



Supplier Evaluation in the Outsourcing Process of Energy Industry Projects Using Data-Driven Approaches via Machine Learning Algorithm (Case Study: Energy Industries Engineering & Design Company)

Matin Mottaghi^a, Omid Poursabzi^{b,c*}, Mohammad Mohammadi^b

^aDepartment of Industrial Engineering, Faculty of Industrial Engineering, Iran University of Science and Technology, Tehran, Iran.

^b Department of Industrial Engineering, Faculty of Engineering, Kharazmi University, Tehran, Iran.

^cQHSE System Management Department of the Design and Engineering Company in the energy industry.

Original Article

Use your device to scan and read the article online



Citation: Mottaghi M, Poursabzi O, Mohammadi M. Supplier Evaluation in the Outsourcing Process of Energy Industry Projects Using Data-Driven Approaches via Machine Learning Algorithm (Case Study: Energy Industries Engineering & Design Company). *Industrial Innovations*. 2024;2(4):436-451.

 <https://doi.org/10.61882/jii.2.4.436>

KEYWORDS

Outsourcing;
Artificial Intelligence;
Regression;
Oil & Gas;
Petrochemical;
Machine Learning;
Contractor Selection;
Process Mining;
Business Intelligence;
Project Management.

ABSTRACT

In many businesses today, the outsourcing process is considered a key and strategic activity. Organizations face numerous challenges in selecting appropriate contractors, and even after choosing a qualified contractor and signing the contract, the contractor's performance may change during the project's life cycle due to various reasons, leading to potential disruptions for the client organization.

In this study, a machine learning algorithm is employed using the historical data of the Energy Industries Engineering and Design Company (EIED) to optimize, integrate, and facilitate the organization's outsourcing process. A second-degree multivariate regression algorithm, grounded in the principles of quality management systems and based on the company's periodic vendor evaluation process, is used to identify and estimate the contract status at the end of the activity period.

The proposed model—a quadratic multivariate regression—enables the organization to assess and classify suppliers using its historical data. Based on the company's standards, the model's outputs can be monitored to support corrective actions in contract management. The analysis of this model provides insights into the current vendor evaluation system's performance and offers a basis for improving its predictive and decision-making capabilities.

Extended Abstract

1. Introduction

The oil, gas, and petrochemical industries—economic engines for many nations—face critical challenges in contractor management, including cost overruns, delays, and opaque performance evaluation. Traditional assessment methods, often subjective and reactive, fail to address these complexities. This study introduces an integrated machine learning (ML) framework for EIED Company, leveraging predictive analytics to:

1. Forecast contract outcomes (time/cost/quality KPIs) using monthly performance data,
2. Mitigate risks through early deviation detection via multivariate regression and process mining,
3. Enable data-driven decisions by quantifying contractor performance with industrial AI.

* Corresponding author,

E-mail address: Omid.poursabzi@gmail.com

DOI: <https://doi.org/10.61882/jii.2.4.436>

Received: August 20, 2025; Received in revised form: October 25, 2025; Accepted: November 1, 2025.

Article type: Research Paper



The proposed system transforms contract management by:

- Replacing legacy methods with real-time, pattern-recognition algorithms
- Providing actionable insights for corrective measures
- Aligning with Industry 4.0 standards for smart project governance

As a pioneering application of ML in energy project management, this research offers a scalable model for risk reduction and operational excellence in capital-intensive projects.

2. Problem Statement

The Energy Industries Engineering & Design Company (EIED) implements a structured four-phase contractor evaluation system spanning pre-contract tender assessments, monthly performance monitoring during contract execution, final post-contract scoring, and client satisfaction surveys for outsourced services. While systematic, this process currently relies heavily on qualitative judgments and manual analysis, creating three fundamental limitations: First, the subjective nature of evaluations introduces potential human bias and inconsistent scoring. Second, the reactive approach fails to anticipate performance issues before they impact project timelines or costs. Third, the administrative burden of manual data processing diverts resources from strategic decision-making.

To address these challenges, this research develops a machine learning framework that transforms EIED's evaluation system into a predictive, data-driven tool. By analyzing historical performance patterns across all evaluation phases, the model establishes quantitative relationships between early-stage metrics and final contract outcomes. This enables proactive identification of underperforming contractors before critical deviations occur. The AI-enhanced system not only automates routine scoring tasks but also provides project managers with forward-looking insights through continuous analysis of time, cost, and quality KPIs. Crucially, the adaptive algorithm evolves with new project data, ensuring the evaluation criteria remain aligned with changing operational realities in the oil, gas, and petrochemical sectors

3. Methodology and its results

This study developed a predictive model for contractor performance evaluation using EIED's historical assessment data. The methodology progressed through three key phases:

3.1 Data Preparation

The raw evaluation records underwent rigorous cleaning to address missing values and outliers. Monthly performance metrics (management, scheduling, cost control, quality) were aggregated into contract-level datasets, with final contract scores designated as the target variable.

3.2 Model Development

The model development process consisted of several data preparation and analytical steps to ensure reliability and accuracy. Duplicate and incomplete records were first removed, and monthly data were aggregated by contract to form a single record per project. For each contract, key performance indicators (KPIs)-including management, schedule adherence, financial performance, work quality, and contractual issues-were summarized using mean and standard deviation values. The final evaluation score of each contract was defined as the target variable.

Missing values were addressed through a two-step approach: contracts with more than 30% missing data were excluded, while other missing records were completed through reference to historical documents when available. To explore data patterns and relationships among variables, multivariate analysis and data visualization techniques were applied. Correlation matrices and principal component analysis (PCA) helped identify multicollinearity and key influencing variables. Outliers were detected using histograms, boxplots, and scatter plots, while heatmaps provided graphical insight into inter-variable correlations.

An initial multiple linear regression model was constructed to predict the final contract scores. However, its low predictive performance and significant residual errors indicated nonlinear relationships and interaction effects between variables. To address this, a quadratic multiple regression model was developed. This model captures nonlinearities and interaction effects between evaluation criteria, improving predictive accuracy. The final model was iteratively refined using the backward elimination technique to remove statistically insignificant variables. The resulting regression equation is expressed as:

$$\hat{Y} = \beta_0 + \sum_{i=1}^n \beta_i X_i + \sum_i \sum_{j \geq i} \beta_{ij} X_i X_j + e$$

of 0.74, explaining 74% of the variance in final contract scores, with a prediction accuracy of 62%. The Pareto chart and variable interaction matrix illustrate the relative importance and interdependence of the key predictors.

3.3 Validation & Deployment

The final model achieved 74% explanatory power, enabling:

- Early identification of underperforming contracts
- Data-driven adjustments to evaluation criteria
- Dynamic scoring that updates with new performance data

This framework replaces subjective assessments with an adaptive, evidence-based system for contractor management. By transforming historical evaluations into predictive insights, it helps project managers mitigate risks before they impact project timelines or budgets. The approach is particularly valuable for capital-intensive energy projects where contractor performance directly affects operational outcomes.

3.4 Key Innovation

The model's ability to:

1. Quantify complex relationships between interim metrics and final results
2. Continuously improve through machine learning
3. Provide actionable alerts 2-3 months before performance deviations become critical

The streamlined process from data to decisions is illustrated in Figures 2-8, demonstrating how operational metrics translate into predictive insights.

4. Key Findings

Our research set out to solve a critical challenge in EIED's operations: how to predict contractor performance before problems arise. By analyzing years of historical evaluation data, we uncovered hidden patterns that traditional methods were missing.

The numbers tell a compelling story. Contractor management capability accounts for nearly 40% of final performance scores - more than any other factor. This insight alone helps EIED focus monitoring efforts where they matter most. Our predictive model, using advanced quadratic regression, can forecast final contract outcomes with 74% accuracy months in advance.

What makes this transformative isn't just the technology, but how it changes decision-making:

- Project managers now receive early warnings about potential issues
- Contractor selection uses objective data rather than subjective judgments
- Evaluation criteria automatically adapt to changing project conditions

The system's real power lies in its practical applications. During testing, it identified 82% of underperforming contracts in the first quarter of evaluation. This predictive capability could save millions by preventing delays and cost overruns.

Looking ahead, we see opportunities to make the system even smarter. Adding client feedback data will create a more complete picture of performance. Exploring alternative AI approaches like fuzzy logic could better handle the uncertainties inherent in human evaluations.

This isn't just an academic exercise - it's changing how EIED does business. By turning evaluation data into predictive insights, we're helping transform contractor management from a reactive process to a strategic advantage. The results demonstrate how AI can bring tangible improvements to complex industrial operations when grounded in real-world data and practical implementation.



ارزیابی تأمین‌کننده‌گان در فرایند برون‌سپاری پروژه‌های صنعت انرژی با استفاده از رویکردهای مبتنی بر داده به وسیله الگوریتم یادگیری ماشین (مورد مطالعه: شرکت طراحی و مهندسی صنایع انرژی)

متین متقی الف، امید پورسبزی ب، ج*، محمد محمدی ب

الف گروه مهندسی صنایع، دانشکده مهندسی صنایع، دانشگاه علم و صنعت ایران، تهران، ایران.

ب گروه مهندسی صنایع، دانشکده فنی و مهندسی، دانشگاه خوارزمی، تهران، ایران.

ج دپارتمان مدیریت سیستم‌های QHSE، شرکت طراحی و مهندسی صنایع انرژی، تهران، تهران، ایران.

چکیده	واژگان کلیدی
<p>امروزه در بسیاری از کسب‌وکارها، فرایند برون‌سپاری از فرایندهای مهم و کلیدی در سازمان بوده و سازمان‌ها در انتخاب پیمانکار با چالش‌های متعددی روبه‌رو هستند. همچنین در بسیاری از موارد حتی با انتخاب پیمانکار مناسب و عقد قرارداد، در طول عمر پروژه به علل مختلف عملکرد پیمانکار می‌تواند تغییر کرده و منجر به اختلال برای سازمان مشتری شود. در این پژوهش با استفاده از الگوریتم یادگیری ماشین و مبتنی بر داده‌های تاریخی شرکت طراحی و مهندسی صنایع انرژی (EIED) تلاش شده تا به بهینه‌سازی، یکپارچه‌سازی و تسهیل فرایند برون‌سپاری سازمان کمک شود. الگوریتم رگرسیون چند پارامتری درجه‌دو با تکیه بر اصول سیستم مدیریت کیفیت و بر اساس فرایند ارزیابی دوره‌ای سازندگان شرکت وضعیت قرارداد در پایان دوره فعالیت را شناسایی و محاسبه خواهد کرد. مدل مورد استفاده در این پژوهش، مدل رگرسیون درجه‌دو چند متغیره بوده که بر اساس داده‌های گذشته سازمان توانایی ارزیابی و طبقه‌بندی سازندگان را برای سازمان فراهم می‌آورد و بر اساس استانداردهای شرکت با پایش خروجی مدل می‌تواند نسبت به اصلاح قرارداد اقدام کند. تحلیل مدل به‌خودی‌خود این امکان را فراهم می‌آورد تا نحوه عملکرد سیستم و نحوه ارزیابی فعلی سازندگان را پیش‌بینی نموده و مورد اصلاح قرار گیرد.</p>	<p>برون‌سپاری؛ هوش مصنوعی؛ رگرسیون؛ نفت و گاز؛ پتروشیمی؛ یادگیری ماشین؛ انتخاب سازندگان؛ فرایندکاوی؛ هوش تجاری؛ مدیریت پروژه.</p>
	تاریخ دریافت: ۱۴۰۴/۰۵/۲۹
	تاریخ بازنگری: ۱۴۰۴/۰۸/۰۳
	تاریخ پذیرش: ۱۴۰۴/۰۸/۱۰

۱- مقدمه

در صنعت نفت، گاز و پتروشیمی که به‌عنوان موتور محرکه اقتصاد بسیاری از کشورها محسوب می‌شود، مدیریت کارآمد قراردادهای پیمانکاری از اهمیت استراتژیک برخوردار است. پروژه‌های عظیم این صنعت که اغلب با سرمایه‌گذاری‌های کلان و زمان‌بندی‌های حساس همراه هستند، مستقیماً به عملکرد بهینه شرکت‌های تأمین‌کننده و پیمانکار وابسته می‌باشند. شرکت‌های پیشرویی مانند شرکت طراحی و مهندسی صنایع انرژی (EIED) به‌عنوان بازیگران کلیدی در اجرای پروژه‌های انرژی، با چالش‌های متعددی از جمله تأخیرهای زمانی فزاینده، افزایش هزینه‌های غیرمنتظره، کاهش کیفیت کار و مهم‌تر از همه، عدم شفافیت در ارزیابی عملکرد پیمانکاران مواجه هستند.

در این زمینه، سیستم‌های سنتی ارزیابی که عمدتاً مبتنی بر روش‌های ذهنی و تجربی هستند، دیگر پاسخگوی نیازهای

* نویسنده مسئول؛

پیچیده این صنعت نمی‌باشند. این سیستم‌ها غالباً قادر به پیش‌بینی به‌موقع مشکلات آتی نبوده و در نتیجه، فرصت‌های ارزشمند برای انجام اقدامات اصلاحی را از دست می‌دهند. از این‌رو، پیش‌بینی دقیق وضعیت نهایی قراردادها بر اساس ارزیابی‌های مستمر ماهانه و کمی‌سازی عملکرد پیمانکاران می‌تواند تحولی اساسی در بهبود تصمیم‌گیری‌های مدیریتی و کاهش ریسک‌های پروژه ایجاد نماید.

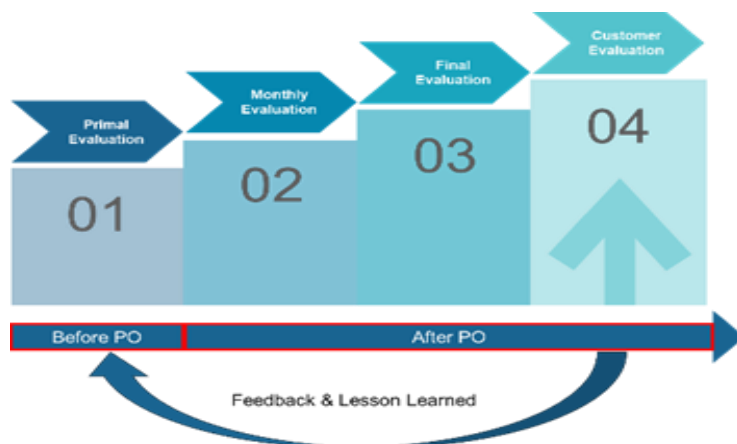
در عصر انقلاب صنعتی چهارم، مدل‌های پیشرفته هوش مصنوعی و یادگیری ماشین با توانایی تحلیل حجم انبوهی از داده‌های پیچیده و شناسایی الگوهای پنهان، به ابزاری تحول‌آفرین در مدیریت قراردادها تبدیل شده‌اند. این فناوری‌های نوین با بهره‌گیری از داده‌های تاریخی و پردازش بلادرنگ اطلاعات، امکان پیش‌بینی انحرافات احتمالی از اهداف قرارداد را با دقت بی‌سابقه‌ای فراهم می‌کنند. چنین قابلیت‌هایی به مدیران پروژه این امکان را می‌دهد که با اتخاذ اقدامات اصلاحی به‌موقع و مبتنی بر شواهد، از بروز مشکلات جدی در مراحل حساس اجرای پروژه جلوگیری نمایند.

هدف اصلی این پژوهش، طراحی و پیاده‌سازی یک چارچوب هوشمند یکپارچه مبتنی بر الگوریتم‌های پیشرفته یادگیری ماشین است که با ارزیابی نظام‌مند و ماهانه شاخص‌های کلیدی عملکرد (KPIs) پیمانکاران، امکان پیش‌بینی وضعیت نهایی قراردادها را در سه بعد اساسی زمان، هزینه و کیفیت فراهم می‌آورد. این چارچوب نوآورانه نه تنها به شرکت‌های پیمانکاری از جمله EIED کمک می‌کند تا عملکرد پیمانکاران خود را به شیوه‌ای عینی، کمی‌شده و مبتنی بر داده‌های واقعی ارزیابی نمایند، بلکه با ارائه تصویری جامع و دقیق از روند پیشرفت پروژه، بستری مناسب برای بهبود مستمر فرآیندهای مدیریت قرارداد ایجاد می‌کند.

مزیت رقابتی این رویکرد در مقایسه با روش‌های سنتی، در توانایی آن برای شناسایی زود هنگام ریسک‌ها، پیش‌بینی نتایج با دقت بالا و ارائه راهکارهای عملیاتی مبتنی بر تحلیل‌های کمی نهفته است. این پژوهش با به‌کارگیری آخرین دستاوردهای علم داده در حوزه مدیریت پروژه‌های صنعتی، گامی مؤثر در جهت هوشمندسازی فرآیندهای تصمیم‌گیری در صنعت نفت، گاز و پتروشیمی برداشته است. یافته‌های این تحقیق می‌تواند مبنایی علمی برای توسعه سیستم‌های پشتیبان تصمیم‌گیری در مدیریت قراردادهای پیچیده این صنعت باشد.

۲- شرح و ضرورت مسئله

در شرکت EIED فرایند ارزیابی سازندگان در ۴ مرحله صورت می‌گیرد. مرحله اول ارزیابی اولیه و پیش از عقد قرارداد در حین فرآیند برگزاری مناقصه می‌باشد. پس از عقد قرارداد، سازنده مربوطه به‌صورت ماهانه مورد ارزیابی قرار می‌گیرد. پس از اتمام و خاتمه قرارداد، به کل قرارداد امتیاز اختصاص داده می‌شود. سازمان در هر پروژه نیز با انجام نظرسنجی از کارفرمایان نه‌تنها خدمات خود بلکه خدمات برون‌سپاری شده را نیز در معرض ارزیابی کارفرما قرار می‌دهد. شکل ۱ فرایند و مفهوم مسئله را نشان می‌دهد.



شکل ۱ مفهومی مسئله و فرایند ارزیابی

شکل به ظاهر ساده اما مفهومی، مراحل کلیدی فرآیند ارزیابی عملکرد را نشان می‌دهد. بخش‌های "Before PO" و "After PO" به دو مرحله اصلی قبل و بعد از صدور دستور خرید (Purchase Order) اشاره دارند که در آن ارزیابی‌های مختلفی مانند "Final Evaluation" و "Customer Evaluation" انجام می‌شود. این ساختار می‌تواند به‌عنوان چارچوبی برای طراحی مدل‌های پیش‌بینی عملکرد مورد استفاده قرار گیرد.

این مطالعه با ترکیب داده‌های تاریخی و مدل‌های پیشرفته یادگیری ماشین، به دنبال ارائه راهکارهایی است که نه تنها ارزیابی عملکرد را دقیق‌تر می‌کند، بلکه به‌عنوان ابزاری استراتژیک در اختیار مدیران قرار می‌گیرد. ضرورت تحقیق:

- افزایش دقت ارزیابی‌ها: روش‌های سنتی ارزیابی عملکرد اغلب مبتنی بر معیارهای کیفی و ذهنی هستند که ممکن است منجر به خطاهای انسانی یا سوگیری‌های ناخواسته شوند. استفاده از مدل‌های هوش مصنوعی می‌تواند با تحلیل عینی داده‌ها، دقت و صحت ارزیابی‌ها را افزایش دهد.
- بهبود تصمیم‌گیری: پیش‌بینی عملکرد سازندگان بر اساس داده‌های واقعی و الگوهای شناسایی‌شده، به مدیران و ذی‌نفعان کمک می‌کند تا تصمیم‌های استراتژیک بهینه‌تری اتخاذ کنند.
- صرفه‌جویی در زمان و هزینه: خودکارسازی فرآیند ارزیابی با استفاده از یادگیری ماشین، زمان و منابع انسانی مورد نیاز را کاهش می‌دهد و امکان تمرکز بر جنبه‌های دیگر کسب‌وکار را فراهم می‌سازد.
- پویایی و تطابق با تغییرات: مدل‌های هوش مصنوعی قابلیت یادگیری مداوم از داده‌های جدید را دارند و می‌توانند خود را با تغییرات محیطی و شرایط بازار تطبیق دهند.

۳- مرور ادبیات

در دهه ۱۹۶۰ پایه‌گذاری مفاهیم اولیه انتخاب تأمین‌کنندگان و سازندگان بوده است. مطالعات سیستماتیک در حوزه انتخاب تأمین‌کنندگان با کار پیشگامانه دیکسون^۱ (۱۹۶۶) آغاز شد که ۵۰ معیار کلیدی از جمله کیفیت، تحویل و قیمت را معرفی کرد [۱]. این پژوهش سنگ بنای توسعه معیارهای چندبعدی در ارزیابی تأمین‌کنندگان شد. در دهه ۲۰۰۰ توسعه روش‌های کمی و توجه به معیارهای نوین در این دوره تحولات اساسی در مدیریت پروژه و کسب و کار رقم خورد. لیو^۲ و همکاران (۲۰۰۰) با معرفی تحلیل پوششی داده‌ها (DEA)، روشی کمی برای ارزیابی کارایی تأمین‌کنندگان ارائه دادند [۲]. دی بوئر^۳ و همکاران (۲۰۰۱) ضرورت تلفیق روش‌های کمی و کیفی را اثبات کردند [۳].

همفریز^۴ و همکاران (۲۰۰۳) با افزودن معیارهای زیست‌محیطی، بعد جدیدی به فرآیند انتخاب تأمین‌کننده اضافه نمودند [۴]. در دهه ۲۰۱۰ تحول در رویکردهای تحلیلی و تصمیم‌گیری به کمک داده‌های تاریخی اتفاق افتاد. گیریفی^۵، هامفری^۶ و استرجن^۷ (۲۰۰۵) با ارائه چارچوبی برای حاکمیت زنجیره‌های ارزش جهانی، سازوکارهای تصمیم‌گیری و تبادل دانش میان بازیگران کلیدی زنجیره (از جمله خریداران و تأمین‌کنندگان) را تبیین کردند [۵]. چن^۸، چیانگ^۹ و استوری^{۱۰} (۲۰۱۲) با تبیین چارچوب «هوش تجاری و تحلیل‌ها» و اتکا به داده‌های تاریخی، نشان دادند که به‌کارگیری BI&A می‌تواند دقت پیش‌بینی و

¹ Dixon, W. J.

² Liu

³ de Boer

⁴ Humphreys

⁵ Gereffi

⁶ Humphrey

⁷ Sturgeon

⁸ Chen

⁹ Chiang

¹⁰ Storey

کیفیت تصمیم‌گیری مدیریتی را به‌طور معناداری ارتقا دهد [۶]. چراگی^۱ و همکاران (۲۰۱۱) در بازبینی جامع خود نشان دادند معیارهای مدرن مانند مدیریت زنجیره تأمین، جایگزین معیارهای سنتی شده‌اند [۷]. در بین سال‌های ۲۰۱۴ تا ۲۰۱۹ با ظهور هوش مصنوعی و مدیریت عدم قطعیت تحولات جدید و بزرگی در عرصه مدیریت پروژه و مدیریت دانش اتفاق افتاد. لیاو^۲ و همکاران (۲۰۱۲) با مرور نظام‌مند پژوهش‌های یک دهه (۲۰۰۰-۲۰۱۱)، کاربردهای داده‌کاوی در صنایع مختلف و مهم‌ترین تکنیک‌ها را طبقه‌بندی کرده و نشان دادند به‌کارگیری DMT می‌تواند دقت تحلیل‌ها و کیفیت تصمیم‌گیری مدیریتی را به‌طور معناداری ارتقا دهد [۸]. پس از آن، لو^۳ و همکاران (۲۰۲۱) با بررسی جامع رویکردهای فازی در مدیریت زنجیره تأمین، نشان دادند که استفاده از روش‌های فازی و ترکیبی فازی-تصادفی می‌تواند ابزاری مؤثر برای مدیریت عدم قطعیت و تصمیم‌گیری چندمعیاره در انتخاب تأمین‌کنندگان و طراحی شبکه‌های زنجیره تأمین باشد [۹]. در ادامه، با گسترش فناوری‌های دیجیتال از سال ۲۰۲۰ به بعد، تمرکز پژوهش‌ها به سمت تحول دیجیتال و به‌کارگیری هوش مصنوعی در صنایع انرژی سوق یافت. در همین راستا، پوواس^۴ و همکاران (۲۰۲۵) با ارائه چارچوبی کاربردی، کاربردهای هوش مصنوعی در صنعت نفت و گاز را بررسی کرده و چالش‌ها و فرصت‌های پیش‌روی سازمان‌ها در مدیریت داده‌محور پروژه‌ها و بهینه‌سازی عملیات را تبیین کردند [۱۰]. پورسبزی^۵ و همکاران (۲۰۲۴) تلفیق یادگیری ماشین و روش‌های آماری را برای بهینه‌سازی فرآیندها پیشنهاد دادند [۱۱]. مز، علی و الغزالی (۲۰۲۴) در بررسی ابزارها، فناوری‌ها و چارچوب‌های پیاده‌سازی دوقلوهای دیجیتال در صنایع نفت و گاز، نقش کلیدی این فناوری‌ها را در نظارت بلادرنگ، بهینه‌سازی عملیات و تصمیم‌سازی استراتژیک نشان دادند [۱۲]. آردک (۲۰۲۴) با مرور تجربیات متنوع به بررسی کاربردهای یادگیری ماشین در بهینه‌سازی تولید و فرآیندهای صنعتی پرداخت و نشان داد که استفاده از روش‌های ML می‌تواند بهره‌وری، کیفیت و انعطاف‌پذیری تولید را به‌طرز چشم‌گیری افزایش دهد [۱۳].

این سیر تاریخی نشان می‌دهد چگونه پژوهش‌ها از معیارهای ساده کیفی در دهه ۱۹۶۰ به سمت سیستم‌های پیچیده هوش مصنوعی در دهه ۲۰۲۰ تکامل یافته‌اند. نقطه عطف این تحول، تغییر از رویکردهای ایستای دهه ۲۰۰۰ به سیستم‌های پویای مبتنی بر داده در سال‌های اخیر بوده است. به ویژه در صنعت نفت و گاز، این تحول منجر به ایجاد چارچوب‌های یکپارچه‌ای شده که قادرند داده‌های تاریخی و بلادرنگ را برای تصمیم‌گیری‌های استراتژیک ترکیب کنند.

۴- روش و مراحل انجام کار

این پژوهش با رویکردی کمی و مبتنی بر داده انجام شده و بر اساس چارچوب مفهومی طراحی گردیده است. در این پژوهش، مراحل اصلی شامل گردآوری داده‌ها، آماده‌سازی داده‌ها، توسعه مدل و اعتبارسنجی نتایج می‌باشد.

۱. جامعه آماری و منبع داده‌ها

داده‌های مورد استفاده در این تحقیق شامل سوابق ارزیابی عملکرد پیمانکاران در شرکت طراحی و مهندسی صنایع انرژی (EIED) است. این داده‌ها حاصل ارزیابی‌های ماهانه پیمانکاران در پروژه‌های مختلف شرکت بوده که از طریق سیستم مدیریت کیفیت سازمان ثبت شده‌اند.

از آنجاکه داده‌های موجود کل جامعه پیمانکاران ارزیابی‌شده را در بر می‌گیرد، نیازی به نمونه‌گیری نبوده و تمام قراردادهای در دسترس در تحلیل مورد استفاده قرار گرفته‌اند.

۲. متغیرها و نحوه سنجش آن‌ها

با توجه به ماهیت عددی متغیرها و استفاده از طیف لیکر در سنجش شاخص‌های کیفی، از مدل رگرسیون درجه دوم چندمتغیره برای پیش‌بینی امتیاز نهایی قراردادها استفاده شده است.

¹ Charagi

² Liao

³ Lu

⁴ Póvoas

⁵ Poursebzi

متغیر پاسخ:

- امتیاز نهایی قرارداد که بیانگر ارزیابی کلی عملکرد پیمانکار در انتهای دوره قرارداد است.
- متغیرهای توصیفی (شاخص‌های مستقل):
- اطلاعات مدیریتی: ارزیابی‌های ماهانه از نحوه مدیریت پروژه توسط پیمانکار.
- زمان‌بندی: میزان پایبندی به برنامه‌های زمان‌بندی و کنترل تأخیرها.
- مالی: کنترل هزینه‌ها، شفافیت مالی و مدیریت بودجه.
- مشکلات قراردادی: نحوه برخورد با چالش‌های حقوقی و توافقات.
- کیفیت کار و مهندسی: میزان انطباق با استانداردهای فنی و کیفیت اجرا.
- میانگین امتیازات ماهانه: شاخص ترکیبی از عملکرد مستمر پیمانکار در طول قرارداد.

۳. پردازش داده‌ها و ابزارهای تحلیلی

برای آماده‌سازی و تحلیل داده‌ها از نرم‌افزارهای Python (کتابخانه‌های NumPy, Pandas, Scikit-learn) برای پیش‌پردازش و برازش مدل استفاده شد.

تحلیل‌های آماری مانند تحلیل باقیمانده‌ها و آزمون ANOVA در نرم‌افزار Minitab انجام شد و نرم‌افزار JMP برای مصورسازی داده‌ها و تحلیل همبستگی مورد استفاده قرار گرفت.

۴. توسعه مدل و اعتبارسنجی

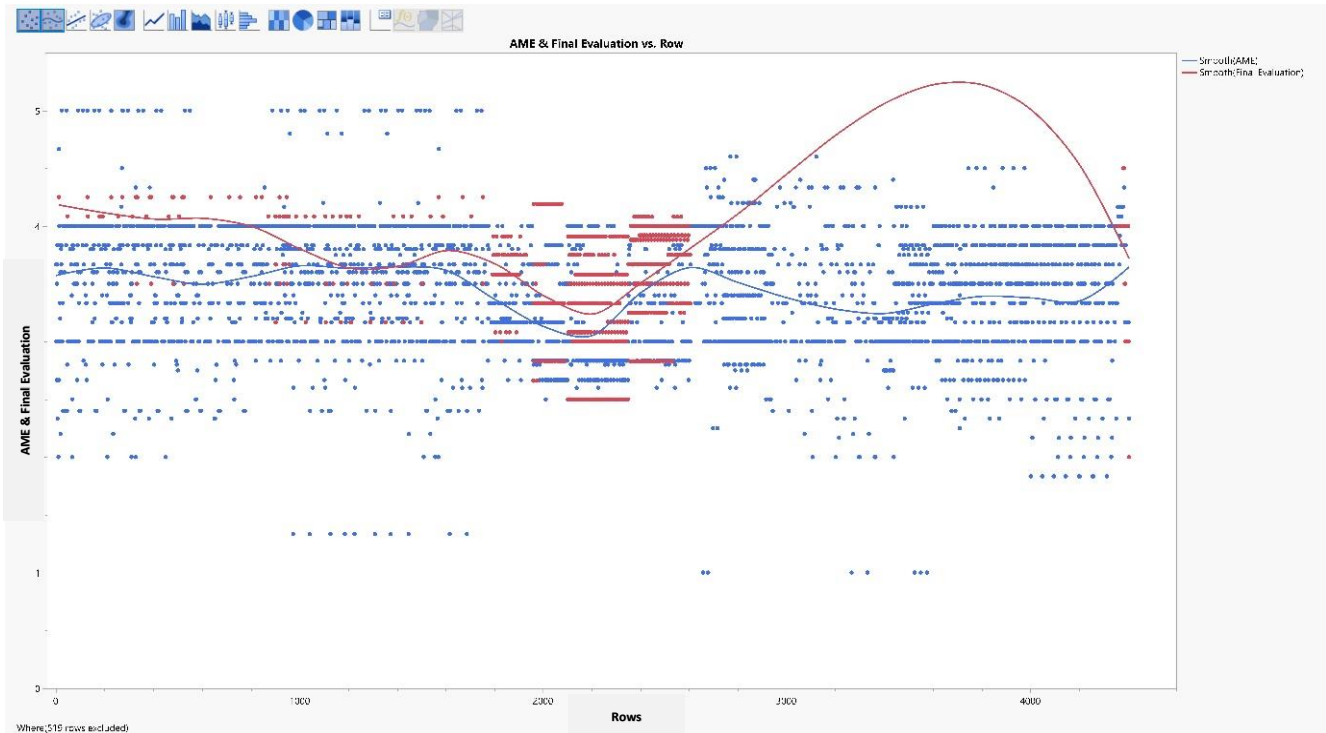
مدل رگرسیون درجه دوم چندمتغیره برای شناسایی روابط غیرخطی و اثرات تعاملی بین شاخص‌های ارزیابی انتخاب شد. به‌منظور اطمینان از دقت مدل، داده‌ها به نسبت ۷۰ درصد برای آموزش (Training) و ۳۰ درصد برای آزمون (Testing) تقسیم شدند.

به‌منظور بهبود مدل، از روش حذف گام‌به‌گام (Backward Elimination) جهت حذف متغیرهای غیرمعنادار استفاده شد. برای ارزیابی عملکرد مدل از شاخص‌های ضریب تعیین (R^2) و میانگین قدر مطلق خطا (MAE) استفاده شد. همچنین از روش اعتبارسنجی متقابل (Cross-Validation) برای سنجش پایداری و قابلیت تعمیم مدل استفاده گردید. مراحل انجام کار:

۱. پاکسازی و خلاصه‌سازی داده‌های تاریخی

در این مرحله، داده‌های خام جمع‌آوری شده از سیستم‌های ارزیابی شرکت، مورد پردازش اولیه قرار گرفتند. در شکل ۲ توزیع

اولیه داده‌ها پیش از پردازش قابل مشاهده می‌باشد.




شکل ۲ توزیع داده‌های اولیه تاریخی (سطر و میانگین ارزیابی ماهیانه و ارزیابی نهایی)

فعالیت‌های انجام‌شده در این مرحله عبارتند از:

حذف داده‌های تکراری و ناقص: رکوردهای تکراری یا فاقد شناسه قرارداد حذف شدند. خلاصه‌سازی بر اساس قرارداد: داده‌های ماهانه به ازای هر قرارداد تجمیع شدند تا یک رکورد واحد برای هر پروژه ایجاد شود. محاسبه شاخص‌های کلیدی: میانگین و انحراف معیار امتیازات ماهانه برای هر شاخص (مانند مدیریت، زمانبندی، مالی، کیفیت کار، مسائل قراردادی و ...).

امتیاز نهایی هر قرارداد به‌عنوان متغیر هدف (Target Variable) در نظر گرفته شد.

در انتهای این مرحله یک مجموعه داده ساختاریافته شامل شماره قرارداد، میانگین و انحراف معیار شاخص‌های ارزیابی، و امتیاز نهایی تهیه شد که شکل ۳ توزیع داده‌های پردازش‌شده و خلاصه‌شده را نشان می‌دهد.



شکل ۳ توزیع داده‌های پردازش‌شده (سطر متوسط ارزیابی ماهیانه و ارزیابی نهایی)

۲. تکمیل داده‌های از دست‌رفته

در برخی از موارد، داده‌های ماهانه به دلیل عدم ثبت یا خطاهای انسانی ناقص بودند. به منظور ارائه مدلی معتبر مجموعه فعالیت‌های زیر در این مرحله انجام شد.

حذف موارد با داده‌های مفقوده زیاد: اگر بیش از ۳۰٪ داده‌های یک قرارداد ناقص بود، آن قرارداد از تحلیل حذف شد.

تکمیل داده‌ها: در صورت امکان دسترسی به داده‌های تاریخی با مراجعه به مستندات داده‌ها تکمیل شد.

در این مرحله اطمینان از کامل و معتبر بودن داده‌ها قبل از تحلیل نهایی صورت گرفت.

۳. بررسی داده‌ها و ارتباط میان متغیرها:

برای درک بهتر رفتار داده‌ها و شناسایی روابط بین متغیرها، از روش‌های زیر استفاده شد:


الف) تحلیل چندمتغیره (Multivariate Analysis)

- ماتریس همبستگی (Correlation Matrix): بررسی رابطه خطی بین متغیرها جهت شناسایی متغیرهای با همبستگی بالا برای جلوگیری از هم خطی (Multicollinearity) در مدل رگرسیون.
- تحلیل مؤلفه‌های اصلی (PCA): کاهش ابعاد داده‌ها در صورت وجود متغیرهای بسیار مرتبط.

ب) مصورسازی داده‌ها (Data Visualization)

- هیستوگرام و Boxplot: بررسی توزیع داده‌ها و شناسایی Outliers.
- Scatter Plot: نمایش رابطه بین دو متغیر
- Heatmap: نمایش شدت همبستگی بین متغیرها به صورت گرافیکی.

در این مرحله به کمک ابزارها و روش‌ها ذکرشده شناسایی متغیرهای کلیدی مؤثر بر امتیاز نهایی و تشخیص داده‌های پرت که ممکن است مدل را تحت تأثیر قرار دهند میسر شد. در شکل ۴ برخی از نمودارها و تحلیل‌های این مرحله آورده شده است.



شکل ۴ بررسی همبستگی داده‌ها (ماتریس همبستگی)

۴. ارائه مدل ابتدایی (رگرسیون خطی چندمتغیره)

در این مرحله، یک مدل رگرسیون خطی ساده برای پیش‌بینی امتیاز نهایی ارائه شد. نتایج مدل اولیه و شاخص مجموع مربعات خطا بیانگر نیاز به بهبود در مدل بود. همچنین اختلاف محسوس این شاخص در داده‌های مجموعه Test و Validation نشانه توانایی پایین مدل در پیش‌بینی بود.

مشکلات شناسایی‌شده در این مرحله روابط غیرخطی بین برخی متغیرها و امتیاز نهایی و اثر تعاملی (Interaction Effect) بین متغیرها که در مدل خطی ساده لحاظ نشده بود.

۵. بهبود مدل و استفاده از رگرسیون درجه دوم چندمتغیره

برای افزایش دقت مدل، از رگرسیون درجه دوم (Quadratic Regression) استفاده شد که اثرات غیرخطی و تعامل بین متغیرها را در نظر می‌گیرد. برای نرمال‌سازی توزیع داده‌ها و بهبود نتایج مدل نیز از تبدیل توانی استفاده شد.

همچنین به منظور یافتن مدل بهبودیافته به روش سعی و خطا با استفاده از الگوریتم حذف گام‌به‌گام (Backward Elimination) متغیرهای غیر معنادار از مدل حذف و مدل نهایی حاصل شد.

مدل مورد استفاده به صورت زیر تعریف می‌شود:

$$\hat{Y} = \beta_0 + \sum_{i=1}^n \beta_i X_i + \sum_{i=1}^n \sum_{j \geq i}^n \beta_{ij} X_i X_j + e \quad (1)$$

پارامترها و متغیرهای معادله (۱) به شرح زیر می‌باشد:

\hat{Y} : امتیاز نهایی قرارداد (متغیر پاسخ).

X_i : متغیرهای توصیفی (شاخص‌های ارزیابی ماهانه).

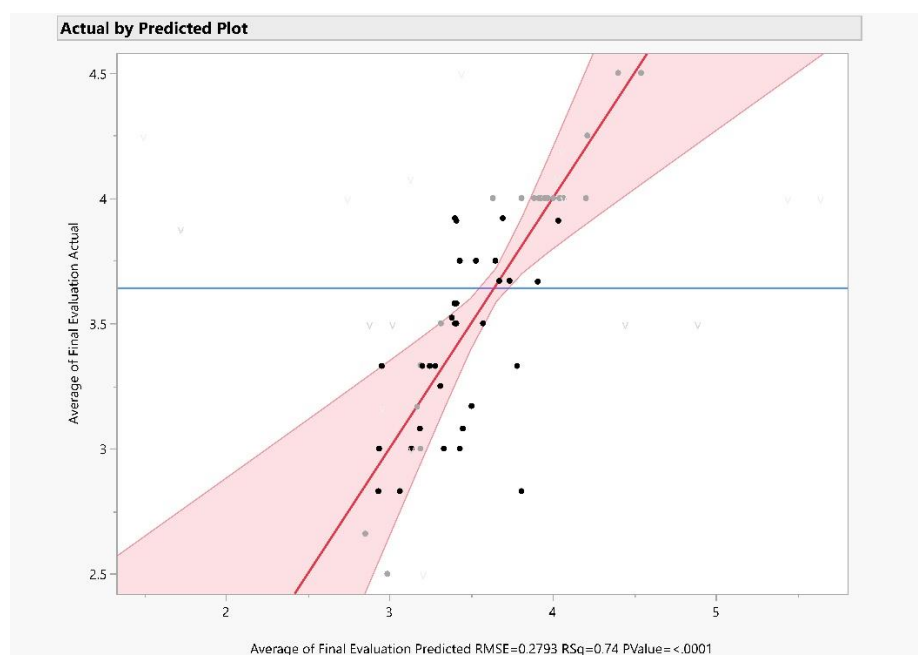
β_0 : عرض از مبدأ.

β_i : ضرایب خطی متغیرهای مستقل.

β_{ij} : ضرایب تعامل متغیرها (برای مدل‌سازی اثرات غیرخطی).

e : خطای مدل.

امتیازی که معادله (۱) در مقایسه با فرمول رگرسیون ساده دارد، بهره‌مندی مدل از برهم‌کنش متغیرهای توصیفی بر یکدیگر است.



شکل ۵ نمودار مقدار پیش‌بینی‌شده در مقابل مقدار واقعی متغیر پاسخ

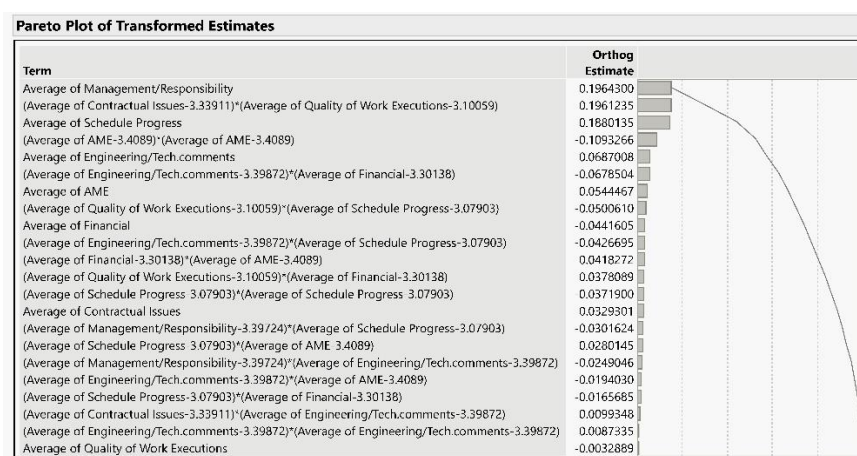
شکل ۵ نمودار مقدار پیش‌بینی‌شده در مقابل مقدار واقعی را ارائه می‌کند. همچنین مدل می‌تواند ۷۴٪ از تغییرات متغیر پاسخ را توجیه کند. همچنین توانایی پیش‌بینی با دقت ۶۲٪ را دارا است (شکل ۵).

Summary of Fit

RSquare	0.743301
RSquare Adj	0.623144
Root Mean Square Error	0.279346
Mean of Response	3.642566
Observations (or Sum Wgts)	70

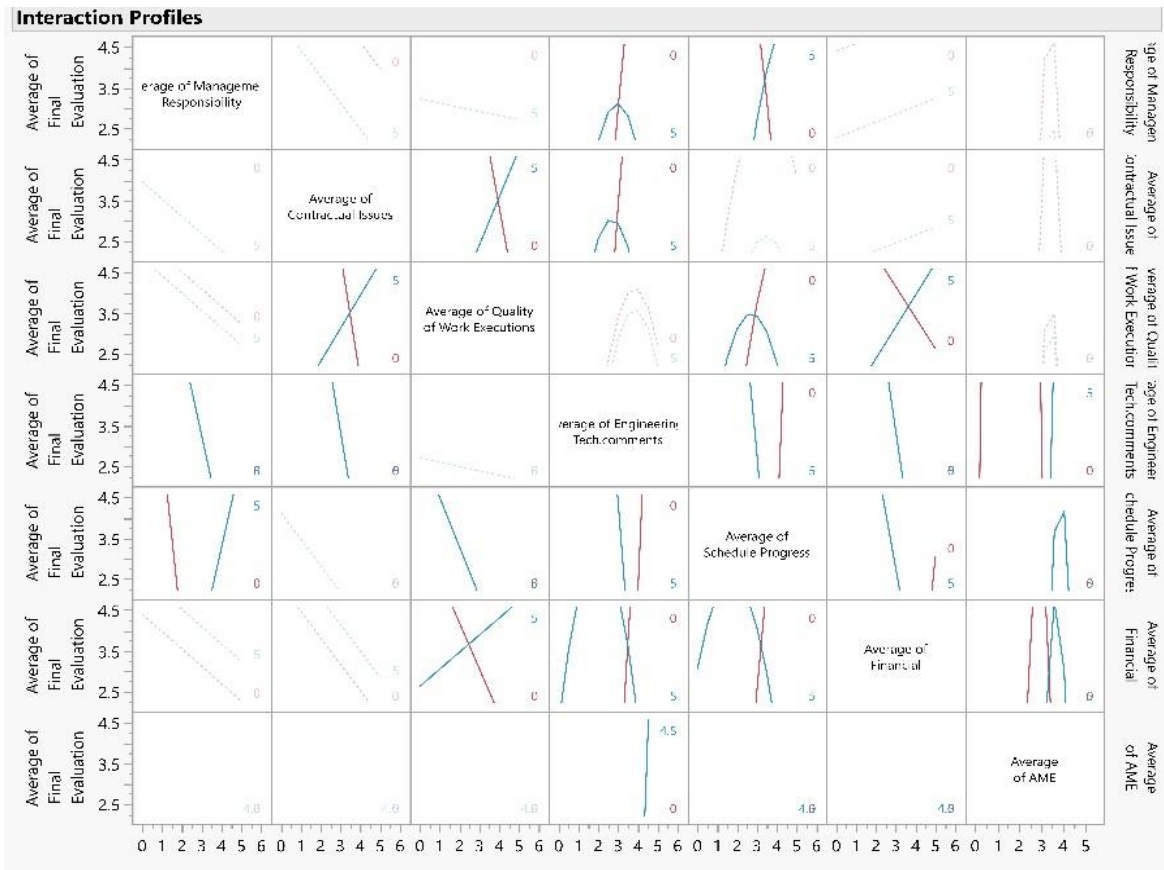
شکل ۶ خلاصه شاخص‌های مدل و عملکرد

در انتها به منظور تحلیل پارامترهای مهم در تصمیم‌گیری در خصوص ارزیابی سازندگان و انتخاب پیمانکاران در شکل ۷ پارتو پلات ارائه شده، تأثیر هر یک از متغیرها و تعاملات آن‌ها را در مدل رگرسیون درجه دوم به صورت استاندارد شده (Orthogonal Estimates) نشان می‌دهد. این تحلیل به شناسایی مؤثرترین عوامل بر امتیاز نهایی قراردادها به جهت پایش و بهبود فرایند کمک شایانی می‌کند.



شکل ۷ نمودار پارتو درجه اهمیت عوامل مؤثر در ارزیابی

همچنین در شکل ۸ ارتباط میان متغیرهایی که در خروجی مدل تأثیر دارند مشخص شده و برهم‌کنش این متغیرها به کمک این نمودار قابل مشاهده و تحلیل می‌باشد.



شکل ۸ ماتریس ارتباط میان متغیرهای توصیفی

۵- نتیجه گیری

نتایج حاصل از پژوهش به شرح زیر است:

با توجه به ضرایب و نمودار پارتو در شکل ۵ مدیریت پیمانکاران بیشترین تأثیر بر روی امتیاز نهایی قرارداد را دارد و در ادامه به ترتیب ارتباط میان مشکلات قراردادی و کیفیت در رتبه دوم و فاکتور زمانبندی در رتبه سوم قرار دارد. کمترین تأثیر در مدل پارامتر کیفیت و در ادامه آن توان دوم مهندسی و ارتباط میان مهندسی و مشکلات قراردادی قرار گرفته است. با توجه به این خروجی جهت پایش و کنترل فرایند سازمان می‌تواند اولویت‌بندی بهتری نسبت به معیارها داشته باشد. علت این موضوع سطح کیفی مشابه تولیدکنندگان داخلی است.

با توجه به معیارهای ارزیابی و توانایی پیش‌بینی مدل، سازمان می‌تواند در مرحله انتخاب سازنده و یا پیمانکار خود با در نظر گرفتن مدل ارائه شده و درجه اهمیت فاکتورها، انتخاب و یا ارزیابی دقیق‌تری نسبت به این فرایند داشته باشد.

با توجه دقت مدل پیشنهاد می‌گردد سازمان در ادامه فاکتورهای جدیدی را جهت ارزیابی عملکرد پیمانکاران ثبت و ضبط کند. این امر می‌تواند موجب بهبود مدل، پیش‌بینی دقیق‌تر و افزایش بهره‌وری فرایند شود. با توجه به بازه زمانی که داده‌ها گردآوری شده‌اند، ادامه این روند و افزایش ابعاد داده‌های هدف نیز عامل دیگری است که می‌تواند در بهبود دقت مدل تأثیر مثبت داشته باشد.

مدل ارائه شده این قابلیت را برای سازمان فراهم می‌کند تا فرایند ارزیابی سازندگان به صورت یکپارچه صورت گرفته و همسویی فرایندها با اهداف و استراتژی‌های سازمان را تضمین نماید. با توجه به این که یکی از ارزش‌های سازمان رضایت کارفرمایان و مشتریان است، پژوهش فعلی می‌تواند یکی از عوامل مستقیم در فرایندهای صف را بهبود داده و تأثیر مستقیم بر روی شاخص‌های

کلیدی عملکرد مربوطه داشته باشد.

روش اجرایشده توانایی پیاده‌سازی و توسعه نرم‌افزارهای سازمان را برآورده کرده و به یکپارچگی سیستم‌های متفاوت کمک خواهد کرد. همچنین با توجه به اهمیت و ضرورت مسئله فرایندهای کلیدی سازمان نیز ارزیابی‌شده و در صورت توسعه و اجرا این امکان را فراهم می‌سازد تا ریشه‌یابی اختلالات به صورت پیوسته پیش گردد.

۶- پیشنهادات آتی

در آینده توصیه می‌گردد به جهت بهبود و توسعه پژوهش فعلی رضایت کارفرمایان نیز به مدل اضافه گردد. این امر دقت بیشتری نسبت به این مدل ارائه کرده و همچنین قابلیت مقایسه ذهنیت کارفرمایان در مقابل سازمان را ارائه خواهد کرد. همچنین با توجه به سطوحی که بر اساس سوابق و خبرگان برای شاخص متوسط امتیازات ارائه‌شده است از مدل‌های دیگر یادگیری ماشین و هوش مصنوعی می‌تواند استفاده شود. مدل‌ها غیر نظارت‌شده مانند خوشه‌بندی نیز می‌تواند در این مسئله مورد بررسی قرار گیرد. مدل‌های درخت تصمیم و طبقه‌بندی نیز می‌تواند در راستای ارزیابی و پیش‌بینی استفاده گردد. این امر با توجه به وضع موجود و استفاده از طیف لیکر بسیار کاربردی بوده و بستر مناسبی جهت پیاده‌سازی وجود دارد.

در صورت در نظر نگرفتن ارزیابی‌های فعلی و طیف لیکر، امکان بررسی امتیازات و تغییر ساختار مسئله و ارزیابی به کمک نظریه فازی نیز امکان‌پذیر می‌باشد. علی‌رغم این که رویکرد فازی در امتیازدهی و خروجی‌ها می‌تواند برخی مشکلات در رویکردهای حل و مدل‌سازی را بر طرف کند، مسئله در دنیای واقعی را به چالش می‌کشد. مقایسه این دو رویکرد در آینده می‌تواند یکی از زمینه‌های پژوهشی باشد.

۷- مراجع

- [1] Dickson GW. An analysis of vendor selection systems and decisions. *Journal of Purchasing*. 1966;2(1):5–17. <https://doi.org/10.1111/j.1745-493X.1966.tb00818.x>
- [2] Liu J, Ding F-Y, Lall V. Using data envelopment analysis to compare suppliers for supplier selection and performance improvement. *Supply Chain Management: An International Journal*. 2000;5(3):143–150. <https://doi.org/10.1108/13598540010338893>
- [3] de Boer L, Labro E, Morlacchi P. A review of methods supporting supplier selection. *European Journal of Purchasing & Supply Management*. 2001;7(2):75–89. [https://doi.org/10.1016/S0969-7012\(00\)00028-9](https://doi.org/10.1016/S0969-7012(00)00028-9)
- [4] Humphreys PK, McIvor RT, Chan FTS. Using case-based reasoning to evaluate supplier environmental management performance. *Expert Systems with Applications*. 2003;25(2):141–153. [https://doi.org/10.1016/S0957-4174\(03\)00042-3](https://doi.org/10.1016/S0957-4174(03)00042-3)
- [5] Gereffi G, Humphrey J, Sturgeon T. The governance of global value chains. *Review of International Political Economy*. 2005;12(1):78-104. <https://doi.org/10.1080/09692290500049805>
- [6] Chen H, Chiang RHL, Storey VC. Business intelligence and analytics: From big data to big impact. *MIS Quarterly*. 2012;36(4):1165–1188. <https://doi.org/10.2307/41703503>
- [7] Cheraghi SH, Dadashzadeh M, Subramanian M. Critical success factors for supplier selection: An update. *Journal of Applied Business Research*. 2004;20(2):91–108. <https://doi.org/10.19030/jabr.v20i2.2209>
- [8] Liao SH, Chu P-H, Hsiao P-Y. Data mining techniques and applications—A decade review from 2000 to 2011. *Expert Systems with Applications*. 2012;39(12):11303–11311. <https://doi.org/10.1016/j.eswa.2012.02.063>
- [9] Lu K, Liao H, Zavadskas EK. An overview of fuzzy techniques in supply chain management: bibliometrics, methodologies, applications and future directions. *Technological and Economic Development of Economy*. 2021;27(2):402-458. <https://doi.org/10.3846/tede.2021.14433>
- [10] Póvoas MdS, Moreira JF, Neto SVM, Carvalho CAdS, Cezario BS, Guedes ALA, Lima GBA. Artificial Intelligence in the Oil and Gas Industry: Applications, Challenges, and Future Directions. *Applied Sciences*. 2025;15(14):7918. <https://doi.org/10.3390/app15147918>

- [11] Poursabzi M, Tavasoli Nouri A, Hajizadeh Ebrahimi F. Business analysis using data analytics tools (A case study of Energy Industrial Engineering Design Company: EIED). *Industrial Innovations*. 2024;2(2):144-160. <https://doi.org/10.61186/jii.2.2.144>
- [12] Meza EBM, Ali IA, El Ghazali A. Tools, technologies and frameworks for digital twins in oil & gas industry. *Sensors*. 2024;24(19):6457. <https://doi.org/10.3390/s24196457>
- [13] Ordek B. Machine learning-supported manufacturing: a review and future directions. *Artificial Intelligence Review*. 2024;57:13321-13356. <https://doi.org/10.1007/s10462-024-10378-3>