



Semnan University



Research Article

Providing a Pattern to Improve the Productivity of Earthmoving Machinery in Infrastructure Projects Using Machine Learning Algorithms (Case Study: Gas Pipeline)

Rojin Mohaghegh^a, Behnod Barmayehvar^{b*}, Hossein Toosi^c

^a Department of Architectural Technology (Project and Construction Management), Faculty of Architecture and Urban Planning, Iran University of Art, Tehran, I. R. Iran.

^b Associate Professor, Department of Architectural Technology (Project and Construction Management), Faculty of Architecture and Urban Planning, Iran University of Art, Tehran, I. R. Iran.

^c Assistant Professor, Faculty of Architecture, University of Tehran, Tehran, I. R. Iran.

PAPER INFO

Paper history:

Received: 2024-07-17

Revised: 2024-08-26

Accepted: 2024-08-28

Keywords:

Productivity of earthmoving machinery;
Machine learning algorithm;
Energy infrastructure projects;
Gas pipeline construction project.

ABSTRACT

The objective of this study is to compare the effectiveness of industrial wastes including cement kiln dust (CKD), fly ash (FA), and ground granulated blast furnace slag (GGBFS) for stabilization of clay soils. To chemically stabilize the soil, optimal amounts of CKD (10%-20%), class C FA (20%-25%) and GGBFS (20%-30%) have been suggested. Considering the soil pH value with different percentages of additives, the amount of each additive was considered the same (20%) for better comparison. Standard compaction and California Bearing Ratio (CBR) tests were conducted on the mixtures. To investigate the microstructural effect of additives, the samples were subjected to scanning electron microscopy (SEM) and X-ray diffraction (XRD) analysis. Results showed that CKD and FA decreased maximum dry density and increased optimum moisture content. Meanwhile, GGBFS decreased optimum moisture content of the samples and increased maximum dry density. The CBR in soil stabilized with CKD, FA, and GGBFS was 21.7, 13.3, and 15.7 times that of pure soil, respectively. According to the results of the SEM and XRD analysis, the increase in strength in the stabilized soil is caused by pozzolanic reactions and creation of cementation products, and as a result, binding of soil particles and stabilizers and filling of the pores. The higher the amount of free lime in the stabilizer, the greater the increase in soil strength. In practical projects, factors such as delay time (the time between the first contact of the additive and water and the final compaction of the mixture) and moisture content that affect the strength parameters should be considered. Also, environmental issues, such as potential of these additives to enter groundwater, are important.

* Corresponding author.

E-mail address: b.barmayehvar@art.ac.ir

How to cite this article: Mohaghegh, R., Barmayehvar, B., & Toosi, H. (2024). Providing a pattern to improve the productivity of earthmoving machinery in infrastructure projects using machine learning algorithms (Case Study: Gas pipeline). *Journal of Transportation Infrastructure Engineering*, 10(2), 71-96

<https://doi.org/10.22075/jtie.2024.34786.1681>

This is an open access article under the CC-BY 4.0 license. (<https://creativecommons.org/licenses/by/4.0/>)



مقاله پژوهشی

ارائه الگویی برای بهبود بهره‌وری ماشین‌آلات خاکبرداری در پروژه‌های زیرساختی با استفاده از الگوریتم‌های یادگیری ماشین (نمونه موردی: خط لوله گاز)

روژین محقق^۱، بهنود برمایه ور^{۲*}، حسین طوسی^۳

^۱گروه فناوری معماری (مدیریت پروژه و ساخت)، دانشکده معماری و شهرسازی، دانشگاه هنر ایران، تهران، ایران.
^۲دانشیار، گروه فناوری معماری (مدیریت پروژه و ساخت)، دانشکده معماری و شهرسازی، دانشگاه هنر ایران، تهران، ایران.
^۳استادیار، دانشکده معماری، دانشگاه تهران، تهران، ایران.

| اطلاعات مقاله | چکیده |
|--|--|
| دریافت مقاله: ۱۴۰۳/۰۴/۲۷ | با توجه به جایگاه برجسته کشور ایران در دنیا از منظر منابع انرژی، مخصوصاً حوزه گازی، اجرای پروژه‌های زیرساختی انرژی، به‌ویژه خط لوله گاز، ضروری می‌نماید. با این وجود، یکی از چالش‌های اساسی در این نوع از پروژه‌ها، موضوع عدم بهره‌وری مناسب منابع (ماشین‌آلات و...) است. از این رو، هدف اصلی پژوهش حاضر عبارت است از بهبود بهره‌وری ماشین‌آلات خاکبرداری پروژه‌های احداث خط لوله گاز، با کمک الگوریتم‌های یادگیری ماشین. در این پژوهش، با بهره‌گیری از مطالعات کتابخانه‌ای، اسنادی (گزارش‌های روزانه هفت پروژه خطوط انتقال گاز)، قضاوت خبرگان، روش متن‌کاوی (و نرم‌افزار رپیدمایتر)، معیارهای مؤثر بر تعیین بهره‌وری ماشین‌آلات خاکبرداری در پروژه‌های احداث خط لوله گاز، شناسایی و نهایی شدند. به‌طور خلاصه، نتیجه اصلی پژوهش کنونی اشاره دارد که پیش‌بینی حجم خاکبرداری، از طریق الگوریتم پیش‌بینانه (به‌عنوان مبنای بهینه‌سازی بهره‌وری ماشین‌آلات خاکبرداری) و نیز الگوریتم دسته‌بندی و با استفاده از مدل یادگیری عمیق (به‌عنوان مدل منتخب و دارای بهترین عملکرد در پیش‌بینی حجم خاکبرداری)، قابل اجرا است. در واقع، یافته‌های پژوهش فعلی در راستای پیش‌بینی حجم خاکبرداری، پیش از شروع پروژه و تهیه برنامه زمان‌بندی کلی که در نهایت موجب بهبود بهره‌وری ماشین‌آلات خاکبرداری در پروژه‌های خط لوله گاز می‌شود، قابل استفاده است. |
| بازنگری مقاله: ۱۴۰۳/۰۶/۰۵ | |
| پذیرش مقاله: ۱۴۰۳/۰۶/۰۷ | |
| واژگان کلیدی: | |
| بهره‌وری ماشین‌آلات عملیات خاکبرداری، الگوریتم یادگیری ماشین، پروژه‌های زیرساختی انرژی، پروژه احداث خط لوله گاز. | |

* پست الکترونیک نویسنده مسئول: b.barmayehvar@art.ac.ir

استناد به این مقاله: محقق، روژین، برمایه ور، بهنود & طوسی، حسین. (۱۴۰۳). ارائه الگویی برای بهبود بهره‌وری ماشین‌آلات خاکبرداری در پروژه‌های زیرساختی با استفاده از الگوریتم‌های یادگیری ماشین (نمونه موردی: خط لوله گاز). مهندسی زیر ساخت های حمل و نقل، ۱۰(۲)، ۷۱-۹۶.

<https://doi.org/10.22075/jtie.2024.34786.1681>

۱. مقدمه

به‌طور کلی، کشور ایران حدود ۱۰ درصد ذخایر نفت (اسرافیلی دیزجی و کیانی هرچگانی، ۲۰۱۱) و همچنین ۱۷/۳ درصد از سهم گاز جهان را در اختیار دارد (وورلد متر، ۲۰۲۴) و از این جهت می‌توان آن را یک ابرقدرت در حوزه انرژی دانست. امروزه بخش اعظم منابع مالی برای توسعه اقتصادی در ایران، از محل درآمدهای نفتی و گازی می‌باشد. به زعم متخصصین امر، موضوع تأمین مالی و توسعه منابع سرمایه‌گذاری را نمی‌توان برای توسعه پایدار اقتصادی کشور کافی دانست؛ بلکه باید به مدیریت صحیح این منابع نیز توجه نمود که یکی از بخش‌های آن، مدیریت پروژه است (فلاح نژاد، ۲۰۱۳). صنعت نفت و گاز به عنوان یکی از بزرگترین سازمان‌های اقتصادی کشور، دارای دو فعالیت اصلی شامل اجرای پروژه‌ها و امور بهره‌برداری می‌باشد. بنابراین، در بخش فعالیت‌های پروژه‌ای، این صنعت شاهد اجرای تعداد زیادی از طرح‌ها و پروژه‌های بزرگ می‌باشد.

پروژه‌های احداث خط لوله گاز به عنوان یکی از انواع پروژه‌های زیرساختی ذیل صنعت نفت و گاز، از دو بُعد ملی و همچنین بین‌المللی مورد توجه می‌باشند (بابور، ۲۰۱۶). با این وجود، شواهد و اطلاعات نشان می‌دهد که درصد قابل توجهی از این پروژه‌ها از حیث دستیابی به اهداف دچار نقصان هستند (بیوس و همکاران، ۲۰۱۸). به عبارت دیگر، پروژه‌های صنعت نفت و گاز، نسبت به اهداف خود دارای انحراف هستند، محدودیت‌های مصوب پروژه‌ها، به‌خصوص حدود زمانی و هزینه‌ای، رعایت نمی‌شود و دوباره‌کاری در انجام پروژه‌های مذکور مشاهده می‌شود که مبین عدم موفقیت این پروژه‌ها می‌باشند (بابور، ۲۰۱۶). از میان

بسته‌های کاری چرخه حیات پروژه‌های زیرساختی احداث خط لوله گاز، خاکبرداری و مسیرسازی از جمله بحرانی‌ترین فعالیت‌ها در تهیه برنامه زمان‌بندی می‌باشند و مسیر بحرانی معمولاً از خاکبرداری و مسیرسازی عبور می‌کند. دو فاز خاکبرداری و مسیرسازی نسبت به سایر فازها، وابستگی بیشتری به شرایط جوی و ویژگی‌های زمین محل پروژه دارد (دافی، ۲۰۰۹). همچنین، شکست در مذاکرات با مالکین زمین‌ها و مشکلات حین عملیات مسیرسازی و خاکبرداری به عنوان مهمترین عوامل تأخیر در پروژه‌های احداث خط لوله گاز ذکر شده است (سویس و همکاران، ۲۰۱۹). ماشین‌آلات در کنار منابع انسانی، مواد و مصالح و پول، یکی از منابع مهم در پروژه‌ها، به‌ویژه پروژه‌های بزرگ زیر ساختی، محسوب می‌شود. در طول عملیات مسیرسازی، معمولاً ماشین‌آلات به صورت گروهی مشغول به حفاری و آماده‌سازی مسیر هستند و بهره‌وری این ماشین‌آلات تأثیر مستقیمی بر عملکرد پروژه دارد. این بهره‌وری معمولاً به عنوان کار انجام شده در واحد زمان تعریف می‌شود (پرچی جلال و همکاران، ۲۰۰۹). امروزه در ایران تقریباً رویکرد مدونی برای پیش‌بینی حجم خاکبرداری در پروژه‌های احداث خطوط لوله گاز وجود ندارد و ترکیب ماشین‌آلات به صورت تجربی تعیین می‌شود. اگر ترکیب ماشین‌آلات خاکبرداری در پروژه‌های احداث خط لوله گاز با توجه به شرایط محیطی تعیین نشود، می‌تواند منجر به کاهش بهره‌وری ماشین‌آلات و هدر رفتن منابع در پروژه شود. برآورد اشتباه حجم خاکبرداری در فاز برنامه‌ریزی پروژه‌های احداث خط لوله گاز منجر به ارائه برنامه زمان‌بندی کلی و تفصیلی اشتباه می‌شود و عدم تخصیص مناسب ماشین‌آلات خاکبرداری با توجه به شرایط محیطی می‌تواند منجر به سرریز زمان و هزینه در فاز اجرا شود

(شهبازی و همکاران، ۲۰۱۴).

هزینه خاکبرداری در دراز مدت و کوتاه مدت برنامه‌ریزی نموده تا منابع هنگام نیاز در دسترس قرار گیرد. اسکندری و همکاران (۲۰۱۴) بهینه‌سازی و بهبود بهره‌وری ماشین‌آلات عملیات خاکی را به وسیله الگوریتم ژنتیک مورد بررسی قرار دادند. در این پژوهش، تلاش شده است تا با استفاده از الگوریتم ژنتیک چند منظوره ترکیب‌هایی از ناوگان‌های مختلف برای انتخاب ناوگان ماشین‌آلات عملیات خاکی، شامل ماشین‌آلات حفاری با چند نوع مختلف کامیون، الگویی مناسب ارائه گردد.

پارنت و همکاران (۲۰۱۶) بهینه‌سازی و بهبود عملیات خاکی را با استفاده از محاسبات نرم‌افزاری مورد مطالعه قرار دادند. نتایج نشان داد که روش مورد مطالعه می‌تواند به جای محاسبات و تخصیص دستی مورد استفاده قرار گیرد.

سلیمی و همکاران (۲۰۱۶)، یک مدل مبتنی بر رگرسیون غیرخطی را برای پیش‌بینی بهره‌وری دستگاه حفاری تونل (سنگ‌های سخت) ارائه کردند. آنها از گزارش‌های عملکرد دو دستگاه حفاری تونل در پروژه تونل زاگرس به طول ۱۴/۳ کیلومتر به عنوان پایگاه داده استفاده کرده‌اند. آنها از الگوریتم‌های سیستم استنتاج عصبی فازی تطبیقی و رگرسیون بردار پشتیبانی استفاده کردند و مطابق یافته‌های آنها، رگرسیون بردار پشتیبانی از عملکرد بهتری برخوردار است.

رستمی (۲۰۱۶) نیز مروری بر مدل‌های پیش‌بینی بهره‌وری دستگاه حفاری تونل با بهره‌گیری از شبیه‌سازی داشته است. مطابق یافته‌های او، مدل‌هایی که بهره‌وری دستگاه حفاری تونل را در زمین‌های نرم پیش‌بینی می‌کنند، دارای دقت بیشتری نسبت به مدل‌هایی هستند که بهره‌وری این دستگاه را در زمین‌های سخت پیش‌بینی می‌کنند. او معتقد است که تعدد عوامل مؤثر بر بهره‌وری

در راستای افزایش بهره‌وری و تعیین ترکیب بهینه ماشین‌آلات، پژوهش‌های متعددی صورت گرفته است. از جمله، اویسی اسکویی و روانشادینا (۲۰۱۲) در پژوهشی به تعیین آرایش بهینه ناوگان ماشین‌آلات عملیات خاکی با استفاده از الگوریتم ژنتیک پرداختند. در این پژوهش، به منظور یافتن آرایش بهینه ماشین‌آلات عملیات خاکی، مدلی بر اساس مدل‌های شبیه‌سازی ارائه شده است که در زمان اندکی امکان دستیابی به پاسخ بهینه را فراهم می‌نماید. نتایج تحقیقات نشان داده است که در الگوریتم ژنتیک توسعه یافته‌ای که وظیفه حل بهینه‌سازی مدل را بر عهده دارد، بدون هیچ محدودیتی قادر است فضای حل مسئله را جستجو نماید. نتایج حاصل از اعتبارسنجی مدل بیانگر کارآمدی مدل پیشنهادی جهت یافتن ناوگان ماشین‌آلات مناسب است. هسیناو و همکاران (۲۰۱۱) از مدل‌های شبیه‌سازی رویداد گسسته برای شبیه‌سازی برنامه اختصاص و اعزام ناوگان کامیون استفاده کرده‌اند. سپس از الگوریتم‌های ژنتیک جهت اختصاص و برنامه‌ریزی بهینه زمانی استفاده شده است. در تحقیق ذکر شده، با استفاده از یک روش نظری، نشان داده شده که الگوریتم ژنتیک می‌تواند راه‌حل‌های نزدیک به بهینه را به صورت مؤثر تعیین کند. این مکانیسم پیشنهادی قابل ارائه به شرکت‌های حمل‌ونقل و عملیات خاکی می‌باشد؛ به طوری که به آسانی می‌تواند از آن استفاده کنند. اشتهاردیان و همکاران (۲۰۱۲) مدل برنامه‌ریزی خطی جهت بهینه‌سازی تعداد ماشین‌آلات با هدف کاهش زمان و هزینه عملیات خاکی در پروژه‌های شهری ارائه کرده است. این مدل به مدیران پروژه کمک می‌کند، تا با توجه به محدودیت‌های مالی و زمانی که با آن درگیر هستند بتوانند منابع مورد نظر از طریق بهینه‌سازی تعداد ماشین‌آلات جهت کمینه کردن زمان و

۱-۱. نوآوری پژوهش

در خصوص شکاف تحقیقاتی این پژوهش، می‌توان به موارد زیر اشاره کرد. اولاً، تخصیص ماشین‌آلات عمرانی در عملیات خاکبرداری پروژه‌های احداث خط لوله گاز بدون توجه به شرایط زمینه‌ای می‌تواند منجر به کاهش بهره‌وری این ماشین‌آلات و سرریز زمان و هزینه شود. با عنایت به اینکه رویکرد مدونی برای بهبود بهره‌وری ماشین‌آلات خاکبرداری وجود ندارد، در این پژوهش، برای پوشش این نقطه ضعف، یک مدل مبتنی بر یادگیری ماشین به منظور پیش‌بینی و بهینه‌سازی بهره‌وری ماشین‌آلات خاکبرداری در پروژه‌های احداث لوله گاز ارائه گردیده است. به عبارتی، تاکنون، تقریباً هیچ پژوهش جامعی، به‌ویژه در ایران، در زمینه پیش‌بینی بهره‌وری ماشین‌آلات (حجم خاکبرداری) در پروژه‌های احداث خط لوله گاز، با بهره‌گیری از الگوریتم‌های یادگیری ماشین، انجام نشده است. ثانیاً، پژوهش‌های پیشین در زمینه پیش‌بینی و بهبود بهره‌وری ماشین‌آلات به صورت عمومی به تمامی انواع پروژه‌ها پرداخته‌اند و تقریباً هیچ پژوهشی به صورت تخصصی به پروژه‌های احداث خط لوله گاز پرداخته است. ثالثاً، در بیشتر پژوهش‌های پیشین از تکنیک‌های شبیه‌سازی مانند الگوریتم ژنتیک و الگوریتم کلونی مورچگان برای بهبود بهره‌وری ماشین‌آلات استفاده شده است. لذا، به طور خیلی خلاصه، جنبه‌های نوآورانه این پژوهش به شرح زیر قابل بیان هستند:

- استفاده از تحلیل نرم‌افزاری (رویکرد متن‌کاوی) و ابزار پرسش‌نامه (به صورت نظرسنجی) در کنار استفاده از مطالعات کتابخانه‌ای به منظور شناسایی معیارهای مؤثر در تعیین بهره‌وری اکیپ‌های کاری ماشین‌آلات

دستگاه حفاری تونل در زمین‌های سخت باعث شده است که مدل‌های مبتنی بر شبیه‌سازی، دقت مناسبی در پیش‌بینی بهره‌وری این ماشین‌آلات نداشته باشند. ارمغانی و همکاران (۲۰۱۷) یک مدل هوشمند ترکیبی برای پیش‌بینی نرخ نفوذ دستگاه حفاری تونل در زمین‌های سخت تو سعه دادند. آنها از گزارش‌های یک پروژه تونل انتقال آب در مالزی به عنوان پایگاه داده استفاده کردند. مدل پیشنهادی آنها حدوداً دارای ۹۱ درصد دقت می‌باشد.

عمران و چن (۲۰۱۶)، با بررسی پژوهش‌هایی در حوزه ساخت که ویژگی مشترک همه آنها استفاده از یکی از تکنیک‌های تحلیل داده بین سال‌های ۲۰۰۰ تا ۲۰۱۴ بود، متوجه شدند که استفاده از مدل‌های پیش‌بینی‌کننده بیشترین کاربرد را در موضوع مدیریت ماشین‌آلات داشته‌اند.

در همین راستا، به طور کلی، پژوهش‌های دیگری نیز به این حوزه موضوعی تحقیقاتی از زوایای گوناگون و در بافت‌های مختلف پرداخته‌اند (از جمله، سیرکار و همکاران (۲۰۲۱) در صنعت نفت و گاز و کاسم و همکاران (۲۰۲۱) در بستر پروژه‌های زیرساختی).

لذا، پژوهش حاضر تلاش دارد تا با استفاده از مدل‌های پیش‌بینی‌کننده، رگرسیون و دسته‌بندی به مبحث پیش‌بینی حجم خاکبرداری بپردازد. محتوای این پژوهش دارای دو بخش اساسی است: در بخش اول، یک مدل پیش‌بینانه مبتنی بر یادگیری ماشین برای پیش‌بینی حجم خاکبرداری در پروژه‌های احداث خط لوله گاز توسعه داده شده و در بخش دوم که مبتنی بر بخش اول می‌باشد، الگویی برای بهبود بهره‌وری ماشین‌آلات در عملیات خاکبرداری پروژه‌های خط لوله گاز ارائه می‌گردد. برای مدل‌سازی در این پژوهش از نرم‌افزار رپیدماینر^۱ استفاده شده است.

^۱- RapidMiner

در ادامه، برای اطمینان از داده‌های به دست آمده و شناسایی میزان اهمیت آن‌ها پرسشنامه‌ای به صورت نظرسنجی در اختیار ۲۴ نفر از خبرگانی که تخصص، تجربه و سابقه و نیز دانش کافی در زمینه ماشین‌آلات عمرانی عملیات خاکی و پروژه‌های خط لوله گاز داشتند، از طریق روش نمونه‌گیری هدفمند و نیز گلوله برفی، قرار گرفت. مشخصات افراد پاسخ دهنده خبره در جدول ۲ نشان داده شده است. در راستای افزایش صحت‌سنجی، روایی یا اعتبار این پرسشنامه‌ی دو گزینه‌ای با ۲۱ سؤال (بلی یا خیر) بر پایه‌ی مطالعات نظام‌مند و دقیق کتابخانه‌ای، مشورت از اساتید این حوزه و نیز خبرگان مشارکت‌کننده قابل تبیین است. همچنین، پایایی یا قابلیت اعتماد و اطمینان این پرسشنامه، نیز با استفاده از روش کودر-ریچاردسون (با شاخص پایایی $0/8$ یعنی بیش از $0/7$) قابل تبیین است. با توجه به نظرات خبرگان تعدادی از معیارها به‌عنوان کم‌اهمیت و تعدادی نیز با اهمیت زیاد معرفی شدند.

خاکبرداری در پروژه‌های احداث خط لوله گاز.

-به‌کارگیری الگوریتم‌های یادگیری ماشین در ایجاد مدل پیش‌بینانه.

-توسعه یک مدل پیش‌بینانه برای پیش‌بینی حجم خاکبرداری در پروژه‌های احداث خط لوله گاز.

-ارائه یک الگوی کاربردی برای بهبود بهره‌وری ماشین‌آلات خاکبرداری در پروژه‌های احداث خط لوله گاز.

۲. روش پژوهش

۱-۲. جمع‌آوری داده‌ها

در این پژوهش، روش جمع‌آوری داده‌ها، ترکیبی از روش‌های کتابخانه‌ای، میدانی و اسنادی است. در ابتدا از روش کتابخانه‌ای به منظور آشنایی با پژوهش‌های پیشین و همچنین استخراج اطلاعات مورد نیاز استفاده شده است. با توجه به اطلاعات به دست آمده از مطالعات کتابخانه‌ای، فهرستی از معیارهای مؤثر بر بهره‌وری ماشین‌آلات خاکبرداری تهیه شده است (جدول ۱).

جدول ۱. معیارهای مؤثر بر بهره‌وری ماشین‌آلات خاکبرداری

| منابع | معیار | دسته معیار |
|--|---|---|
| (Aadal et al., 2014) (Thomas & Kramer, 2002) (Panas & Pantouvakis, 2010) (Parthasarathy et al., 2017) (Ok & Sinha, 2006) | وضعیت آب و هوا | معیارهای مرتبط با شرایط جوی |
| (Ok & Sinha, 2006) (Rashidi et al., 2014) | دما (کمینه و بیشینه) | |
| (Thomas & Kramer, 2002) | درصد رطوبت | |
| (Ok & Sinha, 2006) (Rashidi et al., 2014) (Edwards & Holt, 2000) (Karshenas & Feng, 1992) (Ranjithapriya & Arulselvan, 2020) | نوع زمین | معیارهای مرتبط با ویژگی‌های زمین‌شناسی |
| (Rashidi et al., 2014) (Edwards & Holt, 2000) (Ranjithapriya & Arulselvan, 2020) | جنس زمین (نوع خاک غالب) | |
| (Thomas & Kramer, 2002) (Edwards & Holt, 2000) | مقاومت شیب | |
| (Parthasarathy et al., 2017) | تعداد و نوع ماشین‌آلات | |
| (Rashidi et al., 2014) | نو یا کهنه بودن ماشین‌آلات | معیارهای مرتبط با مشخصات ماشین-آلات |
| (Thomas & Kramer, 2002) (Edwards & Holt, 2000) | مقاومت غلتشی تایر ماشین‌آلات | |
| (Panas & Pantouvakis, 2010) (Ok & Sinha, 2006) (Karshenas & Feng, 1992) | قدرت موتور ماشین‌آلات | |
| (Ok & Sinha, 2006) (Karshenas & Feng, 1992) | مجموع تعداد در قدرت ماشین‌آلات | |
| (Parthasarathy et al., 2017) (Dixit et al., 2017) | برنامه‌ریزی نادرست کارها | |
| (Edwards & Holt, 2000) (Dixit et al., 2017) | شرایط محل کار از نظر خطرات احتمالی | معیارها مرتبط با شرایط کاری و محیطی پروژه |
| (Rashidi et al., 2014) (Edwards & Holt, 2000) | شرایط محل کار از نظر فضای کافی برای تحرک ماشین‌آلات | |
| (Aadal et al., 2014) (Parthasarathy et al., 2017) | وضعیت دسترسی به سوخت (تعداد تانکر سوخت) | |
| (Rashidi et al., 2014) | تعداد اکیپ‌های کاری فعال در سایت | |
| (Thomas & Kramer, 2002) | ارتفاع از سطح دریا | |
| (Parthasarathy et al., 2017) | اشتراک گذاری ماشین‌آلات بین دو یا چند اکیپ کاری | |

| | | |
|---|--------------------------------|--|
| (Thomas & Kramer, 2002) (Rashidi et al., 2014) (Edwards & Holt, 2000) Amirkhanian & Baker, 1992) | مدت زمان (ساعت) | |
| (Thomas & Kramer, 2002) (Rashidi et al., 2014) | تعداد شیفت کاری | |
| (Thomas & Kramer, 2002) (Panas & Pantouvakis ,2010) (Ok & Sinha, 2006) (Rashidi et al., 2014) (Edwards & Holt, 2000) (Ranjithapriya & Arulselvan, 2020) (Dixit et al., 2017) (Amirkhanian & Baker, 1992) | میزان مهارت اپراتور ماشین آلات | معیار مرتبط با نیروی انسانی (اپراتورهای ماشین آلات) |

جدول ۲. مشخصات پاسخ دهندگان (خبرگان پژوهش)

| درصد فراوانی | تعداد | تحصیلات |
|--------------|-------|------------------|
| ۲۹,۱ | ۷ | کارشناسی |
| ۵۴,۲ | ۱۳ | کارشناسی ارشد |
| ۱۶,۷ | ۴ | دکتری |
| ۱۰۰ | ۲۴ | مجموع |
| درصد فراوانی | تعداد | رشته |
| ۴۱,۷ | ۱۰ | عمران |
| ۲۵ | ۶ | صنایع |
| ۱۲,۵ | ۳ | مدیریت ساخت |
| ۴,۲ | ۱ | مدیریت پروژه |
| ۸,۳ | ۲ | مکانیک |
| ۸,۳ | ۲ | مهندسی نفت |
| ۱۰۰ | ۲۴ | مجموع |
| درصد فراوانی | تعداد | سابقه کاری |
| ۱۶,۷ | ۴ | ۵ سال و کمتر |
| ۳۳,۳ | ۸ | بین ۶ تا ۱۰ سال |
| ۲۵ | ۶ | بین ۱۱ تا ۱۵ سال |
| ۱۲,۵ | ۳ | بین ۱۶ تا ۲۰ سال |
| ۴,۲ | ۱ | بین ۲۱ تا ۲۵ سال |
| ۸,۳ | ۲ | بیش از ۲۵ سال |
| ۱۰۰ | ۲۴ | مجموع |

۲-۲. داده کاوی

از ۰/۵ باشد در کمتر از نیمی از منابع مورد توجه قرار گرفته‌اند. فرمول دو مقدار مذکور عبارتند از:
TF (تعداد کل کلمات در سند) / (تعداد تکرار کلمه در سند) =

IDF=log (تعداد اسنادی که این عبارت در آن استفاده شده/تعداد کل اسناد)

پس از مراحل مذکور، فهرست نهایی معیارهای مؤثر تهیه شد. به این شیوه که معیارهایی که از نظر خبرگان کم‌اهمیت بودند (دما، درصد رطوبت، مقاومت غلظتی تأثیر ماشین‌آلات، برنامه‌ریزی نادرست کارها، شرایط محل کار از نظر فضای کافی برای تحرک ماشین‌آلات، تعداد اکیپ‌های کاری فعال در سایت، ارتفاع از سطح دریا، اشتراک‌گذاری ماشین‌آلات بین دو یا چند اکیپ کاری) و نیز فراوانی وزنی کلمه کلیدی آنها کمتر از ۰/۵ بود، حذف و بقیه موارد حفظ شدند (جدول ۴). در واقع، با استفاده از سه ابزار مطالعات کتابخانه‌ای، قضاوت خبرگان و روش متن‌کاوی به ۱۶ معیار نهایی و مؤثر دست یافته شد. اما از آنجایی که مدل‌سازی این پژوهش، بر اساس داده‌های واقعی استخراج شده از پروژه‌ها (گزارش روزانه ثبت شده توسط پیمانکاران)، به تعبیری از طریق بهره‌گیری از ظرفیت نمونه‌های موردی، صورت می‌گیرد، در نتیجه معیارهایی که در گزارش‌های پیمانکاران عموماً ثبت نمی‌شوند و دستیابی به مقادیر آنها به نسبت امکان‌پذیر نیست، در این مدل‌سازی در نظر گرفته نشده‌اند. طبق این محدودیت، از بین ۱۶ معیار به دست آمده، دسترسی تنها به داده‌های مرتبط با ۱۲ معیار میسر بود و در نتیجه، معیارهای مقاومت شیب، نو یا کهنه بودن ماشین‌آلات، شرایط کار از منظر خطرات احتمالی و شرایط محل کار از نظر فضای کافی برای تحرک ماشین‌آلات از پایگاه داده حذف شدند.

در مرحله بعد، به منظور اعتباربخشی بیشتر با کمک ابزار متن‌کاوی در نرم‌افزار رپیدمایئر (روش^۱ TF-IDF، یا فراوانی وزنی کلمه کلیدی) به تحلیل مجدد پژوهش-های پیشین پرداخته و وزن هر کدام از معیارها تعیین گردید (جدول ۳). در این پژوهش، در راستای صحت‌سنجی و اعتباربخشی، از ظرفیت فرآیند استاندارد فراصنعتی داده‌کاوی یا کریسپ^۲ (به عنوان متداول‌ترین روش برای انجام پروژه‌های داده‌کاوی با فازهای درک کسب و کار، شناسایی و درک داده‌ها، آماده‌سازی داده-ها، مدل‌سازی و ارزیابی (چپمن و همکاران، ۱۹۹۹)) بهره‌گیری شده است. فراوانی وزنی کلمه کلیدی یک آمار عددی است که اهمیت یک کلمه را برای مجموعه‌ای که در آن واقع شده است، نشان می‌دهد. همان‌طور که مشخص است TF-IDF از دو قسمت تشکیل شده است: TF که به معنای تعداد تکرار کلمه موردنظر در یک متن می‌باشد و IDF را نیز می‌توان تحت عنوان معکوس تعداد تکرار در کل متون در نظر گرفت. برتری قابل توجه این رویکرد در مقایسه با سایر رویکردهای متن‌کاوی این است که این روش صرفاً میزان تکرار یک کلمه کلیدی یا عبارت را در مدرک نشان نمی‌دهد، بلکه هدف آن نشان دادن اهمیت کلمه کلیدی مورد نظر با استفاده از مقایسه تعداد تکرار کلمه در متن با تکرار آن کلمه در مجموعه‌ای بزرگ‌تر از مستندات (کل اسناد مورد نظر) می‌باشد. با توجه به مطالب فوق، هر چه تکرار کلمه مورد نظر در یک متن بیشتر شده باشد (TF) ولی در متون دیگر کمتر تکرار شود (IDF)، مقدار TF-IDF آن بیشتر می‌شود و این مقدار می‌تواند معیار ارزشمندی جهت تشخیص وزن یک کلمه در مجموعه‌ای از اسناد باشد. در واقع نشان می‌دهد که یک کلمه چقدر می‌تواند دارای اهمیت باشد. به بیان دیگر، در این روش، معیارهایی که وزن آنها کمتر

for data mining

¹- Term frequency–Inverse document frequency

²- CRISP-DM: Cross-Industry Standard Process

جدول ۳. متن کاوی معیارهای (مؤثر بر بهره‌وری ماشین‌آلات خاکبرداری) شناسایی شده در پژوهش‌های پیشین

| TF-IDF نرمال | معیارها | TF-IDF نرمال | معیارها |
|-----------------|---|-----------------|--------------------------------|
| ۰,۳ | برنامه‌ریزی نادرست کارها | ۰,۸ | وضعیت آب و هوا |
| ۰,۵ | شرایط محل کار از نظر خطرات احتمالی | ۰,۵ | دما (کمینه و بیشینه دما) |
| ۰,۵ | شرایط محل کار از نظر فضای کافی برای تحرک ماشین‌آلات | ۰,۳ | درصد رطوبت |
| ۰,۶ | وضعیت دسترسی به سوخت | ۰,۸ | نوع زمین |
| ۰,۴ | تعداد اکیپ‌های کاری فعال در سایت | ۰,۸ | جنس زمین |
| ۰,۶ | ارتفاع از سطح دریا | ۰,۷ | مقاومت شیب |
| ۰,۳ | اشتراک‌گذاری ماشین‌آلات بین دو یا چند اکیپ کاری | ۰,۷ | تعداد و نوع ماشین‌آلات |
| ۰,۸ | مدت زمان (ساعت) | ۰,۶ | نویا کهنه بودن ماشین‌آلات |
| ۰,۷ | تعداد شیفت کاری | ۰,۴ | مقاومت غلته‌ی تایر ماشین‌آلات |
| ۰,۹ | میزان مهارت اپراتورهای ماشین‌آلات | ۰,۶ | قدرت موتور ماشین‌آلات |
| | | ۰,۷ | مجموع تعداد در قدرت ماشین‌آلات |

وضعیت آب‌وهوا: این معیار از نوع چندمتغیره (چندکلاسه) است و این سؤال را مطرح می‌کند که وضعیت آب‌وهوای کارگاه چگونه است؟ مقادیر احتمالی این معیار عبارتند از آفتابی، نیمه‌ابری، ابری، بارانی، رگبار و برفی. دما: این معیار از نوع عددی (پیوسته) است و این سؤال را مطرح می‌کند که کمینه و بیشینه دما در یک روز کاری چقدر است؟ نوع زمین: این معیار از نوع چندمتغیره (چندکلاسه) است و این سؤال را مطرح می‌کند که زمین کارگاه از چه نوعی است؟ مقادیر احتمالی این معیار عبارتند از کوهستانی، تپه ماهور و دشت. جنس زمین: این معیار بیانگر این است که جنس غالب بر زمین پروژه چیست؛ و به سه گروه تقسیم می‌شود: درصد سنگ، درصد دج و درصد خاک. در نتیجه، این معیار به سه زیر معیار تبدیل می‌شود و برای تشکیل پایگاه داده از آن استفاده می‌شود.

برای استفاده از ۱۲ معیار دیگر لازم است تا به بعضی از آن‌ها متناسب با داده‌های موجود در گزارش‌های روزانه، نسبتی داده شود؛ (نظیر معیار نوع و تعداد ماشین‌آلات) و به بعضی دیگر متغیرهای احتمالی نسبت داده شوند. به‌عنوان مثال، برای معیار وضعیت آب و هوا، مقدار متغیرهای احتمالی آن می‌تواند یکی از این شش حالت باشد: ۱- آفتابی، ۲- نیمه‌ابری، ۳- ابری، ۴- بارانی، ۵- رگبار و ۶- برفی. همچنین، برای نوع زمین می‌تواند یکی از این سه حالت باشد: ۱- هموار (دشتی)، ۲- تپه‌ماهوری و ۳- کوهستانی. به علاوه، برای میانگین سابقه رانندگان ماشین‌آلات می‌تواند یکی از این سه حالت باشد: ۱- کم (صفر تا ۵ سال)، ۲- متوسط (۵ تا ۱۰ سال) و ۳- زیاد (بیش از ۱۰ سال). در ادامه، به تشریح هر یک از معیارها و پاسخ آن‌ها پرداخته می‌شود:

جدول ۴. معیارهای نهایی مؤثر در تعیین بهره‌وری ماشین‌آلات خاکبرداری در پروژه‌های احداث خط لوله گاز

| نوع متغیر | پاسخ‌ها | تشریح | معیارها و زیرمعیارها | | گروه |
|------------|--|---|---|---------------------------------|-------------------------|
| Polynomial | ۱-آفتابی، ۲-نیمه‌ابری، ۳-ابری، ۴-بارانی، ۵-رگبار، ۶-برفی | وضعیت آب‌وهوای کارگاه چگونه است؟ | وضعیت آب و هوا | | شرایط جوی و محیطی |
| Numerical | مقدار عددی | کمینه دما در کارگاه چقدر است؟ | کمینه دما | درجه حرارت | |
| Numerical | مقدار عددی | بیشینه دما در کارگاه چقدر است؟ | بیشینه دما | | |
| Numerical | مقدار عددی | ارتفاع کارگاه از سطح دریا چقدر است؟ | ارتفاع از سطح دریا | | |
| Polynomial | ۱- هموار (دشتی) ۲- تپه ماهوری ۳- کوهستانی | زمین بستر از چه نوعی است؟ | نوع زمین | | ویژگی‌های زمین‌شناسی |
| Numerical | مقدار عددی | زمین بستر دارای چند درصد سنگ است؟ | درصد سنگ زمین | جنس زمین | |
| Numerical | مقدار عددی | زمین بستر دارای چند درصد خاک است؟ | درصد خاک زمین | | |
| Numerical | مقدار عددی | زمین بستر دارای چند درصد دج است؟ | درصد دج زمین | | |
| Numerical | مقدار عددی | چه تعداد بولدوزر و از چه مدلی آماده به کار است؟ | مدل و تعداد بولدوزر | تعداد و نوع ماشین آلات | مشخصات ماشین‌آلات |
| Numerical | مقدار عددی | مجموع تعداد بولدوزر ضرب در قدرت موتور بولدوزر چقدر است؟ | مجموع تعداد بولدوزر ضربدر قدرت موتور بولدوزر | | |
| Numerical | مقدار عددی | چه تعداد بیل مکانیکی و از چه مدلی آماده به کار است؟ | مدل و تعداد بیل مکانیکی | | |
| Numerical | مقدار عددی | مجموع تعداد بیل مکانیکی ضرب در قدرت موتور بولدوزر چقدر است؟ | مجموع تعداد بیل مکانیکی ضرب در قدرت موتور بیل مکانیکی | | |
| Numerical | مقدار عددی | چه تعداد لودر و از چه | مدل و تعداد لودر | | |

| | | | | |
|------------|--|---|---|-----------------------|
| | | مدلی آماده به کار است؟ | | |
| Numerical | مقدار عددی | مجموع تعداد لودر ضرب در قدرت موتور بلدوزر چقدر است؟ | مجموع تعداد لودر ضربدر قدرت موتور لودر | |
| Numerical | مقدار عددی | چه تعداد کامیون آماده به کار است؟ | تعداد کامیون | |
| Numerical | مقدار عددی | چه تعداد تانکر سوخت آماده به کار است؟ | تعداد تانکر سوخت | |
| Polynomial | ۱- صفر تا ۵ سال (کم) ۲- ۵ تا ۱۰ سال (متوسط) ۳- بیش از ۱۰ سال (زیاد) | میانگین میزان مهارت اپراتورهای ماشین آلات | میزان مهارت اپراتورهای ماشین آلات | شرایط منابع انسانی |
| Numerical | مقدار عددی | چند شیفت کاری در کارگاه فعال است؟ | تعداد شیفت کاری | |
| Numerical | مقدار عددی | روز کاری چند ساعت است؟ | مدت زمان (ساعت) | شرایط کاری و پروژه |
| Numerical | مقدار عددی | چند متر مکعب خاکبرداری انجام شده است؟ | حجم خاکبرداری | |

است و هریک از این ماشین آلات با مدل های مختلف و با قدرت موتوری متفاوت در هر پروژه مورد استفاده قرار گرفته اند. همچنین، از اهمیت تعداد تانکر سوخت نیز نمی توان چشم پوشی کرد. در نتیجه، معیار تعداد و نوع ماشین آلات به تعدادی زیرمعیار صورت بندی شد تا داده های آن به طور جداگانه وارد پایگاه داده شود و دقت بیشتری برای مدل حاصل گردد. مدل و تعداد بولدوزرها: این معیار از نوع عددی (گسسته) است و این سؤال را مطرح می کند که چه تعداد بولدوزر با مدل مشخص در عملیات خاکبرداری شرکت می کنند؟ مدل های مورد بررسی عبارتند از D8 کاتریپلار،

درصد سنگ زمین: این معیار از نوع عددی (پیوسته) است و این سؤال را مطرح می کند که زمین بستر دارای چند درصد سنگ است؟ درصد دج زمین: این معیار از نوع عددی (پیوسته) است و این سؤال را مطرح می کند که زمین بستر دارای چند درصد دج است؟ درصد خاک زمین: این معیار از نوع عددی (پیوسته) است و این سؤال را مطرح می کند که زمین بستر دارای چند درصد خاک است؟ تعداد و نوع ماشین آلات: با توجه به بررسی گزارش هایی که از پروژه ها در اختیار بود مشخص شد که در آن ها معمولاً ترکیبی از بولدوزر، بیل مکانیکی، لودر و کامیون برای عملیات خاکبرداری استفاده شده

خاکبرداری شرکت می‌کنند؟ مدل‌های لودر اشاره شده در گزارش‌ها، ۹۳۰ کاترپیلار با قدرت موتور ۱۶۰ اسب بخار و WA-750-A کوماتسو با قدرت موتور ۴۴۹ اسب بخار. تعداد کامیون: این معیار از نوع عددی (گسسته) است و این سؤال را مطرح می‌کند که چه تعداد کامیون در حالت آماده به کار در سایت قرار دارد؟ تعداد تانکر سوخت: این معیار از نوع عددی (گسسته) است و این سؤال را مطرح می‌کند که چند تعداد تانکر سوخت در حالت آماده به کار در سایت قرار دارد؟ ارتفاع از سطح دریا: این معیار از نوع عددی (پیوسته) است و این سؤال را مطرح می‌کند که ارتفاع کارگاه نسبت به سطح دریا چقدر است؟ مدت زمان (ساعت): این معیار از نوع عددی (پیوسته) است و این سؤال را مطرح می‌کند که عملیات خاکبرداری روزانه در طول چند ساعت انجام می‌شود؟ تعداد شیفت کاری: این معیار از نوع عددی (پیوسته) است و این سؤال را مطرح می‌کند که عملیات خاکبرداری در چند شیفت انجام می‌شود؟ میانگین میزان مهارت رانندگان: این معیار از نوع چندمتغیره (چندکلاسه) است و این سؤال را مطرح می‌کند که میانگین میزان مهارت اپراتورهای ماشین‌آلات به چه گونه است؟ متغیرهای احتمالی برای این معیار عبارتند از: صفر تا ۵ سال (کم)، ۵ تا ۱۰ سال (متوسط)، بیش از ۱۰ سال (زیاد). حجم خاکبرداری: در انتها باید معیاری (ستونی در پایگاه داده) به عنوان حجم خاکبرداری قرار گیرد، زیرا برای پیش‌بینی متغیر هدف، در ابتدا کامپیوتر باید از داده‌های موجود یاد بگیرد تا بتواند پیش‌بینی کند. در نتیجه، معیار آخر باید حجم خاکبرداری باشد، که طبق تعاریف ارائه شده، معادل همان بهره‌وری است. این معیار از نوع عددی (پیوسته) است و این سؤال را مطرح می‌کند که چند متر مکعب خاکبرداری در یک روز کاری انجام شده است؟

D155A کوماتسو، 5-D355 کوماتسو و D9 کاترپیلار. مجموع تعداد در قدرت بولدوزرها: این معیار از نوع عددی (پیوسته) است و این سؤال را مطرح می‌کند که چه تعداد بولدوزر با قدرت موتور مشخص در عملیات خاکبرداری شرکت می‌کنند؟ مدل‌های بولدوزر اشاره شده در گزارش‌ها، D8 کاترپیلار با قدرت موتور ۳۰۶ اسب بخار، D155A کوماتسو با قدرت موتور ۳۱۴ اسب بخار، 5-D355 کوماتسو با قدرت موتور ۴۴۵ اسب بخار و D9 کاترپیلار با قدرت ۴۵۱ اسب بخار هستند. مدل و تعداد بیل مکانیکی‌ها: این معیار از نوع عددی (گسسته) است و این سؤال را مطرح می‌کند که چه تعداد بیل مکانیکی با مدل مشخص در عملیات خاکبرداری شرکت می‌کنند؟ مدل‌های مورد بررسی عبارتند از PC200-7 کوماتسو، PC220-7 کوماتسو، 320 کاترپیلار و PC350-7 کوماتسو. مجموع تعداد در قدرت بیل مکانیکی‌ها: این معیار از نوع عددی (پیوسته) است و این سؤال را مطرح می‌کند که چه تعداد بیل مکانیکی با قدرت موتور مشخص در عملیات خاکبرداری شرکت می‌کنند؟ مدل‌های بیل مکانیکی اشاره شده در گزارش‌ها، PC200-7 کوماتسو با قدرت موتور ۱۵۰ اسب بخار، PC220-7 کوماتسو با قدرت موتور ۱۶۸ اسب بخار، 320 کاترپیلار با قدرت موتور ۱۷۳ اسب بخار و PC350-7 کوماتسو با قدرت ۲۳۲ اسب بخار هستند. مدل و تعداد بیل لودرها: این معیار از نوع عددی (گسسته) است و این سؤال را مطرح می‌کند که چه تعداد لودر با مدل مشخص در عملیات خاکبرداری شرکت می‌کنند؟ مدل‌های مورد بررسی لودر عبارتند از ۹۳۰ کاترپیلار و WA-750-A کوماتسو. مجموع تعداد در قدرت لودرها: این معیار از نوع عددی (پیوسته) است و این سؤال را مطرح می‌کند که چه تعداد لودر با قدرت موتور مشخص در عملیات

۲-۳. مدل سازی

تعیین بهره‌وری ماشین‌آلات خاکبرداری می‌باشد. با توجه به اینکه پایگاه داده از ابتدا توسط مؤلفین و با استخراج داده‌های گزارش‌های روزانه ساخته شده است، مقادیر گم‌شده، مقادیر تکراری و مقادیر اشتباه در میان داده‌ها یافت نشد. حجم خاکبرداری به‌عنوان متغیر هدف این پژوهش، یک متغیر عددی^۱ پیوسته است. در یادگیری ماشین برای پیش‌بینی متغیرهای عددی اغلب از مدل‌های پیش‌بینی^۲ و برای پیش‌بینی متغیرهای دو جمله‌ای^۳ یا چند جمله‌ای^۴ (گسسته) اغلب از مدل‌های دسته‌بندی^۵ استفاده شود. به علاوه، تعداد مدل‌های دسته‌بندی نسبت به مدل‌های پیش‌بینی بیشتر هستند، اگرچه تعدادی از الگوریتم‌ها بین هر دو مشترک هستند. بنابراین، در این پژوهش، علاوه بر مدل‌های پیش‌بینی از مدل‌های دسته‌بندی نیز استفاده شدند. این کار نیازمند تبدیل متغیر عددی به یک متغیر چند جمله‌ای می‌باشد. برای این منظور، مقادیر حجم خاکبرداری در ۲۰ کلاس دسته‌بندی شده‌اند (شکل ۱). این دسته‌بندی به صورت خودکار توسط نرم‌افزار به گونه‌ای انجام می‌شود که یک توزیع نسبتاً نرمال از داده‌ها به دست آید. خلاصه مراحل مدل‌سازی در این پژوهش عبارتند از: ۱) بارگذاری پایگاه داده در نرم‌افزار ریپدماینر، ۲) تعیین تناسب داده‌های یادگیری^۶ و داده‌های اعتبارسنجی^۷ (در این پژوهش، طبق مطالعات کتابخانه‌ای، حدوداً از ۷۰ درصد داده‌ها برای یادگیری و توسعه مدل و از ۳۰ درصد داده‌ها برای اعتبارسنجی مدل استفاده شده است).

به‌منظور مدل‌سازی با بهره‌گیری از الگوریتم‌های یادگیری ماشین، به داده‌های واقعی از پروژه‌های خط لوله گاز نیاز بود که با استفاده از مطالعات میدانی و اسناد تولید شده در پروژه‌ها، این داده‌ها گردآوری شدند. به عبارت دیگر، داده‌های مورد نیاز برای تولید مدل (داده‌های یادگیری و آزمون) از گزارش‌های روزانه هفت پروژه خطوط انتقال گاز، که توسط سه سازمان متفاوت در کشور بین سال‌های ۱۳۸۶ تا ۱۴۰۰ اجرا شده‌اند، از طریق روش‌های اسنادی و میدانی استخراج و سپس پایگاه داده در نرم‌افزار اکسل ایجاد شد (جدول ۵). ویژگی مشترک این هفت پروژه منتخب از منظر محل اجرای آن‌ها (مناطق کوهستانی ایران) است.

بعد از وارد کردن پایگاه داده به نرم‌افزار ریپدماینر، ستون‌های تاریخ و نام پروژه، به دلیل اینکه فاقد داده‌هایی هستند که در مدل‌سازی مورد نیاز است و همچنین ستون بهره‌وری، به دلیل همبستگی زیاد به دو متغیر حجم خاکبرداری و زمان، جدا شدند. لذا، پایگاه داده نهایی با تعداد ۸۲۷ ردیف و ۲۷ ستون وارد نرم‌افزار شد. متغیر هدف در این پژوهش عبارت است از حجم خاکبرداری انجام شده توسط ماشین‌آلات که به‌عنوان معیار بیست و هفتم در پایگاه داده حضور دارد. در مرحله بعد، نوع هر متغیر (اسمی، چندجمله‌ای، عدد صحیح و عدد اعشاری) تعیین گردید. هر یک از ردیف‌ها معادل یک گزارش روزانه و هر یک از ستون‌ها معادل یک معیار مؤثر در

4- Polynomial

5- Classification

6- Train

7- Test

1- Numerical

2- Prediction

3- Binomial

بودند، به مدل یادگیری عمیق داده شد. بعد از آن، نتایج به دست آمده با داده‌های واقعی مقایسه شد و خروجی‌ها و یافته‌ها قابل قبول بودند.

۳. نتایج

برای پیش‌بینی حجم خاکبرداری، از مدل رگرسیونی و الگوریتم یادگیری عمیق به‌عنوان دقیق‌ترین الگوریتم پیش‌بینی‌کننده و نیز الگوریتم دسته‌بندی بهره‌گیری شد. یعنی، سطح دقت و عملکرد مدل‌های توسعه داده شده با الگوریتم‌های پیش‌بینی و یادگیری عمیق در جدول ۶ و شکل ۲ از طریق نمودارها نمایش داده شده است. همچنین، در این مرحله، از الگوریتم‌های دسته‌بندی برای توسعه مدل پیش‌بینانه استفاده شده است. این عمل، نیازمند تبدیل متغیر عددی به یک متغیر چندجمله‌ای است. لذا، مقادیر حجم خاکبرداری در ۲۰ کلاس (پیش‌فرض نرم‌افزار رپیدماینر) دسته‌بندی شده‌اند. پس از اینکه متغیر هدف به یک متغیر چندجمله‌ای تبدیل شد، تصمیم گرفته شد تا از الگوریتم‌های دسته‌بندی استفاده شود. در جدول ۷، عملکرد این الگوریتم‌های دسته‌بندی در پیش‌بینی حجم خاکبرداری مقایسه شده است. در همین راستا، در شکل ۳، منحنی ROC^۱ (نمودار مشخصه عملکرد) الگوریتم‌های دسته‌بندی، نشان داده شده است. منحنی ROC^۲، توسط نسبت نرخ مثبت صحیح^۲ که به اختصار TPR نامیده می‌شود و برحسب نرخ مثبت کاذب^۳ با نام اختصاری FPR^۳ ایجاد شده است.

این صورت عمل شد که در ابتدا پایگاه داده داخل آن بارگذاری شد؛ سپس، ستونی که داده‌های آن را پیش‌بینی کند، انتخاب گردید تا بر اساس داده‌های موجود از اطلاعات پروژه‌ها یادگیری مدل انجام شود (بخش یادگیری). در ادامه، مشخص شد که کدام اطلاعات از پایگاه داده متغیر عددی پیوسته است یا چندجمله‌ای (گسسته) هستند. همچنین، مشخص گردید که از الگوریتم‌های پیش‌گویانه و دسته‌بندی برای پیش‌بینی استفاده شود. سپس، مدل سازی در نرم‌افزار به صورت اتوماتیک با الگوریتم‌های مختلف بر اساس پایگاه داده ورودی انجام شد. در پایان، نتیجه‌ای که حاصل شد در بخش نتایج (نمودارهای مدل‌های توسعه داده شده که برای هر مدل نشان دهنده دقت و مقایسه انطباق داده‌های واقعی و مقدار پیش‌بینی شده است) ارائه شده است. همچنین، در مورد صحت‌سنجی این مدل‌های یادگیری ماشین، شایان توجه است که بر اساس درصد دقتی که توسط الگوریتم یادگیری عمیق ارائه شد، انتخاب نهایی صورت گرفت. همچنین، نسبت ۷۰-۳۰ برای نرم‌افزار برگزیده شد (به طوری که از حدود ۷۰ درصد اطلاعات پایگاه داده استفاده کند و یادگیری انجام دهد و از ۳۰ درصد برای اعتبارسنجی مدل استفاده شود)، به صورتی که پس از پیش‌بینی، ۳۰ درصد داده‌هایی که در مرحله یادگیری مدل استفاده نشده

²- True Positive Rate

³- False Positive Rate

¹- Receiver Operating Characteristic

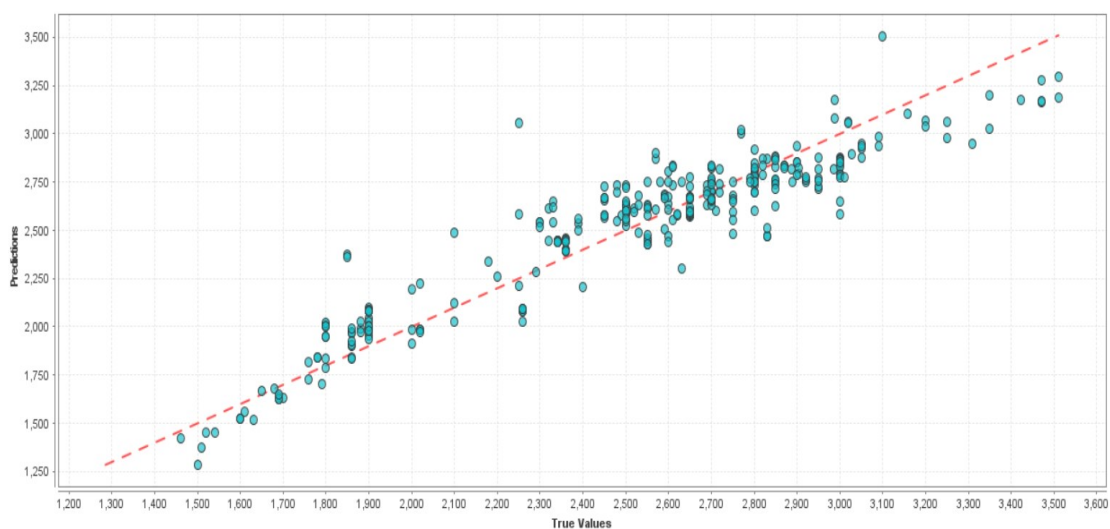
ارائه الگویی برای بهبود بهره‌وری ماشین‌آلات خاکبرداری در پروژه‌های زیرساختی با استفاده از الگوریتم‌های یادگیری ماشین ...

جدول ۶. مقایسه عملکرد الگوریتم‌های پیش‌بینانه در پیش‌بینی حجم خاکبرداری

| ردیف | مدل | دقت (%) | انحراف معیار | زمان اجرا |
|------|--------------------------|---------|--------------|-----------|
| ۱ | Generalized Linier Model | ۶۰,۴ | ± ۱ | ۴۴۴ ms |
| ۲ | Deep learning | ۹۲,۶ | ± ۰,۱ | ۵۲ |
| ۳ | Decision Tree | ۶۴,۵ | ± ۱ | ۴۵۶ ms |
| ۴ | Random Forest | ۴۷,۵ | ± ۲,۵ | ۵۶ |
| ۵ | Gradient Boosted Trees | ۵۶,۳ | ± ۳ | ۱۵ s |
| ۶ | Support Vector Machine | ۷۸,۷ | ± ۰,۵ | ۱۳ s |


(A)

Generalized Linear Model - Predictions Chart




(B)

Deep Learning - Predictions Chart



(C)


Decision Tree - Predictions Chart



ارائه الگویی برای بهبود بهره‌وری ماشین‌آلات خاکبرداری در پروژه‌های زیرساختی با استفاده از الگوریتم‌های یادگیری ماشین ...


(D)

Random Forest - Predictions Chart



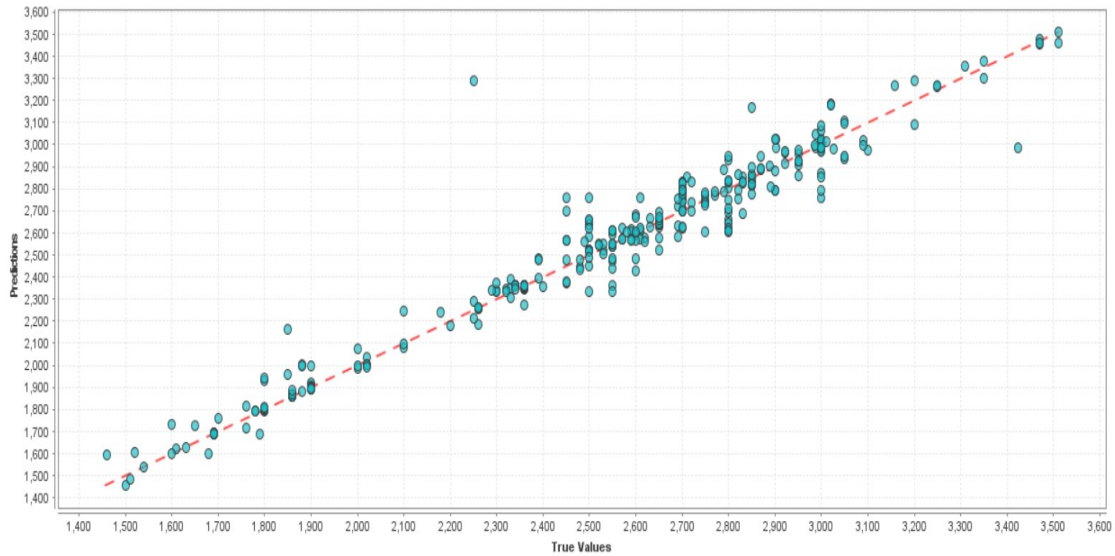
(E)

Gradient Boosted Trees - Predictions Chart



(F)

Support Vector Machine - Predictions Chart

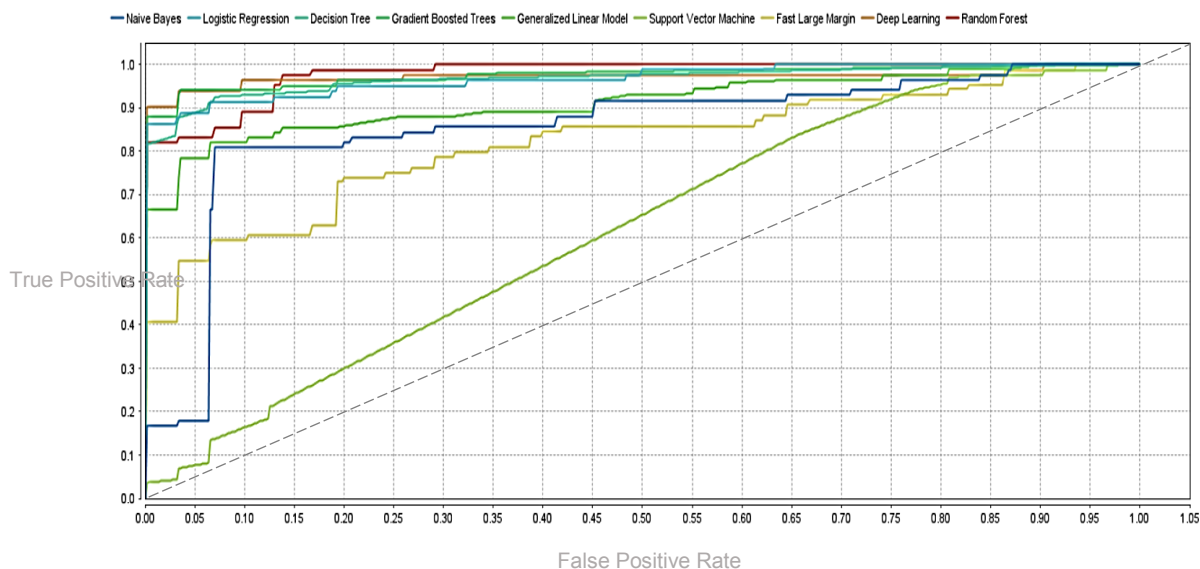


شکل ۲. نمودارهای مدل‌های توسعه داده شده الگوریتم‌های پیش‌بینانه

جدول ۷. مقایسه عملکرد الگوریتم‌های دسته‌بندی

| ردیف | مدل | دقت (%) | انحراف معیار | زمان اجرا |
|------|--------------------------|---------|--------------|--------------|
| ۱ | Naïve Bayes | ٪۸۹,۴ | ±۳,۱ | ۵۹ |
| ۲ | Generalized Linier Model | ٪۸۶,۸ | ±۴,۱ | ۵۸ |
| ۳ | Logistic Regression | ٪۸۶,۹ | ±۲,۸ | ۵۶ |
| ۴ | Fast Large Margin | ٪۷۶,۷ | ±۲,۸ | ۵۸ |
| ۵ | Deep learning | ۹۴,۹٪ | ±۲,۴ | ۵۱۰ |
| ۶ | Decision Tree | ٪۹۲,۸ | ±۱,۲ | ۵۶ |
| ۷ | Random Forest | ٪۹۲,۸ | ±۲,۵ | ۵۱۴ |
| ۸ | Gradient Boosted Trees | ٪۹۴,۹ | ±۲,۴ | ۵۲۹ |
| ۹ | Support Vector Machine | ٪۶۵,۴ | ±۱,۷ | min ۱ ۵۳۰ |

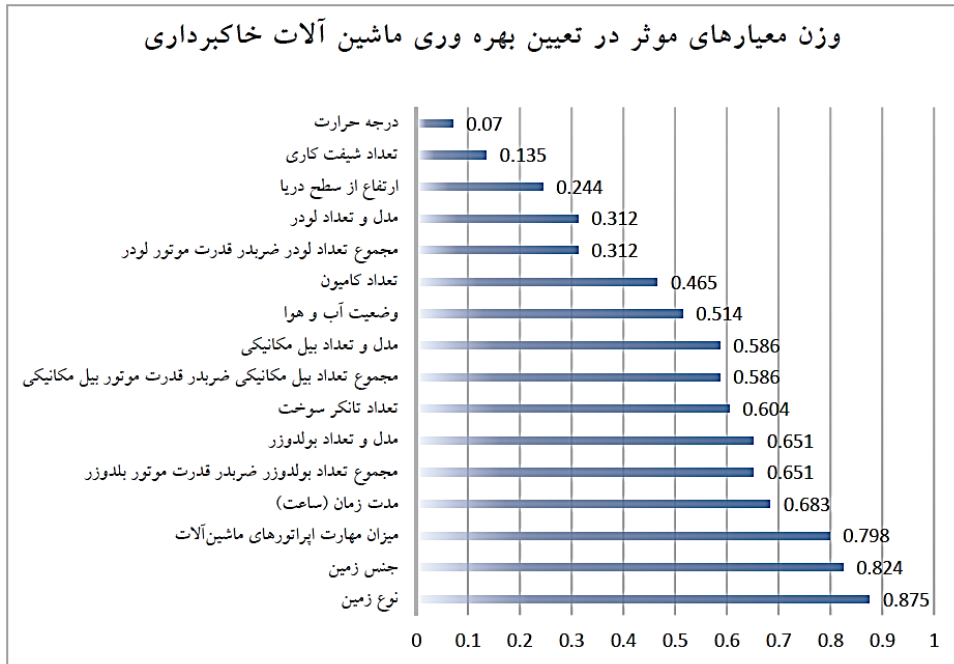
ROC Comparison



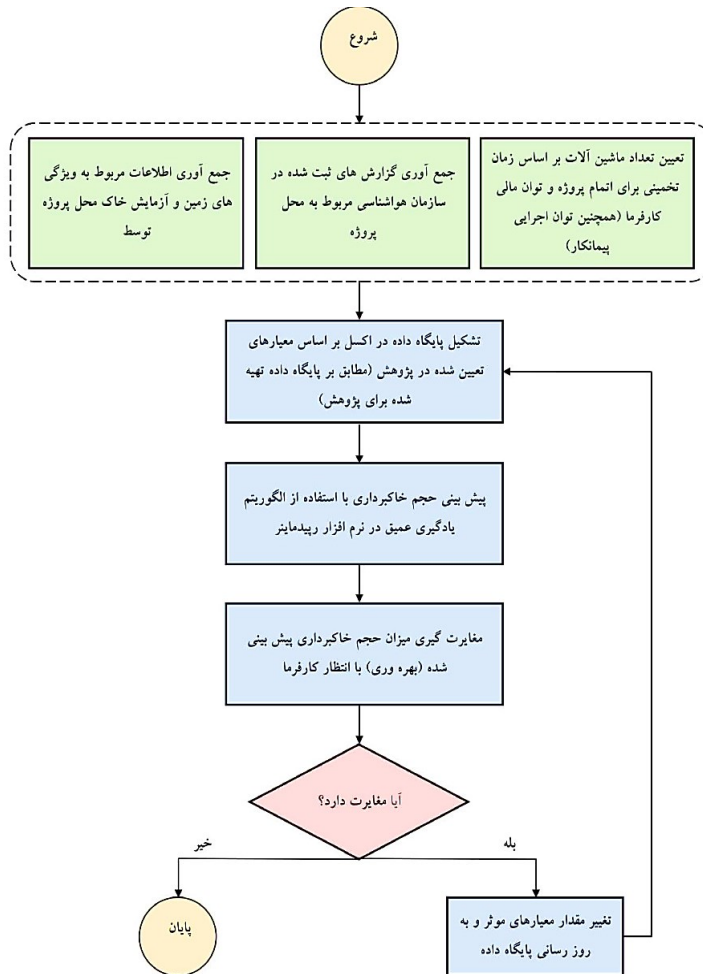
شکل ۳. نمودار مشخصه عملکرد الگوریتم‌های دسته‌بندی

در انتها، پس از توسعه مدل و اندازه‌گیری دقت آن، وزن هر یک از معیارهای تأثیرگذار بر افزایش دقت مدل توسط نرم‌افزار رپیدمایتر تعیین گردید که در شکل ۴ نمایش داده شده است. در نهایت، جهت ایجاد الگویی برای بهبود بهره‌وری ماشین‌آلات خاکبرداری، باید این امکان ایجاد شود تا با تغییر معیارهای قابل تغییر (مانند تعداد ماشین‌آلات) مجدداً حجم خاکبرداری پیش‌بینی شود و این کار آنقدر تکرار شود تا به مقدار مورد نظر کارفرما نزدیک گردد. به منظور ارزیابی الگوی ارائه شده، این الگو توسط پنج نفر از خبرگانی که در تکمیل پرسش‌نامه‌ها شرکت کرده بودند مورد ارزیابی و مورد تایید قرار گرفت (شکل ۵).

همانطور که اشاره شد، مدل‌های توسعه داده شده با الگوریتم "یادگیری عمیق" دارای بهترین عملکرد در پیش‌بینی حجم خاکبرداری می‌باشند. مدل پیش‌بینانه، مبنای بهینه‌سازی بهره‌وری ماشین‌آلات خاکبرداری می‌باشد. به عبارتی، دقت مدل توسعه داده شده با الگوریتم یادگیری عمیق در دسته الگوریتم‌های پیش‌بینانه برابر ۹۲/۶ درصد و در دسته الگوریتم‌های دسته‌بندی برابر با ۹۴/۹ درصد است که در دو حالت دارای بیشترین دقت در مقایسه با الگوریتم‌های دیگر است و می‌تواند با دقت بالاتری حجم خاکبرداری را در پروژه‌های احداث خط لوله گاز پیش‌بینی کند. این دقت عبارت است از نسبت داده‌هایی که درست پیش‌بینی شده است بر تمام داده‌های آزمون.



شکل ۴. وزن هر معیار مؤثر در تعیین بهره‌وری ماشین‌آلات خاکبرداری



شکل ۵. الگویی برای بهبود بهره‌وری ماشین‌آلات خاکبرداری

۴. نتیجه‌گیری

در این پژوهش، پس از شناسایی معیارها و تشکیل پایگاه داده، مدل‌سازی به‌منظور پیش‌بینی حجم خاکبرداری (بهره‌وری) و با کمک الگوریتم‌های پیش‌بینانه و نیز الگوریتم‌های دسته‌بندی انجام گرفت و دقت آن‌ها مقایسه گردید. همان‌طور که پیشتر اشاره شد، الگوریتم یادگیری عمیق به عنوان الگوریتم برگزیده شناسایی شد. سپس، یک الگو برای استفاده از این مدل پیش‌بینی و با هدف بهبود بهره‌وری ارائه گردید. استفاده از این الگو بدین صورت است که پیمانکار پیش از شروع پروژه، اطلاعات مربوط به ویژگی‌های زمین و شرایط اقلیمی محل انجام پروژه را جمع‌آوری کرده و متناسب با ساختار پایگاه داده به‌کار گرفته شده در پژوهش حاضر، آن‌ها را وارد نرم‌افزار اکسل می‌کند.

پس از آن، با توجه به پتانسیل اجرایی خود و توان مالی کارفرما، تعداد و نوع ماشین‌آلاتی را که قادر به تهیه و استفاده از آن‌ها در پروژه است (مطابق با ویژگی‌های ماشین‌آلات مذکور در پایگاه داده)، تعیین می‌کند. در ادامه، پایگاه داده خود را وارد نرم‌افزار رپیدماینر کرده و این نرم‌افزار بر اساس داده‌هایی که پیشتر برای یادگیری و آزمون از آن‌ها استفاده کرده بود، قادر به پیش‌بینی حجم خاکبرداری خواهد بود. پس از این مرحله، پیمانکار باید بررسی کند که آیا حجم خاکبرداری پیش‌بینی شده در هر روز متناسب با اهداف زمانی و هزینه‌ای تعریف شده برای پروژه است یا خیر. در صورتی که مناسب است، از همان شرایط و ماشین‌آلات استفاده می‌کند. در غیر این صورت، مقادیر معیارهای قابل تغییر در پایگاه داده را می‌تواند تغییر دهد و مجدداً پایگاه داده را وارد نرم‌افزار رپیدماینر کند. این فرآیند باید آن قدر انجام گیرد تا به مقدار مورد نظر پیمانکار

نزدیک شود. در نتیجه، یافته‌های این پژوهش می‌تواند در فاز برنامه‌ریزی و فاز اجرای پروژه‌های احداث خطوط لوله گاز توسط طرفین درگیر، خصوصاً پیمانکاران، مورد استفاده قرار گیرند. پیش‌بینی حجم خاکبرداری روزانه در فاز برنامه‌ریزی می‌تواند موجب افزایش دقت برنامه زمان‌بندی کلی و تفصیلی و همچنین افزایش دقت برآوردهای منابع شود. به‌طور موجز و شفاف، می‌توان اینگونه نتایج پژوهش حاضر را جمع‌بندی کرد که پیش‌بینی حجم خاکبرداری، از طریق الگوریتم پیش‌بینانه (به‌عنوان مبنای بهینه‌سازی بهره‌وری ماشین‌آلات خاکبرداری) و نیز با استفاده از مدل یادگیری عمیق (به‌عنوان مدل منتخب و دارای بهترین عملکرد در پیش‌بینی حجم خاکبرداری در بخش پیش‌بینانه)، با دقت ۹۲/۶ درصد و انحراف معیار ۰/۱ و نیز مدت زمان ۲ ثانیه قابل اجرا است و همچنین، از طریق الگوریتم دسته‌بندی و با استفاده از مدل یادگیری عمیق (به‌عنوان مدل منتخب و دارای بهترین عملکرد در پیش‌بینی حجم خاکبرداری در بخش دسته‌بندی)، با دقت ۹۴/۹ درصد و انحراف معیار ۲/۴ و نیز مدت زمان ۱۰ ثانیه قابل اجرا است. بر همین اساس، خروجی‌های این پژوهش کاربردی به شرح زیر قابل تبیین هستند: معیارهای مؤثر شناسایی شده در تعیین بهره‌وری ماشین‌آلات خاکبرداری در پروژه‌های احداث خط لوله گاز؛ مقایسه صورت‌گرفته بین الگوریتم‌های یادگیری ماشین در پیش‌بینی بهره‌وری ماشین‌آلات خاکبرداری در پروژه‌های احداث خط لوله گاز؛ و در نهایت، الگوی ارائه شده با استفاده از الگوریتم‌های یادگیری ماشین (و با کمک نرم‌افزار رپیدماینر) به منظور بهبود بهره‌وری ماشین‌آلات در عملیات خاکبرداری پروژه‌های احداث خط لوله گاز. در خصوص پیشنهاد‌های آتی، با توجه به جدید

چگونه تلقی می شود (در پژوهش انجام شده طبقه بندی توسط تنظیمات پیش فرض ریپدماینر و در ۲۰ کلاس و در بازه های مساوی انجام گرفت). همچنین، برای بررسی تأثیر ابزار بر نتیجه این پژوهش می توان مدل سازی را با دیگر ابزارها (از جمله پایتون، R، Weka) نیز انجام داد. افزون بر این موارد، در این پژوهش فقط ماشین آلات اصلی و متداول در پروژه های مد نظر مورد بررسی قرار گرفته اند و از سایر تجهیزات و ماشین آلات مربوطه صرف نظر شده است. در پایان، شایان ذکر است که طول مدت پروژه های مورد بررسی در این پژوهش تقریباً ۱۵ سال بوده است. اما جهت واسنجی و اعتبارسنجی دقیق تر مدل بهتر است که از پروژه های دیگر و در طول مدت بیشتر بهره گرفت.

بودن موضوع و میان رشته ای بودن آن، نیاز است تا نحوه حل مسئله گسترش داده شود. بدین معنا که حجم داده ها و تعداد معیارها به قدری زیاد شوند تا بتوان پیش بینی و طبقه بندی را در انواع پروژه ها داشت (رویکرد افقی)؛ و یا حجم داده ها در یک نوع پروژه با ویژگی های خاص آنقدر زیاد شود که فقط در آن حوزه دقت مدل زیاد شود (رویکرد عمودی). برای انتخاب مسیر پیش رو نیاز است تا داده های موجود و در دسترس از تمام پروژه ها جمع آوری و بررسی شوند. سپس با توجه به داده های موجود می توان رویکرد کارهای آتی را مشخص نمود. از دیگر پیشنهادها برای بهبود نتیجه این پژوهش استفاده از افراد خبره جهت برچسب گذاری طبقه بندی های انجام شده می باشد. بدین معنا که مشخص شود پیش بینی انجام شده توسط مدل های طبقه بندی از دید افراد خبره

۵. مراجع

- Aadal, H., Bagheri Fard, A., Golchin Rad, K., Ghasemi Poor Sabet, P. and Morshedi, S. R. 2014. "Impact of plants and equipment management in construction industry of Iran". *Res. J. Appl. Sci. Eng. Tech.*, 7(11): 2371-2375.
- Amirkhanian, S. N. and Baker, N. J. 1992. "Expert system for equipment selection for earth-moving operations". *J. Constr. Eng. Manag.*, 118(2): 318-331.
- Armaghani, D. J., Mohamad, E. T., Narayanasamy, M. S., Narita, N. and Yagiz, S. 2017. "Development of hybrid intelligent models for predicting TBM penetration rate in hard rock condition". *Tunn. Undergr. Sp Tech.*, 63: 29-43.
- Babpoor, M. 2016. "What is the relationship between artificial intelligence, machine learning and data mining?" <https://dataak.com/blog/what-is-the-difference-between-artificial-intelligence-machine-learning-data-mining/>
- Biuse, R., Momeni, M. and Hamidizadeh M. R. 2018. "Identifying the most effective factor in the procurement phase of the EPC projects of oil and gas companies using the AHP method". The Second International Conference and the Fourth Conference of the National Logistics and Supply Chain Conference, Tehran.
- Chapman, P., Clinton, J., Kerber, R., Khabaza, T., Reinartz, T., Shearer, C. and Wirth, R. 1999. "The CRISP-DM User Guide". In 4th CRISP-DM SIG Workshop in Brussels, Vol. 1999.
- Dixit, S., Pandey, A. K., Mandal, S. N. and Bansal, S. 2017. "A study of enabling factors affecting construction productivity: Indian scenerio". *Int. J. Civ. Eng. Tech.*, 8(6): 741-758.
- Duffy, G. A. 2009. "Linear scheduling of pipeline construction projects with varying production rates". Oklahoma State University.
- Edwards, D. J. and Holt, G. D. 2000. "ESTIVATE: a model for calculating excavator productivity and output costs". *Eng. Constr. Architect. Manag.*, ۵۲-۶۲ : (۱)۷
- Eshthardian, A., Noorani, M., Vahidi, H. and Najafabadipour, T. 2012. "Linear programming model to optimize the number of machines with the aim of reducing the time and cost of earthworks in urban projects". International Conference on Civil Engineering, Architecture and Sustainable Urban Development, Tabriz, Iran.
- Esrafilizaji, B. and Kiani Harchegani, F. 2011. "Persia land of black gold". 10.13140/2.1.42 64.0001.
- Eskandari, A., Abdi, A. and Eskandari, V. 2014. "Optimization of earthmoving machines by genetic algorithm". Third International Congress on Civil Engineering, Architecture and Urban Development, Tehran, Iran.
- Fallahnejad, M. 2013. "Delay causes in Iran gas pipeline projects". *Int. J. Project Manag.* 31: 136-146. 10.1016/j.ijproman.2012.06.003.
- Hsiao, W. T., Lin, C. T., Wu, H. T. and Cheng, T. M. 2011. "A hybrid optimization mechanism used to generate truck fleet to perform earthmoving operations". *Road Mater. New Innov. Pavement Eng.* [https://doi.org/10.1061/47634\(413\)20](https://doi.org/10.1061/47634(413)20)
- Jordan, M. I. and Mitchell, T. M. 2015. "Machine learning: Trends, perspectives, and prospects". *Sci.*, 349(6245): 255-260.
- Karshenas, S. and Feng, X. 1992. "Application of neural networks in earthmoving equipment production estimating". In: *Computing in Civil Engineering and Geographic Information Systems Symposium*, pp. 841-847, ASCE.
- Kassem, M., Mahamedi, E., Rogage, K., Duffy, K. and Huntingdon, J. 2021. "Measuring and benchmarking the productivity of excavators in infrastructure projects: A deep neural network approach". *Automat. Constr.*, 124 p., 103532.
- Ok, S. C. and Sinha, S. K. 2006. "Construction equipment productivity estimation using artificial neural network model". *Constr. Manag. Econ.*, 24(10): 1029-1044.
- Omran, B. A. and Chen, Q. 2016. "Trend on the implementation of analytical techniques for big data in construction research (2000–2014)". In: *Construction Research Congress 2016*, pp. 990- 999.
- Oyisi Eskoi, A. H. and Ravanshadnia, M. 2012. "Simulation application in multi-objective optimization of earthworks". 7th National Congress of Civil Engineering.
- Panas, A. and Pantouvakis, J. P. 2010. "Comparative analysis of operational coefficients' impact on excavation operations". *Eng. Constr. Architec. Manag.* 17(5): 461-475.
- Parchami Jalal, M., Farsatkar, A. and Forozanfar, Y. 2009. "Operation management of construction

- machinery”. Publication 449.
- Parente, M., Correia, A. G. and Cortez, P. 2016. “A novel integrated optimization system for earthwork tasks”. *Transport. Res. Proc.*, 14: 3601-3610.
- Parthasarathy, M. K., Murugasan, R. and Murugesan, K. 2017. “A critical review of factors affecting manpower and equipment productivity in tall building construction projects”. *J. Constr. Dev. Countries*, 22: 1-18.
- Ranjithapriya, R. and Arulselvan, S. 2020. “Study on factors affecting equipment management and its effect on productivity in building construction”. *Int. J. Eng. Res. Tech. (IJERT)*, 9(4): 223-230.
- Rashidi, A., Rashidi, H. and Maghiar, M. 2014. “Productivity estimation of bulldozers using generalized linear mixed models”. *KSCE J. Civ. Eng.*, 18(6): 1580-1589.
- Rostami, J. 2016. “Performance prediction of hard rock Tunnel Boring Machines (TBMs) in difficult ground”. *Tunn. Undergr. Sp. Tech.*, 57: 173-182.
- Salimi, A., Rostami, J., Moormann, C. and Delisio, A. 2016. “Application of non-linear regression analysis and artificial intelligence algorithms for performance prediction of hard rock TBMs”. *Tunn. Undergr. Sp. Tech.*, 58: 236-246.
- Shahbazbeigi, M., Lotfian, F. and Rezaei-Rad, A. H. 2014. “Study of effective factors in the selection and productivity of road construction machines, case study: Hamedan-Tehran railway project”. *Second Conference on National Construction and Project Management, Tehran*.
- Sircar, A., Yadav, K., Rayavarapu, K., Bist, N. and Oza, H. 2021. “Application of machine learning and artificial intelligence in oil and gas industry”. *Petrol. Res.*, 6(4): 379-391.
- Sweis, R., Moarefi, A., Amiri, M. H., Moarefi, S. and Rawan, S. 2019. “Causes of delay in Iranian oil and gas projects: A root cause analysis”. *Int. J. Energ. Sector Manag.*, 13(3): 630-650.
- Thomas, H. R. and Kramer, D. F. 2002. “The manual of construction productivity measurement and performance evaluation”. SD-35, Construction Industry Institute (CII), Austin, TX.
- Wordmeter. 2024. <https://www.worldometers.info/gas/gas-reserves-by-country/>