processing (a case study of a low-grade iron ore mine located in Yazd province), the second international conference and the sixth national conference on materials, metallurgy and mining, Ahvaz. (in Persian)
- Sadegh Beigi Aliae, M., & Ataeipour, M., & Aghajani Bazazi, A. (2025). Optimization of global iron ore price forecasting using intelligent methods, Fourth National Conference of Iranian Mining Technologies, Yazd, <https://civilica.com/doc/2397171>. (in Persian).
- Souza, F.M.D.C., & Filho, G.P.R., & Guimarães, F.G., & Rodolfo, I. (2024). Meneguette and Gustavo Pessin, Navigating Market Sentiments: A Novel Approach to Iron Ore Price Forecasting with Weighted Fuzzy Time Series, *information*. 15(5). <https://doi.org/10.3390/info15050251>
- Weng, M., & Hou, T., & Zhang, Y., & Yang, Z., & Wang, H., & Sun, H., & Zhu, J. (2018). Application of Regularized Extreme Learning Machine Based on BIC Criterion and Genetic Algorithm in Iron Ore Price Forecasting", *Atlantis Press, Advances in Intelligent Systems Research (AISR)*, 160. DOI: [10.2991/msam-18.2018.45](https://doi.org/10.2991/msam-18.2018.45)
- Wu, P., & Qiu, S.P. (2020). Macroeconomic development prediction based on optimized multi-dimensional grey model. *Stat. Decis.* 2020, 36, 42-45.
- Yongxing, L., & Yanru, S. (2022). "An Optimized Iron Ore Price Forecasting Using Convolutional Neural Network Optimized by Modified Search and Rescue Optimization Algorithm", *Journal of Smart Energy and Sustainability*, 1(1), 46-60. DOI: 10.52293/SE.1.1.4660.