



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 Edalatpanah 

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 by considering undesirable outputs and conditions of uncertainty. Three machine

* 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*, 22(74), 139-174.

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 at being minimized. Matters such as the emission of pollutants, the 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 are ultimately compared with the actual values. This process not only allows for the reduction of 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 the 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, they 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 are 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 simplified manner. The processing of information and the physical structure of the brain are shaped by a web of neural connections, which have an exceptional 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 carried out 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 were 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.



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

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

ابراهیم گلزار 

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

سید اسماعیل نجفی *

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

سید احمد عدالت پناه 

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

امیر عزیزی 

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

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

* نویسنده مسئول: Najafi1515@gmail.com

ترکیب مدل‌های تحلیل پوششی داده‌ها و الگوریتم‌های یادگیری ماشین برای ...؛ گلزار و همکاران | ۱۴۵

نفتی بوده که نتایج نشان‌دهنده بهبود معنادار کارایی با استفاده از داده‌های پیش‌بینی شده در مقایسه با داده‌های واقعی است. این تحقیق 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.

مقدمه

ارزیابی کارایی واحدها همواره بر اساس وجود ستانده مطلوب صورت نمی‌گیرد چرا که هر واحد تولیدی یا صنعتی یا خدماتی می‌تواند ستانده‌های نامطلوبی را نیز تولید نماید که هدف حداقل ساختن آن می‌باشد. مواردی نظیر نشر آلاینده‌گی، نشر دی‌اکسید کربن، تولید زباله و مواردی از این دست در زمره شرایطی هستند که به‌عنوان ستانده نامطلوب تلقی شده و هدف حداقل ساختن آن می‌باشد (Liu et al., 2023). از سوی دیگر ستانده‌های نامطلوب عموماً به صورت غیر قطعی می‌باشند یعنی نمی‌توان قطعیتی در میزان تولید آن‌ها متصور بود که همین امر منجر به پیچیده شدن مسئله می‌شود بنابراین عموماً ستانده نامطلوب در شرایط عدم قطعیت مورد توجه می‌باشد (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 داده‌ها می‌باشد (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 مدل^۱ SBM بوده است. مدل SBM بر اساس متغیرهای مصنوعی شکل می‌گیرد و برای بسیاری از مسائل ارزیابی کارایی دارای کاربرد و استفاده می‌باشد؛ اما با افزایش بهره‌گیری از تکنیک‌های هوش مصنوعی توجه به ترکیب این دو حوزه یعنی تحلیل پوششی داده‌ها 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 شده‌اند (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 داده‌های پیش‌بینی شده صورت گیرد؛ به عبارت دیگر ابتدا پارامترها

¹ Slack-Based Measure

پیش‌بینی شده و مقادیر پیش‌بینی شده وارد مدل ارزیابی عملکرد می‌شود و در نهایت با مقادیر واقعی مقایسه می‌شود این کار هم اجازه می‌دهد که فاصله نتایج واقعی با پیش‌بینی شده کاهش یابد و هم اینکه امکان بهبود کارایی بر اساس نتایج پیش‌بینی شده با توجه به ماهیت تکاملی الگوریتم‌های هوش مصنوعی فراهم می‌شود؛ بنابراین در زمانی که هدف بهبود کارایی باشد الگوریتم‌های هوش مصنوعی نظیر الگوریتم‌های یادگیری ماشین یا یادگیری عمیق می‌توانند در این حوزه کاربرد عملی داشته باشند (Zadmirzaei et al., 2024).

در تحقیق حاضر هدف در ابتدا سنجش کارایی واحدهای تصمیم‌گیری بر اساس ستانده‌های مطلوب و نامطلوب فازی می‌باشد که با توجه به اینکه در تحقیقات پیشین، ستانده نامطلوب بر اساس الگوریتم‌های هوش مصنوعی به‌ندرت پیش‌بینی شده و رویکرد ترکیبی هوش مصنوعی و تحلیل پوششی داده‌ها به‌ندرت استفاده شده است از این جهت می‌توان گفت تحقیق حاضر مشمول نوآوری می‌باشد. به این صورت که یک‌بار با استفاده از مدل تحلیل پوششی داده‌های SBM ارزیابی واحدهای تصمیم‌گیری بر اساس داده‌های واقعی صورت گرفته و سپس پس از دستیابی به مقادیر پیش‌بینی شده دو ستانده نامطلوب، ارزیابی واحدهای تصمیم‌گیری بر اساس مقادیر پیش‌بینی شده ستانده نامطلوب صورت می‌گیرد به این ترتیب نتایج داده‌های واقعی به نتایج سه الگوریتم شبکه عصبی مصنوعی، ماشین بردار پشتیبان و^۱ 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 محدود تحقیقاتی است که اثر بهره‌گیری از هوش مصنوعی و ماهیت تکاملی آن را بر کارایی واحدهای تصمیم‌گیری می‌سنجد که مبتنی بر مدل SBM فازی بوده که به‌ندرت مشابه این تحقیق در ادبیات تحقیق به چشم می‌خورد. ماهیت تکاملی الگوریتم‌های هوش مصنوعی کمک می‌کند که نتایج به‌طور 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

¹ Extreme Gradient Boosting

ادبیات ارائه شده و شکاف تحقیقاتی استخراج می شود و در ادامه مدل و روش شناسی ارائه می گردد. پس از آن تجزیه و تحلیل یافته ها انجام شده و در انتها نتیجه گیری ارائه می گردد.

پیشینه پژوهش

مروری در این بخش به مرور ادبیات در خصوص نزدیک ترین تحقیقات به تحقیق حاضر از نظر مفهومی پرداخته می شود. تحقیقات انجام شده بیشتر متمرکز بر ارزیابی کارایی واحدهای تصمیم گیری بر اساس ستانده نامطلوب بوده و مربوط به ۴ سال اخیر می باشند. ضمن اینکه اغلب داده های مورد استفاده دارای ماهیت غیر قطعی می باشند. 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 داده های کارایی متقاطع استوار را با ستانده نامطلوب ارائه می کنند (Chen et al., 2022). یک مدل تحلیل پوششی داده های شبکه ای استوار را برای ارزیابی پایداری ارائه می کنند. تحقیق (Omrani et al., 2022) به ارزیابی شرکت های بیمه با وجود عدم قطعیت اقدام می کنند. یک مدل تحلیل پوششی داده های شبکه ای چند هدفه با داده های منفی و ستانده نامطلوب به منظور ارزیابی شرکت های بیمه ارائه می شود.

Tavassoli et al (2023) به اندازه گیری پایداری نیروگاه های سیکل ترکیبی می پردازد در این مسیر از یک مدل تحلیل پوششی داده های شبکه ای فازی جدید بهره گرفته می شود. (Omrani et al., 2023) به سنجش کارایی پایدار واحدهای تصمیم گیری با در نظر گرفتن ستانده نامطلوب اقدام می کنند. این مدل برای شرکت های ایرلاین با استفاده از ترکیبی آمار روش های تاپسیس و تحلیل پوششی داده ها به صورت چند هدفه اعمال می شود (Zou et al., 2023). به تحلیل سنجش کارایی و عوامل اثرگذار بر اقتصاد سبز دریایی بر اساس یک مدل تحلیل پوششی داده های شبکه ای دو مرحله ای می پردازند (Omrani et al., 2023). از یک مدل تحلیل پوششی داده های استوار تحت سناریوهای عدم قطعیت جهت ارزیابی شعبات بانک بهره می گیرند (Saeedi et al., 2023). به تجزیه

ترکیب مدل‌های تحلیل پوششی داده‌ها و الگوریتم‌های یادگیری ماشین برای ...؛ گلزار و همکاران | ۱۴۹

کارایی در شبکه سه مرحله‌ای با ستانده مطلوب و نامطلوب فازی و نهاده فازی در تحلیل پوششی داده‌ها می‌پردازند (Amirteimoori et al., 2023). تحلیل پوششی داده‌های تصادفی را با وجود ستانده نامطلوب انجام می‌دهند.

Sanchooli et al (2023) دو مدل تحلیل پوششی داده‌های شبکه‌ای استوار جدید را برای دستیابی به بازه نمره عملکرد سیستم‌های سریالی چندمرحله‌ای ارائه می‌کنند (Zadmirzaei et al., 2024). یک رویکرد ترکیبی هوش مصنوعی و تحلیل پوششی داده‌های فازی را برای ارزیابی کارایی زیست‌محیطی و پیش‌بینی نشر دی‌اکسید کربن ارائه می‌کنند.

همان‌گونه که مشاهده می‌شود تحقیقات انجام‌شده 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 انجام‌شده 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 زیست‌محیطی می‌باشد که البته ستانده‌های نامطلوب صرفاً منحصر به مسائل زیست‌محیطی نبوده و شامل موارد دیگری نیز می‌شوند. از این‌رو با توجه به خلأ مطالعاتی مشاهده‌شده 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

محققین	سال	هدف	ستانده نامطلوب	عدم قطعیت	فازی	تحلیل پوششی داده‌ها	یادگیری ماشین	مورد مطالعه
ابراهیم نژاد و امانی	2020	ارائه یک مدل تحلیل پوششی داده‌های فازی باوجود ستانده نامطلوب	✓	✓	✓	✓		صنایع
توانا و همکاران	2021	ارائه یک مدل تحلیل پوششی داده‌های کارایی متقاطع استوار با ستانده نامطلوب	✓	✓		✓		صنعت نفت
چن و همکاران	2022	یک مدل تحلیل پوششی داده‌های شبکه‌ای استوار برای ارزیابی پایداری	✓	✓		✓		شرکت‌های های تک
عمرانی و همکاران	2022	ارزیابی شرکت‌های بیمه باوجود عدم قطعیت		✓		✓		شرکت‌های بیمه
توسلی و سائن	2023	اندازه‌گیری پایداری نیروگاه‌های سیکل ترکیبی با استفاده از مدل تحلیل پوششی داده‌های شبکه‌ای فازی		✓	✓	✓		نیروگاه‌های سیکل ترکیبی
عمرانی و همکاران	2023	سنجش کارایی پایدار واحدهای تصمیم‌گیری با در نظر گرفتن ستانده نامطلوب در شرکت‌های آنلاین	✓	✓	✓			شرکت‌های آنلاین
ژو و همکاران	2023	تحلیل سنجش کارایی و عوامل اثرگذار بر اقتصاد سبز دریایی بر اساس یک مدل تحلیل پوششی داده‌های شبکه‌ای دو مرحله‌ای				✓		اقتصاد سبز دریایی
عمرانی و همکاران	2023	ارائه یک مدل تحلیل پوششی داده‌های استوار	✓	✓		✓		شعبات بانک

ترکیب مدل‌های تحلیل پوششی داده‌ها و الگوریتم‌های یادگیری ماشین برای ...؛ گلزار و همکاران | ۱۵۱

محققین	سال	هدف	ستانده نامطلوب	عدم قطعیت	فازی	تحلیل پوششی داده‌ها	یادگیری ماشین	مورد مطالعه
		تحت سناریوهای عدم قطعیت جهت ارزیابی شعبات بانک						
سعیدی اول نوقایا و همکاران	2023	تجزیه کارایی در شبکه سه مرحله‌ای با ستانده نامطلوب و مطلوب فازی و تحلیل پوششی داده‌ها	✓	✓	✓	✓		شرکت‌های بیمه
امیر تیموری و همکاران	2023	ارائه یک مدل تحلیل پوششی داده‌های تصادفی باوجود ستانده نامطلوب	✓	✓		✓		شرکت‌های دانش‌بنیان
سانشولی و همکاران	2024	ارائه دو مدل تحلیل پوششی داده‌های شبکه‌ای استوار جدید برای دستیابی به بازه نمره عملکرد سیستم‌های سریالی چندمرحله‌ای						شرکت‌های تجاری
زاد میرزایی و همکاران	2024	ارائه یک رویکرد ترکیبی هوش مصنوعی و تحلیل پوششی داده‌های فازی برای ارزیابی کارایی زیست‌محیطی و پیش‌بینی نشر دی‌اکسید کربن	✓	✓	✓	✓	✓	نهادهای جنگلی وابسته به محیط‌زیست

روش^۱

در تحقیق حاضر یک تحلیل پوششی داده‌های SBM ارائه می‌شود، این مدل شامل ستانده‌های فازی می‌باشد که ترکیبی از ستانده‌های مطلوب و نامطلوب می‌باشد، ضمن اینکه نهاده‌ها به صورت قطعی می‌باشد. در این مدل فرض می‌شود که تعدادی واحد

تصمیم‌گیری وجود دارد که هر یک از ستانده فازی و نهاده قطعی بهره می‌گیرند. ستانده‌ها شامل ارقام فازی مثلی می‌باشند و همان‌طور که گفته شد به دودسته مطلب و نامطلوب تفکیک می‌شوند؛ بنابراین مدل تحلیل پوششی داده‌های فازی SBM مبتنی بر ستانده به صورت زیر ارائه می‌شود:

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

$$\sum_{j=1}^n \lambda_j x_{ij} + S_i^- = x_{io} \quad i = 1.2 \dots n \quad j = 1.2 \dots m$$

$$\sum_{j=1}^n \lambda_j \tilde{y}_{rj} - S_i^- = \tilde{y}_{ro} \quad r = 1.2 \dots k$$

$$\sum_{j=1}^n \lambda_j \tilde{w}_{tj} - S_t^- = \tilde{w}_{to} \quad t = 1.2 \dots T$$

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

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

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

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

ترکیب مدل‌های تحلیل پوششی داده‌ها و الگوریتم‌های یادگیری ماشین برای ...؛ گلزار و همکاران | ۱۵۳

$$\hat{y}_{rj} = [y_{rj}^m - (1 - a)y_{rj}^l \cdot y_{rj}^m + (1 - a)y_{rj}^u] \quad (۲)$$

$$\hat{w}_{rj} = [w_{rj}^m - (1 - a)w_{rj}^l \cdot w_{rj}^m + (1 - a)w_{rj}^u] \quad (۳)$$

به‌علاوه فاصله قطعی می‌تواند در معادلات ذیل قرار گرفته و لذا داده‌های قطعی می‌تواند برای ستانده به‌صورت زیر محاسبه شود.

$$\begin{aligned} \bar{y}_{rj} &= \frac{1}{2} \int_0^1 [y_{rj}^m - (1 - a)y_{rj}^l \cdot y_{rj}^m + (1 - a)y_{rj}^u] dx \\ &= \frac{1}{4} (y_{rj}^l + 2y_{rj}^m + y_{rj}^u) \end{aligned} \quad (۴)$$

$$\begin{aligned} \bar{w}_{rj} &= \frac{1}{2} \int_0^1 [w_{rj}^m - (1 - a)w_{rj}^l \cdot w_{rj}^m + (1 - a)w_{rj}^u] dx \\ &= \frac{1}{4} (w_{rj}^l + 2w_{rj}^m + w_{rj}^u) \end{aligned} \quad (۵)$$

مدل SBM ارائه‌شده در تحقیق حاضر به مدل ذیل قابل تبدیل می‌باشد.

$$\begin{aligned} \frac{1}{e_o^*} &= \text{Max } 1 + \frac{1}{K + T} \left[\sum_{r=1}^K \frac{S_r^+}{\bar{y}_{ro}} + \sum_{t=1}^T \frac{S_t^-}{\bar{w}_{to}} \right] \\ \sum_{j=1}^n \lambda_j x_{ij} + S_i^- &= x_{io} \quad i = 1, 2, \dots, n \\ &= 1, 2, \dots, m \\ \sum_{j=1}^n \lambda_j \bar{y}_{rj} - S_i^- &= \bar{y}_{ro} \quad r = 1, 2, \dots, k \end{aligned} \quad (۶)$$

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

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

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

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

مدل ترکیبی تحلیل پوششی داده‌های SBM و الگوریتم‌های هوش مصنوعی

تکنیک تحلیل پوششی داده‌ها ابزاری جهت سنجش کارایی 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 گونه‌ها به شمار می‌رود؛ اما تحلیل‌های اخیر نشان می‌دهد که تکنیک‌های هوش مصنوعی به دلیل ماهیت تکاملی خود قادر به بهبود نتایج در حوزه‌های بسیاری می‌باشند به عنوان مثال این تکنیک‌ها با پیش‌بینی 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 نهاده‌ها یا ستانده‌ها 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 بهینه‌سازی نتایج حاصل از کارایی واحدهای تصمیم‌گیری و مشخصاً کاهش ستانده نامطلوب یا افزایش کارایی از الگوریتم‌های هوش مصنوعی و مشخصاً تکنیک‌های یادگیری ماشین استفاده می‌شود. با استفاده از این الگوریتم‌ها به پیش‌بینی ستانده‌های نامطلوب پرداخته شده و سپس این مقادیر وارد مدل SBM شده و اندازه‌گیری کارایی بر اساس مقادیر پیش‌بینی شده صورت می‌گیرد این در حالی است که پیش از آن با استفاده از مدل SBM کارایی واحدهای تصمیم‌گیری با استفاده از داده‌های واقعی و نه پیش‌بینی شده صورت می‌گیرد؛ و در نهایت بین چهار روش مقایسه صورت می‌گیرد این چهار روش به شرح ذیل می‌باشند.

۱- مدل تحلیل پوششی داده‌های SBM بر اساس داده‌های واقعی.

۲- ترکیب مدل تحلیل پوششی داده‌های SBM و شبکه عصبی مصنوعی بر اساس داده‌های پیش‌بینی شده.

۳- ترکیب مدل تحلیل پوششی داده‌های SBM و ماشین بردار پشتیبان بر اساس داده‌های پیش‌بینی شده.

۴- ترکیب مدل تحلیل پوششی داده‌های SBM و الگوریتم XGBoost بر اساس داده‌های پیش‌بینی شده.

لازم به ذکر است با توجه به اینکه الگوریتم‌های مورد استفاده در تحقیق حاضر تاکنون در ترکیب با روش SBM به بهینه‌سازی نتایج حاصل از کارایی واحدهای تصمیم‌گیری در تحقیقات پیشین مورد بهره‌برداری قرار نگرفته است، از این‌رو می‌توان گفت تحقیق حاضر صرفاً به دنبال به کارگیری الگوریتم‌های یادگیری ماشین بوده و به دنبال نوآوری در روش‌شناسی یادگیری ماشین یا بهره‌گیری از الگوریتم‌های نوین نظیر الگوریتم‌های یادگیری عمیق نمی‌باشد، چراکه هدف محقق در این تحقیق صرفاً بهینه‌سازی کارایی با کمک الگوریتم‌های یادگیری ماشین است نه نوآوری در روش‌شناسی. 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 نورون‌های 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 غیرخطی است. همچنین شبکه عصبی مصنوعی دارای قابلیت تعمیم خوب بوده و در برابر دیتای مفقود یا پرنویز قوی است. از سوی دیگر طراحی مدل شبکه عصبی برای یک مسئله پردازش خاص دشوار می‌باشد. مسائل مدل‌سازی باید به‌دقت در نظر گرفته شوند. تعیین معماری مناسب نظیر تعداد متغیرهای ورودی، لایه‌های مخفی و

¹ Artificial neuron network

عصب‌های مخفی در هر لایه می‌تواند به صورت یک عامل بحرانی در نظر گرفته شود. برای مثال تعداد لایه‌ها و نرون‌های 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 نرون‌های مخفی بسیاری داشته باشد از نويز 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 نرون‌های مخفی محدود قادر به تمایز بین الگوهای پیچیده نیست که منجر به برآورد خطی از روند واقعی می‌شود.

شبکه عصبی مصنوعی به عنوان روشی برای پیش‌بینی رفتارهای بازار مالی به طور جامع استفاده شده است. الگوریتم نشر به عقب به عنوان یکی از رویه‌های پرکاربرد برای شبکه‌های چندلایه پدیدار شده است. در شکل یک مدل BPNN چند ورودی سه لایه نمایش داده می‌شود ساختار در آن به صورت M در N در ۱ 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 واحدهای مخفی وجود دارد. Z_{jt} نشانگر خروجی نرون‌های لایه مخفی در زمان T می‌باشد 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 می‌باشد: ورودی تمامی نرون‌ها در لایه مخفی به وسیله معادله ذیل تعیین می‌شود (Wong & wong.,2015).

$$net_{jt} = \sum_{i=1}^n w_{ij}x_{ij} - \theta_j, i = 1, 2, \dots, n \quad (۷)$$

خروجی نرون مخفی به این صورت تعیین می‌شود

$$z_{jt} = f_H(net_{jt}) = f_H\left(\sum_{i=1}^n w_{ij}x_{ij} - \theta_j\right), i = 1, 2, \dots, n \quad (۸)$$

که در اینجا θ آستانه نرون در لایه مخفی است. تابع سیگموید 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 آستانه نرون در لایه مخفی بوده و تابع FTX یک نقشه هویت به صورت تابع فعال‌سازی می‌باشد.

ماشین بردار پشتیبان

بردارهای پشتیبان به زبان ساده، مجموعه‌ای از نقاط در فضای n بعدی داده‌ها هستند که مرز دسته‌ها را مشخص می‌کنند و مرزبندی و دسته‌بندی داده‌ها بر اساس 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 آن‌هم یافتن بهترین مرز در بین داده‌هاست به گونه‌ای که بیشترین فاصله ممکن را از تمام دسته‌ها (بردارهای پشتیبان آن‌ها) داشته باشد.

یک راه ساده برای انجام این کار و ساخت یک دسته‌بندی بهینه، محاسبه فاصله‌ی مرزهای به دست آمده با بردارهای پشتیبان هر دسته (مرزی‌ترین نقاط هر دسته یا کلاس) و در نهایت انتخاب مرزی است که از دسته‌های 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 نه‌چندان پیچیده قابل پیاده‌سازی 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 گرادیان بررسی می‌شود.

مدل یادگیری ماشین ساده‌ای نظیر درخت تصمیم می‌تواند به آموزش مدل در مجموعه داده‌ها 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 داده‌شده و در داده‌هایمان به کار برده می‌شوند. از سوی دیگر، عمل تقویت در رویکردی تکراری به اجرا درمی‌آید؛ 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 درصدد تصحیح اشتباهاتی هستند که سایر مدل‌ها مرتکب شده‌اند. در روش کلاسه‌بندی جمعی استاندارد 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 باهدف 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 فرآورده‌های نفتی ایران می‌باشد که این مورد مطالعه در تحقیق پیشین محقق نیز مورد استفاده قرار گرفت. متغیرهای استخراجی از دیتابیس و منابع اطلاعاتی این شرکت‌ها جمع‌آوری 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 تأمین منابع می‌باشد از بخش مالی استخراج شده است. زمان تحقق سفارش در بخش تأمین 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 کتابخانه‌ای جمع‌آوری 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 تأمین	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 پیش‌بینی دو متغیر زمان اتلاف و میزان اتلاف به عنوان دو عامل نامطلوب پرداخته شده و ارزیابی کارایی واحدهای تصمیم‌گیری بر اساس مقادیر پیش‌بینی شده صورت می‌گیرد تا به این ترتیب مشخص شود مقادیر پیش‌بینی شده منجر به کارایی بیشتری می‌شود یا مقادیر واقعی. برای این منظور به مقایسه چهار روش پرداخته شده

ترکیب مدل‌های تحلیل پوششی داده‌ها و الگوریتم‌های یادگیری ماشین برای ...؛ گلزار و همکاران | ۱۶۱

و بهترین روش که می‌تواند روش SBM یا یکی از روش‌های ترکیبی باشد به عنوان روش بهینه برای ارزیابی کارایی عملکرد انتخاب می‌شود. لازم به ذکر است که جمع‌آوری داده‌ها بر اساس اطلاعات شرکت‌های مورد مطالعه هم برای پیش‌بینی ستانده نامطلوب و هم به منظور پیاده‌سازی روش اولیه SBM می‌باشد.

تجزیه و تحلیل یافته‌ها

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


جدول ۳. نمرات کارایی حاصل از روش SBM

واحد تصمیم‌گیری	نمره کارایی روش SBM	واحد تصمیم‌گیری	نمره کارایی روش SBM
DMU1	0/7342	DMU20	0/9439
DMU2	0/8368	DMU21	1
DMU3	0/9137	DMU22	0/9651
DMU4	1	DMU23	0/9596
DMU5	1	DMU24	0/8639
DMU6	1	DMU25	1
DMU7	0/8393	DMU26	0/8501
DMU8	1	DMU27	1
DMU9	0/9797	DMU28	0/7679
DMU10	1	DMU29	0/8376
DMU11	1	DMU30	0/4358
DMU12	1	DMU31	1
DMU13	1	DMU32	1
DMU14	1	DMU33	0/8643
DMU15	0/8962	DMU34	0/994

واحد تصمیم‌گیری	نمره کارایی روش SBM	واحد تصمیم‌گیری	نمره کارایی روش SBM
DMU16	1	DMU35	0/9401
DMU17	0/7883	DMU36	1
DMU18	1	DMU37	1
DMU19	1		

بر اساس نتایج حاصل از جدول فوق می‌توان دریافت برخی واحدهای تصمیم‌گیری با کسب نمره ۱ به کارایی کامل دست‌یافته و برخی نمراتی کمتر از ۱ کسب نموده که نشانگر کارایی کمتر از حد مطلوب می‌باشد. نکته قابل‌توجه این است که واحد تصمیم‌گیری شماره ۳۰ با نمره کارایی ۰/۴۳، ضعیف‌ترین واحد تصمیم‌گیری تلقی می‌شود و واحدهای تصمیم‌گیری نظیر ۳۴ یا ۲۲۹ و ۲۳ نمره کارایی نزدیک به ۱ را کسب نموده و صرفاً چند درصد کمتر از نمره کارایی را به دست آورده‌اند که این امر باعث شده این واحدهای تصمیم‌گیری ناکارا تلقی شوند. در نمودار ذیل نتایج حاصل از نمرات کارایی واحدهای تصمیم‌گیری به‌خوبی ترسیم شده است.


نمودار ۱. نمرات کارایی حاصل از روش SBM




ترکیب مدل‌های تحلیل پوششی داده‌ها و الگوریتم‌های یادگیری ماشین برای ...؛ گلزار و همکاران | ۱۶۳

در نمودار فوق صرفاً با استفاده از روش SBM مشخص شده است که کدام واحدهای تصمیم‌گیری دارای کارایی کامل یعنی مقدار ۱ و کدام یک کمتر از این مقدار می‌باشند. تا اینجا صرفاً به ارزیابی کارایی واحدهای تصمیم‌گیری 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 می‌باشد. الگوریتم‌های مورد استفاده شامل شبکه عصبی مصنوعی، ماشین بردار پشتیبان و XGBoost می‌باشند. 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






همان گونه که دیده می‌شود در نمودار ۲(الف) عملکرد شبکه عصبی بهینه شده است چراکه مقدار حداقل در یکی از تکرارها حاصل شده و پس از آن نمودار آموزش ماهیت نزولی و نمودار تست ماهیت صعودی یافته است؛ بنابراین می‌توان 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 هیستوگرام‌های خطا از توزیع نرمال تبعیت کرده و نشانگر صحت و اعتبار شبکه عصبی مصنوعی مورد استفاده جهت پیش‌بینی ستانده نامطلوب می‌باشد.

ترکیب مدل‌های تحلیل پوششی داده‌ها و الگوریتم‌های یادگیری ماشین برای ...؛ گلزار و همکاران | ۱۶۵

نمودار ۳. رگرسیون شبکه عصبی




همان گونه که دیده می‌شود هر ۴ نمودار (a,b,c,d) نشانگر اصطلاحاً fit بودن داده‌ها در حد بالایی می‌باشد به گونه‌ای که مقادیر پیش‌بینی شده هم‌جواری زیادی با داده‌های واقعی داشته و لذا می‌توان گفت پیش‌بینی ستانده نامطلوب برای واحدهای تصمیم‌گیری به‌خوبی صورت گرفته است. مقدار دقت ۸۵۵٪. برای کل داده‌ها حاصل گردیده است که نشان می‌دهد تا ۸۵ درصد پیش‌بینی ستانده نامطلوب ناشی از متغیرهای ورودی مدل می‌باشد؛ اما

در ادامه از دو الگوریتم دیگر برای پیش‌بینی استفاده شده است که نتایج پیش‌بینی ستانده نامطلوب با کمک آن‌ها در جدول ۴ ارائه گردیده است.

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

تکرار	شبکه عصبی مصنوعی	ماشین بردار پشتیبان	XGBoost
1	0/855	0/813	0/802
2	0/860	0/814	0/806
3	0/864	0/814	0/809
4	0/867	0/815	0/812
5	0/867	0/816	0/814
6	0/870	0/816	0/815
7	0/872	0/817	0/818
8	0/875	0/822	0/818
9	0/876	0/827	0/820
10	0/880	0/830	0/823

نمودار ۴. مقایسه دقت پیش‌بینی 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


ترکیب مدل‌های تحلیل پوششی داده‌ها و الگوریتم‌های یادگیری ماشین برای ...؛ گلزار و همکاران | ۱۶۷

عصبی مصنوعی بافاصله‌ای نسبتاً بعید با دو الگوریتم دیگر دقت خود را بهبود بخشیده است به گونه‌ای که دقت پیش‌بینی 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 پیش‌بینی میزان دقت از تحلیل آن‌ها صرفه نظر می‌شود.

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

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

نمودار ۵. مقایسه خطای پیش‌بینی 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 پیش‌بینی 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 پیش‌بینی به میزان بیشتری نسبت به دو الگوریتم رقیب خود بوده است.

پس از پیش‌بینی ستانده نامطلوب توسط سه الگوریتم یادگیری ماشین و مقایسه الگوریتم‌ها از نظر کارایی پیش‌بینی 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 می‌باشند. نتایج در جدول ۶ ارائه شده است.


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

واحد تصمیم‌گیری	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
DMU9	0/9797	1/02679	1/01511806	1/019531
DMU10	1	1/04116	1/03223899	1/03238502
DMU11	1	1/04808	1/03252795	1/03657448
DMU12	1	1/04294	1/03207577	1/03640392
DMU13	1	1/04193	1/03536719	1/03088405

ترکیب مدل‌های تحلیل پوششی داده‌ها و الگوریتم‌های یادگیری ماشین برای ...؛ گلزار و همکاران | ۱۶۹

واحد تصمیم‌گیری	نمره کارایی روش SBM	شبکه عصبی مصنوعی	ماشین بردار پشتیبان	XGBoost
DMU14	1	1/0402	1/03302483	1/03489967
DMU15	0/8962	0/93964	0/93214719	0/93054893
DMU16	1	1/04339	1/03137523	1/03587049
DMU17	0/7883	0/8355	0/8245593	0/82133829
DMU18	1	1/04586	1/03389979	1/03551531
DMU19	1	1/04058	1/03356702	1/03271922
DMU20	0/9439	0/98624	0/98288484	0/97561156
DMU21	1	1/04181	1/03322853	1/03477286
DMU22	0/9651	1/0099	1/00436321	0/99541227
DMU23	0/9596	1/00897	0/99441982	0/99660836
DMU24	0/8639	0/90587	0/89413595	0/89811513
DMU25	1	1/04943	1/03010345	1/03619782
DMU26	0/8501	0/89312	0/88991221	0/89006471
DMU27	1	1/04733	1/03401077	1/03260387
DMU28	0/7679	0/81587	0/80499949	0/80546452
DMU29	0/8376	0/88295	0/87217967	0/87225777
DMU30	0/4358	0/47927	0/47435634	0/47515964
DMU31	1	1/04321	1/03863352	1/03020794
DMU32	1	1/04378	1/03604494	1/03761337
DMU33	0/8643	0/90663	0/89963367	0/9038508
DMU34	0/994	1/03457	1/02828725	1/02822391
DMU35	0/9401	0/9899	0/97701897	0/97138771
DMU36	1	1/04921	1/03705166	1/03766897
DMU37	1	1/04498	1/03655997	1/03181079

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 تصمیم‌گیری بوده است. روش SBM ضعیف‌ترین نتایج را داشته است که این نشان می‌دهد نتایج با استفاده از روش‌های یادگیری ماشین قابل‌بهبود است. سه الگوریتم یادگیری ماشین همگی موفق شده‌اند تا حدی مقادیر نمرات کارایی 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 کارایی واحدهای غیرکارا، کارا نمودن واحدهای غیرکارا و حتی کارایی بیشتر برای واحدهای کارا گردیده است. درمجموع می‌توان گفت تمامی الگوریتم‌های هوش مصنوعی منجر به بهبود نمرات کارایی 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 کارایی 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 تولیدشده 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 پیش‌بینی‌شده توسط الگوریتم‌های یادگیری ماشین ارزیابی کارایی صورت می‌گیرد.

بر اساس نتایج به دست آمده می‌توان گفت که نتایج حاصل از ارزیابی بر اساس ستانده‌های پیش‌بینی‌شده 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 دو الگوریتم دیگر به میزان بیشتری قادر به بهبود نتایج حاصل از کارایی 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 بهینه‌سازی 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 پیش‌بینی‌شده عمل می‌کنند و به دلیل آنکه بر اساس ماهیت تکاملی خود قادر به دستیابی به نتایج بهتری می‌باشند از این رو نتایج حاصل از داده‌های پیش‌بینی‌شده 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 داده‌ها انجام

می‌شوند بهره برد. تحقیقات آتی می‌تواند مدل تحقیق حاضر را در قالب یک مدل شبکه‌ای مدنظر قرار داده و به‌این 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 هیچ‌گونه تعارض منافع ندارند

سپاسگزاری

از شرکت ملی پخش فرآورده‌های نفتی ایران به‌خاطر حمایت‌های مالی و کمیته پژوهش این شرکت به دلیل حمایت‌های 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

1. Alsarraf, J., Moayedi, H., Rashid, A. S. A., Muazu, M. A., & Shahsavar, 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.
2. 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. d 0.1080/01605682.2023.2172366.
3. 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>
4. 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>
5. 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>
6. 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>
7. 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>
8. 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>
9. 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>.

10. 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
11. 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 ybernetics*, 16(4), 665-696.
12. 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).
13. 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.
14. 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>
15. 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,
16. 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>
17. 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: گلزار، ابراهیم، نجفی، سید اسماعیل، عدالت پناه، سید احمد، عزیزی، امیر. (۱۴۰۳). ترکیب

مدل‌های تحلیل پوششی داده‌ها و الگوریتم‌های یادگیری ماشین برای ارزیابی کارایی واحدهای تصمیم‌گیری با در نظر

گرفتن ستاندهای نامطلوب، مطالعات مدیریت صنعتی، ۲۲(۷۴)، ۱۳۹-۱۷۴. DOI:

10.22054/jims.2024.79619.2918



Industrial Management Studies is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License.