

توسعه شبکه فازی-عصبی (ANFIS) برای پیش‌بینی هوشمند نشست تونل و ارزیابی دقت پیش‌بینی بر پایه داده‌های همگراسنجی

ساسان قربانی^۱، فرهاد صمیمی‌نمین^{۲*}، مهدی محمودجانلو^۳
۱- استادیار گروه مهندسی معدن، دانشگاه صنعتی همدان، همدان، ایران.
۲- دانشیار گروه مهندسی معدن، دانشگاه زنجان، زنجان، ایران.
۳- دانشجوی کارشناسی ارشد مکانیک سنگ، دانشگاه زنجان، ایران.

دریافت: ۱۴۰۵/۰۷/۱۴ پذیرش: ۱۴۰۵/۰۹/۲۸
(*نویسنده مسئول: f.samiminamin@znu.ac.ir)

چکیده

حفاری تونل با برهم‌زدن تنش، موجب تغییر شکل و جابجایی در توده خاک و سنگ پیرامونی می‌شود که پیش‌بینی دقیق آن‌ها برای طراحی نگهداری و ایمنی سازه‌های زیرزمینی ضروری است. در این پژوهش، یک شبکه بر اساس سیستم استنتاج فازی-عصبی تطبیقی (ANFIS) برای پیش‌بینی نشست تونل بر اساس مجموعه‌ای شامل ۶۸ دسته داده استخراج‌شده از پروژه‌های داخلی و خارجی حفاری تونل که به لحاظ حفاری، هندسه تونل و جنس زمین مشابهند، توسعه یافت. پس از عملکرد مطلوب مدل، قابلیت کاربرد عملی آن با استفاده از ۱۸ دسته داده مختص تونل انتقال آب چهل‌چای سد نرمام مورد ارزیابی دقیق قرار گرفت. داده‌ها به صورت تصادفی به سه بخش آموزش، آزمون و اعتبارسنجی تقسیم شده و فرآیند یادگیری با استفاده از الگوریتم ترکیبی حداقل مربعات و پس‌انتشار خطا در محیط *MATLAB* انجام شد. ساختار سیستم فازی بر پایه توابع عضویت مناسب و قوانین استنتاج استخراج شده از داده‌ها شکل گرفت و عملکرد مدل از طریق شاخص‌های آماری ارزیابی شد. نتایج نشان داد مدل پیشنهادی توانسته است با میانگین خطای بسیار کم (در حدود ۰/۰۰۴ در مرحله آزمون و ۰/۰۰۳ در مرحله اعتبارسنجی) و ضریب همبستگی ۰/۹۵، تطابق قابل قبولی با مقادیر اندازه‌گیری شده توسط همگراسنج‌ها ارائه دهد.

سیستم استنتاج فازی عصبی، نشست تونل، همگراسنج، آموزش شبکه

واژگان کلیدی

۱- مقدمه

در طول سال‌های گذشته، نظریه‌های متعددی از جمله تئوری محیط پیوسته و تئوری محیط تصادفی برای تبیین پدیده نشست ارائه شده‌اند. بر مبنای این چارچوب‌های نظری، روش‌های متعارف پیش‌بینی شامل روابط برازش‌شده (مانند استفاده از پارامتر فاصله برای برآورد افت معادل زمین)، تحلیل‌های تئوریک نظیر توابع جابجایی مبتنی بر سری فوریه برای تونل‌های کم‌عمق، شبیه‌سازی‌های عددی همچون روش اجزای محدود و مدل‌سازی گسسته، و نیز رویکردهای برآوردی توسعه یافته‌اند. با این حال، اغلب این روش‌های

آزادسازی نامتعادل تنش‌های درونی زمین در جریان عملیات حفاری معمولاً به بروز نشست سطحی منجر می‌شود. این نشست‌ها می‌توانند موجب آسیب به سازه‌های واقع در سطح زمین شوند و پیامدهایی نظیر کاهش ظرفیت باربری اعضای سازه‌ای همچون تیرها و ستون‌ها را به دنبال داشته باشند. در موارد حاد، این تغییر شکل‌ها ممکن است پایداری کلی سازه را تحت تأثیر قرار داده و ایمنی آن را با مخاطره مواجه سازند [۱].

تلفیق شدند. مدل پیشنهادی با استفاده از مجموعه داده میدانی گسترده شامل بیش از ۹۶۰۰ نمونه از پروژه‌های متروی شهری آموزش داده شد و در مقایسه با روش‌هایی نظیر *LSTM*، *ANN*، *SVR* و *RF* عملکرد برتری نشان داد؛ به گونه‌ای که نسخه مبتنی بر بهینه‌ساز ستاره دریایی بیشترین دقت و توان تعمیم را به دست آورد. چن و همکاران [۷] در پژوهشی نوین، یک مدل ترکیبی با عنوان *TCN-SA* برای پیش‌بینی تغییرشکل سطح زمین در حفاری سپری شهری ارائه نمودند که قادر به بازسازی کامل روند غیرخطی تورم اولیه و سپس نشست است. این چارچوب با تلفیق شبکه کانولوشنی زمانی برای استخراج الگوهای مکانی-زمانی، بهینه‌سازی ازدحام ذرات جهت تنظیم خودکار ابرپارامترها و سازوکار خودتوجهی برای شناسایی وابستگی میان متغیرها توسعه یافت. ارزیابی بر اساس داده‌های میدانی نشان داد مدل پیشنهادی نسبت به روش‌های *RNN*، *LSTM* و *BPNN* کاهش چشم‌گیر خطا و افزایش ضریب تعیین را به همراه دارد. لی و همکاران [۸] در پژوهشی مبتنی بر رویکرد ساخت به روش اتریشی جدید، داده‌های پایش میدانی برای پیش‌بینی روند نشست تاج تونل با بهره‌گیری از شبکه عصبی مصنوعی و برنامه‌نویسی ژنتیک به کار گرفتند. در این مطالعه، علاوه بر مدل‌سازی تغییرات زمانی نشست، رابطه میان عمق مدفون‌شدگی و میزان تغییرشکل نیز تحلیل گردید و عملکرد مدل‌های یادگیری ماشین با رگرسیون کلاسیک مقایسه شد. نتایج نشان داد هر دو روش دقت بالایی دارند، اما مدل برنامه‌نویسی ژنتیک از نظر پایداری و ضریب تعیین عملکرد بهتری ارائه می‌دهد و مقدار نشست بلندمدت را با قابلیت اطمینان بیشتری برآورد می‌کند. همچنین با انتقال نتایج مدل به محیط عددی *FLAC3D*، تطابق مناسبی میان مقادیر پیش‌بینی‌شده و شبیه‌سازی عددی حاصل شد که کارایی مدل را در طراحی تغییرشکل مجاز و ارزیابی پایداری بلندمدت تأیید می‌کند. در مطالعه‌ای دیگر توسط یانگ و همکاران [۹] به منظور بهبود دقت پیش‌بینی نشست سطحی ناشی از احداث تونل‌های شهری، مدل جنگل تصادفی با سه الگوریتم فراابتکاری شامل بهینه‌ساز شیرمورچه، چندجهانی و ملخ بهینه‌سازی شد. نتایج نشان داد نسخه بهینه‌شده با الگوریتم ملخ عملکرد برتری در داده‌های پروژه متروی شهری داشته و شاخص‌های خطا را به‌طور محسوسی کاهش داده

سنتی بر فرضیات ساده‌کننده یا روابط تجربی متکی هستند که این امر دقت پیش‌بینی نشست سطحی را در شرایط پیچیده زمین‌شناسی با محدودیت مواجه می‌سازد [۲]. تاکنون مطالعاتی در زمینه پیش‌بینی نشست سطح زمین تونل توسط محققان مختلفی با استفاده از الگوریتم‌های یادگیری ماشین انجام شده است. زو و همکاران [۳] یک روش مبتنی بر سری‌های زمانی بر اساس شبکه *Bi-LSTM* بهینه‌سازی بیزی برای پیش‌بینی کل روند نشست در حفاری سپری ارائه کردند. این مدل با در نظر گرفتن وابستگی‌های زمانی پیشروی *TBM*، دقت بالاتری نسبت به مدل‌های پایه نشان داد. تحلیل *SHAP* نیز بیانگر نقش کلیدی موقعیت سپر و توقف‌های غیرعادی در میزان نشست بود. این رویکرد قابلیت کاربرد در ارزیابی پویای ریسک و بهینه‌سازی عملیات حفاری را دارد. نیو و هی [۴] یک مدل یادگیری عمیق پیش‌آموزش‌دیده برای پیش‌بینی بیشینه نشست سطح زمین (δ_{max}) با بهره‌گیری از روش *ANN* ارائه کردند. در این چارچوب، شبکه عصبی مصنوعی با بهره‌گیری از داده‌های حاصل از ۴۵۰۰۰ شبیه‌سازی عددی آموزش دید و پارامترهای تصادفی خاک، هندسه تونل و همگرایی به عنوان ورودی لحاظ شدند. نتایج نشان داد مدل پیشنهادی با دقت بسیار بالا و خطای اندک قادر به تعمیم در پروژه‌های مختلف بوده و نیاز به تحلیل‌های عددی تکراری را کاهش می‌دهد. همچنین امکان تحلیل احتمالاتی نشست ناشی از تغییرپذیری مکانی خاک را فراهم می‌سازد. ژیاو و همکاران [۵] یک روشی مبتنی بر یادگیری ماشین برای پیش‌بینی نشست زمین در پروژه‌های تونل دوقلو شهری ارائه دادند که اثر ناهمگنی زمین‌شناسی و اندرکنش تونل‌ها را به‌صورت صریح در نظر می‌گرفت. در این پژوهش، مدل‌های *SVR*، جنگل تصادفی (*RF*)، شبکه‌های عصبی عمیق (*DNN*) و شبکه پس‌انتشار با بهینه‌سازی بیزی (*BPNN*) توسعه یافتند و یک روش نوین کالیبراسیون سه‌بعدی لایه‌های خاک نیز معرفی شد. نتایج نشان داد مدل *DNN* بهینه‌شده دقت بسیار بالایی در پیش‌بینی نشست تونل پیشرو دارد و استفاده از داده‌های آن موجب بهبود چشم‌گیر پیش‌بینی تونل می‌شود. گو و همکاران [۶] رویکردی ترکیبی با هدف پیش‌بینی دقیق نشست طولی ناشی از حفاری سپری ارائه دادند که در آن الگوریتم تقویتی *LSBoost* با سه روش فراابتکاری پیشرفته به منظور تنظیم خودکار ابرپارامترها

روش‌های هوشمند نسبت به رگرسیون خطی چندمتغیره دقت بالاتری دارند و در میان آن‌ها، روش *GRNN* و جنگل تصادفی بهترین توانایی را در بازنمایی روند تکامل نشست از خود نشان می‌دهند. وانگ و همکاران [۱۳] در مطالعه‌ای، برای پیش‌بینی نشست سطحی ناشی از حفاری سپری در پروژه‌های مترو، داده‌های پایش چندنقطه‌ای را جمع‌آوری و با یک روش پیش‌پردازش مبتنی بر هندسه دایره‌های مماس به داده‌های پیوسته و هموار تبدیل نمودند. سپس شبکه عصبی پس‌انتشار با استفاده از الگوریتم ازدحام ذرات بهینه‌سازی گردید و تأثیر ساختار شبکه و شیوه پیش‌بینی بر دقت مدل ارزیابی شد. نتایج پیش‌بینی نشست در بازه پنج‌روزه طی مراحل نشست آهسته و پابدار نشان داد مدل پیشنهادی از انطباق بسیار بالایی با داده‌های واقعی برخوردار است و خطای نسبی ناچیزی دارد. ژانگ و همکاران [۱۴] به بررسی فرآیند به‌کارگیری الگوریتم‌های یادگیری ماشین در پیش‌بینی نشست ناشی از حفاری تونل پرداختند. عملکرد پنج الگوریتم *RF*، *SVM*، *ELM*، *GRNN*، *BPNN* مقایسه قرار گرفت و برای بهینه‌سازی پارامترها از الگوریتم ازدحام ذرات استفاده شد. نتایج نشان داد روش *RF* در شناسایی روند تکامل نشست عملکرد برتری دارد، در حالی که شبکه *BPNN* در شرایط محدودیت داده از قابلیت تعمیم مناسبی برخوردار است. همچنین تحلیل حساسیت بیانگر نقش غالب پارامترهای زمین‌شناسی و هندسی در میزان نشست بود. لیو و همکاران [۱۵] به منظور توسعه کاربرد یادگیری ماشین در پیش‌بینی نشست کوتاه‌مدت و بلندمدت ناشی از حفاری تونل، چارچوبی مبتنی بر یادگیری ماشین آگاه از فیزیک (*PIML*) ارائه دادند. در این رویکرد، با تفکیک نشست به دو مؤلفه کوتاه‌مدت و بلندمدت بر اساس سازوکارهای حاکم، مجموعه متغیرهای ورودی متناسب با هر نوع تغییرشکل انتخاب گردید و پارامترهای استخراج‌شده از روابط فیزیکی در کنار داده‌های میدانی و آزمایشگاهی به مدل افزوده شدند. نتایج نشان داد چارچوب پیشنهادی با دقت قابل قبول قادر به پیش‌بینی حرکات زمین است و تحلیل اهمیت متغیرها بیانگر آن بود که پارامترهای دینامیکی نظیر فاصله جبهه حفاری تا نقاط پایش و پارامتر گپ در نشست کوتاه‌مدت نقش کلیدی دارند، در حالی که ویژگی‌هایی مانند عمق تونل، تراکم‌پذیری حجمی و فشار آب حفره‌ای مازاد در

است. تحلیل حساسیت بیانگر آن بود که گشتاور دستگاه حفاری و شرایط زمین از مهم‌ترین عوامل مؤثر بر نشست هستند، در حالی که برخی شاخص‌های آزمایش صحرائی نقش کمتری داشته‌اند. یه و همکاران [۱۰] در پژوهشی کاربردی، نشست خاک ناشی از حفاری سپری با استفاده از حسگرهای فیبر نوری براگ را به صورت پیوسته پایش کرده و تاریخچه زمانی تغییرشکل در چندین نقطه از مقطع نظارتی را ثبت نمودند. به منظور پیش‌بینی نشست در دوره‌های آتی، شبکه عصبی پس‌انتشار مبتنی بر سری‌های زمانی (*TS-BPNN*) به کار گرفته شد و اثر ساختار مدل و حجم داده‌های آموزشی بر دقت پیش‌بینی بررسی شد. نتایج نشان داد مدل پیشنهادی قادر است روند نشست را در مراحل سریع و کند با خطای نسبی بسیار پایین پیش‌بینی کند و انطباق مناسبی با داده‌های میدانی داشت. تانگ و نا [۱۱] در پژوهشی چندین روش یادگیری ماشین همراه با اعتبارسنجی متقاطع پنج‌تایی برای برآورد بیشینه نشست سطح زمین ناشی از حفاری تونل به کار گرفته و کارایی آن‌ها بر روی دو مجموعه داده با حجم و ویژگی‌های متفاوت مقایسه نمودند. مدل‌های *SVM*، جنگل تصادفی، شبکه عصبی پس‌انتشار و شبکه عصبی عمیق توسعه یافته و با استفاده از الگوریتم ازدحام ذرات و جستجوی شبکه‌ای تنظیم پارامتر شدند. ارزیابی عملکرد بر اساس شاخص‌های *MAE*، *RMSE* و R^2 نشان دادند که تمامی مدل‌ها توانایی پیش‌بینی قابل قبولی دارند، اما جنگل تصادفی در هر دو مجموعه داده بهترین نتایج را ارائه می‌دهد. همچنین تحلیل حساسیت بیانگر آن بود که در یک مجموعه داده شرایط زمین‌شناسی نقش غالب دارد، در حالی که در مجموعه دیگر ویژگی‌های هندسی تأثیر بیشتری بر میزان نشست داشته‌اند، موضوعی که اهمیت کیفیت و ساختار داده‌ها را در مدل‌سازی هوشمند نشان می‌دهد. چن و همکاران [۱۲] در پژوهشی، کارایی شش الگوریتم یادگیری ماشین شامل شبکه عصبی پس‌انتشار، شبکه عصبی موجک، شبکه رگرسیون تعمیم‌یافته (*GRNN*)، ماشین یادگیری افراطی، ماشین بردار پشتیبان و جنگل تصادفی برای پیش‌بینی بیشینه نشست سطح زمین ناشی از حفاری تونل مورد ارزیابی قرار دادند. مدل‌ها با استفاده از داده‌های میدانی شامل شرایط زمین‌شناسی، پارامترهای عملیاتی دستگاه سپر و ویژگی‌های هندسی تونل در چندین مقطع توسعه یافتند. نتایج نشان داد

مجموعه‌ی داده شامل ۶۸ دسته داده جمع‌آوری شده از تونل‌های مختلف، اعم از داخلی و خارجی، انجام شده است. در گام بعدی، جهت سنجش کاربردپذیری و عملکرد مدل در یک سناریوی واقعی و مشخص، داده‌های مربوط به تونل انتقال آب چهل‌چای سد نرمام (شامل ۱۸ دسته داده) به‌عنوان مطالعه‌ی موردی انتخاب و مورد تحلیل قرار گرفت.

۲- جمع‌آوری و تهیه پایگاه داده

بانک اطلاعاتی موجود دارای ۶۸ داده تونل از مترو تبریز، مترو خط ۳ تهران، استانبول، اهواز، لندن، مادرید، مکزیکوسیتی، بلغاست جمع‌آوری شده‌اند. پارامترهای ورودی و خروجی شبکه و بازه مقادیر مربوط به آن‌ها در جدول ۱ ارائه شده‌اند.

ورودی	پارامتر	بازه مقادیر
۱	مدول بالک (MPa)	۷ - ۱/۶
۲	مدول برشی (MPa)	۵/۲ - ۱/۳۶
۳	چسبندگی (kPa)	۴ - ۱/۷۵
۴	زاویه اصطکاک (°)	۲۴ - ۲۰
۵	قطر تونل (m)	۶ - ۱/۵
۶	روپاره (m)	۷۴ - ۲۱
۷	چگالی (kg/m ³)	۴/۳ - ۴
خروجی	جابجایی (m)	-

۳- سیستم استنتاج فازی-عصبی تطبیقی

(ANFIS)

رویکرد مجموعه‌های فازی-عصبی (Neuro-Fuzzy) به‌عنوان یکی از شاخه‌های محاسبات نرم، چارچوبی تلفیقی را ارائه می‌دهد که در آن شبکه‌های عصبی برای شناسایی الگوهای موجود در داده‌های محیطی به‌کار گرفته می‌شوند و هم‌زمان، یک سیستم استنتاج فازی مبتنی بر دانش خبره انسانی وظیفه تحلیل، تصمیم‌گیری و تمایز میان پاسخ‌های ممکن در یک حوزه تخصصی را بر عهده دارد [۱۸ و ۱۹]. کارآیی چنین سامانه‌هایی در پردازش تصمیم و تبیین نتایج باید به‌گونه‌ای باشد که رفتار آن‌ها تا حد امکان به استدلال و قضاوت انسانی نزدیک شود [۲۰]. فزون بر این، این ساختار از قابلیت تحمل

برآورد نشست بلندمدت تعیین‌کننده‌تر هستند. چن و همکاران [۱۶] نیز به‌منظور پیش‌بینی بیشینه نشست سطح زمین با در نظر گرفتن ماهیت چندعاملی و پیچیده آن، مجموعه داده‌ای ترکیبی شامل پارامترهای زمین‌شناسی و اجرایی بر پایه سری‌های مکانی و زمانی تهیه نموده و مسئله پیش‌بینی را به یک مسئله چندمتغیره و چندوجهی تبدیل کردند. در این راستا، شبکه‌ای با عنوان شبکه تلفیق مکانی-زمانی (STF) توسعه یافت که ابتدا از سازوکار ادغام مکانی-زمانی برای برقراری تعامل میان داده‌های فضایی و زمانی بهره می‌گیرد و سپس با استفاده از واحدهای باقیمانده سه‌بعدی، ویژگی‌های پویای نشست را استخراج می‌کند. همچنین لایه‌های تمام‌متصل برای بازیابی اطلاعات ساختاری فضا در نظر گرفته شد و خروجی نهایی از ترکیب این اجزا حاصل گردید. نتایج آزمایش‌ها نشان داد مدل پیشنهادی نسبت به روش‌های پیشرفته موجود عملکرد دقیق‌تر و پایدارتری در پیش‌بینی نشست ارائه می‌دهد. نائینی و خلیلی [۱۷] به بررسی و پیش‌بینی نشست و همچنین یافتن مدلی مناسب برای پیش‌بینی رفتار تونل در خط ۳ متروی تهران با استفاده از روش‌های عددی *ANFIS* و *FLAC3D* با الگوریتم آموزش ترکیبی پرداختند. پایگاه داده مربوط به شبکه بهینه از ۴۶ تونل مترو در ایران و ترکیه که با روش جدید تونل‌سازی اتریشی (*NATM*) با پارامترهای مشابه بر اساس نوع خاک آن‌ها ساخته شده‌اند، به دست آمد. مقایسه نتایج بدست آمده نشان داد که روش *ANFIS* و الگوریتم‌های هوشمند جایگزین خوبی برای مدل‌سازی عددی محسوب می‌شوند.

بر این اساس، هدف اصلی پژوهش حاضر توسعه و ارزیابی یک چارچوب هوشمند مبتنی بر سیستم استنتاج فازی-عصبی تطبیقی برای پیش‌بینی دقیق نشست تونل انتقال آب چهل‌چای سد نرمام و مقایسه نتایج آن با داده‌های ابزار دقیق است. در این راستا، پژوهش حاضر به طراحی یک مدل *ANFIS* در محیط *MATLAB* پرداخته و با استفاده از الگوریتم ترکیبی حداقل مربعات و پس‌انتشار خطا آموزش داده شد. ساختار بهینه سیستم فازی بر پایه استخراج داده‌محور توابع عضویت و قواعد استنتاجی شکل گرفت و عملکرد آن از طریق شاخص‌های آماری در مراحل آموزش، آزمون و اعتبارسنجی ارزیابی گردید. لازم به ذکر است که فرآیند آموزش و اعتبارسنجی اولیه مدل، بر پایه‌ی یک

که در آن A_1-A_2 و B_1-B_2 نشان‌دهنده توابع عضویت مربوط به ورودی‌های مختلف از جمله متغیرهای x و y هستند. این توابع میزان تعلق هر ورودی به مجموعه‌های فازی متناظر را تعیین کرده و مبنای فعال‌سازی قواعد استنتاج را فراهم می‌سازند.

۳-۲- توصیف لایه‌های محاسباتی مدل ANFIS

در شکل ۲ ساختار مدل ANFIS به وضوح نشان داده شده است. اگر خروجی هر لایه (خروجی گره i ام در لایه) $O_{1,i}$ باشد، ساختار ANFIS با دو ورودی و پنج لایه به صورت زیر خواهد بود [۲۳]:

لایه اول - فازی‌سازی (Fuzzification Layer): هر

گره i در این لایه، یک گره تطبیقی با تابع گره است.

$$\begin{aligned} O_{1,i} &= \mu_{A_i}(x) \quad \text{for } i = 1, 2 & \text{or} & & (1) \\ O_{1,i} &= \mu_{B_{i-2}}(y) \quad \text{for } i = 3, 4 \end{aligned}$$

که در آن $\mu_{A_i}(x)$ درجه عضویت x در مجموعه فازی A_i و $\mu_{B_{i-2}}$ درجه عضویت y در مجموعه فازی B_{i-2} است. توابع عضویت می‌توانند شکل‌های مختلفی مانند توابع گوسی و زنگوله‌ای تعمیم‌یافته به ترتیب مطابق روابط (۲) و (۳) داشته باشند.

$$\mu_A(x) = \exp\left(-\frac{(x-c)^2}{2\sigma^2}\right) \quad (2)$$

$$\mu_A(x) = \frac{1}{1 + \left|\frac{x-c}{a}\right|^{2b}} \quad (3)$$

در روابط بالا، a ، b و c پارامترهای پیش‌فرض (Premise parameters) هستند.

خطا برخوردار است؛ به این معنا که حذف یا اصلاح بخشی از اطلاعات یا پارامترها منجر به اختلال جدی در عملکرد کلی سیستم نخواهد شد.

در سال‌های اخیر، هم‌زمان با گسترش زیرساخت‌های نظری در حوزه‌های مختلف علمی، کاربرد روش‌های محاسبات نرم رشد چشم‌گیری یافته است. در این میان، سیستم استنتاج فازی-عصبی تطبیقی (ANFIS) به‌عنوان یکی از زیرشاخه‌های مدل‌های هوش مصنوعی توسعه یافته که سازوکار آن بر پایه سیستم استنتاج فازی تاکاگی-سوگنو بنا شده است [۲۱]. در یک چارچوب واحد، مزایای قابلیت یادگیری شبکه‌های عصبی و توانایی مدل‌سازی عدم قطعیت در منطق فازی را ادغام می‌کند. این سامانه به یک سیستم استنتاج فازی قابل آموزش مجهز است؛ از این رو نسبت به ساختارهای صرفاً فازی-عصبی، از کارایی و انعطاف‌پذیری بیشتری برخوردار است.


۳-۱- ساختار معماری ANFIS

ANFIS کلاسیک دارای ساختار پنج‌لایه‌ای است که هر لایه نقش محاسباتی مشخصی دارد. برای سادگی، سیستم دو ورودی x و y و دو قاعده فازی در نظر گرفته می‌شود.

در پژوهش حاضر، چندین پارامتر ورودی به سیستم معرفی شده و تنها یک متغیر خروجی برای مدل در نظر گرفته شده است. قواعد مورد استفاده بر اساس مدل فازی سوگنو مرتبه اول تعریف می‌شوند، به طوری که مجموعه قواعد به صورت f_1, f_2, \dots, f_n نمایش داده می‌شوند که در آن n بیانگر حداکثر تعداد قواعد فازی در سیستم است [۲۲]. شکل ۱ نمونه‌ای از یک مدل فازی سوگنو مرتبه اول با دو قانون تعریف شده به شرح زیر را نشان می‌دهد:

$$\text{Rule \#1: if } X \text{ is } A_1 \text{ and } Y \text{ is } B_1, \text{ then } f_1 = p_1x + q_1y + r_1$$

$$\text{Rule \#2: if } X \text{ is } A_2 \text{ and } Y \text{ is } B_2, \text{ then } f_2 = p_2x + q_2y + r_2$$




$$w_1 f_1 = p_1 x + q_1 y + r_1$$

$$\Rightarrow f = \frac{w_1 f_1 + w_2 f_2}{w_1 + w_2} = \bar{w}_1 f_1 + \bar{w}_2 f_2$$

$$w_2 f_2 = p_2 x + q_2 y + r_2$$

شکل ۱- مدل فازی سوگنو مرتبه اول [۲۳]



شکل ۲- ساختار مدل ANFIS [۱۹]

می‌آید.

$$O_{3,i} = \bar{w}_i = \frac{w_i}{w_1 + w_2}, \quad i = 1, 2 \quad (5)$$

به طور کلی، خروجی‌های این لایه به عنوان مقاومت نرمال شده در نظر گرفته می‌شوند، که در آن \bar{w}_i فعالیت نرمال شده قانون i ام است.

لایه چهارم- محاسبه خروجی هر قاعده

هر گره i در این، یک تابع گره تطبیقی است.

$$O_{4,i} = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i), \quad i = 1, 2 \quad (6)$$

مجموعه پارامترهای این گره است. پارامترهای این لایه، پارامترهای مؤثر نامیده می‌شوند.

لایه پنجم- تجمیع خروجی‌ها

گره منفرد در این لایه، یک گره ثابت با برچسب Σ است

لایه دوم- محاسبه قدرت فعال‌سازی قواعد: هر

گره در این لایه یک گره ثابت با برچسب II است که خروجی آن حاصل ضرب تمام سیگنال‌های ورودی است (رابطه ۴). در این مرحله از عملگر AND (معمولاً ضرب) استفاده می‌شود.

$$O_{2,i} = w_i = \mu_{A_i}(x) \mu_{B_i}(y), \quad i = 1, 2 \quad (4)$$


که در آن، $\mu_{B_i}(y)$ درجه عضویت y در مجموعه فازی و فعالیت قاعده k ام است.

لایه سوم- نرمال‌سازی قدرت قواعد: در این لایه،

هر گره یک گره ثابت بوده و با نماد N نمایش داده می‌شود. خروجی گره i -ام برابر با شدت فعال‌سازی نرمال شده آن قاعده است که از تقسیم شدت فعال‌سازی قاعده i -ام بر مجموع شدت فعال‌سازی تمامی قواعد مطابق رابطه (۵) به دست

ایمنی این سازه‌ها محسوب می‌شود. با توجه به هزینه‌های اولیه تجهیز کارگاه به سامانه‌های ابزارگذاری، ضروری است راهبردی اتخاذ گردد که با حداقل تعداد تجهیزات، بیشترین داده‌های فنی و تحلیلی قابل استخراج باشد. در میان ابزارهای متداول پایش، سامانه‌های همگرایی‌سنجی به دلیل سادگی اجرا، هزینه نسبتاً پایین و کارایی مناسب، از پرکاربردترین گزینه‌ها در کنترل تغییرشکل تونل‌ها و فضاهای زیرزمینی به‌شمار می‌روند. با این حال، کارآمدی این ابزارها وابسته به تعیین آرایش بهینه، انتخاب تعداد مناسب نقاط اندازه‌گیری و نصب دقیق پین‌های همگرایی است؛ به‌گونه‌ای که از هر ایستگاه پایش بتوان حداکثر اطلاعات رفتاری سازه را با دقت مطلوب استخراج کرد.

اگر چه در این روش تنها جابجایی نسبی بین دو نقطه از محیط تونل اندازه‌گیری می‌شود و محل دقیق حرکت در عمق سنگ تعیین نمی‌گردد، اما شناخت مناطق دارای جابجایی در تونل و تعیین روند این حرکت، این امکان را برای مهندس طراح فراهم می‌نماید تا نسبت به تکمیل اطلاعات و مقایسه آن با فرضیات طراحی اولیه، نسبت به انتخاب انواع ابزار دقیق و حتی سیستم‌های نگهداری بهینه در مترهای بعدی اقدام نماید. همگرایی‌سنجی عموماً با نصب ۳ یا ۵ پین انجام می‌گیرد. استفاده از ۵ پین در فضاهای با سطح مقطع بزرگتر از $25 m^2$ معمول بوده و در تونل‌هایی که بالازدگی کف نیز محتمل است، نصب یک پین در کف نیز قابل انجام می‌باشد. شکل ۴ محل نصب پین یا میخ همگرایی‌سنجی را نشان می‌دهد.



شکل ۴- محل نصب پین یا میخ همگرایی‌سنجی

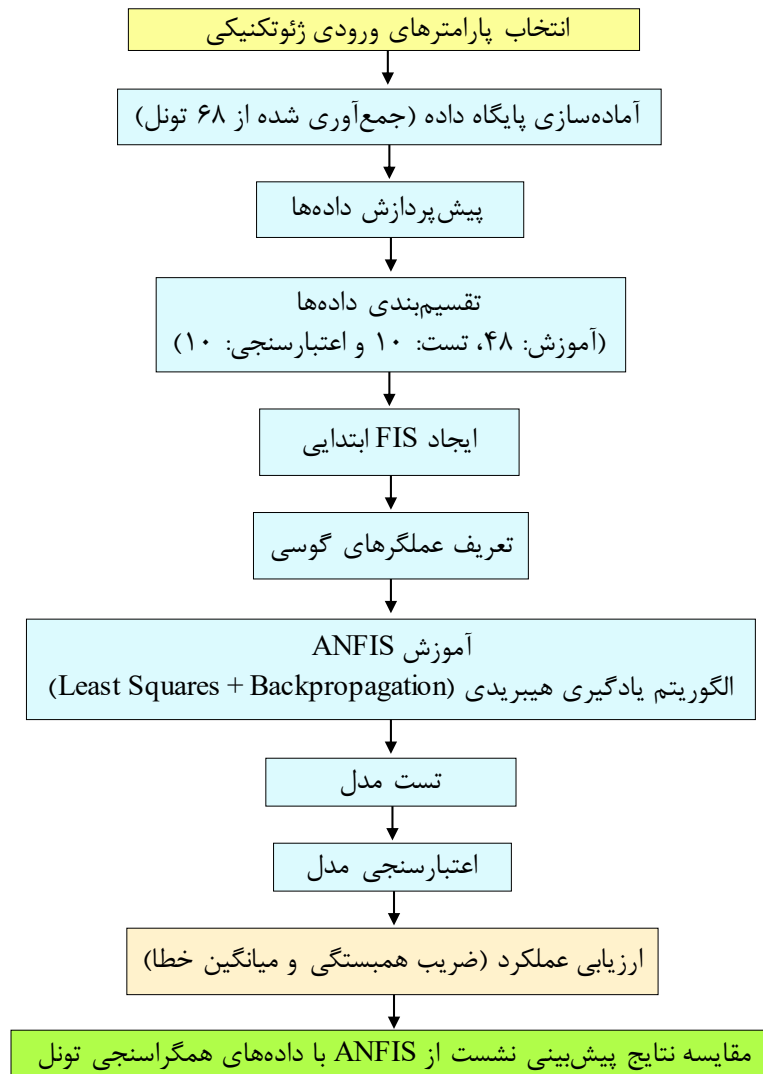
که خروجی کلی را به صورت مجموع تمام سیگنال‌های ورودی مطابق رابطه (۷) محاسبه می‌کند.

$$\text{Overall output} = o_{s,i} = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (7)$$

این رابطه بیانگر خروجی نهایی مدل ANFIS است. سیستم ANFIS از منظر تئوریک دارای ویژگی‌هایی است که آن را به ابزاری کارآمد برای مدل‌سازی مسائل پیچیده مهندسی تبدیل می‌کند. نخست، این چارچوب از خاصیت تقریب همگانی برخوردار است؛ بدین معنا که قادر است هر تابع پیوسته تعریف‌شده در یک فضای فشرده را با دقت دلخواه تقریب بزند، مشروط بر آن‌که تعداد قواعد و ساختار مدل به‌صورت مناسب انتخاب شود. دوم، ماهیت ترکیبی قواعد فازی و توابع خطی قطعه‌ای در بخش نتیجه‌گیری (Consequent) امکان مدل‌سازی روابط غیرخطی پیچیده را فراهم می‌سازد و انعطاف‌پذیری بالایی در بازنمایی رفتار سیستم ایجاد می‌کند. افزون بر این، بهره‌گیری از الگوریتم یادگیری تطبیقی که به‌طور هم‌زمان پارامترهای توابع عضویت (پارامترهای پیش‌فرض) و ضرایب خطی خروجی را به‌روزرسانی می‌کند، موجب افزایش سرعت همگرایی و بهبود پایداری نسبت به روش‌های مبتنی صرف بر گرادینان کاهشی می‌شود. در نهایت، ساختار مبتنی بر قواعد اگرچه داده‌محور است، اما نسبت به شبکه‌های عصبی عمیق از سطح بالاتری از تفسیرپذیری برخوردار بوده و امکان تحلیل فیزیکی و مفهومی روابط میان متغیرهای ورودی و خروجی را فراهم می‌آورد. یک روندنمای کلی از مراحل انجام شده در شکل ۳ نشان داده شده است.

۴- ابزار دقیق کاربردی در رفتارسنجی جابجایی تونل، متر همگرایی‌سنج (Convergence meter)

پایش پایداری سازه‌های زیرزمینی از طریق ابزار دقیق، یکی از قابل‌اعتمادترین روش‌ها برای ارزیابی رفتار مکانیکی و سطح



شکل ۳- روندنمای کلی استفاده شده در پژوهش حاضر

۵- تحلیل نتایج مدل‌سازی‌ها

۵-۱- مدل‌سازی پیش‌بینی نشست تونل توسط

شبکه ANFIS

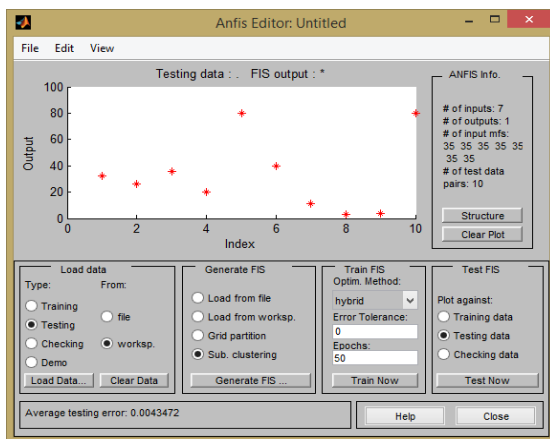
شبکه عصبی-فازی مورد استفاده با به‌کارگیری نرم‌افزار *MATLAB* و با استفاده از *ANFIS* طراحی شده است. در مرحله اول *FIS* مربوط به نشست با استفاده از دیتاهای آموزشی جمع‌آوری شده ساخته می‌شود. قسمتی از دیتاهای آموزشی به عنوان دیتاهای چک و تست‌کننده کنار گذاشته می‌شود تا بعد از پایان یادگیری کنترل‌کننده، توسط آن‌ها یادگیری کنترل‌کننده چک شود.

از ۶۸ داده جمع‌آوری شده، تعداد ۴۸ داده برای آموزش شبکه، ۱۰ داده برای آزمایش شبکه، و ۱۰ داده برای چک کردن شبکه به‌صورت تصادفی انتخاب شدند. در فرآیند مدل‌سازی حاضر، به‌منظور ایجاد سیستم استنتاج فازی اولیه (*FIS*)، از روش خوشه‌بندی تفاضلی (*Subtractive Clustering*) بهره گرفته شده است. میزان همپوشانی میان توابع عضویت برابر با ۲۰ درصد در نظر گرفته شد تا تعادل مناسبی میان تفکیک‌پذیری قواعد و پیوستگی فضای ورودی برقرار گردد. همچنین برای توصیف مجموعه‌های فازی از تابع عضویت گوسی (*gaussmf*) استفاده شده است که به دلیل نرمی و مشتق‌پذیری مناسب،

می‌آورد. در نتیجه، الگوریتم هیبریدی قادر است با دقت بیشتری ساختار قواعد فازی و نگاشت غیرخطی میان متغیرهای ورودی و خروجی را در سیستم *ANFIS* استخراج نماید.

در این پژوهش، به‌منظور دستیابی به همگرایی سریع‌تر و دقت بالاتر، از الگوریتم هیبریدی استفاده شده است. مقدار تلورانس خطا برابر صفر تنظیم گردید تا فرآیند آموزش بدون توقف زود هنگام ادامه یابد. با توجه به اینکه تعداد تکرار پیش‌فرض (*Epoch*) برابر با ۳ بوده و برای حصول یادگیری پایدار کافی نیست، تعداد تکرارها به ۵۰ افزایش داده شد تا شبکه فرصت کافی برای بهینه‌سازی پارامترها داشته باشد.

پس از تنظیم پارامترهای آموزشی، سیستم با اجرای دستور «*Train Now*» وارد مرحله یادگیری می‌شود. افزایش تعداد توابع عضویت در صورت نیاز می‌تواند منجر به بهبود دقت مدل شود، هرچند این امر باید با در نظر گرفتن خطر بیش‌برازش کنترل گردد. در نهایت، عملکرد سیستم استنتاج فازی آموزش‌دیده با استفاده از داده‌های اعتبارسنجی (*Checking Data*) مورد ارزیابی قرار گرفت. نتایج مربوط به داده‌های آزمون و داده‌های کنترل پس از اتمام فرآیند آموزش در شکل‌های ۵ و ۶ ارائه شده‌اند.



شکل ۵- نتایج حاصل از داده‌های آزمون

عملکرد مطلوبی در فرآیند یادگیری ارائه می‌دهد. به‌منظور افزایش شفافیت و قابلیت بازتولید مدل *ANFIS* توسعه‌یافته، جزئیات ساختاری سیستم استنتاج فازی به‌صورت صریح ارائه می‌شود. در این راستا، ساختار اولیه *FIS* با استفاده از روش خوشه‌بندی تفاضلی تعیین گردید که در آن شعاع خوشه‌بندی به‌عنوان پارامتر کنترل‌کننده، منجر به تعیین خودکار تعداد خوشه‌ها و به‌تبع آن تعداد قواعد فازی شد. بر این اساس، برای هر یک از متغیرهای ورودی، مجموعه‌ای از توابع عضویت گوسی در نظر گرفته شد که تعداد آن‌ها بر مبنای نتایج خوشه‌بندی تعیین گردید. در نهایت، ساختار مدل *ANFIS* شامل $[X]$ تابع عضویت برای هر ورودی و مجموعاً $[Y]$ قاعده فازی می‌باشد.

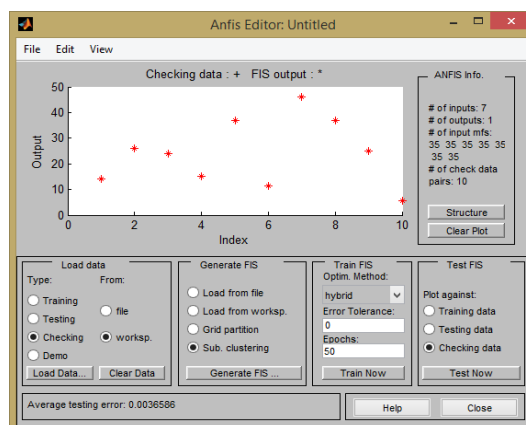
سیستم استنتاج فازی حاصل، از نوع سوگنو مرتبه اول بوده و در آن، هر قاعده فازی از یک تابع خطی در بخش نتیجه‌گیری تشکیل شده است. این ساختار امکان مدل‌سازی روابط غیرخطی پیچیده میان پارامترهای ورودی و میزان نشست تونل را فراهم می‌سازد.

پس از تشکیل ساختار اولیه *FIS*، مرحله آموزش با استفاده از داده‌های آموزشی آغاز می‌شود. در بخشی از برنامه بنام «*Train FIS*» دو الگوریتم برای بهینه‌سازی پارامترهای *ANFIS* شامل روش پس‌انتشار خطا (*Back-Propagation*) و روش هیبریدی که به‌صورت پیش‌فرض تعریف شده و ترکیبی از الگوریتم حداقل مربعات برای تنظیم پارامترهای خطی و گرادیان کاهشی برای به‌روزرسانی پارامترهای توابع عضویت است، در دسترس می‌باشند.

الگوریتم هیبریدی از ترکیب دو روش بهینه‌سازی شامل حداقل مربعات (*Least Squares Estimation*) و گرادیان کاهشی (*Gradient Descent*) بهره می‌گیرد. در مرحله پیشرو (*Forward Pass*)، با فرض ثابت بودن پارامترهای توابع عضویت، پارامترهای خطی بخش نتیجه‌گیری قواعد فازی از طریق روش حداقل مربعات برآورد می‌شوند. سپس در مرحله بازگشتی (*Backward Pass*)، خطای پیش‌بینی به شبکه بازانتشار یافته و پارامترهای غیرخطی توابع عضویت با استفاده از الگوریتم گرادیان کاهشی به‌روزرسانی می‌شوند. این سازوکار دو مرحله‌ای موجب تفکیک بهینه‌سازی پارامترهای خطی و غیرخطی شده و در مقایسه با روش‌های مبتنی بر گرادیان خالص، همگرایی سریع‌تر و پایداری را فراهم

این ساختار شامل تعداد توابع عضویت اختصاص یافته به هر متغیر ورودی، نحوه خوشه‌بندی داده‌ها، تعداد قواعد استخراج شده و روابط ریاضی حاکم بر بخش نتیجه‌گیری است. در واقع، هر قاعده فازی بیانگر یک رابطه محلی میان پارامترهای ورودی و پاسخ خروجی بوده و مجموعه این قواعد، نگاشت غیرخطی میان فضای ورودی و متغیر نشست را شکل می‌دهد. ترکیب توابع عضویت گوسی با الگوریتم یادگیری هیبریدی سبب شده است پارامترهای پیش‌فرض و ضرایب خطی خروجی به صورت هم‌زمان بهینه شوند و ساختاری منسجم و کارآمد حاصل گردد.

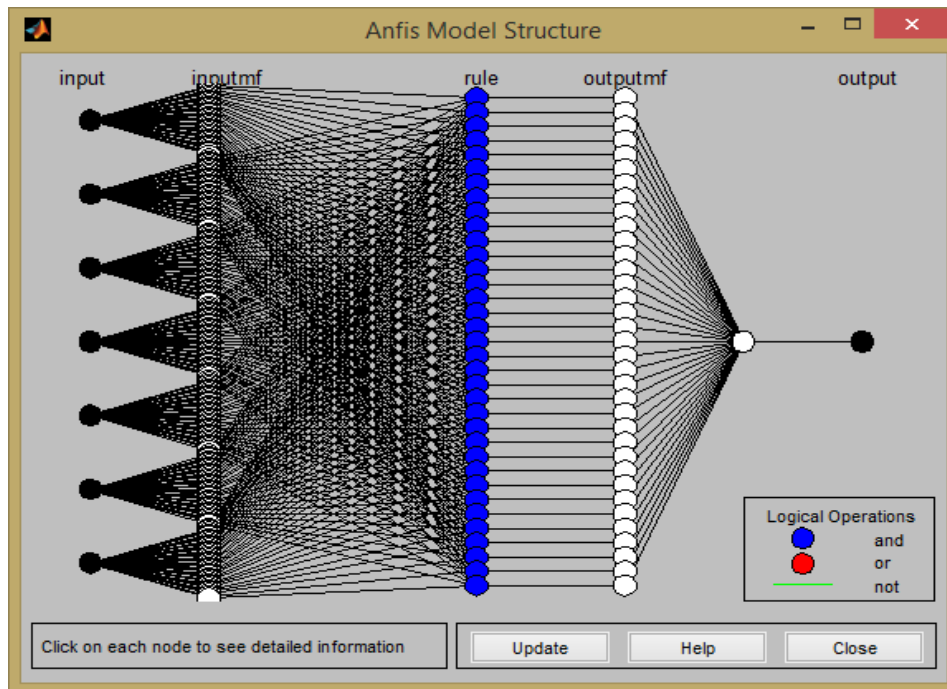
بر اساس قواعد استخراج شده توسط شبکه، با اعمال مقادیر پارامترهای ورودی برای هر نمونه داده، مقدار پیش‌بینی شده نشست به صورت خودکار محاسبه می‌شود. این فرآیند از طریق محاسبه شدت فعال‌سازی هر قاعده، نرمال‌سازی وزن‌ها و در نهایت تجمیع خروجی‌های خطی قواعد انجام می‌گیرد. بدین ترتیب، سهم هر قاعده در خروجی نهایی متناسب با میزان فعال‌سازی آن تعیین می‌شود و نتیجه نهایی به صورت یک ترکیب وزنی از پاسخ‌های موضعی به دست می‌آید. شکل ۸ نمونه‌ای شماتیک از قواعد فعال شده برای یکی از داده‌های ورودی را نمایش می‌دهد که در آن نحوه مشارکت قواعد مختلف در تولید مقدار نهایی نشست قابل مشاهده است. این نمایش گرافیکی نشان می‌دهد که مدل نه تنها توانایی مدل‌سازی روابط پیچیده و غیرخطی میان متغیرها را دارد، بلکه از نظر تبیین‌پذیری نیز امکان تحلیل نقش هر ورودی در فرآیند پیش‌بینی را فراهم می‌سازد.



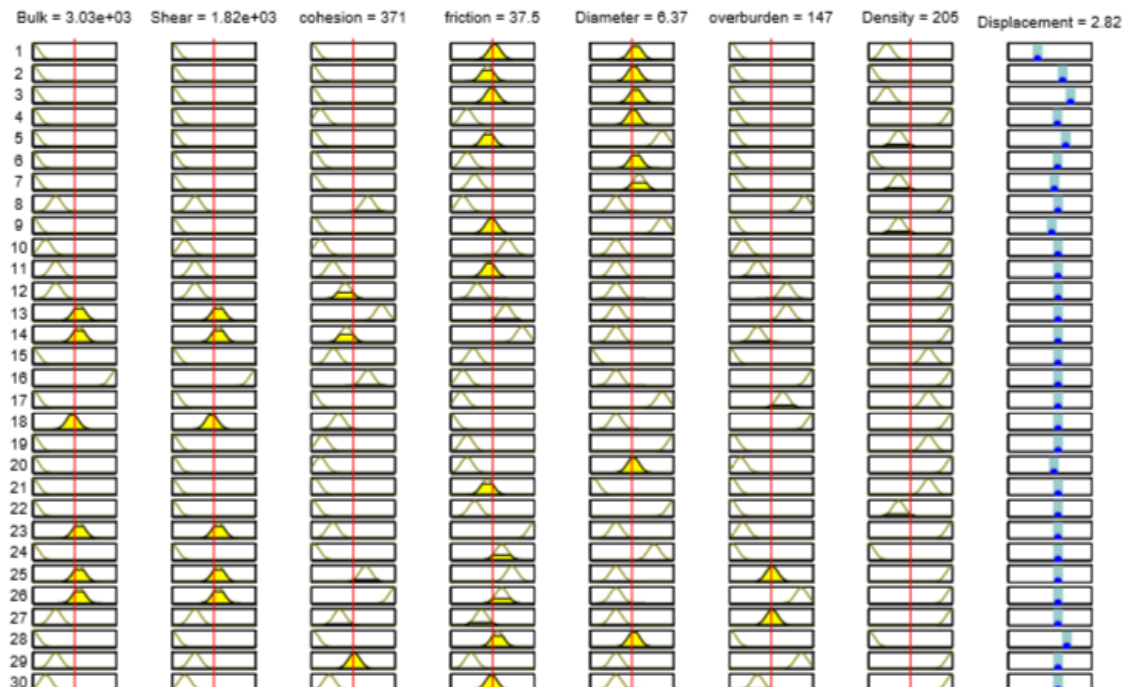
شکل ۶- نتایج حاصل از داده‌های کنترل (وارسی)

مطابق نتایج حاصل از فرآیند آموزش و ارزیابی مدل، میانگین خطای پیش‌بینی در مرحله آزمون برابر با $0/004347$ و در مرحله وارسی معادل $0/003658$ محاسبه گردید. مقادیر به دست آمده نشان‌دهنده سطح خطای بسیار پایین و در نتیجه دقت قابل قبول مدل در بازتولید رفتار واقعی سیستم است. نزدیکی مقادیر خطا در دو مرحله آزمون و وارسی بیانگر آن است که مدل از پایداری مناسبی برخوردار بوده و دچار بیش‌برازش (*Overfitting*) نشده است؛ به بیان دیگر، شبکه علاوه بر انطباق مطلوب با داده‌های آموزشی، توانایی تعمیم‌پذیری مناسبی در مواجهه با داده‌های مستقل نیز دارد.

ساختار نهایی سیستم استنتاج فازی ایجاد شده را می‌توان از طریق بخش «Structure» در محیط نرم‌افزار مشاهده نمود که نمای کلی آن در شکل ۷ ارائه شده است.



شکل ۷- ساختار FIS تولیدشده



شکل ۸- شماتیک نمونه‌ای از قوانین ارائه‌شده توسط ANFIS

۵-۲- نتایج پیش‌بینی جابجایی و نشست و مقایسه آن با ابزار دقیق در تونل انتقال چهل‌چای سد نرماب

۵-۲-۱- موقعیت جغرافیایی و راه‌های دسترسی

محدوده طرح احداث سد مخزنی نرماب و توسعه منابع آب رودخانه‌های نرماب، چهل‌چای و خرمالو در شمال ایران و در استان گلستان و بخش میانی حوضه آبریز رودخانه گرگان قرار گرفته است، که از شرق به رودخانه قلی‌تپه، از غرب به رودخانه قره‌سو و از شمال به رودخانه گرگان محدود می‌گردد. این محدوده در ۱۲۰ کیلومتری شمال شرقی شهر گرگان، بین عرض‌های شمالی ۵۵°-۲۰' تا ۳۵°-۱۸' و طول شرقی ۷۵°-۷' تا ۵۵°-۲۰' واقع شده است. رودخانه نرماب، چهل‌چای و خرمالو پس از پیوست به یکدیگر نهایتاً در ۵ کیلومتری پایین‌دست شهر گنبد به رودخانه گرگان می‌پیوندد. محل اجرای طرح سد نرماب در حدود ۵ کیلومتری شهر مینودشت در استان گلستان می‌باشد.

ورودی تونل انتقال آب چهل‌چای در تراز ۲۳۲/۴ متر بالاتر از سطح دریا و حدوداً در ۶۵۰ متری شمال‌غربی روستای نالاج، در ساحل چپ رودخانه چهل‌چای و خروجی آن در جنوب روستای آرام‌نرو و در ساحل راست رودخانه نرماب با رقم ۲۲۶/۷۵ در نظر گرفته شده است. در شکل ۹ نقشه راه‌های دسترسی و موقعیت پروژه سد مخزنی نرماب و تونل انتقال آب چهل‌چای مشاهده می‌شود.

۵-۲-۲- زمین‌شناسی مسیر تونل

از دیدگاه تقسیمات زمین‌شناسی، گستره طرح در مرز دو زون

گرگان‌دشت و زون کپه داغ هزارمسجد واقع گردیده است. بخش اعظم گستره طرح را کوه‌هایی بلند با روند عمومی شمال‌خاوری-جنوب‌باختری فراگرفته است. با توجه به پوشش گیاهی منطقه، عدم برون‌زدگی سازندها و هوازدگی زیاد سنگ‌ها در مسیر تونل تعدادی گمانه در مسیر تونل برای شناخت لایه‌های زیرسطحی حفر شده است. تونل در مسیر خود از سازندهای مختلف زمین‌شناسی عبور می‌کند که در جدول ۲ ارائه شده‌اند. از پرتال ورودی تونل به ترتیب سازند شمشک (*Jss*) (شیل و ماسه‌سنگ زغال‌دار)، زون خردشده کنتاکت، سازند خوش‌بیلاق (*Dkhlm*) (آهک و مارن و شیل)، زون گسلی و خردشده، سازند میلا (*Emlm*) (آهک دولومیتی و دولومیت) و سازند سلطان میدان (*Sv*) (بازالت و آندزیت بازالت) عبور کرده‌اند. در شکل ۱۰، مقطع زمین‌شناسی مسیر تونل انتقال آب چهل‌چای نشان داده شده است. همانطور که مشاهده می‌شود، این تونل در مسیر خود از ماسه‌سنگ کوارتزیته سازند شمشک (به طول ۱۹۰ m)، سنگ آهک سازند خوش‌بیلاق (به طول ۱۱۷۰ m)، دولومیت سازند میلا (به طول ۸۵۶ m) و در نهایت توده‌سنگ آندزیت-بازالت (به طول ۱۰۳۷ m) عبور می‌کند.

لازم به ذکر است که بخش انتهایی تونل در توده‌سنگ آندزیت بازالت قرار می‌گیرد. لازم به ذکر است که مقطع تونل به صورت *D* شکل با قطر تمام شده ۴/۵ می باشد. حداکثر روبراه در مسیر تونل ۲۹۰ m در نظر گرفته شده است. هندسه تونل در شکل ۱۱ نشان داده شده است.

جدول ۲- تشکیلات و لیتولوژی‌های مرتبط در تونل انتقال آب چهل‌چای


کیلومتر	لیتولوژی	تشکیلات
۰-۲۰۰	تناوبی از ماسه‌سنگ، شیل و زغال‌سنگ	شمشک
۲۰۰-۲۵۰	ماسه‌سنگ، شیل و سنگ آهک	شمشک-خوش‌بیلاق
۲۵۰-۱۳۵۸	سنگ آهک نازک تا متوسط لایه همراه با شیل و مارن	خوش‌بیلاق
۱۳۵۸-۱۴۲۵	آهک و آهک دولومیتی و شیل آهکی سیاه با رگه‌های کلسیت و اکسید آهن	شمشک، خوش‌بیلاق و میلا
۱۴۲۵-۲۲۲۰	دولومیت و آهک دولومیتی، ماسه‌سنگ و شیل میکادار	میلا
۲۲۲۰-۳۱۷۵	بازالت و بازالت آندزیتی	سلطان میدان

عملی برخوردار است.

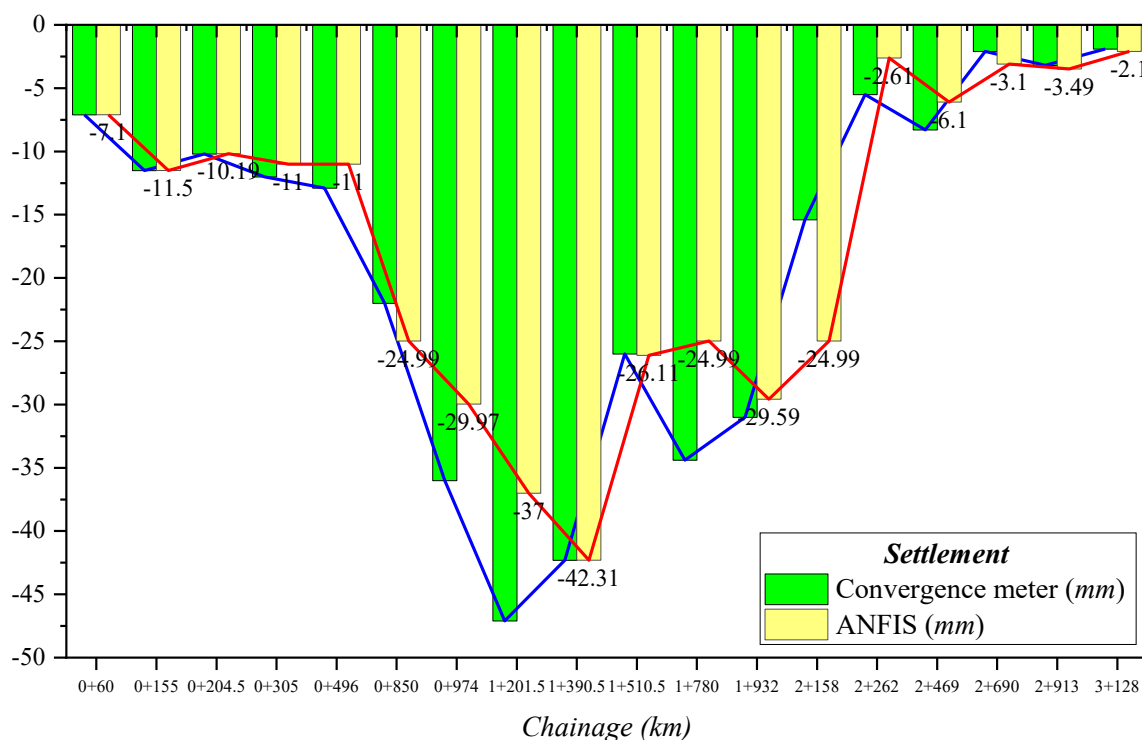
عملکرد جعبه‌ابزار شبکه عصبی مصنوعی در محیط نرم‌افزار *MATLAB* در مقایسه با مقادیر واقعی نشست در شکل ۱۳ ارائه شده است. همان‌گونه که از نمودار مشخص است، تطابق قابل‌توجهی میان مقادیر پیش‌بینی‌شده و داده‌های اندازه‌گیری‌شده مشاهده می‌شود، به‌گونه‌ای که روند تغییرات نشست در مدل به‌خوبی با رفتار واقعی ثبت‌شده توسط ابزار دقیق همخوانی دارد. این هم‌راستایی بیانگر دقت مناسب مدل در بازنمایی پاسخ سیستم و توانایی آن در استخراج روابط غیرخطی حاکم بر پدیده نشست است. در مجموع، نتایج حاصل نشان می‌دهد که بهره‌گیری از جعبه‌ابزار شبکه عصبی مصنوعی در محیط *MATLAB* می‌تواند به‌عنوان روشی کارآمد و قابل‌اعتماد برای پیش‌بینی نشست در پروژه‌های تونل‌سازی مورد استفاده قرار گیرد.

در این مرحله، با بهره‌گیری از شبکه عصبی-فازی آموزش‌دیده، فرآیند پیش‌بینی نشست در تونل انتقال آب چهل‌چای انجام گرفت. بدین‌منظور، مقادیر پارامترهای ورودی مربوط به این تونل به مدل اعمال شده و خروجی متناظر با هر نمونه به‌عنوان مقدار پیش‌بینی‌شده نشست استخراج گردید.

علاوه بر این، به‌منظور ارزیابی کمی میزان انطباق مدل با داده‌های واقعی، ضریب همبستگی بین مقادیر پیش‌بینی‌شده و مقادیر اندازه‌گیری‌شده محاسبه گردید که نتایج آن در شکل ۱۲ نمایش داده شده است. مقدار بالای ضریب همبستگی بیانگر وجود رابطه خطی قوی و هم‌راستایی مناسب بین خروجی مدل و داده‌های میدانی است. این امر نشان می‌دهد که شبکه عصبی-فازی توسعه‌یافته توانسته است الگوی رفتاری نشست تونل را با دقت قابل‌قبولی شناسایی و بازنمایی نماید و از قابلیت تعمیم‌پذیری مناسبی در کاربرد



شکل ۱۲- نمودار ضریب همبستگی مقادیر پیش‌بینی‌شده و اندازه‌گیری‌شده با همگراسنج



شکل ۱۳- مقایسه نتایج حداکثر نشست بدست آمده از شبکه عصبی-فازی با مقادیر اندازه‌گیری شده با همگراسنج

۶- بحث

نشست که ذاتاً رفتاری تدریجی و وابسته به شرایط زمین‌شناسی دارند، اهمیت بسزایی دارد.

به کارگیری الگوریتم یادگیری هیبریدی (ترکیب حداقل مربعات و پس‌انتشار خطا) نیز نقش تعیین‌کننده‌ای در بهبود همگرایی مدل داشته است. بخش حداقل مربعات پارامترهای خطی را با دقت بالا برآورد نموده و بخش گرادیانی پارامترهای غیرخطی توابع عضویت را تنظیم کرده است؛ در نتیجه، سرعت همگرایی افزایش یافته و خطای نهایی کاهش یافته است. این مزیت در مقایسه با روش‌های صرفاً گرادیانی، که معمولاً در بهینه‌های محلی متوقف می‌شوند، کاملاً مشهود است.

از منظر مهندسی ژئوتکنیک، نتایج نشان می‌دهد که نشست تونل تابعی از برهم‌کنش پیچیده بین شرایط زمین، پارامترهای حفاری و ویژگی‌های سازه‌ای است؛ روابطی که با مدل‌های خطی کلاسیک به‌سختی قابل بیان هستند. ANFIS با ترکیب قابلیت یادگیری شبکه‌های عصبی و ساختار مبتنی بر قواعد فازی، توانسته این روابط را به شکلی شفاف‌تر و در عین حال دقیق‌تر مدل‌سازی کند. علاوه بر این، امکان مشاهده ساختار قواعد استخراج‌شده، مزیتی تحلیلی فراهم می‌کند که

نتایج حاصل از مدل‌سازی مبتنی بر سیستم استنتاج فازی-عصبی تطبیقی نشان داد که این چارچوب هوشمند قادر است رفتار پیچیده و غیرخطی نشست تونل را با دقت قابل توجهی بازنمایی کند. مقایسه مقادیر پیش‌بینی‌شده با داده‌های ابزار دقیق بیانگر همخوانی مناسب بین خروجی مدل و مقادیر واقعی بوده و شاخص‌های خطا در هر دو مرحله آزمایش و واری در دامنه بسیار پایین قرار دارند. این امر بیانگر آن است که ساختار طراحی‌شده نه تنها دچار بیش‌برازش نشده، بلکه از قابلیت تعمیم‌پذیری مناسبی نیز برخوردار است.

یکی از مهم‌ترین نقاط قوت مدل ارائه‌شده، بهره‌گیری از خوشه‌بندی زیرتفکیکی برای تولید ساختار اولیه FIS است. این رویکرد امکان استخراج قواعد فازی مبتنی بر توزیع واقعی داده‌ها را فراهم کرده و وابستگی به قضاوت صرفاً ذهنی در تعریف قواعد را کاهش داده است. همچنین استفاده از تابع عضویت گوسی سبب ایجاد انتقال نرم و پیوسته بین نواحی فازی شده و در نتیجه، نوسانات ناگهانی در خروجی مدل مشاهده نمی‌شود. این ویژگی در مدل‌سازی پدیده‌هایی نظیر

در بسیاری از مدل‌های جعبه‌سیاه در دسترس نیست. در مجموع، یافته‌های این پژوهش نشان می‌دهد که رویکرد فازی-عصبی پیشنهادی می‌تواند به‌عنوان ابزاری کارآمد برای پیش‌بینی نشست در پروژه‌های تونل‌سازی مشابه مورد استفاده قرار گیرد. دقت مناسب، پایداری عددی، و قابلیت تعمیم به شرایط زمین‌شناسی هم‌خانواده، بیانگر ظرفیت بالای این روش در کاربردهای عملی و تصمیم‌سازی مهندسی است. پیشنهاد می‌شود در مطالعات آینده، با افزایش حجم داده‌ها و بررسی سناریوهای مختلف حفاری، دامنه اعتبار مدل توسعه یابد و مقایسه آن با سایر روش‌های هوشمند پیشرفته نیز مورد ارزیابی قرار گیرد.

۷- نتیجه‌گیری

در پژوهش حاضر، با هدف پیش‌بینی دقیق نشست تونل انتقال آب چهل‌چای، یک چارچوب مدل‌سازی مبتنی بر سیستم استنتاج فازی-عصبی تطبیقی (ANFIS) توسعه داده شد و عملکرد آن با داده‌های ابزار دقیق مورد ارزیابی قرار گرفت. ساختار اولیه مدل با استفاده از روش خوشه‌بندی زیرتفکیکی ایجاد گردید و فرآیند آموزش از طریق الگوریتم هیبریدی (ترکیب حداقل مربعات و پسانتشار خطا) در محیط *MATLAB* انجام شد. نتایج نشان داد که مدل پیشنهادی قادر است رفتار غیرخطی نشست را با دقت بالا بازتولید کرده و تطابق قابل قبولی با مقادیر واقعی ثبت‌شده ارائه دهد.

- کاهش قابل توجه خطا در مراحل آزمایش و واری و دستیابی به ضریب همبستگی بالا، بیانگر توانایی مدل در تعمیم‌پذیری و عدم بروز بیش‌برازش است. همچنین تحلیل ساختار قواعد فازی استخراج‌شده نشان داد که شبکه طراحی‌شده می‌تواند روابط پیچیده بین پارامترهای ورودی و پاسخ تغییرشکل تونل را به‌صورت قابل تفسیر مدل‌سازی کند. بر این اساس، رویکرد ارائه‌شده می‌تواند به‌عنوان ابزاری قابل اعتماد برای پیش‌بینی نشست در پروژه‌های تونل‌سازی با شرایط مشابه مورد استفاده قرار گیرد.
- نتایج این پژوهش نشان داد که مدل توسعه‌یافته مبتنی بر سیستم استنتاج فازی-عصبی تطبیقی توانسته است با بهره‌گیری از داده‌های ۶۸ تونل مشابه، ساختاری منسجم و داده‌محور برای پیش‌بینی نشست ارائه دهد. استفاده از روش خوشه‌بندی زیرتفکیکی در

ایجاد *FIS* اولیه موجب استخراج قواعد متناسب با توزیع واقعی داده‌ها شد و بنیان مناسبی برای فرآیند یادگیری فراهم آورد.

- فرآیند آموزش با الگوریتم هیبریدی، شامل ترکیب روش حداقل مربعات و پسانتشار خطا، منجر به همگرایی پایدار و کاهش محسوس خطا گردید. مقادیر میانگین خطا در مراحل آزمایش و واری در سطح بسیار پایین قرار داشت که بیانگر دقت مناسب مدل در بازتولید رفتار نشست است. همچنین مقادیر ضریب همبستگی بالا بین داده‌های پیش‌بینی‌شده و مقادیر واقعی، نشان‌دهنده توانایی مدل در شبیه‌سازی دقیق پاسخ تغییرشکل تونل می‌باشد.

- بررسی عملکرد مدل در برابر داده‌های مستقل واری نشان داد که ساختار طراحی‌شده از تعمیم‌پذیری مطلوبی برخوردار است و نشانه‌ای از بیش‌برازش قابل توجه مشاهده نشد. این موضوع اهمیت انتخاب مناسب پارامترهای آموزشی، تعداد تکرارها و نوع تابع عضویت را در دستیابی به یک مدل پایدار و قابل اعتماد برجسته می‌سازد.

- در مجموع، نتایج حاکی از آن است که رویکرد فازی-عصبی پیشنهادی قادر است روابط غیرخطی و پیچیده میان پارامترهای مؤثر بر نشست تونل را با دقت و پایداری مناسب مدل‌سازی کند. این چارچوب می‌تواند به‌عنوان ابزاری کاربردی در پیش‌بینی رفتار تغییرشکل تونل‌های مشابه و پشتیبانی از تصمیم‌گیری مهندسی در مراحل طراحی و پایش مورد استفاده قرار گیرد.

- با وجود نتایج قابل قبول به‌دست‌آمده از مدل *ANFIS* توسعه‌یافته، این پژوهش دارای محدودیت‌هایی است که توجه به آن‌ها در تفسیر و تعمیم نتایج ضروری می‌باشد. نخست، حجم داده‌های مورد استفاده برای آموزش و ارزیابی مدل نسبتاً محدود بوده است که می‌تواند بر میزان تعمیم‌پذیری مدل تأثیرگذار باشد. هرچند تلاش شده است داده‌ها از پروژه‌های مختلف گردآوری شوند، اما افزایش حجم داده‌ها در مطالعات آتی می‌تواند به بهبود پایداری و دقت مدل کمک نماید. بر این اساس، پیشنهاد می‌شود در تحقیقات آتی

با گسترش پایگاه داده، استفاده از داده‌های متنوع‌تر از نظر شرایط زمین‌شناسی و عملیاتی، و همچنین ترکیب مدل‌های هوشمند با رویکردهای مبتنی بر دانش فیزیکی، دامنه کاربرد و دقت پیش‌بینی مدل‌های مشابه بهبود یابد.

منبع‌ها

- [1] Zhu, Z., & Liu, C. (2025). A review of tunnelling caused ground surface settlement prediction with artificial intelligence method. *Civil and Energy Research*, 2-20. DOI: [10.55976/cer.1202513572-20](https://doi.org/10.55976/cer.1202513572-20)
- [2] Wei, G., Zhang, X. H., Xu, Y. F., & Wang, Z. (2019). Prediction of ground settlement due to excavation of a quasi-rectangular shield tunnel based on stochastic medium theory. *Geotechnical and Geological Engineering*, 37(5), 3605-3618. DOI: [10.1007/s10706-019-00856-7](https://doi.org/10.1007/s10706-019-00856-7)
- [3] Zou, N., Cheng, H. Z., Dai, T., & Yang, Z. H. (2026). Real-time surface settlement prediction in shield tunneling using a time-series framework and interpretable machine learning. *Results in Engineering*, 109478. DOI: [10.1016/j.rineng.2026.109478](https://doi.org/10.1016/j.rineng.2026.109478)
- [4] Niu, G., & He, X. (2026). A Deep Learning-Based Approach for the Evaluation of Tunneling-Induced Ground Surface Settlement Considering Spatial Variability of the Soil. *International Journal of Geomechanics*, 26(3), 04026010. DOI: [10.1061/IJGNAI.GMENG-11938](https://doi.org/10.1061/IJGNAI.GMENG-11938)
- [5] Xiao, Z., Zhou, X., Zhang, C., Xiao, Y., Wei, C., & Chen, J. (2025). Machine Learning-Based Prediction of Ground Settlement in Twin-Tunnel Excavation: A Case Study from Dongguan Metro Line 1. *Indian Geotechnical Journal*, 1-20. DOI: [10.1007/s40098-025-01456-4](https://doi.org/10.1007/s40098-025-01456-4)
- [6] Gu, J., Zhou, J., & Li, C. (2026). Metaheuristic-optimized least squares boosting model for longitudinal settlement prediction in EPB shield construction. *Tunnelling and Underground Space Technology*, 169, 107326. DOI: [10.1016/j.tust.2025.107326](https://doi.org/10.1016/j.tust.2025.107326)
- [7] Chen, S., Wang, Y., Huang, J., Xu, D., & Ravy, M. (2025). Dynamic Surface Deformation Prediction in Urban Shield Tunneling Based on Hybrid Machine Learning Method. *Transportation Infrastructure Geotechnology*, 12(7), 257. DOI: [10.1007/s40515-025-00718-1](https://doi.org/10.1007/s40515-025-00718-1)
- [8] Li, S., Lan, A., Yin, L., Yu, B., & Sun, Y. (2026). Prediction of Tunnel Deformation Based on Machine Learning and Numerical Simulation. *Indian Geotechnical Journal*, 1-17. DOI: [10.1007/s40098-026-01479-5](https://doi.org/10.1007/s40098-026-01479-5)
- [9] Yang, P., Zhou, J., Zhang, Y., Xu, C., Khandelwal, M., & Huang, S. (2025). Ground settlement prediction in urban tunnelling: leveraging metaheuristic-optimized random forest models. *Arabian Journal for Science and Engineering*, 50(20), 17025-17044. DOI: [10.1007/s13369-025-10062-8](https://doi.org/10.1007/s13369-025-10062-8)
- [10] Ye, X. W., Jin, T., & Chen, Y. M. (2022). Machine learning-based forecasting of soil settlement induced by shield tunneling construction. *Tunnelling and Underground Space Technology*, 124, 104452. DOI: [10.1016/j.tust.2022.104452](https://doi.org/10.1016/j.tust.2022.104452)
- [11] Tang, L., & Na, S. (2021). Comparison of machine learning methods for ground settlement prediction with different tunneling datasets. *Journal of Rock Mechanics and Geotechnical Engineering*, 13(6), 1274-1289. DOI: [10.1016/j.jrmge.2021.08.006](https://doi.org/10.1016/j.jrmge.2021.08.006)
- [12] Chen, R., Zhang, P., Wu, H., Wang, Z., & Zhong, Z. (2019). Prediction of shield tunneling-induced ground settlement using machine learning techniques. *Frontiers of Structural and Civil Engineering*, 13(6), 1363-1378. DOI: [10.1007/s11709-019-0561-3](https://doi.org/10.1007/s11709-019-0561-3)
- [13] Wang, Q., Shen, C., Tang, C., Guo, Z., Wu, F., & Yang, W. (2024). Machine learning-based forecasting of ground surface settlement induced by metro shield tunneling construction. *Scientific Reports*, 14(1), 31795. DOI: [10.1038/s41598-024-82837-2](https://doi.org/10.1038/s41598-024-82837-2)

- [14] Zhang, P., Wu, H. N., Chen, R. P., & Chan, T. H. (2020). Hybrid meta-heuristic and machine learning algorithms for tunneling-induced settlement prediction: A comparative study. *Tunnelling and Underground Space Technology*, 99, 103383. DOI: [10.1016/j.tust.2020.103383](https://doi.org/10.1016/j.tust.2020.103383)
- [15] Liu, L., Zhou, W., & Gutierrez, M. (2023). Physics-informed ensemble machine learning framework for improved prediction of tunneling-induced short-and long-term ground settlement. *Sustainability*, 15(14), 11074. DOI: [10.3390/su151411074](https://doi.org/10.3390/su151411074)
- [16] Chen, L., Hashiba, K., Liu, Z., Lin, F., & Mao, W. (2023). Spatial-temporal fusion network for maximum ground surface settlement prediction during tunnel excavation. *Automation in Construction*, 147, 104732. DOI: [10.1016/j.autcon.2022.104732](https://doi.org/10.1016/j.autcon.2022.104732)
- [17] Naeini, S. A., & Khalili, A. (2017). Settlement Prediction for Tehran Subway Line-3 via FLAC3D and ANFIS. *International Journal of Geotechnical and Geological Engineering*, 11(7), 612-617.
- [18] Jang, J. S., & Sun, C. T. (1995). Neuro-fuzzy modeling and control. *Proceedings of the IEEE*, 83(3), 378-406. DOI: [10.1109/5.364486](https://doi.org/10.1109/5.364486)
- [19] Liu, X., Hussein, S. H., Ghazali, K. H., Tung, T. M., & Yaseen, Z. M. (2021). Optimized Adaptive Neuro-Fuzzy Inference System Using Metaheuristic Algorithms: Application of Shield Tunnelling Ground Surface Settlement Prediction. *Complexity*, 2021(1), 6666699. DOI: [10.1155/2021/6666699](https://doi.org/10.1155/2021/6666699)
- [20] Vieira, J., Dias, F. M., & Mota, A. (2004). Neuro-fuzzy systems: a survey. In *5th WSEAS NNA international conference on neural networks and applications, Udine, Italia*, 1-6.
- [21] Jang, J. S. (1993). ANFIS: adaptive-network-based fuzzy inference system. *IEEE transactions on systems, man, and cybernetics*, 23(3), 665-685.
- [22] Nikolić, V., Petković, D., Shamshirband, S., & Čojbašić, Ž. (2015). Adaptive neuro-fuzzy estimation of diffuser effects on wind turbine performance. *Energy*, 89, 324-333. DOI: [10.1016/j.energy.2015.05.126](https://doi.org/10.1016/j.energy.2015.05.126)
- [23] Kourehli, S. S., Chehre, M. K., & Zamani, A. G. (2016). Prediction of structural damage location with adaptive neuro-fuzzy inferential system. *Iranian Journal of Structural Engineering*, 3(1), 61-71.



Development of an Adaptive Neuro-Fuzzy Inference System (ANFIS) for Intelligent Prediction of Tunnel Settlement and Evaluation of Predictive Accuracy Based on Convergence Monitoring Data

Sasan Ghorbani¹, Farhad SamimiNamin^{2*}, Mahdi Mahmoodjanloo

1- Assistant Professor, Department of Mining Engineering, Hamedan University of Technology, Hamedan, Iran.

2- Associate Professor, Department of Mining Engineering, University of Zanjan, Zanjan, Iran.

3- MSc of rock mechanics, Department of Mining Engineering, University of Zanjan, Zanjan, Iran.

Received: 06. October. 2025 Accepted: 19. December. 2025

(*Corresponding author: f.samiminamin@znu.ac.ir)

Keywords

Neuro-Fuzzy Inference System
Tunnel settlement
Convergence meter
Network training

Final English Extended Abstract

Summary

Accurate prediction of tunnel-induced ground settlement is a critical component in the design, construction, and safety assessment of underground structures, particularly in urban and hydraulically sensitive environments. This study develops and evaluates an intelligent predictive framework based on an Adaptive Neuro-Fuzzy Inference System (ANFIS) to estimate tunnel settlement using convergence monitoring data and geotechnical parameters from comparable tunneling projects.

Introduction

Tunnel excavation inevitably disturbs the in-situ stress state, leading to ground deformation and surface settlement that may affect adjacent structures and infrastructure. Conventional empirical and numerical approaches often struggle to capture the highly nonlinear and coupled interactions among geological conditions, excavation parameters, and structural responses. Soft computing techniques, especially hybrid neuro-fuzzy systems, offer an alternative data-driven strategy capable of modeling such complex relationships with improved adaptability and predictive performance.

Methodology and Approaches

In this research, a database comprising 68 tunnel cases with similar excavation methods, geometrical characteristics, and ground conditions was compiled. The initial Fuzzy Inference System (FIS) structure was generated using subtractive clustering to automatically extract rule bases from the data. Gaussian membership functions were employed to ensure smooth transitions between fuzzy regions. The ANFIS model was trained in MATLAB using a hybrid learning algorithm that integrates least-squares estimation for consequent parameters and back-propagation for premise parameter tuning. The dataset was randomly divided into training, testing, and validation subsets to evaluate generalization capability. Model performance was assessed using statistical indices including mean error and correlation coefficient between predicted and measured settlements derived from convergence monitoring instruments.

Results and Conclusions

The developed ANFIS model demonstrated high predictive accuracy, with very low mean errors in both testing and validation phases and a strong correlation between predicted and observed settlement values. The results confirm the ability of the proposed framework to effectively model complex nonlinear relationships governing tunnel-induced deformation. The hybrid learning strategy contributed to stable convergence and minimized overfitting, while the rule-based fuzzy structure provided partial interpretability of the system behavior. Overall, the study indicates that ANFIS constitutes a reliable and efficient tool for intelligent settlement prediction and can support engineering decision-making in tunnel design, monitoring, and risk mitigation for projects with comparable geotechnical conditions.
