

پیش‌بینی نشست سطحی خاک ناشی از حفاری تونل توسط دستگاه TBM با استفاده از تکنیک‌های یادگیری ماشین: مطالعه موردی خطوط ۲ و ۳ قطار شهری مشهد

سجاد حسینی^۱، جعفر بلوری بزاز^۲، امیر هوتی^۳

چکیده پیش‌بینی دقیق نشست سطحی ناشی از حفاری تونل در محیط‌های شهری، نقش مهمی در کاهش مخاطرات ژئوتکنیکی و حفاظت از سازه‌های مجاور دارد. در این پژوهش، حداکثر نشست سطحی ناشی از حفاری با دستگاه حفار مکانیزه سپری فشار تعادلی زمین (EPB) در خطوط ۲ و ۳ قطار شهری مشهد با استفاده از تکنیک‌های یادگیری ماشین پیش‌بینی شد. بدین منظور، پایگاه داده‌ای شامل ۲۹۲ نمونه از اطلاعات ژئوتکنیکی، مشخصات هندسی و پارامترهای عملیاتی دستگاه TBM گردآوری و ۲۰ متغیر ورودی مؤثر انتخاب شد. سه مدل شامل شبکه عصبی مصنوعی (ANN)، شبکه عصبی عمیق (DNN) و جنگل تصادفی (RF) توسعه یافته و عملکرد آن‌ها با یکدیگر مقایسه گردید. نتایج نشان داد مدل DNN با سه لایه پنهان بهترین عملکرد را داشته و با ضریب تعیین ۰/۹۸۹۶ و کمترین مقدار خطای میانگین مربعات، بیشترین دقت را در پیش‌بینی نشست ارائه می‌دهد. همچنین تحلیل حساسیت به روش‌های گارسون و اولدن، مهم‌ترین پارامترهای مؤثر بر نشست را شناسایی کرد. نوآوری این پژوهش در توسعه یک مدل داده‌محور مبتنی بر داده‌های واقعی متروی مشهد، تلفیق هم‌زمان پارامترهای ژئوتکنیکی و عملیاتی TBM، و ارزیابی عملکرد آن در مقایسه با روش تجربی پک است. نتایج نشان داد مدل پیشنهادی دقتی به‌مراتب بالاتر از روش پک داشته و می‌تواند به‌عنوان ابزاری مؤثر برای مدیریت ریسک و کنترل نشست در پروژه‌های تونل‌سازی شهری مورد استفاده قرار گیرد.

واژه‌های کلیدی نشست سطحی، حفاری مکانیزه تونل، شبکه عصبی عمیق (DNN)، جنگل تصادفی (RF)، متروی مشهد.

Prediction of TBM-Induced Surface Settlement Using Machine Learning Techniques: A Case Study of Mashhad Urban Railway (Lines 2 and 3)

Sajjad Hosseini, Jafar Bolouri Bazaz, Amir Hooti

Abstract Accurate prediction of surface settlement induced by urban tunneling is essential for mitigating geotechnical risks and protecting adjacent structures. This study investigates the prediction of maximum surface settlement caused by Earth Pressure Balance (EPB) tunneling in Mashhad Urban Railway Lines 2 and 3 using machine learning techniques. A database consisting of 292 samples was compiled from geotechnical investigations, geometric characteristics, and Tunnel Boring Machine (TBM) operational parameters, and 20 key input variables were selected. Three predictive models, including Artificial Neural Network (ANN), Deep Neural Network (DNN), and Random Forest (RF), were developed and compared. The results indicated that the DNN model with three hidden layers achieved the best performance, yielding a coefficient of determination (R^2) of 0.9896 and the lowest mean squared error. Sensitivity analysis based on the Garson and Olden methods was further conducted to identify the most influential parameters affecting settlement behavior. The novelty of this research lies in the development of a data-driven model based on real-world tunneling data from the Mashhad Metro, the integrated use of geotechnical and TBM operational parameters, and the quantitative comparison of machine learning predictions with the conventional Peck empirical method. The proposed DNN model demonstrated substantially higher accuracy than the Peck method and can serve as a reliable tool for settlement risk assessment and management in urban tunneling projects.

Keywords: Surface Settlement, Mechanized Tunneling, Deep Neural Network (DNN), Random Forest (RF), Mashhad Metro.

^۱ دانش آموخته کارشناسی ارشد گروه مهندسی عمران، دانشکده مهندسی، دانشگاه فردوسی مشهد، مشهد.

Email: bolouri@um.ac.ir

^۲ نویسنده مسئول، استاد، گروه مهندسی عمران، دانشکده مهندسی، دانشگاه فردوسی مشهد، مشهد.

^۳ دانشجوی دکتری، گروه مهندسی عمران، دانشکده مهندسی، دانشگاه فردوسی مشهد، مشهد.

۱-مقدمه

توسعه سریع شبکه‌های حمل‌ونقل شهری برای کاهش ترافیک و آلودگی هوا، اتکا به تونل‌سازی مکانیزه، به‌ویژه استفاده از ماشین‌های سپر تعادل فشار زمین^۱ را به‌شدت افزایش داده است. باوجود کارایی بالا، حفاری تونل ناگزیر باعث آزادسازی تنش و کاهش حجم در خاک پیرامونی شده که منجر به نشست سطح زمین می‌گردد. در صورتی‌که این نشست به‌دقت پیش‌بینی و کنترل نشود، می‌تواند آسیب‌های سازه‌ای جدی به ساختمان‌های مجاور، زیرساخت‌های حیاتی و سیستم‌های حمل‌ونقل سطحی وارد کند [1].

میزان و الگوی نشست سطحی، پدیده‌ای کاملاً غیرخطی است که تحت اندرکنش پیچیده‌ای از عوامل مختلف شامل هندسه تونل، ویژگی‌های ژئوتکنیکی خاک، شرایط آب زیرزمینی و پارامترهای عملکردی ماشین حفار تونل^۲ (TBM) قرار دارد. علاوه بر پدیده نشست، ویژگی‌های ژئوتکنیکی نظیر توزیع اندازه ذرات و چگالی خاک می‌توانند چالش‌های عملیاتی مهمی نظیر سایش شدید ابزارهای برشی ماشین‌های EPB را نیز به همراه داشته باشند که این امر مستقیماً بر راندمان و پارامترهای حفاری تأثیرگذار است [2]. به‌طور سنتی، برای تخمین حداکثر نشست سطحی از روش‌های تجربی که مهم‌ترین آن‌ها روش پک [3] است، و همچنین شبیه‌سازی‌های تحلیلی یا عددی استفاده می‌شود. بااین‌حال، اگرچه روش‌های تجربی یک مبنای اولیه و سریع ارائه می‌دهند، اما غالباً اندرکنش‌های پیچیده و به‌شدت غیرخطی بین ماشین و خاک را بیش از حد ساده‌سازی می‌کنند. به عنوان نمونه، مطالعات عددی نشان داده‌اند که نادیده گرفتن اندرکنش‌های پیچیده تونل و سازه‌های سطحی در روش‌های تحلیلی ساده، می‌تواند خطای محاسباتی به همراه داشته باشد، به‌طوری‌که لحاظ کردن عواملی نظیر سختی فونداسیون و وزن سازه‌های مجاور می‌تواند نشست‌های پیش‌بینی‌شده را تا ۱۵ درصد افزایش دهد [4].

برای غلبه بر این محدودیت‌ها، در سال‌های اخیر شاهد تغییر مسیر چشمگیری به سمت تکنیک‌های محاسباتی پیشرفته و هوش مصنوعی (AI) بوده‌ایم. به‌عنوان مثال، سوانساوات و اینشتین [5] شبکه‌های عصبی مصنوعی^۳ (ANN) را با موفقیت برای پیش‌بینی نشست سطحی به کار گرفتند که نشان‌دهنده پتانسیل بالای مدل‌های مبتنی بر داده است. در زمینه شبیه‌سازی‌های سه‌بعدی نیز پژوهش‌های موفقی برای درک فرایند حفاری نظیر مطالعات فارگنولی و همکاران [6] و آموروسی و همکاران [7] انجام شده است. در همین راستا و با تمرکز بر شرایط بومی پروژه، اسکندری، گشتاسبی و حوتی [8] با استفاده از مدل‌سازی اجزای محدود در نرم‌افزار ABAQUS، تأثیر فشار محفظه EPB بر نشست سطح و جابه‌جایی سینه‌کار را در تقاطع تونل‌های سه‌گانه خطوط ۲، ۳ و ۴ متروی مشهد ارزیابی کردند و نقش حیاتی پارامترهای عملکردی را در کنترل تغییر شکل‌ها به اثبات رساندند.

در سال‌های اخیر، پیشرفت الگوریتم‌های یادگیری ماشین موجب توسعه مدل‌های دقیق‌تری برای پیش‌بینی نشست ناشی از حفاری تونل شده است. چن و همکاران [9] با استفاده از شبکه‌های عصبی مصنوعی، نشست حداکثر ناشی از حفاری EPB را پیش‌بینی کرده و دقت بالای این روش را در مدل‌سازی روابط غیرخطی خاک و تونل نشان دادند. برزگری و

¹ Earth Pressure Balance (EPB)

² Tunnel Boring Machine

³ Artificial Neural Network

همکاران [10] با توسعه یک مدل ترکیبی هوش مصنوعی برای تونل‌های دوقلوی مکانیزه، عملکرد مناسبی در پیش‌بینی نشست سطحی گزارش کردند. محمودزاده و همکاران [11] نیز از روش‌های یادگیری ماشین برای پیش‌بینی نشست در پروژه‌های تونل‌سازی شهری استفاده کرده و قابلیت بالای مدل‌های داده‌محور را تأیید نمودند. در ادامه، ژانگ و همکاران [12] با مقایسه چندین الگوریتم هوشمند از جمله ANN و XGBoost نشان دادند که روش‌های نوین یادگیری ماشین می‌توانند دقت پیش‌بینی را به طور محسوسی افزایش دهند. همچنین لیو و همکاران [13] کارایی روش‌های یادگیری ماشین را حتی در مجموعه داده‌های محدود مورد بررسی قرار داده و نتایج امیدوارکننده‌ای ارائه کردند. در یکی از جدیدترین مطالعات، کیم و همکاران [14] با استفاده از الگوریتم‌های یادگیری ماشین همراه با بهینه‌سازی بیزی، دقت پیش‌بینی نشست سطحی در پروژه‌های تونل‌سازی شهری را بهبود بخشیدند. این روند پژوهشی نشان می‌دهد که استفاده از مدل‌های پیشرفته داده‌محور به یکی از مهم‌ترین رویکردهای پیش‌بینی رفتار زمین در پروژه‌های تونل‌سازی تبدیل شده است. ژائو و همکاران [15] نیز با استفاده از نسخه بهبودیافته الگوریتم Informer و بهینه‌سازی پارامترها، نتایج قابل‌توجهی در پیش‌بینی نشست ناشی از حفاری سبزی گزارش کرده‌اند که بیانگر گرایش روزافزون پژوهش‌ها به سمت مدل‌های یادگیری عمیق پیشرفته است.

کاربرد روش‌های هوشمند توسط محققانی نظیر آهنگری و همکاران [16] که از مدل‌های پیش‌بینی مختلفی برای تخمین پارامترهای نشست استفاده کردند، بیش‌ازپیش گسترش یافته است. موفقیت این رویکردها در خاک‌های محلی نیز به اثبات رسیده است؛ به عنوان نمونه، بلوری بزاز و فرخنده [17] در پژوهشی نشان دادند که با استفاده از شبکه‌های عصبی مصنوعی (ANN) می‌توان شاخص تراکم تحکیمی (C_c) خاک‌های رسی شهر مشهد را بر اساس ۱۹۰ مجموعه داده آزمایشگاهی پیش‌بینی کرد که این مدل توانست به دقت بسیار بالایی ($R=0.92$) و ($RMSE=0.021$) دست یابد.

در سال‌های اخیر، رویکردهای داده‌محور مبتنی بر یادگیری ماشین به دلیل توانایی بالا در مدل‌سازی روابط غیرخطی پیچیده، توجه روزافزونی در مسائل ژئوتکنیکی و به‌ویژه پیش‌بینی نشست ناشی از حفاری مکانیزه تونل جلب کرده‌اند. در میان این روش‌ها، شبکه‌های عصبی عمیق به دلیل برخورداری از لایه‌های پنهان متعدد، قابلیت استخراج الگوهای پیچیده میان پارامترهای ژئوتکنیکی، مشخصات هندسی تونل و پارامترهای عملیاتی TBM را دارا بوده و در سال‌های اخیر به عنوان یکی از رویکردهای امیدبخش در مدل‌سازی رفتار خاک مطرح شده‌اند. علاوه بر این، الگوریتم جنگل تصادفی (RF) نیز به دلیل پایداری مناسب، مقاومت در برابر بیش‌برازش و قابلیت تحلیل اهمیت متغیرها، به عنوان یکی از الگوریتم‌های پرکاربرد یادگیری ماشین در مسائل رگرسیون شناخته می‌شود و می‌تواند مبنای مناسبی برای مقایسه عملکرد مدل‌های پیشرفته‌تر فراهم آورد. از این رو، در پژوهش حاضر علاوه بر توسعه مدل DNN، عملکرد آن در مقایسه با مدل‌های ANN و RF مورد ارزیابی قرار گرفته است تا قابلیت مدل عمیق در پیش‌بینی نشست سطحی ناشی از حفاری مکانیزه با داده‌های واقعی پروژه‌های مترو مشهد به صورت جامع بررسی شود.

مروار مطالعات پیشین نشان می‌دهد که اگرچه استفاده از روش‌های یادگیری ماشین و هوش مصنوعی در پیش‌بینی نشست ناشی از حفاری تونل طی سال‌های اخیر رشد قابل توجهی داشته است، اما همچنان چند محدودیت اساسی مشاهده می‌شود. بخش قابل توجهی از پژوهش‌ها بر مجموعه داده‌های نسبتاً کوچک، تعداد محدود پارامترهای ورودی یا شرایط زمین‌شناسی خاص متمرکز بوده‌اند. همچنین در بسیاری از مطالعات، پارامترهای عملیاتی TBM و مشخصات ژئوتکنیکی خاک به صورت همزمان مورد بررسی قرار نگرفته‌اند و تحلیل حساسیت جامعی برای شناسایی سهم نسبی متغیرهای مؤثر ارائه نشده است. علاوه بر این، اگرچه الگوریتم‌های پیشرفته یادگیری عمیق در سال‌های اخیر توسعه یافته‌اند، اما کاربرد آن‌ها در پیش‌بینی نشست ناشی از حفاری مکانیزه بر پایه داده‌های واقعی پروژه‌های شهری هنوز محدود است. این موضوع ضرورت انجام پژوهش حاضر را برای توسعه و ارزیابی مدل‌های داده‌محور پیشرفته بر اساس داده‌های واقعی خطوط ۲ و ۳

قطار شهری مشهد نشان می‌دهد.

در راستای رفع این شکاف پژوهشی، مطالعه حاضر با استفاده از داده‌های واقعی حاصل از حفاری خطوط ۲ و ۳ قطار شهری مشهد انجام شده است. پایگاه‌داده جامع شامل ۲۹۲ نمونه کامل با ۲۰ متغیر ورودی در سه گروه پارامترهای هندسی، مشخصات ژئوتکنیکی خاک و پارامترهای عملکردی دستگاه TBM است.

نوآوری‌های اصلی این پژوهش شامل توسعه و ارزیابی مدل شبکه عصبی عمیق^۱ (DNN) برای پیش‌بینی نشست سطحی ناشی از حفاری مکانیزه در شرایط زمین‌شناسی شهر مشهد، بررسی هم‌زمان تأثیر پارامترهای ژئوتکنیکی و عملیاتی TBM در یک چارچوب داده‌محور، انجام تحلیل حساسیت با استفاده از روش‌های گارسون و اولدن برای شناسایی مهم‌ترین عوامل مؤثر بر نشست و مقایسه عملکرد مدل‌های ANN، DNN و RF و ارزیابی دقت مدل برتر در برابر روش تجربی پک است.

۲- روش شناسی

این بخش به تشریح چارچوب کلی پژوهش پرداخته و شامل فرایند آماده‌سازی داده‌ها، توصیف الگوریتم‌های یادگیری ماشین به‌کاررفته، معرفی روش تجربی پایه جهت مقایسه و همچنین معیارهای ارزیابی عملکرد مدل‌ها است.

۲-۱- آماده‌سازی داده‌ها و توصیف پایگاه‌داده

داده‌های مورد استفاده در این پژوهش از سه منبع اصلی شامل گزارش‌های مطالعات ژئوتکنیکی، سامانه ثبت پارامترهای عملکردی دستگاه حفار تمام مقطع (TBM) و نتایج سیستم مانیتورینگ نشست سطحی در خطوط ۲ و ۳ قطار شهری مشهد گردآوری شده است. داده‌های ژئوتکنیکی از ۶۸ گزارش مطالعات مکانیک خاک شامل ۱۸۵ گمانه ماشینی و دستی استخراج شد که دربرگیرنده نتایج آزمایش‌های صحرایی و آزمایشگاهی نظیر SPT، پرسیومتری، دانه‌بندی، حدود اتربرگ، برش مستقیم، آزمایش‌های سه‌محوری و سایر آزمایش‌های تکمیلی بود. همچنین داده‌های عملکردی TBM شامل فشار تعادلی زمین در جبهه کار (EPB)، نرخ نفوذ سرحفار (ROP)، نرخ پیشروی ماشین (Advance Rate)، درصد پرکنندگی گروت، گشتاور سرحفار و نیروی رانش محوری از گزارش‌های ثبت‌شده سامانه هدایت و کنترل ماشین حفار استخراج گردید. مقادیر نشست سطحی نیز از طریق سیستم مانیتورینگ پروژه و نقشه‌برداری دقیق به دست آمد به‌طوری که تغییرات ارتفاعی نقاط پایش نصب‌شده در سطح زمین توسط دوربین توتال استیشن نسبت به نقاط مبنای پایدار اندازه‌گیری و حداکثر نشست ثبت‌شده برای هر مقطع به‌عنوان متغیر هدف در نظر گرفته شد.

پس از تجمیع بیش از ۱۰۹۴۴ رکورد اولیه، فرایند کنترل کیفیت، حذف داده‌های پرت، استانداردسازی داده‌ها و انتخاب رکوردهای دارای اطلاعات کامل انجام شد. در نهایت ۲۹۲ نمونه کامل که به‌طور هم‌زمان شامل تمامی پارامترهای ژئوتکنیکی، عملیاتی TBM و مقادیر متناظر نشست سطحی بودند، برای آموزش و ارزیابی مدل‌های یادگیری ماشین انتخاب شدند. این پایگاه‌داده شامل ۲۰ متغیر ورودی در سه گروه مشخصات هندسی، پارامترهای ژئوتکنیکی خاک و پارامترهای عملکردی TBM است و متغیر هدف در تمامی مدل‌سازی‌ها حداکثر نشست سطحی (S_{max}) است.

به منظور تشکیل هر رکورد داده، نزدیک‌ترین گمانه ژئوتکنیکی به مقطع حفاری به عنوان نماینده شرایط زمین انتخاب شد و پارامترهای ژئوتکنیکی متناظر با تراز حفاری تونل از آن استخراج گردید. سپس داده‌های عملکردی TBM و مقادیر

^۱ Deep Neural Network

نشست اندازه‌گیری شده مربوط به همان محدوده مکانی به رکورد نهایی اختصاص یافتند.

انتخاب متغیرهای ورودی بر اساس سه معیار اصلی شامل مبانی فیزیکی و ژئوتکنیکی مؤثر بر مکانیزم ایجاد نشست، مطالعات پیشین معتبر در زمینه پیش‌بینی نشست ناشی از حفاری تونل و همچنین دسترس‌پذیری داده‌های واقعی پروژه انجام شد. اگرچه برخی از پارامترهای ژئوتکنیکی ممکن است دارای درجاتی از همبستگی آماری باشند، اما هر یک بیانگر جنبه متفاوتی از رفتار فیزیکی و مکانیکی خاک یا عملکرد دستگاه حفار هستند. همچنین با توجه به استفاده از مدل‌های یادگیری ماشین غیرخطی شامل ANN، DNN و RF که حساسیت کمتری نسبت به هم‌خطی متغیرها دارند، تمامی پارامترهای منتخب در فرآیند مدل‌سازی مورد استفاده قرار گرفتند. در ادامه نیز اهمیت نسبی متغیرها با استفاده از روش‌های گارسون و اولدن مورد ارزیابی قرار گرفت.

اگرچه پایگاه داده نهایی شامل ۲۹۲ نمونه معتبر است، بررسی مطالعات پیشین نشان می‌دهد که بسیاری از پژوهش‌های داده‌محور در زمینه پیش‌بینی نشست ناشی از حفاری تونل نیز بر پایه مجموعه‌داده‌هایی با ابعاد مشابه توسعه یافته‌اند. از این رو، حجم داده مورد استفاده در این پژوهش با مطالعات مشابه همخوانی داشته و به‌منظور افزایش قابلیت تعمیم مدل و کاهش احتمال بیش‌برازش، ارزیابی عملکرد تمامی مدل‌ها با استفاده از اعتبارسنجی متقابل K-Fold انجام شده است.

به‌منظور ارزیابی قابلیت تعمیم مدل‌ها و جلوگیری از وابستگی نتایج به تقسیم‌بندی داده‌ها، عملکرد تمامی مدل‌های یادگیری ماشین با استفاده از روش اعتبارسنجی متقابل K-Fold مورد ارزیابی قرار گرفت. این روش امکان بررسی پایداری مدل‌ها و مقایسه منصفانه عملکرد الگوریتم‌های مختلف را بر روی پایگاه داده ۲۹۲ نمونه‌ای فراهم ساخت.

انتخاب متغیرهای ورودی بر مبنای مطالعات پیشین، دانش مهندسی ژئوتکنیک و نقش فیزیکی آن‌ها در مکانیزم ایجاد نشست سطحی انجام شد. همچنین تنها پارامترهایی در مدل‌سازی نهایی مورد استفاده قرار گرفتند که علاوه بر اهمیت مهندسی، تعداد داده‌های کافی و کیفیت مناسب در پایگاه داده پروژه برای آن‌ها وجود داشت.

به‌منظور تشکیل هر رکورد داده، نزدیک‌ترین گمانه ژئوتکنیکی به مقطع حفاری به عنوان نماینده شرایط زمین انتخاب شد. سپس پارامترهای ژئوتکنیکی متناظر با لایه‌های واقع در محدوده تراز حفاری تونل از آن گمانه استخراج گردید. داده‌های عملکردی TBM نیز از بخش متناظر با همان محدوده حفاری اخذ شد و در نهایت مقادیر نشست اندازه‌گیری شده از سیستم مانیتورینگ به همان مقطع اختصاص یافت. بدین ترتیب، هر رکورد نهایی شامل مجموعه‌ای یکپارچه از مشخصات هندسی، پارامترهای ژئوتکنیکی، داده‌های عملکردی TBM و مقدار نشست اندازه‌گیری شده در یک محدوده مکانی مشخص است.

جدول ۱ پارامترهای ورودی و خروجی

نماد	پارامترها	طبقه‌بندی
D_t	عمق تونل	مشخصات هندسی
Z_1	عمق شروع لایه	
Z_2	عمق پایان لایه	
FC	درصد ریزدانه خاک	پارامترهای ژئوتکنیکی خاک
LL	حد روانی	
PL	نشانه خمیری	
γ_d	وزن مخصوص خشک	
ω	درصد رطوبت	
c	چسبندگی	
ϕ	زاویه اصطکاک داخلی	
E_p	مدول الاستیسیته پرسیمتری	

نماد	پارامترها	طبقه بندی
N_{SPT}	عدد ^۱ SPT اصلاح شده	
S_r	درصد اشباع	
G_s	وزن مخصوص ویژه خاک	
P_f	فشار تعادلی زمین در چپه کار	پارامترهای عملکردی TBM
P_r	نرخ نفوذ ^۲ سر حفار	
A_r	نرخ پیشروی ^۳ ماشین	
G_f	درصد پرکنندگی تزریق	
T_c	نیروی گشتاور سر حفار	
F_{ax}	نیروی رانش ^۴ محوری ماشین	
S_{max}	نشست سطحی پیشینه	پارامتر خروجی

به منظور نشان دادن تنوع و توزیع آماری مجموعه داده، آمار توصیفی شامل حداقل، حداکثر، میانگین، انحراف معیار و ضریب تغییرات^۵ (COV) برای تمامی متغیرها در جدول ۲ خلاصه شده است.

جدول ۲ آمار توصیفی و ضریب تغییرات پارامترهای ورودی و خروجی داده ها

پارامتر	یکا	کمینه	بیشینه	میانگین	انحراف معیار	COV
عمق تونل	m	۴/۷	۴۵	۳۰/۶۴	۱۴/۱۵	۰/۴۶
درصد ریزدانه خاک	%	۱۱/۴	۹۸	۵۲/۵۹	۳۳/۰۱	۰/۶۳
حد روانی	%	۰	۴۲	۲۱/۷۳	۱۰/۸۸	۰/۵
نشانه خمیری	%	۰	۱۷/۷	۶/۵۳	۴/۵۸	۰/۷
وزن مخصوص خشک	g/cm ³	۱/۵۱	۲/۱	۱/۸۱	۰/۱۸	۰/۱
درصد رطوبت	%	۴/۵	۲۹/۱	۱۴/۴۴	۸/۵۵	۰/۵۹
چسبندگی	kg/cm ²	۰/۰۴	۰/۵۵	۰/۱۷	۰/۱۵	۰/۸۸
زاویه اصطکاک داخلی	°	۱	۳۹/۱	۲۵/۰۵	۱۱/۷۴	۰/۴۷
مدول الاستیسیته پرسیمتری	kg/cm ²	۹۷/۵	۵۶۴/۵	۳۹۵/۴۹	۱۲۰/۹۷	۰/۳۱
عدد اصلاح شده	-	۳	۲۹	۲۰/۲۲	۶/۰۴	۰/۳
درصد اشباع	%	۶	۱۰۰	۷۵/۶۵	۳۰/۳۲	۰/۴

^۱ Standard Penetration Test

^۲ Rate of Penetration

^۳ Advance Rate

^۴ Thrust Force

^۵ Coefficient of Variation

پارامتر	یکا	کمینه	بیشینه	میانگین	انحراف معیار	COV
وزن مخصوص ویژه خاک	-	۲/۶	۲/۷۲	۲/۶۷	۰/۰۲	۰/۰۱
فشار تعادلی زمین در جبهه کار	Bar	۰/۲۵۹	۱/۷۵	۱/۱۶	۰/۳۷	۰/۳۲
نرخ نفوذ سر حفار	mm/rpm	۵/۶۶	۴۵/۵	۲۴/۶۶	۱۰/۶۹	۰/۴۳
نرخ پیشروی ماشین	mm/min	۸/۴۹	۴۸	۲۶/۸۲	۱۰/۷۱	۰/۴
درصد پرکنندگی تزریق	%	۱۰۰/۱۴	۲۸۳/۵۹	۱۸۷/۲۷	۰/۴۴	۰/۰۰۲
نیروی گشتاور سر حفار	KN.m	۲۸۶۸/۳۳	۹۵۶۰	۶۳۴۸/۰۹	۲۰۸۷/۲۹	۰/۳۳
نیروی رانش محوری ماشین	KN	۱۳۳۲۷/۱۴	۳۶۱۹۹	۲۶۸۰۷/۵۸	۵۹۰۷/۵۸	۰/۲۲
نشست سطحی بیشینه	m	۰	۰/۰۲۷	۰/۰۱۳	۰/۰۰۷۸	۰/۶

۲-۲- مدل‌های یادگیری ماشین


در این پژوهش، سه مدل قدرتمند یادگیری ماشین شامل شبکه عصبی مصنوعی (ANN)، شبکه‌های عصبی عمیق (DNN) و جنگل تصادفی (RF) به منظور پیش‌بینی نشست سطح زمین ناشی از TBM توسعه داده شده‌اند.

مدل شبکه‌ی عصبی مصنوعی با استفاده از یک معماری استاندارد پیش‌خور پس‌انتشار^۱ و یک لایه‌ی پنهان توسعه یافت. به منظور ارتقای هرچه بیشتر قابلیت پیش‌بینی و همچنین درک روابط بسیار غیرخطی میان پارامترهای ورودی عملیاتی، هندسی، ژئوتکنیکی و نشست سطح حاصل از آن‌ها، مدل‌های شبکه‌ی عصبی عمیق با دو و سه لایه‌ی پنهان نیز ایجاد شدند. طی یک فرایند دقیق بهینه‌سازی ساختاری، مشخص شد که معماری بهینه برای کارآمدترین مدل DNN (مدلی با سه لایه‌ی پنهان)، به ترتیب شامل ۳۲، ۲۱ و ۱۱ نورون در لایه‌های پنهان خود است. از توابع فعال‌سازی مناسب جهت پردازش غیرخطی‌ها استفاده شد و شبکه‌ها با هدف به حداقل رساندن خطای پیش‌بینی، آموزش داده شدند. برای به تصویر کشیدن پیچیدگی ساختاری، معماری مدل‌های توسعه‌یافته‌ی ANN و DNN در شکل‌های ۱ و ۲ نشان داده شده است.


هر دو مدل ANN و DNN از نوع شبکه عصبی پیش‌خور با الگوریتم پس‌انتشار خطا هستند. در لایه‌های پنهان از تابع فعال‌سازی تانژانت هیپربولیک سیگموئیدی (tansig) و در لایه خروجی از تابع خطی (purelin) استفاده شد. معیار آموزش مدل‌ها کمینه‌سازی میانگین مربعات خطا (MSE) بود. داده‌ها با روش اعتبارسنجی متقابل^۲ لایه‌ی ارزیابی شدند و در هر تکرار، مکانیزم توقف زودهنگام برای جلوگیری از بیش‌برازش به کار رفت. معماری نهایی مدل ANN شامل یک لایه پنهان با ۲۰ نورون بود. مدل بهینه DNN نیز شامل سه لایه پنهان با ۲۰، ۱۵ و ۱۰ نورون، یک لایه ورودی با ۲۰ متغیر و یک لایه خروجی برای پیش‌بینی S_{max} بود. تمام مدل‌سازی‌ها در محیط MATLAB انجام شد.

^۱ Feed Forward Back Propagation

^۲ 10-Fold Cross Validation



شکل ۱ ساختار نهایی مدل بهینه ANN



شکل ۲ ساختار نهایی مدل بهینه DNN با سه لایه پنهان

علاوه بر شبکه‌های عصبی، الگوریتم جنگل تصادفی نیز به عنوان یک روش یادگیری تجمعی مقاوم مورد استفاده قرار گرفت. این الگوریتم با ایجاد تعداد زیادی درخت تصمیم و میانگین‌گیری از نتایج آن‌ها، موجب کاهش بیش برآزش و افزایش قدرت تعمیم مدل می‌شود.

به منظور ارزیابی دقیق عملکرد مدل‌ها و جلوگیری از بیش برآزش^۱، از روش اعتبارسنجی متقابل K-Fold^۲ با مقدار K برابر ۱۰ در تمامی مدل‌ها استفاده شد. این روش موجب می‌شود عملکرد مدل‌ها بر روی زیرمجموعه‌های مختلف داده بررسی شده و ارزیابی واقع‌بینانه‌تری از دقت پیش‌بینی حاصل گردد.

۲-۳- روش تجربی پک

برای مقایسه عملکرد مدل‌های هوشمند، از روش تجربی پک به عنوان مدل مبنا استفاده شد. در این روش فرض می‌شود پروفیل نشست عرضی سطح زمین از توزیع گاوسی^۳ پیروی می‌کند. نشست سطحی بیشینه در بالای محور تونل از رابطه زیر محاسبه می‌شود: [3]

$$S_{max} = \frac{0.313 \cdot V_L \cdot D^2}{k \cdot z_0} \quad (1)$$

که در آن V_L مقدار افت حجم^۴ است و درصدی از حجم تونل است که به دلیل عواملی مانند جابه‌جایی خاک به سمت تونل، فشرده شدن خاک و خطاهای اجرایی، به صورت نشست در سطح زمین ظاهر می‌شود، D قطر تونل، z_0 عمق محور

^۱ Overfitting

^۲ K-Fold Cross Validation

^۳ Gaussian Distribution

^۴ Volume Loss

مرکزی تونل از سطح زمین و K ضریب پهنای تشنگ نشست^۱ است. اگرچه روش پک به طور گسترده مورد استفاده قرار می‌گیرد، اما به دلیل ساده‌سازی رفتار پیچیده خاک و ماشین حفار، بیشتر به عنوان یک روش پایه جهت مقایسه با مدل‌های پیشرفته یادگیری ماشین مناسب است.

۴-۲- معیارهای ارزیابی عملکرد مدل‌ها

برای ارزیابی کمی عملکرد مدل‌های توسعه‌یافته، از دو معیار آماری میانگین مربعات خطا^۲ (MSE) و ضریب تعیین^۳ (R^2) استفاده شد.

معیار MSE میزان خطای پیش‌بینی مدل را نشان می‌دهد و مقادیر کمتر آن بیانگر دقت بالاتر مدل است. همچنین ضریب تعیین R^2 میزان توانایی مدل در توضیح تغییرات متغیر هدف را مشخص می‌کند و مقادیر نزدیک‌تر به ۱ نشان‌دهنده عملکرد بهتر مدل هستند. روابط این دو معیارهای ذکر شده به شرح زیر است:

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \bar{y}_i)^2 \quad (2)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \bar{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (3)$$

که در آنها N تعداد کل نمونه‌ها، y_i میزان واقعی نشست اندازه‌گیری شده، $\bar{y}_i$ میزان نشست پیش‌بینی شده و $\bar{y}$ میانگین مقادیر واقعی است.

۳- بحث و نتیجه‌گیری

۳-۱- مقایسه عملکرد مدل‌های یادگیری ماشین

عملکرد مدل‌های توسعه‌یافته شامل ANN، DNN و RF با استفاده از معیارهای R^2 و MSE ارزیابی شد. نتایج نشان داد که مدل DNN با سه‌لایه پنهان و معماری بهینه [۱۱ ۲۱ ۳۲] بهترین عملکرد را در میان تمامی مدل‌ها داشته و به بالاترین ضریب تعیین ($R^2=0.9896$) و پایین‌ترین مقدار MSE در داده‌های تست دست پیدا کند.

نتایج به‌وضوح نشان می‌دهد که استفاده از معماری‌های عمیق‌تر، توانایی مدل در یادگیری روابط پیچیده و غیرخطی میان متغیرهای ورودی و نشست سطحی را به طور قابل توجهی افزایش داده است. در مقابل، مدل جنگل تصادفی با وجود عملکرد مناسب، دقت پایین‌تری نسبت به مدل‌های مبتنی بر شبکه عصبی عمیق داشت. همچنین مدل ANN با یک لایه پنهان عملکرد قابل قبولی ارائه داد، اما در مقایسه با DNN سه‌لایه از توانایی کمتری در مدل‌سازی روابط پیچیده برخوردار بود.

جدول ۳ خلاصه‌ای از مقادیر معیارهای ارزیابی برای داده‌های آزمون نشان می‌دهد.

جدول ۳ مقایسه عملکرد نهایی مدل‌های توسعه‌یافته بر روی داده‌های آزمون

مدل	معماری بهینه	R^2 آزمون	MSE آزمون
-----	--------------	-------------	-----------

^۱ Trough Width Parameter


^۲ Mean Squared Error

^۳ Coefficient of Determination


ANN	[۲۴]	۰/۹۶۱	$5/53 \times 10^{-10}$
DNN دولایه	[۱۶ ۸]	۰/۹۳۷	$7/56 \times 10^{-6}$
DNN سه لایه	[۳۲ ۲۱ ۱۱]	۰/۹۸۹	$6/۸۹ \times 10^{-7}$
RF	۱۶۳ درخت	۰/۸۷۶	$4/۱۸ \times 10^{-5}$

۲-۳- تحلیل نمودارهای پراکندگی و توزیع خطا


به منظور ارزیابی بصری دقت مدل‌ها، نمودارهای پراکندگی بین مقادیر واقعی و مقادیر پیش‌بینی شده نشست سطحی ترسیم گردید. نتایج نشان داد که نقاط مربوط به مدل DNN سه لایه، بیشترین انطباق را با خط ایده‌آل دارند که این موضوع بیانگر توانایی بالای مدل در تعمیم‌پذیری و پیش‌بینی دقیق داده‌های جدید است.



شکل ۳ نمودارهای رگرسیون برای داده‌های آموزش، اعتبارسنجی، آزمون و کل برای مدل ANN (محور قائم پیش‌بینی مقدار نشست شبکه و محور افقی نشست برداشت شده از نقشه‌برداری دقیق)



شکل ۴ نمودار رگرسیون مدل بهینه DNN با سه لایه پنهان (محور قائم پیش‌بینی مقدار نشست شبکه و محور افقی نشست برداشت شده از نقشه‌برداری دقیق)



شکل ۵ نمودار مقادیر واقعی و مقادیر پیش‌بینی‌شده توسط جنگل تصادفی


شکل ۳ نتایج رگرسیون مدل ANN را برای مجموعه‌های آموزش، اعتبارسنجی، آزمون و کل داده‌ها نشان می‌دهد. مقادیر ضریب تعیین به ترتیب برابر با ۰/۹۸۲۶، ۰/۹۶۴۷، ۰/۹۶۱۵ و ۰/۹۷۵۸ به دست آمده است که بیانگر توانایی مناسب مدل در یادگیری رابطه بین پارامترهای ورودی و نشست سطحی است. نزدیکی نسبی نقاط به خط برازش و مقادیر بالای

ضریب تعیین نشان می‌دهد که مدل ANN توانسته است بخش قابل توجهی از رفتار غیرخطی مسئله را شبیه‌سازی کند. با این حال، پراکندگی بیشتر نقاط در مقایسه با مدل DNN بیانگر محدودیت نسبی این مدل در استخراج روابط پیچیده‌تر میان پارامترهای ژئوتکنیکی و عملیاتی TBM است.

به همین ترتیب در شکل ۴ مشاهده می‌شود، مدل DNN با سه‌لایه پنهان عملکرد بسیار مطلوبی در تمامی مجموعه داده‌ها ارائه کرده است. ضرایب تعیین برابر با ۰/۹۹۹۹ برای داده‌های آموزش، ۰/۹۹۱۱ برای اعتبارسنجی و ۰/۹۸۹۶ برای آزمون به دست آمده‌اند که نشان‌دهنده دقت بسیار بالای مدل در پیش‌بینی نشست سطحی است. تمرکز نقاط در اطراف خط $x=y$ و نزدیکی مقادیر پیش‌بینی شده به مقادیر واقعی نشان می‌دهد که مدل قادر به یادگیری روابط پیچیده و غیرخطی حاکم بر اندرکنش خاک و ماشین حفار بوده است. همچنین اختلاف اندک بین نتایج آموزش و آزمون بیانگر قابلیت تعمیم مناسب مدل و عدم بروز بیش‌برازش قابل توجه در فرایند آموزش است.

شکل ۵ مقایسه مقادیر واقعی نشست و مقادیر پیش‌بینی شده توسط مدل جنگل تصادفی را نشان می‌دهد. مقدار ضریب تعیین برابر با ۰/۸۷۶۹ به دست آمده است که اگرچه بیانگر عملکرد قابل قبول مدل است، اما در مقایسه با مدل‌های ANN و DNN دقت کمتری دارد. پراکندگی بیشتر نقاط پیرامون خط مرجع $x=y$ نشان می‌دهد که مدل جنگل تصادفی در تخمین برخی مقادیر حدی نشست با خطای بیشتری مواجه بوده است. این موضوع بیانگر آن است که اگرچه الگوریتم RF در شناسایی روند کلی داده‌ها موفق عمل کرده، اما در مدل‌سازی روابط پیچیده و چندبعدی میان پارامترهای ژئوتکنیکی و عملیاتی TBM نسبت به مدل DNN کارایی پایین‌تری داشته است.

همچنین تحلیل هیستوگرام خطا نشان داد که توزیع خطاهای مدل DNN حول مقدار صفر متمرکز بوده و دامنه خطاها محدود است؛ موضوعی که دقت و پایداری بالای مدل را تأیید می‌کند.



شکل ۶ نمودار هیستوگرام توزیع خطای مدل بهینه DNN سه‌لایه

شکل ۶ توزیع خطاهای پیش‌بینی مدل DNN بهینه را در قالب هیستوگرام نشان می‌دهد. تمرکز عمده خطاها (اختلاف مقدار پیش‌بینی شده توسط مدل با مقدار واقعی) در اطراف مقدار صفر و شکل تقریباً متقارن توزیع بیانگر آن است که مدل

فاقد سوگیری سیستماتیک در بیش برآورد یا کم برآورد نشست ها است. همچنین توزیع زنگوله ای خطاها و کاهش فراوانی با فاصله گرفتن از صفر نشان می دهد که اکثر پیش بینی های مدل دارای خطای اندک بوده اند. این ویژگی، همراه با مقادیر بالای ضریب تعیین، بیانگر پایداری و قابلیت اطمینان بالای مدل DNN در پیش بینی نشست سطحی ناشی از حفاری مکانیزه تونل است.

۳-۳- مقایسه با روش تجربی پک

عملکرد مدل بهینه DNN با روش تجربی پک مقایسه شد و نتایج نشان داد که روش پک، اگرچه برای تخمین اولیه نشست مفید است، اما در بسیاری از موارد به دلیل فرضیات ساده کننده، قادر به مدل سازی دقیق رفتار واقعی زمین نیست. در مقابل، مدل DNN توسعه یافته در این پژوهش توانست با دقت بسیار بالاتر، روابط پیچیده میان پارامترهای ورودی و نشست سطحی را شناسایی و مدل سازی کند. اختلاف مشاهده شده میان نتایج دو روش بیانگر محدودیت روابط تجربی ساده در مدل سازی رفتار پیچیده و غیرخطی اندرکنش خاک و TBM است. از آنجا که روش پک بر پایه تعداد محدودی پارامتر تجربی توسعه یافته، هدف از این مقایسه اثبات برتری مطلق مدل DNN نبوده، بلکه نشان دادن ظرفیت مدل های داده محور در بهره گیری هم زمان از اطلاعات ژئوتکنیکی، هندسی و عملیاتی پروژه برای بازنمایی دقیق تر رفتار واقعی نشست سطحی بوده است.

به منظور ارائه یک مقایسه کیفی میان روش تجربی پک و مقادیر واقعی ثبت شده در پروژه، شش مقطع از پایگاه داده انتخاب و نتایج پیش بینی شده با مقادیر اندازه گیری شده در جدول ۴ مقایسه شد. با توجه به اینکه روش پک بر پایه روابط تجربی ساده توسعه یافته و صرفاً بازه ای تقریبی از نشست را بر اساس شرایط کلی پروژه ارائه می دهد، اجرای این مقایسه برای تمامی ۲۹۲ رکورد، تأثیر قابل توجهی بر نتیجه گیری های پژوهش نداشته و تنها موجب افزایش حجم مقاله می شد. بنابراین، ارزیابی کمی عملکرد مدل ها بر اساس کل مجموعه داده و شاخص های آماری ارائه شده در بخش نتایج انجام شده است.

جدول ۴ مقایسه عملکرد مدل بهینه DNN با روش تجربی پک


شناسه نقطه	نوع خاک	عمق تاج (m)	قطر تونل (m)	V_L (%)	K	i (m)	نشست واقعی (mm)	نشست DNN (mm)	تخمین پک (mm)
۱	SM	۳۳/۵	۹/۴	۰/۲ - ۱	۰/۲۵	۹/۵۵	۲۶/۳	۲۵/۹۷	۷/۴ - ۳۶/۹
۲	CL	۳۷/۵	۹/۴	۱ - ۲	۰/۵	۲۱/۱	۱۰	۹/۸۹	۱۶/۷ - ۳۳/۴
۳	SM	۳۰	۹/۴	۰/۲ - ۱	۰/۲۵	۸/۶۸	۷/۴	۷/۳۸	۸/۱ - ۴۰/۷
۴	SM	۴۵	۹/۴	۰/۲ - ۱	۰/۲۵	۱۲/۴۳	۲۱	۲۰/۸۳	۵/۷ - ۲۸/۴
۵	CL	۵/۶	۹/۴	۱ - ۲	۰/۵	۵/۱۵	۲۸	۲۷/۲۳	۶۸/۴ - ۱۳۶/۸
۶	SM	۸	۹/۴	۰/۲ - ۱	۰/۲۵	۳/۱۸	۱۲	۱۱/۷۶	۲۲/۲ - ۱۱۱

همان طور که در جدول ۴ مشاهده می شود، رویکرد تجربی از ویژگی های هندسی و ژئوتکنیکی (مانند نوع خاک، عمق تاج تونل و قطر تونل) در کنار پارامترهای اختصاصی روش پک، شامل درصد کاهش حجم (V_L)، ضریب پهنای تشنگ نشست (K) و فاصله نقطه عطف گودی نشست تا خط مرکزی تونل (i) بهره می گیرد. با این پارامترها، روش پک بازه تخمینی گسترده ای را برای بیشینه نشست سطحی ارائه می دهد. این دامنه وسیع، موجب ایجاد عدم قطعیت قابل توجهی در کاربردهای مهندسی شهری می شود، جایی که دقت در حد میلی متر اغلب مورد نیاز است.

همان گونه که در جدول ۴ مشاهده می شود، اختلاف قابل توجهی بین مقادیر برآورد شده توسط روش تجربی پک و

مقادیر واقعی نشست وجود دارد. علت اصلی این موضوع آن است که روش پک بر پایه روابط تجربی ساده شده و فرض توزیع گاوسی نشست توسعه یافته و تأثیر بسیاری از عوامل مؤثر نظیر مشخصات ژئوتکنیکی خاک، تغییرات لایه بندی زمین و پارامترهای عملکردی دستگاه TBM را به صورت مستقیم در نظر نمی گیرد. در مقابل، مدل DNN با استفاده از ۲۰ متغیر ورودی و داده های واقعی حاصل از خطوط ۲ و ۳ قطار شهری مشهد آموزش دیده و قادر است روابط پیچیده و غیرخطی میان شرایط زمین و پارامترهای اجرایی حفاری را شناسایی کند. از این رو، مقادیر پیش بینی شده توسط مدل DNN تطابق بسیار بیشتری با مقادیر واقعی نشست داشته و عملکرد آن نسبت به روش تجربی پک به طور محسوس برتر است.

به منظور درک بصری بهتر این تفاوت ها، شکل ۷ مقایسه ای میان نشست واقعی، پیش بینی مدل DNN و برآورد روش پک برای ۶ نقطه را نشان می دهد. در این نمودار، ستون های خاکستری رنگ نشان دهنده میانگین بازه تخمینی روش پک هستند و خطوط خطا^۱ رسم شده بر روی آن ها، نمایانگر حداقل و حداکثر دامنه نشست محاسبه شده توسط این روش تجربی هستند.




شکل ۷ مقایسه نشست واقعی، پیش بینی مدل DNN و محدوده برآورد روش تجربی پک در نقاط پایش منتخب

همان گونه که در شکل ۷ مشاهده می شود، مقادیر پیش بینی شده توسط مدل DNN در اکثر نقاط پایش تطابق بسیار خوبی با نشست های اندازه گیری شده دارند. در مقابل، مقادیر برآورد شده توسط روش تجربی پک در بسیاری از نقاط دارای اختلاف قابل توجهی با مقادیر واقعی هستند. این موضوع نشان می دهد که روش پک به دلیل اتکا به فرضیات ساده سازی شده و عدم در نظر گرفتن هم زمان پارامترهای ژئوتکنیکی و عملیاتی TBM، قادر به بازنمایی کامل رفتار واقعی زمین نیست. در حالی که مدل DNN با بهره گیری از داده های واقعی پروژه و یادگیری روابط غیرخطی میان متغیرها، توانسته است دقت بسیار بالاتری در پیش بینی نشست سطحی ارائه دهد.


۴-۳- تحلیل حساسیت پارامترها

¹ Error Bars

به منظور غلبه بر ماهیت جعبه سیاه^۱ شبکه‌های عصبی و درک روابط فیزیکی حاکم، تحلیل حساسیت جامعی بر روی مدل ANN انجام شد. جدول ۵ به همراه شکل‌های ۸ و ۹، اهمیت نسبی متغیرهای ورودی را با استفاده از دو رویکرد مجزا، شامل الگوریتم گارسون^۲ (Garson) و اولدن^۳ (Olden) نشان می‌دهند. به منظور حفظ انسجام بصری و جلوگیری از شلوغی محورها در نمودارها، از نمادهای اختصاری برای نمایش پارامترها استفاده شده است.



شکل ۸ نمودار اهمیت نسبی متغیرهای ورودی بر اساس الگوریتم گارسون



شکل ۹ نمودار تحلیل حساسیت و جهت تأثیر متغیرهای ورودی بر اساس روش اولدن

^۱ Black Box

^۲ Garson Algorithm

^۳ Olden Algorithm

درحالی که الگوریتم گارسون (شکل ۸) تنها بزرگی مطلق و درصد اهمیت نسبی هر پارامتر را محاسبه می کند، روش اولدن (شکل ۹) علاوه بر بزرگی اثر، جهت تأثیر (همبستگی مستقیم یا معکوس) را نیز به خوبی ارزیابی می کند. برای مثال، همان گونه که در شکل ها و جدول ۵ مشاهده می شود، متغیر نیروی رانش محوری ماشین (F_{ax}) در هر دو روش در رتبه نخست تأثیرگذاری قرار گرفته است. الگوریتم گارسون بیشترین اهمیت نسبی معادل ۶۶/۶٪ را به این پارامتر اختصاص داده و روش اولدن نیز مقدار امتیاز ۲/۷۶۸- را همراه با اثر معکوس نشان می دهد که به این معنا که افزایش این پارامتر موجب کاهش قابل توجه نشست سطحی می شود.

در رتبه های بعدی، پارامترهایی نظیر وزن مخصوص خشک (γ_d)، نرخ نفوذ سرحفار (P_r) و نرخ پیشروی ماشین (A_r) دارای تأثیر مستقیم بر نشست هستند. مقایسه این دو روش نشان می دهد که مدل نه تنها قادر به شناسایی مؤثرترین عوامل است، بلکه منطق درونی شبکه عصبی را نیز با واقعیت های ژئوتکنیکی کاملاً همسو می سازد.

اگرچه تحلیل حساسیت مبتنی بر روش اولدن اثر معکوس نیروی رانش محوری (F_{ax}) را بر نشست سطحی نشان می دهد، این نتیجه از دیدگاه مکانیزم حفاری EPB-TBM نیز قابل تفسیر است. در شرایط بهره برداری مناسب، افزایش کنترل شده نیروی رانش موجب پایداری بهتر جبهه حفاری، کاهش افت فشار موضعی و محدود شدن اتلاف حجم خاک پیرامون تونل می شود که در نهایت می تواند به کاهش نشست سطحی منجر گردد. با این حال، از آنجا که پارامترهای عملیاتی TBM دارای وابستگی متقابل با ویژگی های ژئوتکنیکی خاک هستند، بخشی از رتبه بندی به دست آمده ممکن است ناشی از همبستگی میان متغیرهای ورودی باشد و بنابراین تفسیر نتایج باید همراه با شرایط اجرایی پروژه انجام گیرد. این یافته با نتایج پژوهش های ژانگ و همکاران [10] و لیو و همکاران [11] نیز همخوانی دارد؛ به طوری که این مطالعات نیز پارامترهای عملیاتی دستگاه حفار از جمله نرخ پیشروی، نرخ نفوذ، فشار تزریق گروت، فشار جبهه و نیروی رانش را در زمره مهم ترین عوامل مؤثر بر پیش بینی نشست سطحی معرفی کرده اند.

جدول ۵ نتایج تحلیل های حساسیت برای مدل ANN

رتبه اهمیت	الگوریتم گارسون		روش اولدن (امتیاز خالص و جهت)	
	پارامتر ورودی	درصد نسبی (%)	پارامتر ورودی	امتیاز اولدن
۱	نیروی رانش محوری ماشین	۶/۶۶	نیروی رانش محوری ماشین	۲/۷۶۸
۲	فشار تعادلی زمین در جبهه کار	۶/۱	وزن مخصوص خشک	۱/۵۲۴
۳	درصد اشباع	۶/۰۲	نرخ نفوذ سرحفار	۱/۳۰۳
۴	عمق شروع لایه	۵/۶۴	نرخ پیشروی ماشین حفار	۱/۰۶۵
۵	نرخ نفوذ سرحفار	۵/۴۸	درصد پرکنندگی تزریق	۱/۰۵
۶	وزن مخصوص ویژه	۵/۴۲	عمق شروع لایه	۰/۸۷۳
۷	نیروی گشتاور سرحفار	۵/۲۲	عمق پایان لایه	۰/۷۶۱
۸	مدول الاستیسیته پرسبومتری	۵/۲۲	وزن مخصوص ویژه	۰/۷۰۸
۹	نرخ پیشروی ماشین حفار	۵/۰۳	فشار تعادلی زمین در جبهه کار	۰/۶۹۲
۱۰	زاویه اصطکاک داخلی	۴/۸۶	حد روانی	۰/۶۶۲
۱۱	چسبندگی خاک	۴/۸	نشانه خمیری	۰/۵۸۴
۱۲	عمق پایان لایه	۴/۷۷	چسبندگی خاک	۰/۵۴۳
۱۳	عمق تونل	۴/۶۷	عدد اصلاح شده SPT	۰/۵۰۳
۱۴	حد روانی	۴/۶۴	نیروی گشتاور سرحفار	۰/۴۸۲

۱۵	درصد پرکنندگی تزریق	۴/۶	درصد ریزدانه	۰/۴۲۷	مستقیم
۱۶	درصد ریزدانه	۴/۶	زاویه اصطکاک داخلی	۰/۳۷۶	مستقیم
۱۷	وزن مخصوص خشک	۴/۲۶	مدول الاستیسیته پرسپومتري	۰/۳۳	مستقیم
۱۸	عدد اصلاح شده SPT	۴/۲۶	درصد اشباع	۰/۲۶۸	مستقیم
۱۹	درصد رطوبت	۳/۹	درصد رطوبت	۰/۱۵۴	معکوس
۲۰	نشانه خمیری	۳/۸۵	عمق تونل	۰/۱۰۹	مستقیم

۴- نتیجه گیری

در این پژوهش، به منظور پیش بینی نشست سطحی ناشی از حفاری مکانیزه تونل، سه مدل یادگیری ماشین شامل ANN، DNN و RF بر پایه داده های واقعی خطوط ۲ و ۳ قطار شهری مشهد توسعه داده شد. نتایج نشان داد که تمامی مدل ها از توانایی مناسبی در پیش بینی نشست برخوردارند؛ با این حال، مدل شبکه عصبی عمیق با سه لایه پنهان با ضریب تعیین ۰/۹۸۹۶ در مجموعه آزمون، بهترین عملکرد را ارائه داد و با دستیابی به بیشترین ضریب تعیین و کمترین خطا، به عنوان مدل بهینه معرفی شد.

همچنین تحلیل حساسیت نشان داد که پارامترهای ژئوتکنیکی و عملیاتی مختلف به صورت هم زمان بر نشست سطحی تأثیرگذار هستند. علاوه بر این، مقایسه نتایج مدل بهینه با روش تجربی پک، برتری چشمگیر مدل داده محور توسعه یافته در این پژوهش را نشان داد.

برتری مدل DNN در این پژوهش با نتایج مطالعات اخیر در زمینه استفاده از یادگیری ماشین برای پیش بینی نشست تونل سازی همخوانی دارد. مطالعات چن و همکاران [7]، ژانگ و همکاران [10] و کیم و همکاران [12] نیز نشان داده اند که مدل های داده محور و یادگیری عمیق قادرند رفتار غیرخطی اندرکنش خاک و تونل را با دقت بالاتری نسبت به روش های تجربی یا مدل های ساده تر پیش بینی کنند. همچنین نتایج این پژوهش از نظر اهمیت هم زمان پارامترهای ژئوتکنیکی و عملیاتی TBM با یافته های اسکندری و همکاران [6] و محمودزاده و همکاران [9] سازگاری مناسبی دارد.

دقت بالای مدل DNN در پژوهش حاضر با نتایج مطالعات پیشین نیز همخوانی دارد. به عنوان مثال، برزگری و همکاران [8] و محمودزاده و همکاران [9] نیز به ضرایب تعیین در حدود ۰/۹۷ دست یافته اند. بنابراین عملکرد مدل توسعه یافته در این پژوهش اگرچه بالاتر از مطالعات مذکور است، اما خارج از دامنه نتایج گزارش شده در ادبیات موضوع محسوب نمی شود. یکی از دلایل دستیابی به دقت بالا در این پژوهش، استفاده هم زمان از پارامترهای ژئوتکنیکی، هندسی و عملیاتی TBM در کنار داده های واقعی مانیتورینگ پروژه بوده است. برخلاف بسیاری از مطالعات که تنها از تعداد محدودی متغیر ورودی استفاده کرده اند، پایگاه داده حاضر شامل ۲۰ متغیر مؤثر و اطلاعات واقعی حاصل از خطوط ۲ و ۳ قطار شهری مشهد است که امکان یادگیری دقیق تر روابط غیرخطی بین شرایط زمین و عملکرد TBM را فراهم کرده است.

به طور کلی، نتایج این تحقیق نشان می دهد که شبکه های عصبی عمیق ابزارهایی بسیار قدرتمند برای مدل سازی رفتارهای پیچیده و غیرخطی در مسائل ژئوتکنیکی هستند و می توانند به عنوان یک ابزار کمکی مؤثر در طراحی، کنترل و مدیریت پروژه های تونل سازی شهری مورد استفاده قرار گیرند.

یکی از محدودیت های پژوهش حاضر آن است که مدل های توسعه یافته بر اساس داده های واقعی حاصل از خطوط ۲ و ۳ قطار شهری مشهد آموزش داده شده اند و بنابراین بیشترین دقت و قابلیت تعمیم آن ها در شرایط زمین شناسی، ژئوتکنیکی و اجرایی مشابه با محدوده داده های مورد استفاده قابل انتظار است. اگرچه پایگاه داده شامل ۲۹۲ نمونه کامل، ۲۰ متغیر ورودی و طیف گسترده ای از شرایط خاکی و عملیاتی بوده است، اما به کارگیری مدل در پروژه هایی با ویژگی های زمین شناسی کاملاً

متفاوت، انواع دیگر ماشین‌های حفار یا شرایط اجرایی خارج از دامنه داده‌های آموزشی نیازمند کالیبراسیون و اعتبارسنجی مجدد خواهد بود.

ازسوی دیگر، باوجود عملکرد بسیار مطلوب مدل DNN در پیش‌بینی نشست سطحی، نتایج این پژوهش نشان می‌دهد که دقت مدل‌های داده‌محور به کیفیت، کامل بودن و گستره داده‌های ورودی وابستگی مستقیم دارد. بنابراین توسعه بانک‌های اطلاعاتی بزرگ‌تر و استفاده از داده‌های پروژه‌های مختلف می‌تواند موجب افزایش قابلیت تعمیم مدل و بهبود عملکرد آن در شرایط متنوع‌تر شود.

از دیدگاه کاربردی، مدل ارائه‌شده می‌تواند به عنوان یک ابزار کمکی در پروژه‌های تونل‌سازی مکانیزه مورد استفاده قرار گیرد. امکان پیش‌بینی سریع و نسبتاً دقیق نشست سطحی بر اساس پارامترهای ژئوتکنیکی و عملیاتی TBM این قابلیت را فراهم می‌کند که در مراحل طراحی و اجرا، مناطق با ریسک بالاتر شناسایی شده و تنظیم پارامترهای عملیاتی دستگاه حفار با هدف کاهش تغییر شکل‌های سطحی انجام گیرد.

نوآوری اصلی این پژوهش در استفاده از یک پایگاه داده واقعی و گسترده حاصل از خطوط ۲ و ۳ قطار شهری مشهد، توسعه مدل شبکه عصبی عمیق برای پیش‌بینی نشست ناشی از حفاری مکانیزه، مقایسه هم‌زمان سه مدل ANN، DNN و RF، انجام تحلیل حساسیت با روش‌های گارسون و اولدن و همچنین ارزیابی عملکرد مدل برتر در مقایسه با روش تجربی یک است. نتایج نشان داد مدل DNN با استفاده هم‌زمان از پارامترهای ژئوتکنیکی، هندسی و عملیاتی TBM توانایی مناسبی در بازنمایی رفتار پیچیده نشست سطحی دارد، در حالی که روش تجربی یک به دلیل ماهیت ساده و تعداد محدود پارامترهای ورودی، بیشتر برای برآوردهای اولیه و تقریبی مناسب است. بنابراین، مقایسه انجام‌شده در این پژوهش با هدف نشان دادن محدودیت‌های روابط تجربی و ظرفیت رویکردهای داده‌محور در تحلیل داده‌های واقعی پروژه انجام شده است.

۴-۱- محدودیت‌های پژوهش و پیشنهادها برای تحقیقات آینده

اگرچه مدل‌های توسعه‌یافته در این پژوهش عملکرد بسیار مطلوبی در پیش‌بینی نشست سطحی ناشی از حفاری مکانیزه تونل نشان دادند، نتایج حاصل باید در چارچوب دامنه داده‌ها و فرضیات پژوهش تفسیر شوند. پایگاه داده مورد استفاده از اطلاعات واقعی پروژه‌های خطوط ۲ و ۳ قطار شهری مشهد استخراج شده است؛ ازاین‌رو، بیشترین قابلیت تعمیم مدل در شرایط زمین‌شناسی، ژئوتکنیکی و اجرایی مشابه با محدوده داده‌های آموزشی قابل انتظار است. به‌کارگیری مدل در پروژه‌هایی با شرایط زمین‌شناسی متفاوت، انواع دیگر ماشین‌های حفار یا روش‌های اجرایی متفاوت، مستلزم اعتبارسنجی و کالیبراسیون مجدد خواهد بود.

انتخاب متغیرهای ورودی در این پژوهش بر اساس مبانی فیزیکی و ژئوتکنیکی، مطالعات پیشین و نقش مهندسی آن‌ها در مکانیزم ایجاد نشست سطحی انجام شده است. همچنین با توجه به استفاده از مدل‌های یادگیری ماشین غیرخطی شامل ANN، DNN و RF که نسبت به روش‌های رگرسیونی کلاسیک حساسیت کمتری به هم‌خطی متغیرهای ورودی دارند، تمامی پارامترهای منتخب در فرآیند مدل‌سازی مورد استفاده قرار گرفتند. علاوه بر این، تحلیل حساسیت به روش‌های گارسون و اولدن نیز سهم نسبی هر یک از متغیرها را در عملکرد مدل نشان داد. با وجود این، در این پژوهش ارزیابی صریح هم‌خطی متغیرها با استفاده از شاخص‌هایی نظیر عامل تورم واریانس^۱ انجام نشده است؛ ازاین‌رو، بررسی کمی هم‌خطی و استفاده از روش‌های انتخاب ویژگی یا کاهش ابعاد می‌تواند در مطالعات آینده به درک بهتر روابط میان متغیرهای ورودی

^۱ Variance Inflation Factor

کمک کند.

از سوی دیگر، ارزیابی عملکرد مدل پیشنهادی در این پژوهش با استفاده از سه الگوریتم ANN، DNN و RF انجام شد و مقایسه روش‌های داده‌محور با روش تجربی پک نیز با هدف نشان دادن تفاوت میان رویکردهای مبتنی بر داده و روابط تجربی صورت گرفت. با این حال، بررسی و مقایسه عملکرد مدل با سایر الگوریتم‌های نوین یادگیری ماشین و یادگیری عمیق، نظیر XGBoost، LightGBM، CatBoost و همچنین الگوریتم‌های Informer می‌تواند زمینه مناسبی برای توسعه پژوهش‌های آینده و ارزیابی جامع‌تر توانایی مدل‌های پیش‌بینی نشست فراهم سازد.

همچنین توسعه پایگاه‌های داده بزرگ‌تر، شامل پروژه‌های تونل‌سازی با شرایط زمین‌شناسی متنوع‌تر و استفاده از داده‌های حاصل از پروژه‌های مختلف، می‌تواند موجب افزایش قابلیت تعمیم مدل، کاهش عدم قطعیت و بهبود پایداری مدل‌های یادگیری ماشین در کاربردهای عملی شود.

۵- منابع و مراجع

- [1] D. N. Chapman, N. Metje, and A. Stark, *Introduction to Tunnel Construction*. Boca Raton, FL, USA: CRC Press, 2017.
- [2] V. Bsharat, M. Davoodi, and M. K. Jafari, "Investigation of the effect of tunnel–structure interaction on surface building settlement using a numerical method," *Ferdowsi Civil Engineering*, vol. 26, no. 1, pp. 101–120, 2015, doi: 10.22067/civil.v26i1.44046. (in Persian)
- [3] R. B. Peck, "Deep excavation and tunnelling in soft ground, state of the art volume," in *Proc. 7th Int. Conf. Soil Mechanics and Foundation Engineering (ICSMFE)*, 1969.
- [4] M. Darbor, H. Chakeri, and T. Ansari, "The Impact of Soil Particle Size Distribution on the Abrasion of EPB Machine Cutting Tools," *Ferdowsi Civil Engineering*, vol. 35, no. 4, pp. 17–34, 2022, doi: 10.22067/jfcei.2022.76503.1140. (in Persian)
- [5] S. Suwansawat and H. H. Einstein, "Artificial neural networks for predicting the maximum surface settlement caused by EPB shield tunneling," *Tunnelling and Underground Space Technology*, vol. 21, no. 2, pp. 133–150, 2006.
- [6] V. Fargnoli, D. Boldini, and A. Amorosi, "Twin tunnel excavation in coarse-grained soils: Observations and numerical back-predictions under free field conditions and in presence of a surface structure," *Tunnelling and Underground Space Technology*, vol. 49, pp. 454–469, 2015.
- [7] A. Amorosi, D. Boldini, and G. Falcone, "Numerical prediction of tunnel performance during centrifuge dynamic tests," *Acta Geotechnica*, vol. 9, no. 4, pp. 581–596, 2014.
- [8] F. Eskandari, K. G. Goharrizi, and A. Hooti, "The impact of EPB pressure on surface settlement and face displacement in intersection of triple tunnels at Mashhad metro," *Geomechanics and Engineering*, vol. 15, no. 2, pp. 769–774, Jan. 2018.
- [9] R.-P. Chen et al., "Prediction of maximum surface settlement caused by earth pressure balance (EPB) shield tunneling with ANN methods," *Soils and Foundations*, vol. 59, no. 2, pp. 284–295, 2019.
- [10] G. Barzegari, A.-A. Nadiri, and H. Javid, "Prediction of maximum settlement in EPB mechanized twin tunneling by using supervised combined artificial intelligence model," *Advanced Applied Geology*, vol. 9, no. 3, pp. 256–271, 2019.
- [11] A. Mahmoodzadeh et al., "Forecasting maximum surface settlement caused by urban tunneling," *Automation in Construction*, vol. 120, p. 103375, 2020.
- [12] W. Zhang et al., "Soft computing approach for prediction of surface settlement induced by earth pressure balance shield tunneling," *Underground Space*, vol. 6, no. 4, pp. 353–363, 2021.
- [13] L. Liu, W. Zhou, and M. Gutierrez, "Effectiveness of predicting tunneling-induced ground settlements using machine learning methods with small datasets," *Journal of Rock Mechanics and Geotechnical Engineering*, vol. 14, no. 4, pp. 1028–1041, 2022.
- [14] D. Kim et al., "Surface settlement prediction for urban tunneling using machine learning algorithms with Bayesian optimization," *Automation in Construction*, vol. 140, p. 104331, 2022.
- [15] S. Zhao, X. Feng, and K. Peng, "Prediction and parameter optimization of

surface settlement induced by shield tunneling using improved Informer algorithm," *Applied Sciences*, vol. 15, no. 12, p. 6766, 2025.

- [16] K. Ahangari, S. R. Moeinossadat, and D. Behnia, "Estimation of tunnelling-induced settlement by modern intelligent methods," *Soils and Foundations*, vol. 55, no. 4, pp. 737–748, 2015.
- [17] J. Bolouri Bazaz and S. Farkhondeh, "Estimation of consolidation settlement of clayey soils using artificial neural networks," in *Proc. 5th National Congress on Civil Engineering*, Mashhad, Iran, 2010. (in Persian) [Online]. Available: <https://civilica.com/doc/80532>

نسخه
پیش
انتشار