

Combining data envelopment analysis models and machine learning algorithms for evaluating the efficiency of decision-making units considering undesirable outputs

Ebrahim Golzar 

PhD student of Industrial Engineering, Faculty of Technology and Engineering, Science and Research Branch, Islamic Azad University, Tehran, Iran

Seyyed Esmaeil Najafi* 

Associate Professor of Industrial Engineering, Faculty of Technology and Engineering, Science and Research Branch, Islamic Azad University, Tehran, Iran

Seyyed Ahmad dalatpanah 

Associate Professor of Applied Mathematics, Ayandegan Institute of Higher Education, Tonokabon, Iran

Amir Azzi 

Assistant Professor of Industrial Engineering, Faculty of Technology and Engineering, Science and Research Branch, Islamic Azad University, Tehran, Iran

Abstract

Undesirable outputs are an integral part of production in various decision-making units, and to bring analyses closer to the real world, it is necessary to consider, undesirable outputs in performance evaluation research. In this paper, a new hybrid model for evaluating the efficiency of decision-making units in the oil industry is presented, which uses slack-based data envelopment analysis techniques and advanced machine learning algorithms. The proposed model specifically focuses on improving efficiency considering undesirable

* Corresponding Author: Najafi1515@gmail.com

How to Cite: Golzar, E., Najafi, E., Edalatpanah, A., Azizi, A.(2024). Combining data envelopment analysis models and machine learning algorithms for evaluating the efficiency of decision-making units considering undesirable outputs, *Industrial Management Studies*.....

Received: Original Research

Review

Accepted:

ISSN: 2251-8037

eISSN: 2476-5988

outputs and conditions of uncertainty. Three machine learning algorithms including artificial neural networks, support vector machines, and XGBoost are used to predict and improve the results of slack-based models. This study involves the evaluation of 37 decision-making units within the National Petroleum Products Distribution Company, and the results show a significant improvement in efficiency using predicted data compared to actual data. This research not only contributes to new perspectives in efficiency evaluation and improvement but also offers innovative hybrid methods to address challenges in operational management.

Introduction

Efficiency assessment of units is not always based on the existence of desirable outputs, as each production, industrial, or service unit can produce undesirable outputs, which are aimed to be minimized. Matters such as emission of pollutants, emission of carbon dioxide, waste generation, and the like are among the conditions that are considered undesirable outputs and the goal is to minimize them (Liu et al., 2023). On the other hand, undesirable outputs are generally uncertain, meaning that one cannot assume certainty in their production rate, which makes the issue more complex. Therefore, undesirable outputs are generally considered under conditions of uncertainty (Al-Saraf et al., 2020).

The application of artificial intelligence techniques alongside Data Envelopment Analysis (DEA) works in such a way that, in addition to evaluating the efficiency of decision-making units based on actual data using DEA, artificial intelligence techniques assist in conducting this evaluation based on predicted data. In other words, parameters are first predicted, and the predicted values are entered into the performance evaluation model, which is ultimately compared with the actual values. This process not only allows for reducing the gap between actual and predicted results but also enables improving efficiency based on the predicted results, considering the evolutionary nature of artificial intelligence algorithms. Therefore, when the goal is to enhance efficiency, artificial intelligence algorithms such as machine learning or deep learning can have practical applications in this field (Zadmirzaei et al., 2024).

The process involves first evaluating decision-making units using the SBM (Slacks-Based Measure) DEA model based on actual data. After obtaining the predicted values for two undesirable outputs, the evaluation of decision-making units is conducted based on these predicted values. Consequently, the results from actual data are compared with the results from

three algorithms: Artificial Neural Networks (ANN), Support Vector Machines (SVM), and XGBoost. The best method that leads to the highest efficiency for the decision-making units is selected.

Literature Review

In other words, this research is among the few studies that assess the impact of utilizing artificial intelligence and its evolutionary nature on the efficiency of decision-making units, based on a fuzzy SBM model, which has rarely been seen in existing literature. The evolutionary nature of artificial intelligence algorithms helps ensure that results are continuously improved, focusing on two variables with undesirable outputs so that improvements based on the evolution of these variables also enhance overall performance evaluation results.

Ebrahimi Nejad and Amani (2020) propose a fuzzy Data Envelopment Analysis (DEA) model that incorporates undesirable outputs with ideal points. Tavan and colleagues (2021) present a robust cross-efficiency DEA model that includes undesirable outputs. Chen et al. (2022) introduce a robust network DEA model for assessing sustainability. Omrani and colleagues (2022) evaluate insurance companies in the presence of uncertainty, proposing a multi-objective network DEA model with negative data and undesirable outputs for assessing insurance firms.

This review highlights the existing approaches in the field while identifying gaps that this research aims to address, particularly concerning the integration of artificial intelligence techniques with fuzzy DEA models in evaluating decision-making units with both desirable and undesirable outputs.

Methodology

In the present research, a Data Envelopment Analysis (DEA) using the SBM (Slacks-Based Measure) approach is presented. This model includes fuzzy outputs, which are a combination of desirable and undesirable outputs, while the inputs are considered deterministic. In this model, it is assumed that there are several Decision-Making Units (DMUs), each utilizing fuzzy outputs and deterministic inputs. The outputs consist of triangular fuzzy numbers and, as mentioned, are categorized into two groups: desirable and undesirable.

The combined model of Data Envelopment Analysis (DEA) using the SBM (Slacks-Based Measure)

approach and artificial intelligence algorithms is designed to enhance the efficiency and effectiveness of decision-making units (DMUs). This

integrated model leverages the strengths of both DEA, which evaluates the relative efficiency of DMUs, and AI algorithms, which can optimize parameters, predict outcomes, and improve data analysis.

Artificial Neural Networks

Artificial Neural Networks (ANNs) are computational networks that attempt to simulate the neural networks of central nervous systems in a crude manner. The processing of information and the physical structure of the brain are formed by a web of neural connections, which have a high capacity for modeling nonlinear systems. Additionally, ANNs possess good generalization capabilities and are robust against missing or noisy data.

Support Vector Machine

Support Vector Machine (SVM) is a classification algorithm that identifies the optimal boundary between different classes of data by utilizing support vectors. In simple terms, support vectors are a set of points in an n-dimensional data space that define the boundaries of the classes. The classification and separation of data are performed based on these support vectors, and moving one of them can potentially change the classification output.

XGBoost Algorithm

XGBoost (Extreme Gradient Boosting) is an open-source library that plays a significant role in the efficient implementation of decision trees. The C++ code of the XGBoost algorithm, along with its Python interface, can create a powerful package that is easy to execute. Due to its outstanding performance, XGBoost has achieved success in many Kaggle competitions. XGBoost utilizes gradient boosting techniques to enhance the predictive power of models by combining multiple weak learners (typically decision trees) into a single strong learner.

Result

The subject of the present study includes 37 subsidiaries of the National Iranian Oil Products Distribution Company. This case study was also utilized in the researcher's previous investigation. The extracted variables have been collected from the database and information sources of these companies.

The results of the present study indicate that the use of artificial intelligence algorithms can help improve the efficiency of decision-making units, as these algorithms operate based on predicted data. Due to their


evolutionary nature, they are capable of achieving better results; therefore, the outcomes derived from predicted data are superior to those obtained from actual data. Consequently, artificial intelligence techniques can be utilized in other research related to efficiency evaluation, especially in studies conducted based on Data Envelopment Analysis (DEA) models.

Keywords: Data envelopment analysis, Machine learning, Artificial neural network, Support vector machine, XGBoost, Undesirable outputs, Oil industry.


آماده انتشار

ترکیب مدل‌های تحلیل پوششی داده‌ها و الگوریتم‌های یادگیری ماشین برای ارزیابی کارایی واحدهای تصمیم‌گیری با در نظر گرفتن ستانده‌های نامطلوب^۱


دانشجوی دکتری رشته مهندسی صنایع، دانشکده فنی و مهندسی، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی تهران، ایران

ابراهیم گلزار  ID


دانشیار گروه مهندسی صنایع، دانشکده فنی و مهندسی، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی تهران، ایران

سید اسماعیل نجفی  ID *

دانشیار گروه ریاضی کاربردی، موسسه آموزش عالی آیندگان، تنکابن، ایران

سید احمد عدالت پناه  ID

استادیار گروه مهندسی صنایع، دانشکده فنی و مهندسی، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی تهران، ایران

امیر عزیزی  ID

چکیده

ستانده نامطلوب جز لاینفکی از تولید در واحدهای تصمیم‌گیری مختلف می‌باشد و در جهت نزدیک‌تر کردن تحلیلها به جهان واقعی نیاز به در نظر گرفتن ستانده نامطلوب در تحقیقات مرتبط با ارزیابی عملکرد می‌باشد، در این مقاله، یک مدل ترکیبی جدید برای ارزیابی کارایی واحدهای تصمیم‌گیری در صنعت نفت ارائه شده است که در آن از تکنیک‌های تحلیل پوششی داده‌های اسلک محور و الگوریتم‌های پیشرفته یادگیری ماشین استفاده می‌شود. مدل پیشنهادی به‌خصوص بر بهبود کارایی با توجه به ستانده‌های نامطلوب و در شرایط عدم قطعیت تمرکز دارد. سه الگوریتم یادگیری ماشین شامل شبکه‌های عصبی مصنوعی، ماشین‌های بردار پشتیبانی و XGBoost برای پیش‌بینی و بهبود نتایج مدل‌های اسلک محور مورد استفاده قرار گرفته‌اند. این مطالعه شامل ارزیابی ۳۷ واحد تصمیم‌گیری زیرمجموعه شرکت ملی پخش فرآورده‌های نفتی بوده که نتایج نشان دهنده بهبود معنادار کارایی با استفاده از داده‌های پیش‌بینی شده در مقایسه با داده‌های واقعی است. این تحقیق

^۱. مقاله حاضر برگرفته از رساله دکتری رشته مهندسی صنایع دانشگاه آزاد واحد علوم و تحقیقات است.

* نویسنده مسئول: Najafi1515@gmail.com

نه تنها به ارائه دیدگاه‌های جدید در ارزیابی و بهبود کارایی کمک می‌کند، بلکه روش‌های ترکیبی نوآورانه‌ای را برای مقابله با چالش‌های موجود در مدیریت عملیاتی ارائه می‌دهد.

کلیدواژه‌ها: تحلیل پوششی داده‌ها، یادگیری ماشین، شبکه عصبی مصنوعی، ماشین بردار پشتیبان، XGBoost، ستانده‌های نامطلوب، صنعت نفت.

آماده انتشار

مقدمه

ارزیابی کارایی واحدها همواره بر اساس وجود ستانده مطلوب صورت نمی گیرد چرا که هر واحد تولیدی یا صنعتی یا خدماتی می تواند ستانده های نامطلوبی را نیز تولید نماید که هدف حداقل ساختن آن می باشد. مواردی نظیر نشر آلاینده‌گی، نشر دی اکسید کربن، تولید زباله و مواردی از این دست در زمره شرایطی هستند که به عنوان ستانده نامطلوب تلقی شده و هدف حداقل ساختن آن میباشد (Liu et al., 2023). از سوی دیگر ستانده‌های نامطلوب عموماً به صورت غیر قطعی می باشند یعنی نمی توان قطعیتی در میزان تولید آنها متصور بود که همین امر منجر به پیچیده شدن مسئله می شود بنابراین عموماً ستانده نامطلوب در شرایط عدم قطعیت مورد توجه می باشد. (Al-Saraf et al., 2020)

به منظور ارزیابی کارایی یکی از تکنیکهای مهم و کاربردی و همواره در تحقیقات مختلف ارزیابی عملکرد نتایج خوبی را از خود بروز داده است تکنیک تحلیل پوششی داده ها می باشد (Kao et al., 2021). این تکنیک همچون سایر تکنیکها در گذر زمان دچار تحولات بسیاری شده است به گونه‌ای که یکی از این تحولات شکلگیری مدل¹ SBM بوده است. مدل SBM بر اساس متغیرهای مصنوعی شکل می گیرد و برای بسیاری از مسائل ارزیابی کارایی دارای کاربرد و استفاده می باشد. اما با افزایش بهره گیری از تکنیکهای هوش مصنوعی توجه به ترکیب این دو حوزه یعنی تحلیل پوششی داده ها و هوش مصنوعی افزایش قابل توجهی یافته است. به گونه‌ای که محققان به منظور بهبود نتایج حاصل از ارزیابی کارایی به تکنیکهای هوش مصنوعی سوق داده شده اند (Li et al., 2022).

کاربرد تکنیکهای هوش مصنوعی در کنار تحلیل پوششی داده‌ها به این صورت است که در کنار ارزیابی کارایی واحدهای تصمیمگیری بر اساس داده‌های واقعی با کمک تکنیک تحلیل پوششی داده‌ها، تکنیکهای هوش مصنوعی کمک میکند که این ارزیابی بر اساس داده های پیش بینی شده صورت گیرد. به عبارت دیگر ابتدا پارامترها پیش بینی شده و مقادیر پیش بینی شده وارد مدل ارزیابی عملکرد می شود و در نهایت با مقادیر واقعی مقایسه می شود این کار هم اجازه می دهد که فاصله نتایج واقعی با پیش بینی شده کاهش یابد و هم اینکه امکان بهبود کارایی بر اساس نتایج پیش بینی شده با توجه به ماهیت تکاملی الگوریتمهای هوش مصنوعی فراهم می شود. بنابراین در زمانی که هدف بهبود کارایی باشد

¹ Slack-Based Measure

الگوریتمهای هوش مصنوعی نظیر الگوریتمهای یادگیری ماشین یا یادگیری عمیق می توانند در این حوزه کاربرد عملی داشته باشند (Zadmirzaei et al., 2024).

در تحقیق حاضر هدف در ابتدا سنجش کارایی واحدهای تصمیم گیری بر اساس ستانده های مطلوب و نامطلوب فازی می باشد که با توجه به اینکه در تحقیقات پیشین ، ستانده نامطلوب بر اساس الگوریتمهای هوش مصنوعی به ندرت پیش بینی شده و رویکرد ترکیبی هوش مصنوعی و تحلیل پوششی داده ها به ندرت استفاده شده است از این جهت می توان گفت تحقیق حاضر مشمول نوآوری می باشد. به این صورت که یکبار با استفاده از مدل تحلیل پوششی داده های SBM ارزیابی واحدهای تصمیم گیری بر اساس داده های واقعی صورت گرفته و سپس پس از دستیابی به مقادیر پیش بینی شده دو ستانده نامطلوب، ارزیابی واحدهای تصمیم گیری بر اساس مقادیر پیش بینی شده ستانده نامطلوب صورت میگیرد به این ترتیب نتایج داده های واقعی به نتایج سه الگوریتم شبکه عصبی مصنوعی، ماشین بردار پشتیبان و¹ XGboost مقایسه شده و بهترین روش که منجر به بیشترین کارایی برای واحدهای تصمیمگیری شده است انتخاب میگردد به عبارت دیگر تحقیق حاضر در زمره معدود تحقیقاتی است که اثر بهره گیری از هوش مصنوعی و ماهیت تکاملی انرا بر کارایی واحدهای تصمیم گیری می سنجد که مبتنی بر مدل SBM فازی بوده که به ندرت مشابه این تحقیق در ادبیات تحقیق به چشم میخورد. ماهیت تکاملی الگوریتمهای هوش مصنوعی کمک میکند که نتایج به طور مستمر بهبود یافته و این بهبود بر روی دو متغیر دارای ستانده نامطلوب صورت میگیرد تا با بهبود مبتنی بر تکامل این متغیرها نتیجه کل ارزیابی عملکرد نیز بهبود یابد. مقاله به این صورت تنظیم شده است که در ابتدا مرور ادبیات ارائه شده و شکاف تحقیقاتی استخراج می شود و در ادامه مدل و روش شناسی ارائه میگردد. پس از آن تجزیه و تحلیل یافته ها انجام شده و در انتها نتیجهگیری ارائه میگردد.

پیشینه پژوهش

مروری در این بخش به مرور ادبیات در خصوص نزدیکترین تحقیقات به تحقیق حاضر از نظر مفهومی پرداخته میشود. تحقیقات انجام شده بیشتر متمرکز بر ارزیابی کارایی واحدهای تصمیمگیری بر اساس ستانده نامطلوب بوده و مربوط به ۴ سال اخیر میباشند. ضمن اینکه

¹ Extreme Gradient Boosting

اغلب داده‌های مورد استفاده دارای ماهیت غیر قطعی میباشند. در انتها بر اساس مرور ادبیات انجام شده شکاف تحقیقاتی استخراج می شود. (Ebrahimnejad & Amani.,2021) یک مدل تحلیل پوششی داده های فازی را با وجود ستانده نامطلوب با نقاط ایده آل ارائه می کنند. (Tavana et al.,2021) یک مدل تحلیل پوششی داده‌های کارائی متقاطع استوار را با ستانده نامطلوب ارائه میکنند. (Chen et al.,2022) یک مدل تحلیل پوششی داده های شبکه‌های استوار را برای ارزیابی پایداری ارائه میکنند. تحقیق (Omrani et al.,2022) به ارزیابی شرکتهای بیمه با وجود عدم قطعیت اقدام میکنند. یک مدل تحلیل پوششی داده های شبکه‌های چند هدفه با داده‌های منفی و ستانده نامطلوب به منظور ارزیابی شرکتهای بیمه ارائه میشود.

(Tavassoli et al.,2023) به اندازه‌گیری پایداری نیروگاههای سیکل ترکیبی میردازد در این مسیر از یک مدل تحلیل پوششی داده های شبکه ای فازی جدید بهره گرفته میشود. (Omrani et al., 2023) به سنجش کارائی پایدار واحدهای تصمیمگیری با در نظر گرفتن ستانده نامطلوب اقدام میکنند. این مدل برای شرکتهای ایرلاین با استفاده از ترکیبی از روشهای تاپسیس و تحلیل پوششی داده‌ها به صورت چند هدفه اعمال میشود. (Zou et al., 2023) به تحلیل سنجش کارائی و عوامل اثرگذار بر اقتصاد سبز دریایی بر اساس یک مدل تحلیل پوششی داده‌های شبکه‌های دو مرحله‌ای میردازند. (Omrani et al., 2023) از یک مدل تحلیل پوششی داده‌های استوار تحت سناریوهای عدم قطعیت جهت ارزیابی شعبات بانک بهره میگیرند. (Saeedi et al., 2023) به تجزیه کارائی در شبکه سه مرحله‌ای با ستانده مطلوب و نامطلوب فازی و نهاده فازی در تحلیل پوششی داده‌ها میردازند. (Amirteimoori et al., 2023) تحلیل پوششی داده های تصادفی را با وجود ستانده نامطلوب انجام میدهند.

(Sanchooli et al., 2023) دو مدل تحلیل پوششی داده های شبکه ای استوار جدید را برای دستیابی به بازه نمره عملکرد سیستمهای سریالی چند مرحله‌ای ارائه میکنند. (Zadmirzaei et al., 2024) یک رویکرد ترکیبی هوش مصنوعی و تحلیل پوششی داده‌های فازی را برای ارزیابی کارائی زیست محیطی و پیشبینی نشر دی اکسید کربن ارائه میکنند.

همانگونه که مشاهده می شود تحقیقات انجام شده عمدتاً به ارزیابی واحدهای تصمیمگیری بر اساس ستانده نامطلوب پرداخته‌اند که از تکنیک تحلیل پوششی داده‌ها در این مسیر استفاده شده است. اما در بین تحقیقات انجام شده غیر از تحقیق (Zadmirzaei et al., 2024) که از ترکیب هوش مصنوعی و تحلیل پوششی داده‌های فازی استفاده نموده است هیچ تحقیقی متمرکز بر این روش صورت نگرفته است. در این تحقیق تمرکز بر دو ستانده نامطلوب زیست محیطی می باشد که البته ستانده‌های نامطلوب صرفاً منحصر به مسائل زیست محیطی نبوده و شامل موارد دیگری نیز میشوند. از این رو با توجه به خلا مطالعاتی مشاهده شده تحقیق حاضر به ارائه یک رویکرد ترکیبی هوش مصنوعی و تحلیل پوششی داده‌ها در جهت ارزیابی واحدهای تصمیمگیری میپردازد که هدف بهبود کارایی با دو ستانده نامطلوب زمان اتلاف و میزان اتلاف میباشد که در تحقیقات گذشته مورد توجه قرار نگرفته است. از اینرو تحقیق حاضر مشمول نوآوری میباشد.

جدول ۱. مرور ادبیات

مورد مطالعه	یادگیری ماشین	تحلیل پوششی داده‌ها	فازی	عدم قطعیت	ستانده نامطلوب	هدف	سال	محققین
صنایع		✓	✓	✓	✓	ارائه یک مدل تحلیل پوششی داده‌های فازی با وجود ستانده نامطلوب	2020	ابراهیم نژاد و امانی
صنعت نفت		✓		✓	✓	ارائه یک مدل تحلیل پوششی داده‌های کارائی متقاطع استوار با ستانده نامطلوب	2021	توانا و همکاران
شرکتهای های تک		✓		✓	✓	یک مدل تحلیل پوششی داده‌های شبکه‌ای استوار برای ارزیابی پایداری	2022	چن و همکاران
شرکتهای بیمه		✓		✓		ارزیابی شرکتهای بیمه با وجود عدم قطعیت	2022	عمرانی و همکاران

نیروگاههای سیکل ترکیبی	✓	✓	✓		اندازه گیری پایداری نیروگاههای سیکل ترکیبی با استفاده از مدل تحلیل پوششی داده های شبکه ای فازی	2023	توسلی و سائن
شرکتهای انلاین		✓	✓	✓	سنجش کارائی پایدار واحدهای تصمیم گیری با در نظر گرفتن ستانده نامطلوب در شرکتهای آنلاین	2023	عمرانی و همکاران
اقتصاد سبز دریایی	✓				تحلیل سنجش کارائی و عوامل اثر گذار بر اقتصاد سبز دریایی بر اساس یک مدل تحلیل پوششی داده های شبکه ای دو مرحله ای	2023	ژو و همکاران
شعبات بانک	✓		✓	✓	ارائه یک مدل تحلیل پوششی داده های استوار تحت سناریوهای عدم قطعیت جهت ارزیابی شعبات بانک	2023	عمرانی و همکاران
شرکتهای بیمه	✓	✓	✓	✓	تجزیه کارائی در شبکه سه مرحله ای با ستانده نامطلوب و مطلوب فازی و نهاد فازی در تحلیل پوششی داده ها	2023	سعیدی اول نوقابیا و همکاران

شرکتهای دانش بنیان		✓		✓	✓	ارائه یک مدل تحلیل پوششی داده های تصادفی با وجود ستانده نامطلوب	2023	امیر تیموری و همکاران
شرکتهای تجاری						ارائه دو مدل تحلیل پوششی داده های شبکه ای استوار جدید برای دستیابی به بازه نمره عملکرد سیستمهای سریالی چند مرحله ای	2024	سانشولی و همکاران
نهادهای جنگلی وابسته به محیط زیست	✓	✓	✓	✓	✓	ارائه یک رویکرد ترکیبی هوش مصنوعی و تحلیل پوششی داده های فازی برای ارزیابی کارائی زیست محیطی و پیش بینی نشر دی اکسید کربن	2024	زاد میرزایی و همکاران

روش¹

در تحقیق حاضر یک تحلیل پوششی دادههای SBM ارائه میشود، این مدل شامل ستاندههای فازی می باشد که ترکیبی از ستانده های مطلوب و نامطلوب می باشد، ضمن اینکه نهاده ها به صورت قطعی می باشد. در این مدل فرض میشود که تعدادی واحد تصمیمگیری وجود دارد که هر یک از ستانده فازی و نهاده قطعی بهره میگیرند. ستانده ها شامل ارقام فازی مثلثی میباشند و همانطور که گفته شد به دو دسته مطلب و نامطلوب تفکیک میشوند. بنابراین مدل تحلیل پوششی داده های فازی SBM مبتنی بر ستانده به صورت زیر ارائه میشود:

1. method

$$\frac{1}{e_o^*} = \text{Max } 1 + \frac{1}{K+T} \left[\sum_{r=1}^K \frac{S_r^+}{\tilde{y}_{ro}} + \sum_{t=1}^T \frac{S_t^-}{\tilde{w}_{to}} \right]$$

$$\sum_{j=1}^n \lambda_j x_{ij} + S_i^- = x_{io} \quad i = 1, 2, \dots, n$$

$$= 1, 2, \dots, m$$

$$\sum_{j=1}^n \lambda_j \tilde{y}_{rj} - S_r^+ = \tilde{y}_{ro} \quad r = 1, 2, \dots, k$$

$$\sum_{j=1}^n \lambda_j \tilde{w}_{tj} - S_t^- = \tilde{w}_{to} \quad t = 1, 2, \dots, T$$

$$\lambda_j = 0 \text{ if } z_j > z_o + \delta(z)$$

$$\lambda_j \geq 0 \quad S_i^- \geq 0 \quad S_r^+ \geq 0 \quad S_t^- \geq 0 \quad \delta(z) \geq 0$$

$$S_i^- = \beta_i e_i, S_r^+ = \beta_r e_r, S_t^- = \beta_t e_t, S_r^+ = \beta_r e_r$$

مدل فوق به دنبال افزایش ستانده مطلوب و کاهش ستانده نامطلوب به طور همزمان می باشد. در رابطه فوق محدودیت اول به ارزیابی عملکرد واحدهای تصمیمگیری در زمان مواجهه با نهاده بیرونی می پردازد. مدل فوق یک مدل فازی می باشد که می بایست به یک مدل قطعی تبدیل شود برای این منظور از رویکرد برش الفا که پرکاربردترین رویکرد در بحث فازی زدایی میباشد استفاده میشود. ستانده های مطلوب و نامطلوب میتواند با اعمال تکنیک برش آلفا به صورت زیر تبدیل شود (Zadmirzaei et al., 2024).

$$\hat{y}_{rj} = [y_{rj}^m - (1-a)y_{rj}^l, y_{rj}^m + (1-a)y_{rj}^u] \quad (2)$$

$$\hat{w}_{tj} = [w_{tj}^m - (1-a)w_{tj}^l, w_{tj}^m + (1-a)w_{tj}^u] \quad (3)$$

به علاوه فاصله قطعی میتواند در معادلات ذیل قرار گرفته و لذا دادههای قطعی میتواند برای ستانده به صورت زیر محاسبه شود

$$\begin{aligned}\bar{y}_{rj} &= \frac{1}{2} \int_0^1 [y_{rj}^m - (1-a)y_{rj}^l \cdot y_{rj}^m + (1-a)y_{rj}^u] dx \\ &= \frac{1}{4} (y_{rj}^l + 2y_{rj}^m + y_{rj}^u)\end{aligned}\quad (4)$$

$$\begin{aligned}\bar{w}_{rj} &= \frac{1}{2} \int_0^1 [w_{rj}^m - (1-a)w_{rj}^l \cdot w_{rj}^m + (1-a)w_{rj}^u] dx \\ &= \frac{1}{4} (w_{rj}^l + 2w_{rj}^m + w_{rj}^u)\end{aligned}\quad (5)$$

مدل SBM ارائه شده در تحقیق حاضر به مدل ذیل قابل تبدیل می‌باشد

$$\begin{aligned}\frac{1}{e_o^*} &= \text{Max } 1 + \frac{1}{K+T} \left[\sum_{r=1}^K \frac{S_r^+}{\bar{y}_{ro}} + \sum_{t=1}^T \frac{S_t^-}{\bar{w}_{to}} \right] \\ \sum_{j=1}^n \lambda_j x_{ij} + S_i^- &= x_{io} \quad i = 1, 2, \dots, n \quad j = 1, 2, \dots, m \\ \sum_{j=1}^n \lambda_j \bar{y}_{rj} - S_i^- &= \bar{y}_{ro} \quad r = 1, 2, \dots, k \\ \sum_{j=1}^n \lambda_j \bar{w}_{tj} - S_t^- &= \bar{w}_{to} \quad t = 1, 2, \dots, T \\ \lambda_j &= 0 \text{ if } z_j > z_o + \delta(z) \\ \lambda_j \geq 0 \quad S_i^- \geq 0 \quad S_r^+ \geq 0 \quad S_t^- \geq 0 \quad \delta(z) \geq 0 \\ S_i^- &= \beta_i e_i, S_t^- = \beta_t e_t, S_r^+ = \beta_r e_r\end{aligned}\quad (6)$$

مدل ترکیبی تحلیل پوششی داده های SBM و الگوریتمهای هوش مصنوعی تکنیک تحلیل پوششی دادهها ابزاری جهت سنجش کارائی واحدهای تصمیمگیری مختلف از سالها پیش مورد استفاده قرار گرفته و در طی سالیان متمادی در معرض تغییرات بسیاری قرار گرفته و لذا گونههای مختلفی از این مدل شکل گرفته است که مدل SBM یکی از این گونها به شمار میرود. اما تحلیل های اخیر نشان میدهد که تکنیکهای هوش مصنوعی به دلیل ماهیت تکاملی خود قادر به بهبود نتایج در حوزه های بسیاری میباشند به عنوان مثال این تکنیکها با پیش بینی نتایج و بهبود آن میتوانند منجر به بهبود کلی برآیندهای حاصل شوند. در خصوص ارزیابی عملکرد نیز تکنیکهای هوش مصنوعی کاملاً دارای کاربرد است. به

عنوان مثال الگوریتمهای یادگیری ماشین با پیشبینی و محاسبه برخی نهاده ها یا ستاندها و ورود آنها به تکنیک تحلیل پوششی دادهها میتوانند نتایج را بهبود بخشند. این هدفی است که در تحقیق حاضر دنبال میشود.

در تحقیق حاضر به منظور بهینه سازی نتایج حاصل از کارائی واحدهای تصمیمگیری و مشخصا کاهش ستانده نامطلوب یا افزایش کارائی از الگوریتمهای هوش مصنوعی و مشخصا تکنیکهای یادگیری ماشین استفاده میشود. با استفاده از این الگوریتمها به پیشبینی ستاندهای نامطلوب پرداخته شده و سپس این مقادیر وارد مدل SBM شده و اندازه گیری کارائی بر اساس مقادیر پیش بینی شده صورت میگیرد این در حالیست که پیش از آن با استفاده از مدل SBM کارائی واحدهای تصمیم گیری با استفاده از داده های واقعی و نه پیش بینی شده صورت می گیرد. و در نهایت بین چهار روش مقایسه صورت میگیرد این چهار روش به شرح ذیل میباشد.

- ۱- مدل تحلیل پوششی داده های SBM بر اساس دادههای واقعی.
- ۲- ترکیب مدل تحلیل پوششی دادههای SBM و شبکه عصبی مصنوعی بر اساس داده های پیش بینی شده.
- ۳- ترکیب مدل تحلیل پوششی دادههای SBM و ماشین بردار پشتیبان بر اساس داده های پیش بینی شده.
- ۴- ترکیب مدل تحلیل پوششی داده های SBM و الگوریتم XGBoost بر اساس داده های پیش بینی شده.

لازم به ذکر است با توجه به اینکه الگوریتمهای مورد استفاده در تحقیق حاضر تاکنون در ترکیب با روش SBM به بهینه سازی نتایج حاصل از کارائی واحدهای تصمیمگیری در تحقیقات پیشین مورد بهره برداری قرار نگرفته است، از اینرو میتوان گفت تحقیق حاضر صرفا به دنبال بکارگیری الگوریتمهای یادگیری ماشین بوده و به دنبال نوآوری در روششناسی یادگیری ماشین یا بهرهگیری از الگوریتمهای نوین نظیر الگوریتمهای یادگیری عمیق نمیشود، چرا که هدف محقق در این تحقیق صرفا بهینهسازی کارائی با کمک الگوریتمهای یادگیری ماشین است نه نوآوری در روش شناسی.

در ادامه به شرح الگوریتمهای مربوطه پرداخته میشود.

شبکه عصبی مصنوعی^۱

شبکه عصبی مصنوعی یک شبکه محاسباتی است که تلاش میکند تا به صورتی ناخالص شبکههای نرونهاي سیستمهای عصبی مرکزی را شبیهسازی نماید. پردازش اطلاعات و ساختار فیزیکی مغز با توری از اتصالات عصبی شکل گرفته است که دارای ظرفیت بالایی در مدلسازی سیستمهای غیر خطی است. همچنین شبکه عصبی مصنوعی دارای قابلیت تعمیم خوب بوده و در برابر دیتای مفقود یا پر نویز قوی است. از سوی دیگر طراحی مدل شبکه عصبی برای یک مسئله پردازش خاص دشوار میباشد. مسائل مدلسازی باید به دقت در نظر گرفته شوند. تعیین معماری مناسب نظیر تعداد متغیرهای ورودی، لایههای مخفی و عصبهای مخفی در هر لایه میتواند به صورت یک عامل بحرانی در نظر گرفته شود. برای مثال تعداد لایهها و نرونهاي مخفی در هر لایه مخفی متناسب با قابلیت شبکه برای برآورد توابع پیچیدهتر میباشد. اما این دال بر آن نیست که ساختارهای پیچیده شبکهها همواره عملکرد بهتری دارند. اگر شبکه نرونهاي مخفی بسیاری داشته باشد از نویز در دیتا به دلیل پارامتری سازی بیش از حد تبعیت میکنند که منجر به تعمیم ضعیف برای دیتای آموزش نداده میشود. از سوی دیگر شبکه با نرونهاي مخفی محدود قادر به تمایز بین الگوهای پیچیده نیست که منجر به برآورد خطی از روند واقعی می شود.

شبکه عصبی مصنوعی به عنوان روشی برای پیش بینی رفتارهای بازار مالی به طور جامع استفاده شده است. الگوریتم نشر به عقب به عنوان یکی از رویه های پر کاربرد برای شبکه های چند لایه پدیدار شده است. در شکل یک مدل BPNN چند ورودی سه لایه نمایش داده میشود ساختار در آن به صورت M در N در 1 میباشد که در آن M تعداد ورودی N تعداد نرون در لایه مخفی و یک واحد خروجی میباشد. X_{t+1} نشانگر مجموعهای از بردارهای ورودی نرونها در زمان T بوده و Y_{t+1} نشانگر خروجی شبکه در زمان $T+1$ میباشد. بین ورودی و خروجی یک لایه از واحدهای پردازشگر با عنوان

¹ Artificial neuron network

واحدهای مخفی وجود دارد. ZJT نشانگر خروجی نرونهای لایه مخفی در زمان T می باشد و W_{ij} وزنی است که گره I را در نرونهای لایه ورودی به گره J در لایه مخفی متصل میکند. V_j وزنی است که گره J را در نرونهای لایه مخفی به گره در لایه خروجی متصل میکند. مرحله لایه مخفی به شرح ذیل می باشد: ورودی تمامی نرونها در لایه مخفی به وسیله معادله ذیل تعیین میشود. (Wong & wong.,2015)

$$\text{net}_{jt} = \sum_{i=1}^n w_{ij}x_{ij} - \theta_j . i = 1.2. \dots n \quad (7)$$

خروجی نرون مخفی به این صورت تعیین میشود

$$z_{jt} = f_H(\text{net}_{jt}) = f_H\left(\sum_{i=1}^n w_{ij}x_{ij} - \theta_j\right) . i = 1.2. \dots n \quad (8)$$

که در اینجا θ_j استانه نرون در لایه مخفی است. تابع سیگموئید در لایه مخفی به صورت تابع فعالسازی عمل میکند. خروجی لایه مخفی به این صورت تعیین میشود.

$$y_{t+1} = f_t\left(\sum_{j=1}^m v_j z_{jt} - \theta_T\right) \quad (9)$$

که در اینجا θ_j استانه نرون در لایه مخفی بوده و تابع FTX یک نقشه هویت به صورت تابع فعالسازی میباشد.

ماشین بردار پشتیبان:

بردارهای پشتیبان به زبان ساده، مجموعه‌های از نقاط در فضای n بعدی داده‌ها هستند که مرز دسته‌ها را مشخص میکنند و مرزبندی و دسته‌بندی داده‌ها براساس آنها انجام میشود و با جابجایی یکی از آنها، خروجی دسته‌بندی ممکن است تغییر کند SVM یا ماشین بردار پشتیبان، یک دسته‌بندی یا مرزی است که با معیار قرار دادن بردارهای پشتیبان، بهترین دسته‌بندی و تفکیک بین داده‌ها را برای ما مشخص می‌کند. در SVM فقط داده‌های قرار گرفته در بردارهای پشتیبان مبنای یادگیری ماشین و ساخت مدل قرار می‌گیرند و این الگوریتم به

سایر نقاط داده حساس نیست و هدف آن هم یافتن بهترین مرز در بین داده هاست به گونه ای که بیشترین فاصله ممکن را از تمام دسته ها (بردارهای پشتیبان آنها) داشته باشد. یک راه ساده برای انجام اینکار و ساخت یک دسته بند بهینه، محاسبه فاصلهی مرزهای به دست آمده با بردارهای پشتیبان هر دسته (مرزی ترین نقاط هر دسته یا کلاس) و در نهایت انتخاب مرزیست که از دسته های موجود، مجموعاً بیشترین فاصله را داشته باشد که در شکل فوق خط میانی، تقریب خوبی از این مرز است که از هر دو دسته فاصلهی زیادی دارد. این عمل تعیین مرز و انتخاب خط بهینه (در حالت کلی، ابر صفحه مرزی) به راحتی با انجام محاسبات ریاضی نه چندان پیچیده قابل پیاده سازی است.

الگوریتم XGBoost

کتابخانه متن‌بازی است که نقش مؤثری در اجرای کارآمد درخت‌های تصمیم دارد. کد ++C الگوریتم GXBoost به همراه واسط کاربری پایتون می‌تواند بسته‌ای قدرتمند بسازد که به راحتی اجرا شود XGBoost. به دلیل عملکرد فوق‌العاده‌ای که دارد، در بسیاری از مسابقات Kaggle به موفقیت رسیده است. در ابتدا، سازوکار تقویت گرادینت بررسی میشود.

مدل یادگیری ماشین ساده‌ای نظیر درخت تصمیم می‌تواند به آموزش مدل در مجموعه داده مان کمک کند. این مدل در امر پیش‌بینی استفاده می‌شود. ممکن است پارامترها را قدری تغییر دهیم یا امر داده‌افزایی را بررسی کنیم؛ اما در نهایت فقط از یک مدل استفاده می‌کنیم. حتی در صورتی که یک مجموعه بسازیم، همه مدل‌ها به صورت جداگانه آموزش داده شده و در داده‌هایمان به کار برده می‌شوند. از سوی دیگر، عمل تقویت در رویکردی تکراری به اجرا در می‌آید؛ اما کماکان یک روش کلاسه‌بندی جمعی برشمرده می‌شود. مدل‌های بسیاری در این روش‌ها با یکدیگر ادغام می‌شوند، تا عملیات نهایی صورت گیرد، اما رویکرد هوشمندانه‌ای در پیش گرفته می‌شود.

به جای آموزش کلیه مدل‌ها به صورت جدا از یکدیگر، عمل «تقویت» مدل‌ها را پشت سر هم آموزش می‌دهد. هر مدل جدید با این هدف آموزش داده می‌شود که خطاهای

ناشی از مدل‌های پیشین تصحیح شوند. مدل‌ها تا زمانی به صورت متوالی افزوده می‌شوند که دیگر امکان پیشرفت بیشتر وجود نداشته باشد. مزیت این روش تکراری این است که مدل‌های اضافه‌شده در صدد تصحیح اشتباهاتی هستند که سایر مدل‌ها مرتکب شده‌اند. در روش کلاسه‌بندی جمعی استاندارد می‌شود که مدل‌ها به صورت جداگانه آموزش داده می‌شوند، کلیه مدل‌ها ممکن است اشتباهات یکسانی را مرتکب شوند.

تقویت گرادیان به روشی اطلاق می‌شود که در آن، مدل‌های جدید با هدف پیش‌بینی باقی‌مانده‌های مدل‌های پیشین آموزش داده می‌شوند.

در پایان می‌توان مراحل انجام تحقیق حاضر را در قالب فلوچارت ذیل ترسیم نمود

شکل ۴. مراحل انجام تحقیق



یافته‌ها

مورد مطالعه در تحقیق حاضر شامل ۳۷ شرکت تابعه شرکت ملی پخش فرآورده های نفتی ایران می باشد که این مورد مطالعه در تحقیق پیشین محقق نیز مورد استفاده قرار گرفت. متغیرهای استخراجی از دیتابیس و منابع اطلاعاتی این شرکتها جمع آوری شده است. به عنوان مثال متغیرهایی نظیر زمان عمر تجهیزات، از بخش تعمیر و نگهداری این شرکتها و هزینه منبع یابی که شامل جستجو برای تامین منابع میباشد از بخش مالی استخراج شده است. زمان تحقق سفارش در بخش تامین این شرکتها ثبت شده و توسط کارشناسان برآورد گردیده است. سایر متغیرها نیز از منابع و واحدهای مربوطه ۳۷ گانه شرکت مورد بررسی حاصل گردیده است. متغیرهای ورودی و خروجی به تفکیک مطلوب و نامطلوب که با استفاده از نظر خبرگان و مطالعات میدانی و کتابخانه ای جمع آوری گردید در جدول ذیل معرفی شده‌اند.

جدول ۲. متغیرهای تحقیق

ردیف	عنوان متغیر	نماد	نوع متغیر	مطلوب یا نامطلوب	قطعی یا غیر قطعی
1	هزینه منبع یابی	X1	ورودی	قطعی
2	زمان چرخه تحقق سفارش	X2	ورودی	قطعی
3	زمان عمر تجهیزات	X3	ورودی	قطعی
4	هزینه مواد	X4	ورودی	قطعی
5	زمان اتلاف	Z1	خروجی	نامطلوب	فازی
6	زمان پاسخ زنجیره تامین	Y1	خروجی	مطلوب	فازی
7	میزان اتلاف	Z2	خروجی	نامطلوب	فازی

8	هزینه کل حمل و نقل و تحویل	Y2	خروجی	مطلوب	فازی
---	----------------------------	----	-------	-------	------

همانگونه که مشاهده میشود ۴ متغیر ورودی و ۴ متغیر خروجی به عنوان متغیرهای تحقیق حاضر شناخته شده‌اند که در مرحله اول این متغیرها بر اساس آخرین داده‌ها و داده‌های واقعی به منظور ارزیابی واحدهای تصمیمگیری استفاده شده و در مرحله بعدی بر اساس داده‌های گذشته به پیش بینی دو متغیر زمان اتلاف و میزان اتلاف به عنوان دو عامل نامطلوب پرداخته شده و ارزیابی کارائی واحدهای تصمیمگیری بر اساس مقادیر پیش‌بینی شده صورت می‌گیرد تا به این ترتیب مشخص شود مقادیر پیش بینی شده منجر به کارائی بیشتری میشود یا مقادیر واقعی. برای این منظور به مقایسه چهار روش پرداخته شده و بهترین روش که می‌تواند روش SBM یا یکی از روشهای ترکیبی باشد به عنوان روش بهینه برای ارزیابی کارائی عملکرد انتخاب میشود. لازم به ذکر است که جمع‌آوری داده‌ها بر اساس اطلاعات شرکتهای مورد مطالعه هم برای پیش بینی ستانده نامطلوب و هم به منظور پیاده سازی روش اولیه SBM می‌باشد.

تجزیه و تحلیل یافته‌ها

در این بخش به تجزیه و تحلیل یافته‌ها پرداخته میشود ابتدا مدل SBM پیاده سازی شده و نمره کارائی واحدهای تصمیمگیری بدست می‌آید سپس با الگوریتمهای یادگیری ماشین تلاش میشود تا نتایج حاصل از نمره کارائی روش SBM بهبود یابد و محقق به دنبال کشف این نکته است که این بهبود تا چه میزان قابل تحقق است. در ابتدا نمرات کارائی حاصل از روش SBM ارائه میشود.

جدول ۳. نمرات کارائی حاصل از روش SBM


واحد تصمیم‌گیری	نمره کارائی روش SBM	واحد تصمیم‌گیری	نمره کارائی روش SBM
DMU1	0/7342	DMU20	0/9439

1	DMU21	0/8368	DMU2
0/9651	DMU22	0/9137	DMU3
0/9596	DMU23	1	DMU4
0/8639	DMU24	1	DMU5
1	DMU25	1	DMU6
0/8501	DMU26	0/8393	DMU7
1	DMU27	1	DMU8
0/7679	DMU28	0/9797	DMU9
0/8376	DMU29	1	DMU10
0/4358	DMU30	1	DMU11
1	DMU31	1	DMU12
1	DMU32	1	DMU13
0/8643	DMU33	1	DMU14
0/994	DMU34	0/8962	DMU15
0/9401	DMU35	1	DMU16
1	DMU36	0/7883	DMU17
1	DMU37	1	DMU18
		1	DMU19

بر اساس نتایج حاصل از جدول فوق می توان دریافت برخی واحدهای تصمیم گیری با کسب نمره ۱ به کارائی کامل دست یافته و برخی نمراتی کمتر از ۱ کسب نموده که نشانگر کارائی کمتر از حد مطلوب می باشد. نکته قابل توجه این است که واحد تصمیم گیری

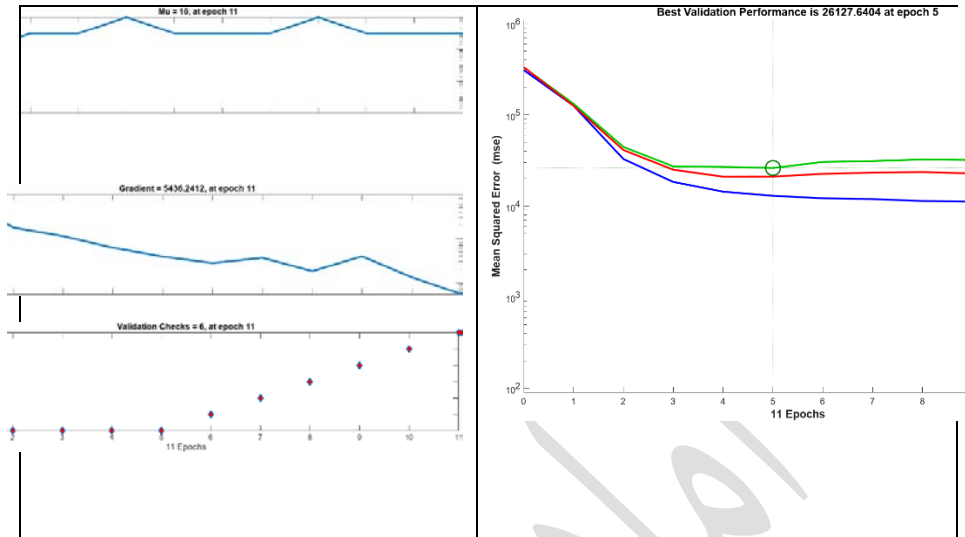
شماره ۳۰ با نمره کارائی ۰/۴۳. ضعیفترین واحد تصمیم گیری تلقی می شود و واحدهای تصمیم گیری نظیر ۳۴ یا ۲۲۹ و ۲۳ نمره کارائی نزدیک به ۱ را کسب نموده و صرفاً چند درصد کمتر از نمره کارائی را بدست آورده اند که این امر باعث شده این واحدهای تصمیم گیری ناکارا تلقی شوند. در نمودار ذیل نتایج حاصل از نمرات کارائی واحدهای تصمیم گیری به خوبی ترسیم شده است.

نمودار ۱. نمرات کارائی حاصل از روش SBM



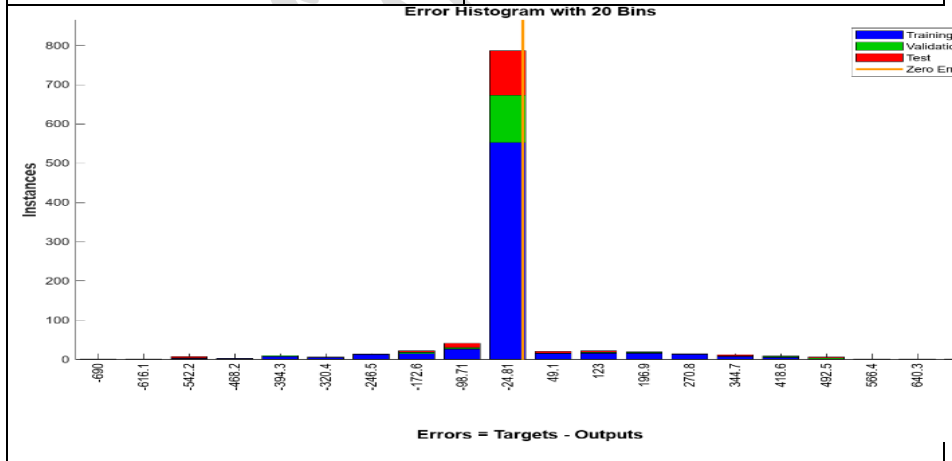
در نمودار فوق صرفاً با استفاده از روش SBM مشخص شده است که کدام واحدهای تصمیم گیری دارای کارائی کامل یعنی مقدار ۱ و کدامیک کمتر از این مقدار می باشند. تا اینجا صرفاً به ارزیابی کارائی واحدهای تصمیم گیری بر اساس ستانده نامطلوب پرداخته شد در ادامه هدف بهبود نتایج با استفاده از تکنیکهای هوش مصنوعی و یادگیری ماشین به دلیل ماهیت تکاملی آنها می باشد. الگوریتمهای مورد استفاده شامل شبکه عصبی مصنوعی، ماشین بردار پشتیبان و XGBoost می باشند. در ابتدا مطابق نمودار ۲ نتایج حاصل از شبکه عصبی به عنوان یکی از تکنیکهای یادگیری ماشین ارائه شده است.

نمودار ۲. نتایج حاصل از شبکه عصبی به عنوان یکی از تکنیکهای یادگیری ماشین



(ب) شیب μ و اعتبار سنجی شبکه عصبی در بهبود روش SBM

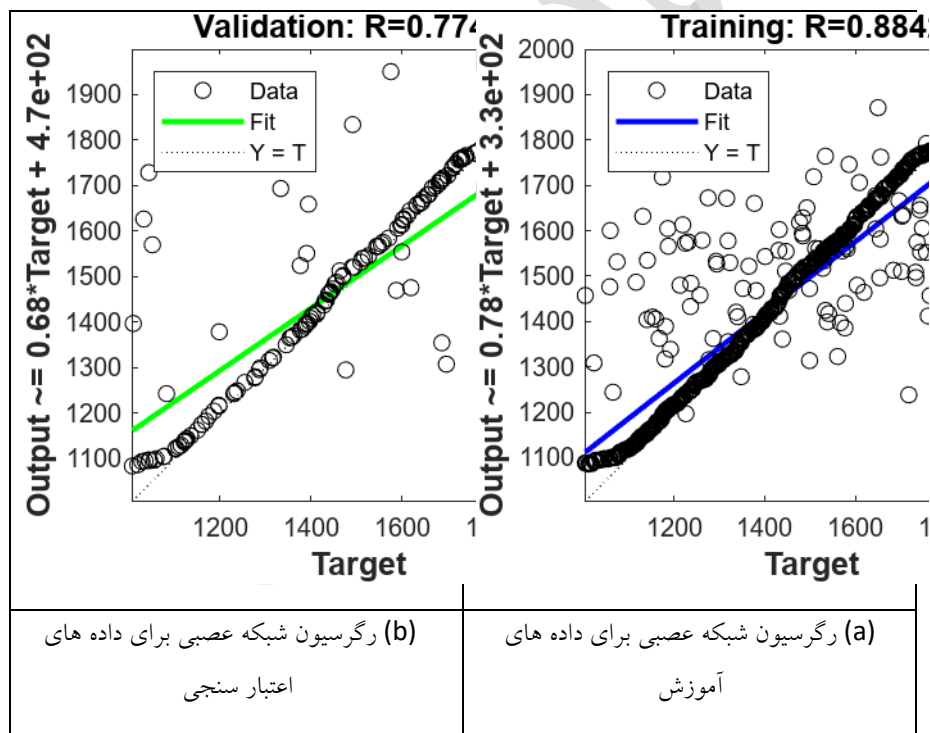
(الف) عملکرد شبکه عصبی در بهبود روش SBM

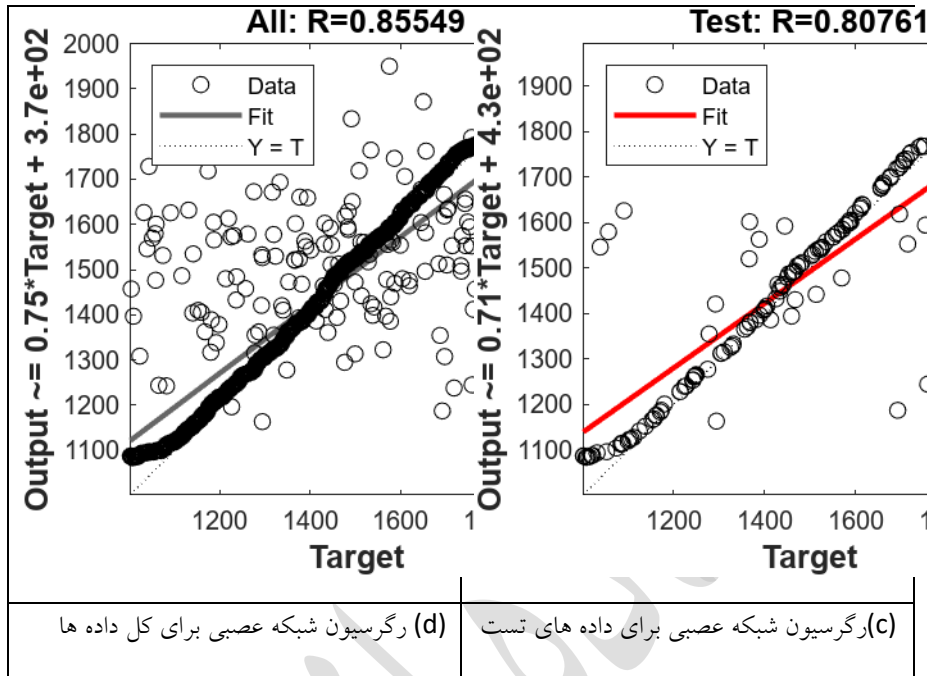


(ج) هیستوگرامهای خطای شبکه عصبی در بهبود روش SBM

همانگونه که دیده می شود در نمودار ۲(الف) عملکرد شبکه عصبی بهینه شده است چرا که مقدار حداقل در یکی از تکرارها حاصل شده و پس از آن نمودار آموزش ماهیت نزولی و نمودار تست ماهیت صعودی یافته است. بنابراین می توان عملکرد شبکه عصبی را در خصوص پیشبینی ستانده نامطلوب مورد تأیید قرار داد. در ادامه نزولی بودن نمودار شیب آموزش و صعودی بودن نمودار اعتبار سنجی در نمودار ۲(ب) نشانه دیگری بر عملکرد صحیح الگوریتم شبکه عصبی مصنوعی میباشد و در انتها نمودارهای هیستوگرام های خطا از توزیع نرمال تبعیت کرده و نشانگر صحت و اعتبار شبکه عصبی مصنوعی مورد استفاده جهت پیش بینی ستانده نامطلوب میباشد.

نمودار ۳. رگرسیون شبکه عصبی






همانگونه که دیده می شود هر ۴ نمودار (a,b,c,d) نشانگر اصطلاحاً fit بودن داده ها در حد بالایی میباشد به گونهای که مقادیر پیشبینی شده همجواری زیادی با داده های واقعی داشته و لذا میتوان گفت پیش بینی ستانده نامطلوب برای واحدهای تصمیمگیری به خوبی صورت گرفته است. مقدار دقت ۰/۸۵۵. برای کل دادهها حاصل گردیده است که نشان میدهد تا ۸۵ درصد پیش بینی ستانده نامطلوب ناشی از متغیرهای ورودی مدل می باشد. اما در ادامه از دو الگوریتم دیگر برای پیشبینی استفاده شده است که نتایج پیش بینی ستانده نامطلوب با کمک آنها در جدول ۴ ارائه گردیده است.

جدول ۴. مقایسه دقت پیش بینی برای سه الگوریتم یادگیری ماشین مورد استفاده

XGBoost	ماشین بردار پشتیبان	شبکه عصبی مصنوعی	تکرار
0/802	0/813	0/855	1
0/806	0/814	0/860	2

0/809	0/814	0/864	3
0/812	0/815	0/867	4
0/814	0/816	0/867	5
0/815	0/816	0/870	6
0/818	0/817	0/872	7
0/818	0/822	0/875	8
0/820	0/827	0/876	9
0/823	0/830	0/880	10

نمودار ۴. مقایسه دقت پیش بینی برای سه الگوریتم یادگیری ماشین مورد استفاده




همانگونه که در نمودار ۴ مشاهده میشود با افزایش تکرارها نتایج دقت برای هر سه الگوریتم بهبود یافته است اما در مقام مقایسه مشاهده میشود که نمودار مرتبط با شبکه عصبی مصنوعی با فاصلهای نسبتاً بعید با دو الگوریتم دیگر دقت خود را بهبود بخشیده است به گونهای که دقت پیش بینی از ۸۶٪ به ۸۸٪ در تکرار دهم رسیده است البته این وضعیت در خصوص سایر الگوریتمها نیز دیده میشود اما به دلیل برتری شبکه عصبی در پیش بینی میزان دقت از تحلیل آنها صرفه نظر میشود.

جدول ۵. مقایسه خطای پیش بینی برای سه الگوریتم یادگیری ماشین مورد استفاده

XGBoost	ماشین بردار پشتیبان	شبکه عصبی مصنوعی	تکرار
0/035	0/031	0/023	1
0/032	0/030	0/020	2
0/028	0/027	0/017	3
0/026	0/023	0/017	4
0/023	0/021	0/014	5
0/021	0/019	0/012	6
0/019	0/017	0/012	7
0/018	0/016	0/010	8
0/017	0/015	0/006	9
0/013	0/013	0/002	10

نمودار ۵. مقایسه خطای پیش بینی برای سه الگوریتم یادگیری ماشین مورد استفاده



نمودار ۵ نشانگر بهبود نتایج حاصل از الگوریتمهای یادگیری ماشین با افزایش تعداد تکرارها میباشد به گونهای که مقدار خطا نیز ماهیت نزولی داشته اما همچنان دیده میشود که شبکه عصبی مصنوعی به میزان بهتری نسبت به دو الگوریتم دیگر قادر به کاهش خطای پیش بینی بوده است. از این جهت میتوان گفت همچنان الگوریتم شبکه عصبی مصنوعی نسبت به دو الگوریتم دیگر برتری دارد چرا که قادر به کاهش خطای پیش بینی به میزان بیشتری نسبت به دو الگوریتم رقیب خود بوده است.

پس از پیش بینی ستانده نامطلوب توسط سه الگوریتم یادگیری ماشین و مقایسه الگوریتمها از نظر کارایی پیش بینی در ادامه به مقایسه اثر الگوریتمها بر نمرات کارایی حاصل از روش SBM پرداخته میشود. در واقع محقق در این بخش به دنبال کشف این نکته است که هر یک از الگوریتمهای یادگیری عمیق تا چه میزان قادر به بهبود نتایج حاصل از روش SBM میباشد. نتایج در جدول ۶ ارائه شده است.


جدول ۶. مقایسه اثر الگوریتمهای مختلف یادگیری ماشین بر بهبود نمره کارایی روش SBM

واحد تصمیم گیری	نمره کارایی روش SBM	شبکه عصبی مصنوعی	ماشین بردار پشتیبان	XGBoost
DMU1	0/7342	0/77433	0/76668119	0/76972005
DMU2	0/8368	0/88521	0/86710222	0/86880361
DMU3	0/9137	0/9622	0/94817988	0/94556766
DMU4	1	1/04047	1/03529501	1/03893548
DMU5	1	1/04565	1/0331595	1/03346928
DMU6	1	1/04453	1/03523489	1/03395126
DMU7	0/8393	0/88815	0/87368887	0/87158498
DMU8	1	1/04101	1/03223077	1/0357966

1/019531	1/01511806	1/02679	0/9797	DMU9
1/03238502	1/03223899	1/04116	1	DMU10
1/03657448	1/03252795	1/04808	1	DMU11
1/03640392	1/03207577	1/04294	1	DMU12
1/03088405	1/03536719	1/04193	1	DMU13
1/03489967	1/03302483	1/0402	1	DMU14
0/93054893	0/93214719	0/93964	0/8962	DMU15
1/03587049	1/03137523	1/04339	1	DMU16
0/82133829	0/8245593	0/8355	0/7883	DMU17
1/03551531	1/03389979	1/04586	1	DMU18
1/03271922	1/03356702	1/04058	1	DMU19
0/97561156	0/98288484	0/98624	0/9439	DMU20
1/03477286	1/03322853	1/04181	1	DMU21
0/99541227	1/00436321	1/0099	0/9651	DMU22
0/99660836	0/99441982	1/00897	0/9596	DMU23
0/89811513	0/89413595	0/90587	0.8639	DMU24
1/03619782	1/03010345	1/04943	1	DMU25
0/89006471	0/88991221	0/89312	0/8501	DMU26
1/03260387	1/03401077	1/04733	1	DMU27
0/80546452	0/80499949	0/81587	0/7679	DMU28

0/87225777	0/87217967	0/88295	0/8376	DMU29
0/47515964	0/47435634	0/47927	0/4358	DMU30
1/03020794	1/03863352	1/04321	1	DMU31
1/03761337	1/03604494	1/04378	1	DMU32
0/9038508	0/89963367	0/90663	0/8643	DMU33
1/02822391	1/02828725	1/03457	0/994	DMU34
0/97138771	0/97701897	0/9899	0/9401	DMU35
1/03766897	1/03705166	1/04921	1	DMU36
1/03181079	1/03655997	1/04498	1	DMU37

نمودار ۶. مقایسه اثر الگوریتمهای مختلف یادگیری ماشین بر بهبود نمره کارایی روش SBM



همانگونه که در نمودار ۶ مشاهده میشود شبکه عصبی مصنوعی بیش از سایر روشها قادر به بهبود کارایی واحدهای تصمیم گیری بوده است. روش SBM ضعیفترین نتایج را داشته است که این نشان می دهد نتایج با استفاده از روشهای یادگیری ماشین قابل بهبود است سه

الگوریتم یادگیری ماشین همگی موفق شده‌اند تا حدی مقادیر نمرات کارائی واحدهای تصمیم‌گیری را بهبود بخشند اما بیشترین اثرگذاری از جانب شبکه عصبی مصنوعی است که بیش از سایر الگوریتمها اثرگذار بوده است به گونه‌ای که قادر به افزایش کارائی واحدهای غیر کارا، کارا نمودن واحدهای غیر کارا و حتی کارائی بیشتر برای واحدهای کارا گردیده است. در مجموع می‌توان گفت تمامی الگوریتمهای هوش مصنوعی منجر به بهبود نمرات کارائی شده‌اند که در مقام مقایسه همچنان الگوریتم شبکه عصبی مصنوعی دارای برتری بوده و پس از آن ماشین بردار پشتیبان و رتبه سوم از آن الگوریتم XGBoost است که هر سه الگوریتم موفق به بهبود نتایج حاصل از روش SBM شده‌اند.

بحث و نتیجه‌گیری

تحقیق حاضر به دنبال استفاده از یک رویکرد ترکیبی هوش مصنوعی و تحلیل پوششی داده‌های SBM به منظور بهبود نمرات کارائی واحدهای تصمیم‌گیری بود. در این تحقیق ابتدا ارزیابی عملکرد واحدهای تصمیم‌گیری بر اساس روش SBM صورت گرفت و سپس هدف دوم بهبود این نتایج با استفاده از الگوریتمهای تکاملی هوش مصنوعی بود. نتایج نشان می‌دهد که الگوریتمهای هوش مصنوعی قادر به بهبود نتایج حاصل از روش SBM می‌باشند به این صورت که در ابتدا به پیش‌بینی ستانده نامطلوب تولید شده توسط واحدهای تصمیم‌گیری پرداخته و سپس این ستانده مجدداً وارد مدل SBM شده و پس از ارزیابی واحدهای تصمیم‌گیری با داده‌های واقعی در مرتبه بعد با داده‌های پیش‌بینی شده توسط الگوریتمهای یادگیری ماشین ارزیابی کارایی صورت می‌گیرد.

بر اساس نتایج بدست آمده می‌توان گفت که نتایج حاصل از ارزیابی بر اساس ستاندهای پیش‌بینی شده به نتایج بهتری نسبت به روش SBM دست می‌یابد که البته در میان الگوریتمها از این نظر تفاوت وجود دارد چرا که الگوریتم شبکه عصبی مصنوعی با تفاوت زیاد نسبت به دوالگوریتم دیگر به میزان بیشتری قادر به بهبود نتایج حاصل از کارائی بوده است. ضمن اینکه از نظر دقت پیش‌بینی نیز شبکه عصبی به میزان بهتری قادر به پیش‌بینی ستانده نامطلوب بوده است از این جهت الگوریتم برتر در تحقیق حاضر الگوریتم شبکه

عصبی مصنوعی است که به میزان قابل توجهی قادر به بهینه سازی نتایج حاصل از روش SBM بوده است.

نتایج تحقیق حاضر بیان میکند که استفاده از الگوریتمهای هوش مصنوعی میتواند به بهبود کارایی واحدهای تصمیمگیری کمک کند چرا که این الگوریتمها بر اساس دادههای پیش بینی شده عمل میکنند و به دلیل آنکه بر اساس ماهیت تکاملی خود قادر به دستیابی به نتایج بهتری میباشند از اینرو نتایج حاصل از دادههای پیش بینی شده نسبت به دادههای واقعی بهتر است. بنابراین میتوان از تکنیکهای هوش مصنوعی در سایر تحقیق مرتبط با ارزیابی کارایی به ویژه تحقیقاتی که بر اساس مدل تحلیل پوششی داده ها انجام میشوند بهره برد. تحقیقات آتی می تواند مدل تحقیق حاضر را در قالب یک مدل شبکه ای مد نظر قرار داده و به این ترتیب به توسعه مدل حاضر پردازند. همچنین الگوریتمهای نوین مانند شبکههای عصبی کانولوشن، شبکههای عصبی بازگشتی، مدلهای ترنسفورمر، و حتی الگوریتمهای نسل جدید مانند VAE و Diffusion در تحقیقات آینده برای بهبود بیشتر نتایج و نوآوری در این حوزه مورد استفاده قرار گیرند.





تعارض منافع

نویسندگان هیچ گونه تعارض منافی ندارند

سپاسگزاری

از شرکت ملی پخش فرآورده های نفتی ایران بخاطر حمایت های مالی و کمیته پژوهش این شرکت بدلیل حمایت های معنوی بسیار سپاسگزارم

ORCID

Ebrahim Golzar		http://orcid.org/0009-0005-3579-5821
Seyyed esmaeil Najafi		http://orcid.org/0000-0002-8734-5436
Seyyed Ahmad Edalatpanah		http://orcid.org/0000-0001-9349-5695
Amir Azizi		http://orcid.org/0000-0001-7217-9503

References

- Alsarraf, J., Moayedi, H., Rashid, A. S. A., Muazu, M. A., & Shahsavari, A. (2020). *Application of PSO-ANN modelling for predicting the exergetic performance of a building integrated photovoltaic/thermal system*. *Engineering with Computers*, 36, 633-646.
- Amirteimoori, A., Charles, V., & Mehdizadeh, S. (2023). *Stochastic data envelopment analysis in the presence of undesirable outputs*. *Journal of the Operational Research Society*, 74(12), 2619-2632. doi:10.1080/01605682.2023.2172366.
- Chen, Z., Kourtzidis, S., Tzeremes, P., & Tzeremes, N. (2022). *A robust network DEA model for assessment: An application to Chinese Provinces*. *Operational Research*, 22(1), 235-262. sustainability <https://doi.org/10.1007/s12351-020-00553-x>
- Ebrahimnejad, A., & Amani, N. (2021). *Fuzzy data envelopment analysis in the presence of undesirable outputs with ideal points*. *Complex & intelligent systems*, 7(1), 379-400. <https://doi.org/10.1007/s40747-020-00211-x>
- Kao, C., & Hwang, S. N. (2021). *Measuring the effects of undesirable outputs on the efficiency of production units*. *European Journal of Operational Research*, 292(3), 996-1003. <https://doi.org/10.1016/j.ejor.2020.11.026>
- Li, F., Wang, Y., Emrouznejad, A., Zhu, Q., & Kou, G. (2022). *Allocating a fixed cost across decision-making units with undesirable outputs: A bargaining game approach*. *Journal of the Operational Research Society*, 73(10), 2309-2325. <https://doi.org/10.1080/01605682.2021.1981781>
- Liu J, Chen L, Xu W, Feng M, Han Y, Xia T, Geng Z (2023) *Novel production prediction model of gasoline production processes for energy saving and economic increasing based on AM-GRU integrating the UMAP algorithm*. *Energy* 26:125536. <https://doi.org/10.1016/j.energy.2022.125536>
- Omrani, H., A. Emrouznejad, M. Shamsi and P. Fahimi (2022) *Evaluation of Insurance Companies Considering Uncertainty: A Multi-Objective Network Data Envelopment Analysis Model with Negative Data and Undesirable Outputs*, *Socio-Economic Planning Sciences*, Accepted. <https://doi.org/10.1016/j.seps.2022.101306>
- Omrani, H., Shamsi, M., & Emrouznejad, A. (2023). *Evaluating sustainable efficiency of decision-making units considering undesirable outputs: an application to airline using integrated multi-objective DEA-TOPSIS*. *Environment, Development and Sustainability*, 25(7), 5899-5930. <https://doi.org/10.1007/s10668-022-02285-8>.
- Omrani, H., Shamsi, M., Emrouznejad, A., & Teplova, T. (2023). *A robust DEA model under discrete scenarios for assessing bank branches*. *Expert systems with applications*, 219, 119694
- Saeedi Aval Noughabia, F., Malekmohammadi, N., Hosseinzadeh Lotfi, F., & Razavyan, S. (2023). *Efficiency decomposition in three-stage network with fuzzy desirable and undesirable output and fuzzy input in data envelopment analysis*. *International Journal of Intelligent Computing and Cybernetics*, 16(4), 665-696.
- Sanchooli, F., Najafi, S. E., Lotfi, F. H., & Sobhani, F. M. (2024). *TWO NOVEL ROBUST NETWORK DATA ENVELOPMENT ANALYSIS MODELS TO OBTAIN THE PERFORMANCE SCORE INTERVAL OF MULTI-STAGE SERIES SYSTEMS*. *International Journal of Industrial Engineering: Theory, Applications and Practice*, 31(1).

- Tavana, M., Toloo, M., Aghayi, N., & Arabmaldar, A. (2021). *A robust cross-efficiency data envelopment analysis model with undesirable outputs*. *Expert systems with applications*, 167, 114117.
- Tavassoli, M., & Saen, R. F. (2023). *Sustainability measurement of combined cycle power plants: a novel fuzzy network data envelopment analysis model*. *Annals of Operations Research*, 1-41. <https://doi.org/10.1007/s10479-023-05170-3>
- Wang, G., Huang, S. H. (2015). "Product-driven supply chain selection using integrated multi-criteria decision-making methodology," *International journal of production economics*, vol. 91, no. 1, pp. 1-15.
- Zadmirzaei, M., Hasanzadeh, F., Susaeta, A., & Gutiérrez, E. (2024). *A novel integrated fuzzy DEA-artificial intelligence approach for assessing environmental efficiency and predicting CO2 emissions*. *Soft Computing*, 28(1), 565-591. <https://doi.org/10.1007/s00500-023-08300-y>
- Zou W, Yang Y, Yang M, Zhang X, Lai S and Chen H (2023) *Analyzing efficiency measurement and influencing factors of China's marine green economy: Based on a two-stage network DEA model*. *Front. Mar. Sci.* 10:1020373. doi: 10.3389/fmars.2023.1020373

استناد به این مقاله: نام خانوادگی نویسنده اول، نام. (سال). عنوان مقاله. عنوان نشریه (ایتالیک)، سال (شماره)، ص آغاز-ص پایان.



Name of Journal is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License.

اماره انتشار

آماده انتشار