

کارایی مدل هیبریدی NNA-ANN در مدل‌سازی تنش خاک در بدنه سدهای خاکی در زمان ساخت و مقایسه با مدل عددی (مطالعه موردی سد کبودال)

حسین حکیمی خانسر^{۱*}، جواد پارسا^۲، علی حسین‌زاده دلیر^۳ و جلال شیری^۴

۱، ۲، ۳ و ۴- به ترتیب: دانشجوی دکترا، استادیار، استاد و دانشیار گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران
تاریخ دریافت: ۱۴۰۰/۷/۱۲؛ تاریخ پذیرش: ۱۴۰۱/۴/۲۶

چکیده

تخمین دقیق مقادیر تنش خاک در بدنه سد خاکی در زمان ساخت از گام‌های ضروری برای مدیریت پایداری آن است. در این پژوهش، تأثیرگذارترین ویژگی‌ها در مدل‌سازی تنش خاک به صورت مطالعه موردی (سد کبودال) با استفاده از الگوریتم هیبرید شبکه عصبی - شبکه عصبی مصنوعی (NNA-ANN) تعیین و بین نتایج مدل هیبریدی با مدل عددی مقایسه شد. پنج ویژگی شامل تراز مخزن، تراز خاکریزی، زمان ساخت، سرعت آبیاری و سرعت خاکریزی برای ورودی مدل هیبریدی هوشمند انتخاب گردید. با استفاده از الگوریتم هیبریدی و روش انتخاب ویژگی، ترکیب سه ویژگی، شامل تراز خاکریزی، زمان ساخت سد و تراز آب گیری (با RMSE برابر با ۰/۵۰۲۴) مؤثرترین ویژگی‌ها در مدل‌سازی تنش کل در سلول منتخب بودند. نتایج بررسی‌ها نشان داد که مدل هیبریدی در سد کبودال با مقادیر R^2 ، RMSE، MAE و NS به ترتیب برابر با ۰/۹۹۹۹، ۰/۹۹۹۹، ۰/۹۹۹۹ و ۰/۹۹۹۹ نسبت به مدل عددی با مقادیر به ترتیب برابر با ۰/۹۶۲۵، ۰/۹۶۲۵، ۰/۹۶۲۵ و ۰/۹۶۲۵ دارای عملکرد بهتری در مدل‌سازی تنش کل خاک است. این پیش‌بینی برای سایر سلول‌ها در مقاطع مختلف سد مذکور نیز قابل استناد است. نتایج حاصل از این تحقیق برای ساخت‌گاه جدید با مشخصات ژئوتکنیکی جدید یعنی سد مسجد سلیمان نیز معتبر بود ولی برای هر ساخت‌گاه از ترکیب مناسب به خود باید استفاده کرد.

واژه‌های کلیدی

انتخاب ویژگی، سلول تنش سنجی خاک، المان محدود، هوش مصنوعی

مقدمه

برنامه ساخت، فراهم کردن محافظت قانونی و فراهم کردن اطلاعات برای اندازه‌گیری کمیت‌ها، از ابزار گذاری در زمان ساخت استفاده می‌شود (Salmasi et al., 2019). از نظر روش ساخت، سدهای خاکی به دو گروه تقسیم می‌شوند که تقریباً همه آنها در گروه غلتکی (کوبیدنی) قرار دارند. تراکم خاک در سدهای خاکی به روش‌های معمول تراکم صورت می‌گیرد. ضخامت لایه‌ها ۱۵ تا ۲۵ سانتی‌متر است؛

سدها و مخازن ذخیره آب وظیفه‌ای مهم در پیشرفت اقتصادی و تأمین آب دارند (Nourani et al., 2012). به علت آسان بودن اجرا، در دسترس بودن مصالح و عملکرد سازه‌ای، سدهای خاکی در بین انواع مختلف سد اهمیت بالایی دارند (Hakimi Khansar., 2021). برای حصول اطمینان از ایمنی، به‌حداقل رساندن هزینه‌های ساخت، کنترل روش و

مانند ایران که فاقد ابزار پیشرفته، امکانات و اطلاعات برای تخمین تنش خاک در مدت زمان ساخت سدهای خاکی هستند و آب و هوای مختلف دارند، برآورد تنش خاک به یک چالش تبدیل شده است. هدف این مطالعه برآورد تنش خاک با یک مدل هیبریدی با شبکه عصبی است برای از بین بردن دو محدودیت، یکی فقدان مدل جامع برای همه سدهای خاکی و دیگری کمبود اطلاعات ژئوتکنیکی و پر هزینه بودن آن در ایران. مدل‌های هوش مصنوعی از جمله شبکه‌های عصبی برای بررسی و مدل‌سازی بسیاری از علوم مهندسی کاربرد دارند. با گسترش الگوریتم‌های فرا ابتکاری، ترکیب آنها با شبکه‌های عصبی به دلیل نتایج دقیق‌تر بسیار متداول شده است.

فرایند انتخاب ویژگی^۱ برای دو حالت تخمین و طبقه‌بندی ویژگی‌ها کاربرد دارد (Wu et al., 2014). تخمین زیرمجموعه همیشه نظارت شده است، درحالی‌که ویژگی‌ها را می‌توان نظارت شده یا در برخی موارد غیر نظارت شده طبقه‌بندی کرد (Cucci et al., 2015). با استفاده از روش انتخاب ویژگی می‌توان محاسبات ضروری را دنبال کرد و زمان اجرای محاسبات را کاهش داد بی آنکه دقت پیش‌بینی کاهش یابد (Chandrashekar & Sahin., 2014). رانکوویچ و همکاران (Ranković et al., 2014) به کمک رگرسیون بردار پشتیبان یک سد بتنی را مدل‌سازی کردند که نتایج نشان داد مدل هوشمند نتایج دقیق‌تری ارائه می‌دهد. نوکوویچ و همکاران (Novakovic et al., 2014) برای پیش‌بینی فشار آب حفره‌ای پیزومتریک سد آبرون گیت^۲ از مدل فازی-عصبی استفاده کردند؛ مقایسه مقادیر پیش‌بینی‌شده با این مدل با داده‌های مشاهداتی حاکی از آن بود که مدل فازی-عصبی نتایج دقیقی

لایه‌ها در هر مرحله کوبیده می‌شوند (Hakimi Khansar., 2021). نیازمند بودن به تخصص، محاسبات طولانی و وقت‌گیر، و تعیین دقیق شرایط اولیه مسئله در مدل‌سازی عددی (معمولا با روش المان محدود) در پیش‌بینی تنش خاک در بدنه سدهای خاکی در زمان ساخت باعث شده است تا در این مطالعه از مدل‌سازی هوشمند برای این منظور استفاده شود. تنش ایجادشده در داخل خاک به طور چشمگیری بر رفتار مهندسی آن تأثیر می‌گذارد و تغییر مقدار آن در زمان ساخت سدهای خاکی باعث تغییر حجم، ایجاد گسیختگی پیش‌رونده، تراکم خاک، تغییر مقاومت برشی و ایجاد نشست در سدهای خاکی می‌شود، بنابراین، اندازه‌گیری تنش کل خاک یکی از راهکارهای ضروری است که در سدهای خاکی با ابزار دقیق نصب‌شده در آن اجرا می‌شود (Parsa et al., 2021). عواملی مثل مدت زمان ساخت سد، تراز و سرعت خاکریزی، تراز و سرعت تراز آب مخزن و ... در حین ساخت سدهای خاکی در مقدار تنش خاک تأثیرگذار هستند که نحوه توزیع آن در هر پروژه به صورت تصادفی رخ می‌دهد. بنابراین، استفاده از مدل‌های هوش مصنوعی که ورودی و خروجی مشاهداتی را دریافت می‌کنند و مقدار آن را تخمین می‌زنند، با توجه به پیچیدگی زیاد و قطعیت‌نداشتن، می‌تواند در بهبود مدل‌سازی آن مؤثر باشد (Nourani et al., 2012; Parsa et al., 2021). به علت گسترش دامنه علوم و پیچیدگی در تصمیم‌گیری‌ها، استفاده از هوش مصنوعی اهمیت زیادی دارد. مدل‌های هوش مصنوعی نتیجه کوشش‌های علمی جدید است که مدل‌سازی، تحلیل و کنترل سیستم‌های پیچیده را به آسانی و با موفقیت به سرانجام می‌رساند (Nourani, 2013; Nourani & Babakhani, 2015). کشورهای

مشاهداتی و مدل شده را نشان داد. در این تحقیق با استفاده از ترکیب یک الگوریتم تکاملی با مدل شبکه عصبی مصنوعی، تنش کل خاک در تمام مقاطع حین ساخت سد خاکی مدل سازی شد و کارایی مدل هیبریدی NNA-ANN با مدل عددی در یکی از مقاطع مقایسه و نتایج با سد با ساختگاه متفاوت دیگر مقایسه گردید.


مواد و روش ها

سد کبودوال

سد کبودوال (قره سو زرینگل) در شمال شرق ایران و در استان گلستان و اطراف شهر علی آباد در ۴۰ کیلومتری شرق گرگان واقع قرار دارد. این سد در حد فاصل طول جغرافیایی ۵۴ درجه و ۴۰ دقیقه تا ۵۴ درجه و ۵۶ دقیقه شرقی و عرض جغرافیای ۳۶ درجه و ۵۴ دقیقه تا ۳۷ درجه و ۶۰ دقیقه شمالی قرار دارد. سد کبودوال همگن و دارای فیلتر و زهکش میل است. به علت اینکه نحوه و سرعت بارگذاری در زمان ساخت سد بر پی و بدنه سد کبودوال تأثیرگذار است و همچنین ارزیابی رفتار پی و بدنه سد، به خصوص در بخش میانی بدنه، برای تغییر شکل پذیری پی در این بخش از مقطع عرضی ۱۹ (مقطع عرضی بخش میانی بدنه و پی سد) برای بررسی فشار قائم خاک در زمان ساخت استفاده گردید. از داده های ابزار دقیق سد کبودوال (اخذ شده از شرکت آب منطقه ای استان گلستان) در زمان ساخت در دوره آماری ۴ ساله، ۱۹۵ عدد، برای پژوهش حاضر استفاده شد. جا نمایی سیستم پیزومتریک (پیزومترهای الکتریکی) و سلول های فشارسنجی خاک مقطع ۱۹ در شکل ۱ ارائه شده

ارائه می دهد. نورانی و همکاران (Nourani *et al.*, 2012) در یک سد خاکی در ایران، برای بررسی فشار آب پیزومتریک از مدل های ANN و از داده های تراز آب بالادست-پایین دست سد استفاده و نتایج به دست آمده را با نتایج مدل FEM مقایسه کردند و به این نتیجه رسیدند که مدل ANN دارای دقت بالاتری نسبت به مدل عددی (FEM) است. تایفور و همکاران (Tayfur *et al.*, 2005) جریان داخلی سدی را در کشور لهستان با روش های المان محدود و شبکه عصبی مدل سازی کردند. این محققان سطح آب در بالادست و پایین دست سد را ورودی های مدل هوشمند و سطح آب در داخل پیزومتر را خروجی آن قرار دادند و به این نتیجه رسیدند که مدل سازی با شبکه عصبی برای بررسی سطح آب در داخل خاک، نتایج مناسبی ارائه می دهد. نورانی و باباخانی (Nourani & Babakhani, 2013) از شبکه مصنوعی تابع شعاعی (RBF) استفاده کردند و به این نتیجه رسیدند که شبکه عصبی به سبب انعطاف پذیری آن قادر به پیش بینی مناسبی از مقادیر نشت خواهد بود. حکیمی خانسر (Hakimi Khansar, 2021) رفتار سد کبودوال را در حین ساخت با مدل سازی عددی سه بعدی تخمین زدند و مقادیر حاصل از شبیه سازی عددی را با تحلیل برگشتی با مقادیر نظیر داده های ابزار دقیق سد مقایسه کردند. کماسی و بیرانوند (Koması & Beiranvand, 2020) جابه جایی های قائم و افقی سد خاکی ایوشان را با استفاده از ابزار دقیق و مدل عددی بررسی و به منظور تطبیق داده های مشاهداتی و پیش بینی شده از رگرسیون چند متغیره استفاده کردند که نتایج همخوانی حدود ۸۵ درصدی بین داده های

است. در این مقطع، دو سلول فشارسنجی از سلول^۱ فشارسنجی TPC19.1 برای مقایسه TPC19.1 و TPC19.2 وجود دارد (Hakimi Khansar et al., 2014). در این تحقیق مدل عددی و هوشمند استفاده شده است.



شکل ۱- جا نمایی ابزار دقیق نصب شده در مقطع عرضی ۱۹


Figure 1- Location of instrumentation installed in the cross section 19

یکی از سلول‌های نصب شده در مقاطع ۴، ۲۳، ۲۵، ۲۷ برای مقایسه نتایج مدل‌سازی هوشمند با مقطع ۱۹ استفاده شده است که به علت محدودیت در صفحات مقاله از آوردن شکل‌های مربوط به آن خودداری شده است. هدف از این کار این است که مشخص شود آیا نتایج مدل‌سازی هوشمند در دیگر سلول‌های نصب شده در مقاطع دیگر سد نیز قابل استناد هست یا نه.

سد مسجدسلیمان

سد مسجد سلیمان از نوع سنگریزه‌ای با هسته رسی قائم است، با ارتفاع حداکثر ۱۷۸ متر از پی سد، یکی از بلندترین سدهای خاکی ایران و دومین سد خاکی بلند خاورمیانه محسوب می‌شود. این سد در ۲۵ کیلومتری شمال شرقی شهر مسجدسلیمان در استان خوزستان به روی رودخانه کارون احداث شده

است. زمردیان و چوچی (Zomorodian & Chochi, 2013) در تحقیقی ضمن مدل‌سازی عددی سد مسجدسلیمان، تغییر شکل‌های داخلی، فشار آب منفذی، ضریب فشار آب منفذی و تنش کل محاسبه شده را با مقادیر اندازه‌گیری شده با ابزار دقیق سد در هنگام ساخت و آگیری سد مقایسه و برای آنالیز از نرم‌افزار ژئواستودیو^۲ و از بلندترین مقطع سد (شکل ۲) استفاده کردند. مدل‌های رفتاری استفاده شده در تحلیل، مدل الاستیک خطی و الاستیک غیرخطی بود. برای ارزیابی دقیق و به‌دست آوردن ویژگی‌های صحیح مدل رفتاری، آزمایش‌های سه محوری مدل گردید که روی مصالح هسته صورت گرفته است. این محققان تأثیر آگیری را بر تغییر شکل، فشار آب منفذی، ضریب فشار آب منفذی و تنش کل ارزیابی کردند.



شکل ۲- مرتفع ترین مقطع عرضی سد مسجدسلیمان و نحوه ابزار گذاری آن
Figure 13- The highest cross section and instrument of Masjed Soleiman dam

در جهت کاهش مقدار خطا توسط طراح مشخص می گردد (Parsa et al., 2021).

الگوریتم فرا ابتکاری شبکه عصبی (NNA)

الگوریتم های تکاملی زیرمجموعه ای از محاسبات تکاملی اند و در شاخه هوش مصنوعی قرار می گیرند. الگوریتم های تکاملی شامل الگوریتم هایی برای جستجو هستند که در آنها جستجو از چندین نقطه در فضای جواب صورت می گیرد. الگوریتم فرا ابتکاری شبکه عصبی (NNA) را (Sadollah et al., 2018) گسترش دادند. این الگوریتم بهینه سازی با الهام از سیستم های عصبی بیولوژیکی و شبکه های عصبی مصنوعی (ANNs) برای حل مشکلات پیچیده بهینه سازی پیشنهاد شده است. روش پیشنهادی، که الگوریتم شبکه عصبی (NNA) نامیده می شود، بر اساس ساختار منحصر به فرد مدل های شبکه عصبی مصنوعی (ANN) توسعه یافته است. این الگوریتم از ساختار پیچیده شبکه عصبی و عملگرهای آن به منظور ایجاد راه حل های جدید سود می برد. داشتن یک الگوریتم بدون هیچ گونه تلاشی برای تنظیم دقیق پارامترهای اولیه و آماری در مدل

در این تحقیق از نتایج مدل عددی این سد برای مقایسه با مدل هوشمند استفاده شده است.

شبکه های عصبی مصنوعی (ANN)

شبکه های عصبی مصنوعی بر اساس استنباط از سیستم عصبی بیولوژیکی استوار است. در میان نمونه های متعدد شبکه های عصبی، شبکه انتشار به عقب کاربرد بیشتری دارد (Lippmann, 1987). در این پژوهش، نوع شبکه عصبی مصنوعی پرسپترون چند لایه (MLP) با الگوریتم پس انتشار خطا انتخاب شد. اساس روش پس انتشار خطا بر پایه قانون یادگیری اصلاح خطاست که از دو مسیر اصلی رفت و برگشت تشکیل می شود. در مسیر رفت، بردار ورودی به شبکه اعمال می شود و تأثیراتش از طریق لایه های میانی به لایه خروجی انتشار می یابد و بردار خروجی پاسخ واقعی شبکه را تولید می کند (Haykin, 1998; Norouzi et al., 2021). تعداد نرون های موجود در لایه های ورودی و خروجی با توجه به ماهیت مسئله مورد بررسی مشخص می شود، حال آنکه تعداد نرون های موجود در لایه های پنهانی و نیز تعداد این لایه ها با سعی و خطا

ویژگی در این روش با تعداد ویژگی مطلوب از پیش تعیین شده و معلوم، با کد بندی گسسته به صورت مسئله بهینه‌سازی جای گشتی انجام گرفت. سپس داده‌ها به دو دسته آموزشی (۷۰ درصد) و آزمون (۳۰ درصد) تقسیم‌بندی شدند و برای محاسبه خطای مدل، از میانگین وزنی خطاهای آموزشی و آزمون به صورت زیر در سلول TPC19.1 استفاده شد:

$$\text{Error}_{rf} = 0.8\text{error}_{tr} + 0.2\text{error}_t \quad (1)$$

که در آن،

Error_{rf} ، error_{tr} و error_t = به ترتیب خطای نهایی مدل به ازای ترکیب‌های متفاوت از ویژگی‌ها؛ خطای داده‌های آموزشی؛ و آزمون.

شاخص خطا نیز RMSE انتخاب گردید. به دلیل اینکه در فرایند انتخاب ویژگی، هدف تشخیص ویژگی‌های مهم و موثر بر متغیر خروجی است و نه تخمین آن، بنابراین خطای داده‌های آموزشی اهمیت بالاتری نسبت به خطای داده‌های آزمون دارد، زیرا رابطه بین متغیرهای ورودی و هدف با توجه به داده‌های آموزشی حاصل می‌شود. برای افزایش بازده آموزش شبکه ابتدا تمامی داده‌ها با استفاده از رابط ۲ بین ۰/۱ و ۰/۹ نرمال شدند.

$$x_n = \left(0.8 * \left(\frac{(x - x_{min})}{(x_{max} - x_{min})} \right) \right) + 0.1 \quad (2)$$

که در آن،

X_n = نرمال‌شده داده‌های مشاهداتی؛ و X_{min} = داده‌های مشاهداتی؛ و X_{max} = حداقل داده‌ها؛

آنالیز حساسیت

آنالیز حساسیت اطلاعات مفیدی در مورد میزان حساسیت مدل به متغیرهای ورودی در اختیار طراح

می‌تواند این الگوریتم را از دیگر بهینه‌سازهای گزارش شده متمایز کند. این الگوریتم روشی تطبیقی بدون نظارت برای حل مشکلات بهینه‌سازی است. بدون نظارت در آن به این معنی است که هیچ سرنخ و اطلاعاتی در مورد فرآیند بهینه وجود ندارد و راه‌حل‌ها با یادگیری از محیط به‌روز شده است. این الگوریتم روش بهینه‌سازی پرسپترون تک لایه است که بازخورد خود دارد.

انتخاب ویژگی

نوع و تعداد داده‌های ورودی مهم‌ترین نکته در مدل‌سازی هوش مصنوعی است. با بررسی داده‌های سلول TPC19.1 در مقطع ۱۹ در سد کبودوال، تراز خاکریزی (F) بر حسب (m.a.s.l)، تراز آب مخزن (R) بر حسب (m.a.s.l)، مدت زمان ساخت سد (T) بر حسب (day)، سرعت خاکریزی بر حسب $\left(\frac{\text{m.a.s.l}}{\text{day}}\right)$ به عنوان ورودی و فشار قائم خاک (P) بر حسب (kp) ایجادشده بر بدنه سد خاکی در حین ساخت، به عنوان خروجی مدل هوشمند انتخاب شده است.

روش انتخاب ویژگی، انتخاب زیرمجموعه‌ای از ویژگی‌های مرتبط با یک هدف خاص به کار می‌رود و اصل مهم در آن، انتخاب ویژگی‌های پایدار و حذف ویژگی‌های اضافی است (Kumar & Minz, 2014).

در این فرایند، مؤثرترین زیرمجموعه ویژگی‌ها از مجموعه کل ویژگی‌های ورودی با توجه به حداقل خطای ممکن انتخاب می‌شود و ویژگی‌های مازاد حذف می‌شوند. در این پژوهش، یک الگوریتم تکاملی (الگوریتم شبکه عصبی مصنوعی (NNA)) با شبکه عصبی مصنوعی (ANN) در محیط متلب ۲۰۱۴ باهم ترکیب شد که قادر است روابط پیچیده و غیرخطی را پیش‌بینی کند و ویژگی‌های مؤثر برای مدل‌سازی متغیر هدف را استخراج کند. انتخاب

P_i = مقدار ویژگی محاسبه شده از تحلیل عددی یا هوش مصنوعی، و O_i = مقدار ویژگی واقعی از ابزار دقیق سد؛ و N = تعداد داده ها.

هر چه شاخص نش ساتکلیف (NS) و ضریب تبیین (R^2) به عدد یک نزدیک تر باشد کارایی مدل مطلوب تر است و هر اندازه جذر میانگین مربعات خطا (RMSE) و نیز میانگین هندسی نسبت خطا (MAE) به عدد یک نزدیک تر باشند، خروجی ها دقیق تر و مقادیر واقعی و پیش بینی شده به هم نزدیک ترند (Nouri & Salmasi, 2019). از شاخص میانگین هندسی نسبت خطا (GMER) برای مشخص کردن بیش برآورد یا کم برآورد مدل استفاده شده است. اگر مقدار GMER کمتر یا بیشتر از عدد یک باشد به ترتیب نشان دهنده کم برآورد یا بیش برآورد مدل است (AmiriMijan et al., 2019).

آنالیز برگشتی

تحلیل برگشتی روشی است که در آن توانایی تأمین پارامترهای کنترل کننده به کمک تحلیل رفتار خروجی حاصل می شود (Jeon & Yang, 2004; Karakus & Fowell, 2005). تحلیل برگشتی به دو صورت است: روش معکوس و روش مستقیم. تحلیل برگشتی مستقیم بر اساس کاهش مقدار اختلاف بین مقدار پارامتر اندازه گیری شده با مقادیر محاسبه شده از تحلیل عددی معمول با فرض پارامترهای مجهول استوار است (Karakus & Fowell, 2005). این کار با تابعی به نام تابع خطا صورت می گیرد که با رابطه ۸ نشان داده می شود.

$$E = \left(\frac{\sum_{i=1}^n (P_i - O_i)^2}{\sum_{i=1}^n O_i} \right) \quad (۸)$$

که در آن،

مدل قرار می دهد. با شناسایی میزان تأثیر متغیرهای ورودی بر دقت پیش بینی مدل می توان متغیرهای کم اثر را از مدل سازی حذف و مدل ساده تری را بسط داد و تأثیر هر یک از متغیرها را روی مدل نشان داد. در پژوهش حاضر، آنالیز حساسیت به روش هیل (Hill, 2000) برای متغیرهای ورودی اجرا شد. در روش هیل، با تغییر هر یک از ویژگی های ورودی، به یک مقدار معلوم (مثلاً ۲۰ درصد)، تأثیرگذاری آن بر خروجی مدل محاسبه می گردد (Hill, 2000).

ارزیابی مناسب بودن مدل

در این مطالعه از شاخص های آماری جذر میانگین مربعات خطا (RMSE)، ضریب تبیین (R^2)، میانگین هندسی نسبت خطا (MAE)، نش ساتکلیف (NS) و نیز میانگین هندسی نسبت خطا (GMER) برای بررسی و ارزیابی دقت مدل ها استفاده گردید. شاخص های مذکور با استفاده از رابطه های ۳ تا ۷ محاسبه می شوند:

$$R^2 = \left(\frac{\sum_{i=1}^n (O_i - \bar{O})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^n (O_i - \bar{O})^2 \sum_{i=1}^n (P_i - \bar{P})^2}} \right)^2 \quad (۳)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (P_i - O_i)^2}{N}} \quad (۴)$$

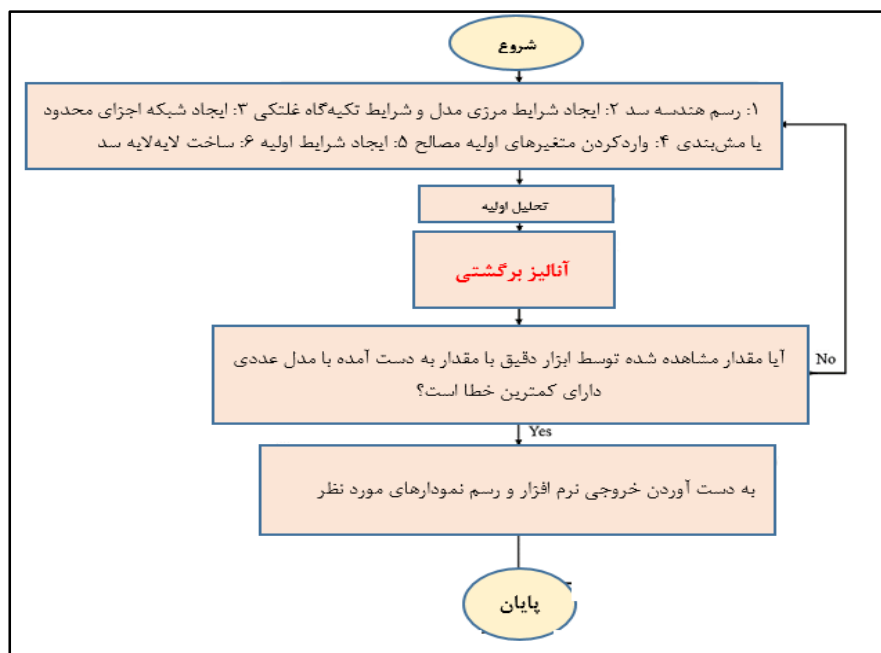
$$MAE = \frac{\sum_{i=1}^n |E_i - O_i|}{n} \quad (۵)$$

$$NS = \left| 1 - \left[\frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \right] \right| \quad (۶)$$

$$GMER = \exp \left[\frac{1}{N} \sum_{i=1}^n \ln \left(\frac{P_i}{O_i} \right) \right] \quad (۷)$$

که در آنها،

E = تابع خطا؛ و P_i = مقادیر محاسبه‌شده از تحلیل
 عددی؛ و O_i = مقادیر واقعی از ابزار دقیق سد؛ و n =
 تعداد داده‌های مورد استفاده.
 شکل ۳ فلوجارت آنالیز برگشتی و نحوه
 اجرای آن را در این مطالعه نشان
 می‌دهد.



شکل ۳- روش آنالیز برگشتی در تحقیق (Rashidi & Haeri, 2017)

Figure 3 - Back analysis method in research

سد کبودوال استفاده شده است (Hakimi Khansar et al., 2014)

مدل موهر-کولمب پنج پارامتر ورودی دارد: در این مدل، مدول یانگ برای الاستیسیته خاک، ضریب پواسون برای الاستیسیته خاک، چسبندگی برای پلاستیسیته خاک، زاویه اصطکاک داخلی خاک برای پلاستیسیته خاک، و زاویه اتساع استفاده می‌شود. برای سهولت کار و بی‌نیاز بودن به پارامترهای زیاد، در بسیاری از پژوهش‌ها از این مدل به طور گسترده استفاده می‌شود.

مدل سخت شونده (HS)

در مدل رفتاری سخت شونده، سطح تسلیم در فضای تنش‌های اصلی محدود نیست و به علت وجود کرنش‌های پلاستیک سطح مزبور توسعه می‌یابد. در

مدل موهر-کولمب (MC)

محاسبهٔ نمو کرنش‌های پلاستیک، الاستیک و نمو تنش در تحلیلی ژئوتکنیکی به علت حاکمیت رفتار الاستوپلاستیک به کمک مدل‌های رفتاری مناسب به صورت دقیق ضروری است. مدل‌های رفتاری نقاط قوت و ضعف خاص خود را دارند (Bolouri-Bazaz & Mobini-Zad, 2010). در مطالعهٔ حاضر از نرم‌افزار پلاکسیس و از مدل‌های رفتاری موهر-کولمب و خاک سخت شونده برای مدل‌سازی استفاده گردید. از آنجا که در پژوهش‌های انجام‌شده توسط نرم‌افزار پلاکسیس در مورد سدهای خاکی مدل‌های رفتاری موهر-کولمب و خاک سخت شونده بیشترین کاربرد را نسبت به سایر مدل‌ها دارند از این دو مدل رفتاری برای مدل‌سازی عددی

اصلاح شده k^* مرتبط کرد، به عبارتی دیگر رابطه های ۱۲ و ۱۳ را داریم :

$$E_{ur}^{ref} = 3p^{ref}(1 - 2v_{ur})/k^* \quad (12)$$

$$k^* = k/(1 + e_0) \quad (13)$$

که در این مدل v_{ur} اثر خزش یا نشست ثانویه در نظر گرفته نمی شود زیرا معمولاً در درازمدت رخ می دهد (Brinkgreve & Vermeer, 2001). روشن است با توجه به اینکه در دوره ساخت معمولاً نشست های اولیه اتفاق می افتد مدل سخت شونده کار آیی بهتری می تواند در مدل سازی خاک داشته باشد. این مدل مدلی است پیشرفته برای شبیه سازی رفتار خاک، آن چنان که برای مدل موهر کلمب حالات محدود تنش به وسیله زاویه اصطکاک و چسبندگی c و زاویه اتساع ϕ بیان می شود. سختی خاک با استفاده از سه ورودی متفاوت سختی بسیار دقیق تر توصیف می شود (Salmasi et al., 2019). با توجه به شکل ۴، سختی بارگذاری محوری E_{50} ، سختی باربرداری E_{ur} ، سه محوری و سختی بارگذاری ادنومتر E_{oed} که مقدار میانگین برای انواع مختلف خاک داریم:

$$E_{oed} = E_{50} \text{ و } E_{ur} = 3E_{50} \quad (14)$$

این مدل، دو رفتار برشی و فشاری سخت شونده وجود دارد که به ترتیب برای مدل کردن کرنش های پلاستیک غیرقابل برگشت در اثر تنش انحرافی و تنش فشاری همه جانبه استفاده می شود. این مدل برای شبیه سازی رفتار انواع مختلف خاک های نرم و سخت نیز کاربرد زیادی دارد. (Brinkgreve & Vermeer, 2001). یکی از ویژگی های این مدل وابستگی سختی خاک به تنش است که در شرایط تحکیمی با رابطه ۹ بیان می شود:

$$E_{oed} = E_{oed}^{ref} (\sigma/p^{ref})^m \quad (9)$$


برای خاک های نرم فرض $m=1$ به واقعیت نزدیک تر است. در این حالت رابطه های ۱۰ و ۱۱ را خواهیم داشت.

$$E_{oed}^{ref} = p^{ref}/\lambda^* \quad (10)$$

$$\lambda^* = \lambda/(1 + e_0) \quad (11)$$

که در آنها،

p^{ref} = تنش مرجع؛ و m = اندیس فشردگی اصلاح شده؛ E_{oed}^{ref} = سختی مماسی در یک تنش عمودی؛ و E_{oed} = مدل سختی مماسی. به بیان دیگر، ضریب ارتجاعی باربرداری - بارگذاری مجدد یعنی k را می توان به ضریب تورم



شکل ۴- پارامترهای مرتبط برای نتایج آزمایش سه محوری زهکشی شده
Figure 4. Relevant parameters for the results of the Consolidated Drained test

مهم‌ترین فرق بین مدل موهرکلمب و خاک سخت شونده این است که در مدل خاک سخت شونده تمام سختی‌ها با فشار افزایش می‌یابند یعنی این مدل، تابع تنش بودن مدول سختی را در نظر می‌گیرد. به عبارت دیگر هر سه سختی ورودی وابسته به تنش مرجع ۱۰۰ کیلو پاسکال است (Brinkgreve & Vermeer, 2001).

مدل عددی (المان محدود)

در این تحقیق، برای مدل‌سازی عددی از نرم‌افزار پلاکسیس سه بعدی نسخه ۱/۶ استفاده شده است که به روش اجزای محدود^۱ کار می‌کند. معمولاً برای تحلیل تنش-کرنش سدهای خاکی و خاک ریزه‌ای از روش اجزای محدود به صورت دو بعدی در شرایط کرنش صفحه‌ای استفاده می‌شود که موجب ساده شدن محاسبات می‌گردد اما این کار باعث می‌شود دقت محاسبات کم شود و شرایط واقعی سد، که به صورت سه بعدی است، در مدل دیده نشود، تحقیقات با مدل‌سازی عددی سه بعدی در حین ساخت سدهای خاکی در ایران اندک است، از این رو نگارندگان این پژوهش مدل عددی سه بعدی سد کبودوال را مطالعه کردند. ابتدا هندسه سد در نرم‌افزار، مدل و شرایط مرزی مدل و شرایط تکیه‌گاه غلتکی در کناره‌های عمودی در آن ایجاد شد. پس از ساخت مدل، شبکه اجزای محدود مش‌بندی مقطع ایجاد گردید، که در شکل ۷ مش‌بندی سه بعدی در نرم‌افزار پلاکسیس نشان داده شده است. در مدل‌سازی در حالت سه بعدی

این نکات مد نظر قرار گرفت: از مش بندی ریز استفاده گردیده است و عرض مدل ۵۰ متر و پی سد ۴۰ متر در نظر گرفته شد، که این مقادیر با سعی و خطا و در مقدار بهینه به دست آمده است. در خلال اجرای مش‌بندی سه بعدی، وضعیت لایه‌های خاک میان چاهک‌ها متناسب شد و مش‌بندی به گونه‌ای اجرا شد که انطباق کاملی بین حد و مرزهای میان لایه‌های خاک و حد و مرزهای المان‌ها وجود داشته باشد. در این تحقیق، از المان‌های مثلثی ۱۵ گره‌ای استفاده گردید. با نرم‌افزار، ساخت به صورت لایه به لایه و مرحله‌ای سد مدل‌سازی و پدیده تحکیم در آن شبیه‌سازی شده است. در ساخت سد از ۸ لایه استفاده شده است. پس از ساخت هندسه مدل و وارد کردن متغیرهای اولیه مصالح، تحلیل اولیه صورت می‌پذیرد و پس از آن تحلیل‌های برگشتی قابل اجراست. با توجه به طبیعت غیرخطی مصالح خاکی استفاده‌شده در بدنه و پی سد، باید از مدل رفتاری مناسبی در تحلیل‌ها استفاده شود. با توجه به تحقیقات سلماسی و همکاران (Salmasi et al., 2019)، که نشان دادند مدل خاک سخت‌شونده برای مدل‌سازی عددی سد خاکی نتایج مطلوب‌تری ارائه می‌دهد، از این مدل رفتاری خاک در بدنه سد کبودوال برای مدل عددی استفاده شده است و برای پی سد از مدل موهر کلمب استفاده گردید. در جدول‌های ۱ و ۲، مشخصات مصالح نهایی پس از تحلیل برگشتی (Jeon & Yang, 2004) و با مدل رفتاری سخت شونده در بدنه سد آورده شده است.

جدول ۱- پارامترهای مصالح بعد از تحلیل برگشتی در مدل عددی

Table 1- Material parameters after back analysis in numerical model

$K_{x,y}$ (m/day)	Φ (°)	c_{ref} (KN/m2)	ν	E_{ref} (KN/m2)	γ_{sat} (KN/m3)	γ_{unsat} (KN/m3)	نوع مصالح	خصوصیات مصالح
۰/۰۰۰۰۸۷	۲۹	۱۸	۰/۳	۱۰۰۰۰	۲۰	۱۷	Undrain	پی
۰/۰۰۰۸۶۸	۲۵	۲۲	۰/۴	۱۰۰۰۰	۲۳	۱۹	Drained	بدنه
۸/۶۴	۳۶	۱۲	۰/۲۵	۲۵۰۰	۲۱	۲۰	Drained	فیلتر و زهکش


جدول ۲- مشخصات تکمیلی مصالح در مدل رفتاری سخت شونده

Table 2 - Additional characteristics of materials in the hardening behavioral model

k_0^{nc}	E_{ur} (KN/m2)	E_{oed} (KN/m2)	E_{50} (KN/m2)	κ^*	λ^*	خصوصیات مصالح
۰/۴۷۸	۵۰۰۰۰	۲۵۰۰۰	۲۵۰۰۰	۰/۰۰۱	۰/۰۰۱	بدنه

آب مخزن با توجه به تراز آبگیری سد، از تراز ۱۶۰ تا تراز ۱۷۴ متر در نرم افزار شبیه سازی گردید. این عمل در قسمت چاهک ها و نیز بخش محاسبات نرم افزار اجرا شده است (شکل ۵). روند خاک ریزی طبق برنامه زمان بندی اجرای سد شبیه سازی (مدلسازی) شده است و در خود نرم افزار هنگام خاک ریزی، آبگیری با فعال کردن تراز سطح آب در ارتفاع خواسته شده صورت پذیرفته است.

در جدول های بالا عوامل ژئوتکنیکی و مکانیکی خاک عبارت اند از c_{ref} چسبندگی (موثر)، Φ زاویه اصطکاک داخلی (موثر)، ν نسبت پواسون، γ_{sat} وزن مخصوص اشباع، γ_{unsat} وزن مخصوص غیراشباع، E_{ref} ضریب پواسون و k هدایت هیدرولیکی آب، k_0^{nc} نسبت تنش در حالت تحکیم نرمال. دیگر پارامترها در قسمت مربوط به مدل سخت شونده توضیح داده شده است. در مدل عددی تراز



شکل ۵- مش بندی سه بعدی (سمت چپ) و وضعیت تراز آب مخزن و خط فریاتیکی در پایان ساخت مدل HS (سمت راست)

Figure 5- Three-dimensional mesh (left) and the reservoir level and ferriatic line at the end of construction of the HS model (right)

مقایسه مدل عددی و هوشمند


در آخرین مرحله خاک ریزی سد کبودوال یعنی پایان ساخت نشان داده شده است. بر اساس نتایج ارائه شده مدل سازی تنش خاک با مدل هیبریدی NNA-ANN در شکل ۷، زیرمجموعه سه تایی، کمترین خطا (مقدار RMSE برابر با ۰/۵۰۲۴) را در مدل سازی تنش خاک دارد. با آنالیز حساسیت روی ویژگی ها، از بین ۵ ویژگی اندازه گیری شده، سه ویژگی شامل تراز خاکریزی، مدت زمان ساخت سد و تراز آبگیری بیشترین تأثیر را در مدل سازی تنش کل خاک در سلول TPC19.1 داراست (شکل ۷). ترکیب های متفاوتی از سه ویژگی به صورت جدا محاسبه شد تا دقت این ورودی ها مشخص شود. این عمل مانند همان کاری است که الگوریتم هیبریدی NNA-ANN می کند.

ولی در اینجا محاسبات به صورت جدا در این سلول اجرا شد تا نتایج دقت در هر زیرمجموعه ورودی مشخص و نتایج با مدل هیبریدی مقایسه شود.

در این تحقیق از سلول TPC19.1 در مقطع ۱۹ برای مقایسه مدل های عددی و NNA-ANN استفاده شده است. سلول TPC19.1 در مقطع ۱۹ و در تراز ۱۶۶ متر و در قسمت بالادست بدنه سد و کمی بالاتر از پی و دورتر از مرکز مقطع عرضی و بین مرکز مقطع عرضی با مخزن سد قرار دارد (شکل ۱). ویژگی های ورودی شامل تراز خاکریزی، تراز آب مخزن، مدت زمان ساخت سد و سرعت خاکریزی و سرعت آبگیری به عنوان ورودی مدل هیبریدی انتخاب شدند و با استفاده از الگوریتم هیبریدی NNA-ANN بهترین زیرمجموعه از ویژگی ها، با کمترین خطا در مدل سازی ویژگی هدف (تنش کل) استخراج شده است.

نتایج و بحث

شکل ۶ نتایج حاصل از مدل عددی را نشان می دهد. در این شکل، تغییرات تنش خاک مقطع ۱۹ و




شکل ۶- تغییرات تنش خاک مقطع ۱۹، آخرین مرحله خاک ریزی مدل سخت شونده (HS)

Figure 6 - Soil stress changes of section 19, the last stage of fill in the hardening model (HS)

ANN را تأیید می کند زیرا در این الگوریتم هیبریدی، ترکیب سه تایی (دارای کمترین RMSE) از زیرمجموعه های ورودی دارای کمترین خطاست.


همان طور که در شکل ۷ مشاهده می شود، ورودی با سه ویژگی دارای عملکرد بهتری در مدل سازی تنش کل خاک در سلول TPC19.1 است که این نتایج عملکرد الگوریتم هیبریدی NNA-ANN



شکل ۷- مقادیر خطا (A) و آنالیز حساسیت (B) ویژگی های ورودی با استفاده از روش انتخاب ویژگی در سلول TPC19.1
Figure 7- Error values (A) and sensitivity analysis (B) of input Feature using the feature selection method in TPC19.1

نتایج مدل ANN با سه ویژگی ورودی شامل تراز خاکریزی، تراز آب مخزن، مدت زمان ساخت سد و مدل عددی با شاخص های آمار مذکور مقایسه شد. همان طور که از جدول ۳ استنباط می شود، مدل ANN با مقادیر R^2 ، RMSE، MAE و NS به ترتیب برابر با ۰/۹۹۴۳، ۲/۵۶۵۳، ۱/۹۹۷۳ و ۰/۹۹۹۹ نسبت به مدل عددی با مقادیر به ترتیب برابر با ۰/۹۶۲۵، ۲۶/۲۵۶۷، ۲۵/۱۶۶۷ و ۰/۹۷۷۲ دارای عملکرد بهتری در مدل سازی تنش کل است. همچنین با توجه به شاخص GMER در داده های آموزشی و آزمون مدل عددی کم برآورد رخ داده است ولی در داده های آموزشی مدل ANN، بیش برآورد جزئی و در داده های آزمون، کم برآورد جزئی رخ داده است.

نتایج مدل ANN با سه ویژگی ورودی شامل تراز خاکریزی، تراز آب مخزن، مدت زمان ساخت سد و مدل عددی با شاخص های آمار مذکور مقایسه شد. همان طور که از جدول ۳ استنباط می شود، مدل ANN با مقادیر R^2 ، RMSE، MAE و NS به ترتیب برابر با ۰/۹۹۴۳، ۲/۵۶۵۳، ۱/۹۹۷۳ و ۰/۹۹۹۹ نسبت به مدل عددی با مقادیر به ترتیب برابر با ۰/۹۶۲۵، ۲۶/۲۵۶۷، ۲۵/۱۶۶۷ و ۰/۹۷۷۲ دارای عملکرد بهتری در مدل سازی تنش کل است.



شکل ۸- مقادیر RMSE برای ترکیب های متفاوت ورودی سلول TPC19.1
Figure 8 - RMSE values for different combinations of inputs in TPC19.1 cell

مقادیر بهینه الگوریتم NNA در سلول TPC19.1 در جدول ۴ آورده شده است. شکل ۹، روند همگرایی الگوریتم NNA در این سلول را برای انواع ترکیب ویژگی ها نشان می دهد. در این شکل مشاهده می شود که ترکیب سه ویژگی، نسبت به سایر ترکیب ها، خطای کمتری دارد، مقدار خطای آن (RMSE) به صفر نزدیک تر است.

مقادیر بهینه الگوریتم NNA در سلول TPC19.1 در جدول ۴ آورده شده است. شکل ۹، روند همگرایی الگوریتم NNA در این سلول را برای انواع ترکیب ویژگی ها نشان می دهد. در این شکل مشاهده می شود که ترکیب سه ویژگی، نسبت به سایر ترکیب ها، خطای کمتری دارد، مقدار خطای آن (RMSE) به صفر نزدیک تر است.

جدول ۳- مقایسه مدل‌های عددی و هیبریدی در تخمین تنش کل خاک سلول TPC19.1


Table - Comparison of numerical and hybrid models in estimating the total soil stress of TPC19.1 cell

آموزش					آزمون					
مدل	GMER	NS	MAE	RMSE(kPa)	R ²	GMER	NS	MAE	RMSE(kPa)	R ²
FEM	۰/۸۷۹۸	۰/۹۷۷۷	۱۹/۳۳۳۳	۲۱/۰۶۹۳	۰/۹۴۶۰	۰/۹۱۰۲۲	۰/۹۷۷۲	۲۵/۱۶۶۷	۲۶/۲۵۶۷	۰/۹۶۲۵
NNA-ANN	۱/۰۰۶۷	۰/۹۹۲۵	۰/۰۱۰۱	۰/۰۱۰۱	۰/۹۹۲۷	۰/۹۹۹۵	۰/۹۹۲۶	۰/۰۰۰۹	۰/۰۱۴۶	۰/۹۹۲۶

جدول ۴- مقادیر بهینه الگوریتم NNA در مدل هیبریدی NNA-ANN

Table 4 - Optimal values of NNA algorithm in NNA-ANN hybrid model

تعداد تکرار	تعداد جمعیت	کران پایین و بالا
۱۰۰۰	۱۰۰	LB=0; UB=10



شکل ۹- روند همگرایی الگوریتم NNA در پیرومتر TPC19.1 برای ترکیب ویژگی‌های مختلف

Figure 9 - Convergence process of NNA algorithm in TPC19.1 cell to combine different features


آنالیز همبستگی ویژگی‌های ورودی

برای آنالیز همبستگی برای تصمیم‌گیری درباره تأخیر زمانی ورودی‌ها و نیز بررسی صحت نتایج مدل هیبریدی از نرم‌افزار SPSS نسخه ۲۰۱۴ و به منظور برآورد تأخیرهای زمانی از تابع خود همبستگی، تأخیر (۱۰ تا ۱۰ روز و محدوده اطمینان ۹۵ درصد استفاده شده است (شکل ۱۰). (مقادیر منفی، نشان‌دهنده زمان قبل و مقادیر مثبت، نشان‌دهنده زمان بعد است).

با توجه به خروجی نرم‌افزار SPSS در این شکل در سلول TPC19.1 واضح است که سه ویژگی تراز خاکریزی، تراز آبگیری، مدت زمان ساخت با تأخیر زمانی منفی همبستگی بین ویژگی‌ها کاهش یافته است، بنابراین، می‌توان گفت که شرایط فعلی مقادیر تراز خاکریزی، تراز آبگیری، مدت زمان ساخت می‌توانند به عنوان ورودی برای مدل‌های هوشمند در این سلول کافی باشند. همچنین، ویژگی‌های سرعت خاکریزی و سرعت آبگیری به علت

همبستگی پایین و نیز قرار نگرفتن در محدوده اطمینان از ورودی مدل ها حذف می شوند که این نتایج با نتایج مدل هیبریدی و آنالیز حساسیت یکسان است. بنابراین، با توجه به آنالیز

همبستگی داده ها، خروجی مدل هیبریدی به خوبی توانسته ویژگی های مازاد را حذف و بهترین ویژگی ها را برای مدل سازی تنش خاک انتخاب کند.



شکل ۱۰- آنالیز همبستگی داده های مورد استفاده در سلول TPC19.1: شکل (A) همبستگی متقابل بین مدت زمان ساخت و تنش خاک، شکل (B) همبستگی متقابل بین تراز خاکریزی و تنش خاک، شکل (C) همبستگی متقابل بین تراز آب مخزن و تنش خاک، شکل (D) همبستگی متقابل بین سرعت آب گیری و تنش خاک، شکل (F) همبستگی متقابل بین سرعت خاکریزی و تنش خاک.

Figure 10- Correlation analysis in TPC19.1 cell: Figure (A) Cross correlation between construction time and soil stress, Figure (B) Cross correlation between fill level and soil stress, Figure (C) Cross correlation between reservoir level and soil stress Figure (D) Cross Correlation between impounding velocity and soil stress, Figure (F) Cross correlation between fill velocity and soil stress.

هیبریدی استفاده شد. همان طور که مشاهده می شود، با توجه به شاخص های آماری در تمام سلول ها نتایج بسیار مطلوب و در جهت اطمینان است و مدل هیبریدی NNA-ANN به خوبی توانسته تنش خاک را پیش بینی کند.

بررسی نتایج در مقاطع دیگر سد

در این قسمت نتایج مدلسازی با مدل هیبریدی NNA-ANN در تمام مقطع سد کبودال، که دارای سلول فشار سنجی است، در جدول ۵ نشان داده شده است. در اینجا نیز از سه ویژگی تراز خاکریزی، تراز آبیگری، مدت زمان ساخت برای ورودی مدل

جدول ۵- نتایج مدل شبکه عصبی در تمام مقاطع سد کبودوال


Table 5 - Results of neural network model in all sections of Kaboudwal Dam

آموزش					آزمون					نام مقطع
GMRE	NS	MAE	RMSE(kPa)	R ²	GMRE	NS	MAE	RMSE(kPa)	R ²	
۱/۰۰۰۵	۰/۹۹۲۸	۰/۰۰۹۸	۰/۰۱۴۵	۰/۹۹۲۸	۱/۰۲۱۲	۰/۹۹۱۹	۰/۰۱۰۸	۰/۰۱۶۴	۰/۹۹۳۹	۴
۰/۹۹۹۵	۰/۹۹۲۶	۰/۰۰۹	۰/۰۱۴۶	۰/۹۹۲۶	۱/۰۰۶۷	۰/۹۹۲۵	۰/۰۱۰۱	۰/۰۱۰۱	۰/۹۹۲۷	۱۹
۱/۰۰۱۳	۰/۹۹۱۹	۰/۰۱۱۰	۰/۰۱۶۰	۰/۹۹۱۹	۰/۹۹۷۰	۰/۹۹۴۷	۰/۰۰۷۶	۰/۰۰۷۶	۰/۹۹۴۸	۲۳
۱/۰۰۱۲	۰/۹۹۲۰	۰/۰۰۹۶	۰/۰۱۴۷	۰/۹۹۲۰	۱/۰۱۰۵	۰/۹۹۳۱	۰/۰۱۱۰	۰/۰۱۱۰	۰/۹۹۴۳	۲۵
۱/۰۰۱۲	۰/۹۹۳۲	۰/۰۰۹۷	۰/۰۱۴۶	۰/۹۹۳۲	۰/۹۹۳۴	۰/۹۹۰۴	۰/۰۱۰۵	۰/۰۱۰۵	۰/۹۹۱۳	۲۷

بررسی نتایج در سد دیگر با ساخت گاه متفاوت

در دست نبود و با توجه به اینکه ویژگی مدت زمان ساخت در سد کبودوال به خوبی توانست مدل‌سازی را پیش ببرد، از این ویژگی برای مدل‌سازی تنش کل به روش ANN استفاده و با نتایج مدل عددی آنها مقایسه شد.

شکل ۱۱، نتایج مدل عددی و ابزار دقیق سد مسجد سلیمان ارائه شده توسط زمردیان و چوچی (Zomorodian & Chochi, 2013) را نشان می‌دهد. از آنجا که اطلاعاتی در مورد تراز خاکریزی و تراز آبیگری (مخزن) سد مسجد سلیمان



شکل ۱۱- نتایج تنش کل مدل عددی و ابزار دقیق سد مسجد سلیمان (Zomorodian & Chochi, 2013)

Figure 11- Soil stress results of numerical model and instrumentation of Masjed Soleiman dam

همان‌طور که از جدول ۶ استنباط می‌شود، با توجه به شاخص‌های آماری جذر میانگین مربعات خطا ($RMSE$)، ضریب تبیین (R^2)، میانگین هندسی نسبت خطا (MAE)، نش ساتکلیف (NS) و نیز شاخص میانگین هندسی نسبت خطا ($GMER$)، مدل ANN با مقادیر $RMSE$ ، R^2 ، MAE و NS به ترتیب برابر با ۰/۹۹۸۹، ۳۳/۳۹۴۸، ۲۱/۳۲۸۹ و ۰/۹۹۹۹، نسبت به مدل عددی با مقادیر به ترتیب برابر با ۰/۹۱۵۰، ۵۴۱/۵۹۲۶، ۴۸۵/۱۲۳۹ و ۰/۹۸۰۲، در سد مسجد سلیمان عملکرد بهتری در مدل‌سازی تنش کل دارد.

همان‌طور که از جدول ۶ استنباط می‌شود، با توجه به شاخص‌های آماری جذر میانگین مربعات خطا ($RMSE$)، ضریب تبیین (R^2)، میانگین هندسی نسبت خطا (MAE)، نش ساتکلیف (NS) و نیز شاخص میانگین هندسی نسبت خطا ($GMER$)، مدل ANN با مقادیر $RMSE$ ، R^2 ، MAE و NS به ترتیب برابر با ۰/۹۹۸۹، ۳۳/۳۹۴۸، ۲۱/۳۲۸۹ و ۰/۹۹۹۹، نسبت به مدل عددی با مقادیر به ترتیب برابر با ۰/۹۱۵۰، ۵۴۱/۵۹۲۶، ۴۸۵/۱۲۳۹ و ۰/۹۸۰۲، در سد مسجد سلیمان عملکرد بهتری در مدل‌سازی تنش کل دارد.

جدول ۶ - مقایسه مدل عددی و شبکه عصبی در تخمین تنش کل خاک سد مسجدسلیمان

Table 6 - Comparison of numerical model and artificial neural network in estimating soil stress of Masjed Soleiman dam

آزمون					آموزش					مدل
R ²	RMSE	MAE	NS	GMER	R ²	RMSE	MAE	NS	GMER	
۰/۹۱۵۰	۵۴۱/۵۹۲۶	۴۸۵/۱۲۳۹	۰/۹۸۰۲	۰/۹۸۵۶	۰/۹۱۰۴	۹۹/۵۳۷۰	۹۱/۰۶۶۳	۰/۹۸۰۱	۲/۱۲۹۹	FEM
۰/۹۹۸۹	۳۳/۳۹۴۸	۲۱/۳۲۸۹	۰/۹۹۹۹	۰/۹۸۴۲	۰/۹۹۰۸	۲۳/۵۱۴۰	۱۵/۲۵۴۷	۰/۹۹۹۸	۱/۰۰۰۵	ANN

محدودیت‌هایی ذاتی دارند و اعتبار نتایج به دست آمده از آنها قابل اعتماد نیست. بنابراین، ترکیب داده‌های ورودی در مدل هیبریدی مورد مطالعه، برای سد کبودوال و مسجدسلیمان مناسب است و برای هر ساخت‌گاه از ترکیب مناسب به خود باید استفاده کرد.

مدل هیبریدی NNA-ANN پیشنهادی توانایی خوبی برای تخمین تنش خاک نشان داد. با این همه، آزمایش مدل با استفاده از سدهای دیگر با خواص مختلف ضروری است تا از کاربرد این مدل در شرایط واقعی اطمینان حاصل شود. با توجه به اینکه اندازه‌گیری تنش خاک با روش‌های مستقیم و عددی نیاز به هزینه و زمان دارد، توسعه روش‌های داده محور می‌تواند معرفی شود و به کار رود.

نتیجه‌گیری

نتایج استفاده از الگوریتم هیبریدی NNA-ANN و روش انتخاب ویژگی برای سلول TPC19.1 در سد کبودوال نشان داد که در سلول منتخب از بین ۵ ویژگی اندازه‌گیری شده، سه ویژگی شامل تراز خاکریزی، مدت زمان ساخت سد و تراز آبگیری بیشترین تأثیر را در مدل سازی تنش کل خاک داراست که این نتایج با آنالیز همبستگی و تابع همبستگی متقابل انطباق کامل دارد. نتایج تحقیق نشان داد که کاهش ویژگی‌های ورودی به دلیل کم کردن زمان و کاهش هزینه اقتصادی‌تر و موثرتر

با توجه به شاخص GMER در داده‌های آموزشی و آزمون مدل عددی به ترتیب بیش‌برآورد و کم‌برآورد رخ داده است ولی در داده‌های آموزشی مدل ANN، بیش‌برآورد جزئی و در داده‌های آزمون، کم‌برآورد جزئی رخ داده است. نتایج بررسی‌ها نشان می‌دهد مدل هیبریدی NNA-ANN با توجه به شاخص آماری R² دقت شبیه‌سازی تنش خاک را در سدهای کبودوال و مسجدسلیمان به ترتیب ۳ و ۹ درصد، در مقایسه با مدل عددی، بهبود بخشیده است. دقت بالای مدل NNA-ANN، در مقایسه با مدل عددی، نشان‌دهنده عملکرد الگوریتم هیبریدی NNA-ANN برای فرار از بهینه‌سازی‌های محلی است که باعث شده این الگوریتم به عنوان ابزاری قدرتمند برای برآورد تنش خاک در مدت زمان ساخت سدهای خاکی تبدیل شود. به طور کلی، مدل هیبریدی NNA-ANN عملکرد قابل اعتمادتری را نشان می‌دهد که می‌تواند به پیش‌بینی تنش خاک در مدت زمان ساخت سدهای خاکی کمک کند. در بسیاری از مطالعات از جمله مطالعات Khansar, (hakimi 2021) از مدل سازی عددی برای مدل سازی تنش خاک استفاده شده است و نتیجه این تحقیق نشان داد که مدل هوشمند این مطالعه (با R² برابر با ۰/۹۹۴۳) دارای عملکرد بهتری نسبت به مدل عددی آنها (با R² برابر با ۰/۹۶۲۳) در مدل سازی تنش خاک داراست. باید خاطر نشان کرد که مدل‌های هوشمند از نظر تعمیم‌پذیری

است زیرا با افزایش تعداد ویژگی‌ها در مدل هیبریدی، افزایش دقت مدل‌سازی رخ نداد. نتایج آنالیز حساسیت نشان داد تراز خاکریزی و مدت زمان ساخت با بالاترین ضریب حساسیت، مهم‌ترین ویژگی در مدل‌سازی تنش کل در سلول منتخب است. مدل‌سازی با ویژگی زمان ساخت، در سد مسجد سلیمان با ساخت‌گاه جدید و مشخصات جدید ژئوتکنیکی نشان داد که استفاده از مدل هیبریدی NNA-ANN، نسبت به مدل عددی، با توجه به شاخص‌های آماری دارای جواب‌های دقیق‌تری است. نتایج بررسی‌ها نشان داد که استفاده از مدل هیبریدی NNA-ANN در طراحی و برآوردهای اولیه پارامتر تنش خاک در سدهای خاکی به جای استفاده از روش عددی اعتماد و دقت بالایی دارد. ترکیب داده‌های ورودی در مدل هیبریدی مورد مطالعه، برای سد کبودال و مسجدسلیمان مناسب است و برای هر ساخت‌گاه از ترکیب مناسب به خود باید استفاده کرد. پیشنهاد می‌شود برای سایر کمیت‌های سد خاکی مثل نشست، تراوش و فشار آب حفره‌ای نیز مدل‌سازی با ویژگی‌های پیشنهادی به‌کار گرفته شود.

مراجع

- AmiriMijan, F., Shirani, H., Esfandiarpour, I., Besalatpour, A., & Shekofteh, H. (2019). Identifying the Determinant Factors Influencing S Index in Calcereous Soils Using Anneling Simulated- Artificial Neural Network Hybrid Algorithm [Research]. *Journal of Water and Soil Science*, 23(3), 381-394. <https://doi.org/10.47176/jwss.23.3.17551>. (in Persian)
- Bolouri-Bazaz, J., & Mobini-Zad, M. (2010). Evaluation of the behavior of Nahreyn embankment dam during construction and comparing instrumentation data with the results of a finite element code. *Iranian Water Research Journal*, 4(6), 1-15. <https://www.magiran.com/paper/835543> (in Persian)
- Brinkgreve, R., & Vermeer, P. (2001). Plaxis 2D, general information-reference & scientific manual. In: Balkema Publisher. Netherlands.
- Chandrashekar, G., & Sahin, F. (2014). A survey on feature selection methods. *Computers & Electrical Engineering*, 40(1), 16-28.
- Cucci, G., Lacolla, G., Pagliai, M., & Vignozzi, N. (2015). Effect of reclamation on the structure of silty-clay soils irrigated with saline-sodic waters. *International agrophysics*, 29(1).
- Hakimi Khansar, H. (2021). Simulation of behavior the Kabudval Dam during construction with 3D numerical modeling. *Amirkabir Journal of Civil Engineering*, 53(9), 20-20. <https://doi.org/10.22060/ceej.2020.18172.6790> (in Persian)
- Hakimi Khansar, H., Golmaei, H., & Sheidaei, M. (2014). Evaluating of Kaboodval dam during construction using finite element method with software PLAXIS and a comparison with the actual values of instrumentation data. *Journal of Water Science & Engineering*, 4(9), 33-50. http://wsej.iauhvaz.ac.ir/article_531129_9c5d0549d922be8a56971dc85bc286cc.pdf
- Haykin, S. (1998). Neural Networks, A Comprehensive foundation. Prenticer Hall. In: Inc.
- Hill, M. C. (2000). Methods and guidelines for effective model calibration. In *Building Partnerships* (pp. 1-10).

- Jeon, Y. S., & Yang, H. S. (2004). Development Of A Back Analysis Algorithm Using Flac. *International Journal of Rock Mechanics and Mining Sciences*, 41, 447-453. <https://doi.org/https://doi.org/10.1016/j.ijrmms.2004.03.081>
- Karakus, M., & Fowell, R. (2005). Back analysis for tunnelling induced ground movements and stress redistribution. *Tunnelling and Underground Space Technology*, 20(6), 514-524.
- Komasi, M., & Beiranvand, b. (2020). Study of Vertical and Horizontal Displacements of Eyvashan Earth Dam Using Instrumentation and Numerical Analysis. *Iranian Journal of Soil and Water Research*, 51(1), 245-256. <https://doi.org/10.22059/ijswr.2019.281594.668205>
- Kumar, V., & Minz, S. (2014). Feature selection: a literature review. *SmartCR*, 4(3), 211-229.
- Lippmann, R. (1987). An introduction to computing with neural nets. *IEEE Assp magazine*, 4(2), 4-22.
- Norouzi, R., Sihag, P., Daneshfaraz, R., Abraham, J., & Hasannia, V. (2021). Predicting relative energy dissipation for vertical drops equipped with a horizontal screen using soft computing techniques. *Water Supply*.
- Nourani, V. (2015). Basics of hydroinformatics. *Farsi. Tabriz University Press, Tabriz*.
- Nourani, V., & Babakhani, A. (2013). Integration of Artificial Neural Networks with Radial Basis Function Interpolation in Earthfill Dam Seepage Modeling. *Journal of Computing in Civil Engineering*, 27(2), 183-195. [https://doi.org/doi:10.1061/\(ASCE\)CP.1943-5487.0000200](https://doi.org/doi:10.1061/(ASCE)CP.1943-5487.0000200)
- Nourani, V., Sharghi, E., & Aminfar, M. (2012). Integrated ANN model for earthfill dams seepage analysis: Sattarkhan Dam in Iran. *Artif. Intell. Res.*, 1(2), 22-37. <https://doi.org/10.5430/air.v1n2p22>
- Nouri, M., & Salmasi, F. (2019). Predicting Seepage of Earth Dams using Artificial Intelligence Techniques. *Irrigation Sciences and Engineering*, 42(1), 83-97. <https://doi.org/10.22055/jise.2017.21384.1537>
- Novakovic, A., Rankovic, V., Grujovic, N., Divac, D., & Milivojevic, N. (2014). Development of neuro-fuzzy model for dam seepage analysis. *Annals of the Faculty of Engineering Hunedoara*, 12(2), 133-136.
- Parsa, J., Hakimi Khansar, H., Hoseinzadeh dalir, A., & Shiri, J. (2021). Simulation of soil stress in earth dams using artificial intelligence models and determination of effective features. *Amirkabir Journal of Civil Engineering*, -. <https://doi.org/10.22060/ceej.2021.18682.6925> (in Persian)
- Ranković, V., Grujović, N., Divac, D., & Milivojević, N. (2014). Development of support vector regression identification model for prediction of dam structural behaviour. *Structural Safety*, 48, 33-39. <https://doi.org/https://doi.org/10.1016/j.strusafe.2014.02.004>
- Rashidi, M., & Haeri, S. M. (2017). Evaluation of behaviors of earth and rockfill dams during construction and initial impounding using instrumentation data and numerical modeling. *Journal of Rock Mechanics and Geotechnical Engineering*, 9(4), 709-725.
- S. M. A. Zomorodian, & H. Chochi. (2013). Numerical Analysis of Earth – Rockfill Dams Behavior, During Construction and First Stage Impounding (Case Study: Masjed-e-

- Soleyman Dam) [Research]. *Journal of Water and Soil Science*, 16(62), 229-242. <http://jstnar.iut.ac.ir/article-1-2507-fa.html>.
- Sadollah, A., Sayyaadi, H., & Yadav, A. (2018). A dynamic metaheuristic optimization model inspired by biological nervous systems: Neural network algorithm. *Applied Soft Computing*, 71, 747-782.
- Salmasi, F., Hakimi Khansar, H., & Norani, B. (2019). Investigation of the Structure of the Dam Body during Construction and its Comparison with the Analytical Results Using PLAXIS Software (the Case Study of Kaboodvall Dam) [Research]. *Journal of Water and Soil Science*, 22(4), 155-171. <https://doi.org/10.29252/jstnar.22.4.155> (in Persian)
- Tayfur, G., Swiatek, D., Wita, A., & Singh, V. P. (2005). Case study: Finite element method and artificial neural network models for flow through Jeziorsko earthfill dam in Poland. *Journal of Hydraulic Engineering*, 131(6), 431-440.
- Wu, K., Soci, C., Shum, P. P., & Zheludev, N. I. (2014). Computing matrix inversion with optical networks. *Optics express*, 22(1), 295-304.

Efficiency of NNA-ANN Hybrid Model in Modeling Soil Stress in the Body of Earth Dams During Construction and Comparison with Numerical Model (Case Study Of Kaboud-Val Dam)

H. Hakimi Khansar*, J. Parsa, A. Hosseinzadeh-Dalir and J. Shiri

* Corresponding Author: Ph.D Candidate, University of Tabriz / Department of Water Engineerin, University of Tabriz, Iran.

Email: : hakimi1904@yahoo.com

Received: 4 October 2021, Accepted: 17 July 2022

Introduction

The stress created in the soil significantly affects its engineering behavior. Changing its value during the construction of earthen dams causes volume change and shear strength, causing rupture, soil compaction and settlement in earthen dams. So measuring soil stresses of dams is essential that it is done by instrumentation installed. Artificial intelligence models such as artificial neural networks for modeling many engineering applications. Also by extending the meta-heuristic algorithms, combined with neural networks have become very popular due to more accurate results.

Methodology

In this study, the cross-section 19 (cross-section of the middle part of the body and dam foundation) for the modeling of soil stress were used during the construction of the dam Kaboud-val. Also Kaboud-val dam instrumentation data (derived from Golestan Regional Water Co.) was used at the time of construction during the period of 4 years. Type and number of input data is the most important thing in modeling artificial intelligence. By examining data TPC19.1 cells in section 19 in Kaboud-val dam, embankment alignment (F), the water level of the reservoir (R), the construction of the dam (T), speed filling and dewatering speed was selected for input. The soil stress (P) in the body of the dam during construction, intelligent model was selected for output. This process is most effective in a subset of features from the set of input features according to the least error, selected and additional features will be removed. In this research, a meta-algorithm (artificial neural network (NNA) algorithm) is combined with an artificial neural network (ANN) that has the ability to predict complex and nonlinear relationships and extracts effective features for modeling soil stress with appropriate accuracy. In this study, the most effective features in soil stress modeling were determined in a case study (Kaboud-val Dam) using the NNA-ANN hybrid algorithm and a comparison was made between the results of the hybrid model and the numerical model. Five features include reservoir level, fill level, dam construction time, impounding velocity and fill velocity was selected for the input.

Results and Discussion

Using hybrid algorithm and feature selection method, a combination of three features, including reservoir level, fill level, dam construction time (with RMSE equal to 0.5024) were the most effective features in modeling soil stress in the selected cell. The results showed that the hybrid model in Kaboud-val Dam (with values of R^2 , RMSE, MAE and NS equal to 0.9943, 2.5653, 1.9973 and 0.9999, respectively) has better performance in modeling soil stress than the numerical model. (With values of R^2 , RMSE, MAE and NS are equal to 0.9625, 26.2567, 16.6725 and 0.9772, respectively). The results showed that the

reduction in the input features to reduce the time and cost reduction is more economical and more effective. Because with the increase in the number of features in the hybrid model, the increase in modeling accuracy did not occur. Sensitivity analysis showed that the dam construction time and fill level, of the highest sensitivity factor, the most important feature of the model is the total stress in cells. Modeling with the mentioned features, in another dam with a new construction site and new geotechnical specifications (Masjed Soleiman Dam) showed that the use of artificial intelligence model according to statistical indicators has more accurate answers than the numerical model.

Conclusion

The results showed that the use of artificial intelligence methods in the design and initial estimates of soil stress parameters in earthen dams instead of using numerical methods has high reliability and accuracy. The combination of input data in the hybrid model under study is suitable for Kaboud-val dam and Masjed Soleiman dam and the appropriate combination should be used for each construction site. By completing the number of data in different sections of the dam and the number of construction sites in areas with similar climate and geotechnical conditions, a design software can be obtained to predict the amount of soil stress during construction in the body and foundations of earth dams.

Keywords: Feature selection, Soil stress cell, Finite element, Neural network algorithm