



شاپا چاپی: ۲۲۵۱-۷۴۸۰
شاپا الکترونیکی: ۲۲۵۰-۷۴۰۰

نشریه حفاظت منابع آب و خاک

آدرس تارنما:

<https://wsrj.srbiau.ac.ir>

پست الکترونیک:

iauwsrj@srbiau.ac.ir

iauwsrj@gmail.com

سال یازدهم

شماره چهار

تابستان ۱۴۰۱

تاریخ دریافت:

۱۴۰۰/۰۷/۰۷

تاریخ پذیرش:

۱۴۰۰/۱۰/۰۸

صفحات: ۱۱۵-۱۲۷



مدل سازی رفتار سدهای بتنی با استفاده از روش های شبکه عصبی مصنوعی و رگرسیون لجستیک

فردین سعید^۱، محسن ابران دوست^{۲*} و نوید جلال کمالی^۳

(۱) دانشجوی دکتری، گروه مهندسی آب، واحد کرمان، دانشگاه آزاد اسلامی، کرمان، ایران.

(۲) استادیار، گروه مهندسی آب، واحد کرمان، دانشگاه آزاد اسلامی، کرمان، ایران.

(۳) استادیار، گروه مهندسی آب، واحد کرمان، دانشگاه آزاد اسلامی، کرمان، ایران.

* ایمیل نویسنده مسئول: mohsenirandost@yahoo.com

چکیده:

زمینه و هدف: اندازه گیری و رفتارسنجی سد موضوع جدیدی می باشد که می تواند به دلیل تغییر پارامترهای موجود برای ارائه مدلی باشد که رفتار پارامترهای منفرد را بر روی سد و همچنین روی یکدیگر بررسی کند و تغییرات ایجاد شده را آنالیز کرده و سیاست های لازم را ایجاد کند. هدف این پژوهش ایجاد یک روش ترکیبی از رگرسیون لجستیک با بهینه سازی الگوریتم بهینه سازی گروه ذرات با مقدار حقیقی جهت پیش بینی رفتار تجهیزات سد می باشد.

روش پژوهش: در این مطالعه از داده های ۳۶۵ روزه، از ۱۳۹۷/۰۱/۳۱ تا ۱۳۹۸/۰۱/۳۱ که ۶۰۰ مجموعه داده تجهیزات سد شامل پارامترهای دمای آب، سطح آب، فشار دریچه، میزان رسوب گذاری، فشار منافذ، دمای هوا، حجم آب ورودی، مشخصات ویژه سد، شرایط بتن، سطح آب مخزن، تغییر مکان افقی و عمودی، اجزای اتصال انتقالی و شتاب زمین، قدرت، فشار، کشش و تنش بالا برای مدل سازی استفاده شدند. برای آموزش مدل سازی الگوریتم بهینه سازی گروه ذرات مقدار حقیقی-رگرسیون لجستیک و ۱۲۰ مجموعه داده جهت آزمایش استفاده گردید. برای ارزیابی عملکرد روش پیشنهادی، از چهار آماره شامل ضریب تعیین (R^2)، ریشه میانگین مربعات خطا (RMSE)، ضریب پراکندگی (SI) و میانگین خطاهای انحرافی (MBE) استفاده گردید.

یافته ها: نتایج نشان داد که مدل در پیش بینی فشار پیژومتریک در بدنه سد عملکرد قابل قبولی دارد. همچنین نتایج حاصل از مدل شبکه عصبی مصنوعی با کسب $R^2 = 0.930$ و $SI = 0.587$ همگرایی قابل قبولی را نشان می دهد. نتایج مربوط به داده های آموزش مدل نیز بیانگر این است که میانگین (μ) و انحراف معیار (σ) مدل ارائه شده، برای داده های آموزش به ترتیب برابر با ۱/۳۴۱ و ۱/۵۲۶ می باشد و برای داده های صحت سنجی این مقادیر برابر با ۱/۵۷۶ و ۲/۲۴۷ می باشد که این نشان از عملکرد خوب مدل پیشنهاد شده دارد. در معیار احتمال تجمعی، مدل پیشنهاد شده با $P_{50} = 0.940$ و $P_{90} = 1.742$ مبین این است که نتایج قابل قبول می باشد.

نتایج: نتایج بیانگر این است که بهینه سازی گروه ذرات مقدار حقیقی-رگرسیون لجستیک در عوض به حداقل رساندن ریسک تجربی که تعمیم عالی برای اندازه های نمونه کوچک را فراهم می سازد، اصل کاهش ریسک سازه ای را اجرا می کند. نسبت مقادیر پیژومتریک پیش بینی شده به مقادیر قرائت شده برای حدود ۷۲ درصد داده ها در این مدل در حدود یک بوده که بیانگر آموزش و قدرت پیش بینی مناسب این مدل می باشد. در نهایت بر اساس معیارهای ارزیابی مدل ترکیبی عملکرد بهتری نسبت به روش های بیان شده دارد.

کلیدواژه ها: سد بتنی، تحلیل رگرسیون، الگوریتم بهینه سازی گروه ذرات، سد ستارخان

مقدمه

ارائه مدلی باشد که رفتار پارامترهای منفرد را بر روی سد و همچنین روی یکدیگر بررسی کند و تغییرات ایجاد شده را آنالیز کرده و سیاست‌های لازم را ایجاد کند. بدین منظور، چندین مدل ساخته شد که شامل مدل‌های کرک‌دار، شبکه‌های عصبی، مونت‌کارلو و ... می‌باشد. تجهیزات موجود در سد یک بسته نرم‌افزاری برای کنترل رفتار سد می‌باشد و به کاربر اجازه شبیه‌سازی را تحت روش سیستم طراحی دینامیکی را می‌دهد (Gitooe *et al.*, 2018; Li *et al.*, 2020). با استفاده از رگرسیون‌های معمولی در تجهیزات سد مدلی که به دست می‌آید که در موقعیت‌های گوناگون برای مصرف‌کنندگان حوضه است. از آنجایی که رفتار سد همانند رگرسیون به صورت قطعی نیست و تابع شرایط حاکم بر سد است نیازمند بهبود این تجهیزات با مدل‌های غیرقطعی مانند هوش مصنوعی و الگوریتم‌های فرا ابتکاری هستیم. مدل برنامه‌ریزی بهینه‌سازی نیز مدلی است که در مقایسه با روش مدل‌سازی سنتی هیچ نوع فرم تابع فرضی را از قبل در نظر نمی‌گیرد، اما به‌عنوان نمونه در روش رگرسیون، ساختار و سازه مدل از پیش تعیین شده است (مثلاً رگرسیون خطی، درجه دوم و...) و در مرحله بعدی پارامترهای مدل تعیین می‌شوند. هنگامی که برنامه‌ریزی بهینه‌سازی شده گروه ذرات معادله یا فرمولی بین متغیرهای ورودی و خروجی به دست می‌آورد، مزیت اصلی این روش توانایی انتخاب اتوماتیک متغیرهای ورودی در مدل مفید واقع شده و همچنین نادیده گرفتن متغیرهایی که مفید واقع نشده، می‌باشد (Schratz *et al.*, 2018)؛ بنابراین، اغلب گفته می‌شود که اصلاح بهینه‌سازی گروه ذرات می‌تواند ابعاد متغیرهای ورودی را کاهش دهد و تعیین تغییرات در محیط‌های مختلف برنامه‌نویسی برای روابطی که ارائه می‌شود، امکان‌پذیر سازد. به عبارت دیگر، با تغییر نمودار هر پارامتر که بر سیستم تأثیرگذار می‌باشد، می‌توان رفتار سایر پارامترها را در نظر گرفت. علاوه بر این، رگرسیون لجستیک به دلیل تئوری آموزش آماری و یک اصل کاهنده ریسک سازه‌ای که با موفقیت برای

در یک حوضه آبریز سیستم‌های مختلف طبیعی و انسانی در اندرکنش با یکدیگر هستند که این امر موجب شده تا برنامه‌های مدیریت حوضه‌های آبریز اهمیت روز افزونی پیدا کنند. در مدیریت منابع آب در سطح حوضه آبریز تأثیر اندرکنش اجزای درون هر سیستم و اندرکنش سیستم‌های مختلف با یکدیگر باید در نظر گرفته شود. سدها دارای تعاملات قوی با عوامل محیطی، هیدرولیکی و ژئومکانیک، مانند درجه حرارت هوا و آب، سطح آب، فشار منافذ و شکل‌پذیری هستند که هر کدام بر ساختار و رفتار سد تأثیر می‌گذارد (Meier and Kramer, 2019; Neshat *et al.*, 2016). حوضه‌های آبریز شامل عواملی همچون بارندگی، جریان آب سطحی، شکل حوضه، خصوصیات فیزیکی حوضه، دما، تبخیر، شرایط آب‌های زیرزمینی و ... با اقلیم زمان و شرایط آب و هوایی متغیر می‌باشد که هر کدام از این عوامل می‌تواند نقش تعیین کننده‌ای را در حالت کلی حوضه ایفا کند، از طرف دیگر به دلیل محدودیت منابع آب (به‌خصوص در ایران) لازم است که رفتار سدها در شرایط مختلف زمانی جهت مدیریت بهتر و استفاده بهینه و پارامترهای مؤثر بر آن بررسی شود. این امر نیازمند بررسی تک‌تک پارامترها و ارتباط متقابل آنها به صورت دینامیکی می‌باشد (Han *et al.*, 2018). از سال ۱۹۳۰ تاکنون مدل‌های خطی و غیرخطی فراوانی جهت شبیه‌سازی و پیش‌بینی فرایندها و متغیرهای هیدرولوژیکی پیشنهاد گردیده (Li *et al.*, 2020) و این مدل‌ها در طول زمان پیشرفت کرده و به‌طور مداوم با بالا رفتن دانش بشری و معرفی ابزار جدید کیفیت آنها ارتقا یافته است. برای توصیف و پیش‌بینی رفتار ساختاری سدها، طی دهه‌های گذشته تعدادی از مدل‌های ریاضی قطعی، آماری و ترکیبی توسعه یافته است (Li and Wang, 2019; Reis *et al.*, 2018; Samigulina and Massimkanova, 2019; Shakarami *et al.*, 2018). در نتیجه، اندازه‌گیری و رفتار سد موضوع جدیدی می‌باشد که می‌تواند به دلیل تغییر پارامترهای موجود برای

برای ارزیابی تغییرات ترک‌های سدهای بتنی و پیش‌بینی روند تغییرات آن‌ها در آینده، الگوریتم‌های فرا ابتکاری روشی بسیار دقیق و قدرتمند محسوب شده و به‌وسیله این روش‌ها می‌توان دید بسیار خوبی بر وضعیت آسیب دیدگی سدهای بتنی پیدا نمود. Gu و همکاران (۲۰۲۰) یک رویکرد تحلیلی برای تغییر رفتار سدهای بتنی با استفاده از مدل‌های داده پانلی ارائه کردند. این رویکرد برای تشخیص اینکه آیا رفتار سدهای بتنی در طول عمر خود و خدمات آن دچار تغییر خواهند شد یا خیر، استفاده گردید. نتایج آنها بیانگر این است که روش بکار گرفته دارای اعتبار زمانی و مکانی در خصوص رفتار سدهای بتنی را دارد. Mata و همکاران (۲۰۲۱) اقدام به اعتبارسنجی مدل‌های یادگیری ماشین جهت مدل‌سازی رفتار سد سالاموند در پرتغال پرداختند. به این منظور از مدل‌های شبکه عصبی مصنوعی (ANN)، ماشین بردار پشتیبان (SVM)، جنگل تصادفی (RF) و درخت‌های رگرسیون تقویت شده (BRT) استفاده کردند. آنها بیان داشتند که قبل از استفاده از روش‌های ماشین یادگیرنده در ارزیابی و پیش‌بینی رفتار سدها ابتدا آنها بایستی از نظر کاربرد اعتبارسنجی شوند. روش‌های ماشین یادگیرنده ابزاری مناسب برای توسعه مدل‌های پایگاه داده هستند که عمدتاً زمانی بکار می‌روند که مقدار اطلاعات کافی موجود باشد و اعتبارسنجی آنها برای تحلیل و تفسیر رفتار سدها قابل اعتماد است. هدف این پژوهش ایجاد یک روش ترکیبی از رگرسیون لجستیک با بهینه‌سازی الگوریتم بهینه‌سازی گروه ذرات با مقدار حقیقی جهت پیش‌بینی رفتار تجهیزات سد می‌باشد. همچنین مدل مرسوم رگرسیون لجستیک و مدل شبکه عصبی نیز در رفتارسنجی سدهای بتنی مورد مقایسه قرار گرفتند.

مواد و روش‌ها

منطقه مورد مطالعه

سد مخزنی ستارخان واقع در استان آذربایجان شرقی در ۱۵ کیلومتری غرب شهرستان اهر و بر روی رودخانه ستارخان احداث شده است. رودخانه ستارخان از

مدل‌سازی سیستم غیرخطی استفاده شد، یک ماشین آموزشی مؤثری باشد (Schratz *et al.*, 2018). در مقایسه با شبکه‌های عصبی مصنوعی، رگرسیون لجستیک عملکرد قابل‌اعتمادتر و بهتری را در همان شرایط آموزشی ارائه می‌دهد (Kalita *et al.*, 2020). با این حال ویژگی‌های بهتری دارا می‌باشد، اما رگرسیون لجستیک در تحقیقات آکادمیک و کاربردهای صنعتی به دلیل تعریف مناسب پارامترهای مختلف توسط کاربر محدود می‌باشد. پارامترهای رگرسیون لجستیک باید با دقت تنظیم شوند تا این مدل به‌طور مؤثرتری ساخته شود (Colkesen *et al.*, 2016; Ma and Xia, 2017; Tsirikoglou *et al.*, 2017). پارامترهای رگرسیون لجستیک به‌صورت نامناسب انتخاب شده که به دنبال آن یا تعداد بیش از حد متغیر مستقل در رگرسیون قرار داده شده یا تعداد کمتر از آن، در پی خواهد داشت و ممکن است تنظیمات مختلف پارامترها نیز باعث تفاوت قابل‌توجهی در عملکرد شوند (Siniscalchi and Salerno, 2016). بنابراین، انتخاب پارامترهای بهینه گامی مهم در طراحی رگرسیون لجستیک می‌باشد. با این وجود، هیچ نوع راهنمایی کلی برای کمک به انتخاب این پارامترها در دسترس نمی‌باشد (Acerbi and Ji, 2017; Oneto *et al.*, 2016). امامی و همکاران (۱۳۹۹) با استفاده از الگوریتم فرا ابتکاری انتخابات (EA) و با لحاظ داده‌های تراز آب و دمای بتن طی سال‌های ۱۳۷۹-۱۳۹۲ به‌عنوان پارامترهای ورودی و مقدار تغییر مکان افقی و قائم ترک‌ها به‌عنوان پارامترهای خروجی، نحوه تغییرات ترک‌های سد بتنی قوسی زاینده‌رود را مورد ارزیابی قرار دادند و نتایج را با روش الگوریتم ژنتیک (GA) و شبکه‌ی عصبی مصنوعی (ANN) مقایسه کردند. برای ارزیابی عملکرد روش پیشنهادی، از سه آماره شامل ضریب تبیین (R^2)، جذر میانگین مربعات خطا (RMSE) و معیار نش-ساتکلیف (NSE) استفاده گردید. نتایج آنها نشان داد که الگوریتم EA با کسب مقادیر $R_2=0.96$ ، $RMSE=0.022$ و $NSE=0.74$ در مقایسه با دو روش الگوریتم GA و شبکه‌ی عصبی مصنوعی (ANN) از کارایی بالاتری برخوردار است. آنها همچنین بیان داشتند که

شیب بالادست پوسته سد با لایه محافظ ریپ‌راپ و فیلتر زیر آن، در مقابل عمل امواج مخزن سد حفاظت می‌شوند، فرازبند سد با مقطعی مشابه مقطع بدنه اصلی سد، شامل هسته آب‌بند رسی در مرکز و پوسته‌های سنگریزه‌ای، در بالادست بدنه سد اصلی احداث می‌گردد. (شکل ۱)

موقعیت سد ستارخان را نشان می‌دهد

بهینه‌سازی گروه ذرات

اساس حرکت ذرات، شبیه‌سازی رفتار جرمی می‌باشد که برای نشان‌دادن حرکت گروهی از پرندگان و ماهی‌ها استفاده می‌شود که یکی از رایج‌ترین تکنیک‌های بهینه‌سازی متاهیروستیک^۱ (فرا ابتکاری) است. حرکت گروهی ذرات از فاکتور جمعیت، از جمله راه‌حل‌های بالقوه برای مسئله مورد مطالعه، برای کاوش در فضای جستجو استفاده می‌کند. در حرکت گروهی ذرات، هر یک از اعضای جمعیت دارای یک سرعت اتخاذی (جابه‌جایی) می‌باشد که با استفاده آن در فضای جستجو حرکت می‌کند. علاوه بر این، هر یک از آنها به دلیل دارا بودن یک حافظه، بهترین موقعیت در فضا را نیز دارا هستند. آنها تاریخچه جستجوی خود را به‌خاطر می‌آورند، در نتیجه هر یک از اعضا در دو جهت حرکت می‌کنند: به بهترین وضعیتی که تلاقی شده‌اند و به بهترین وضعیت بهترین عضو که در همسایگی خود ملاقات کرده‌اند (Oneto et al., 2016). یکی از جنبه‌های اصلی و جذابیت روش بهینه‌سازی گروه ذرات سادگی آن می‌باشد. به‌طوریکه فقط از دو معادله سرعت و مکان تشکیل شده است که در آن مختصات هر ذره پاسخ احتمالی مربوط به دو بردار را نشان می‌دهد. ظاهراً، $f: \mathbb{R}^n \rightarrow \mathbb{R}$ تابع هزینه‌ای می‌باشد که باید به حداقل برسد. این تابع یک راه‌حل کاندیداتوری را به‌عنوان یک بردار از اعداد حقیقی به‌عنوان متغیر مستقل می‌گیرد و یک عدد حقیقی به‌عنوان خروجی تولید می‌کند که مقدار تابع هدف راه‌حل کاندیداتوری داده شده را نشان می‌دهد. شیب معین نمی‌باشد. هدف یافتن راه‌حل a برای f

ارتفاعات واقع در شمال‌غرب کشور در مرز ایران و ترکیه سرچشمه می‌گیرد و پس از عبور از شهر اهر و طی مسافتی در حدود ۵۰ کیلومتر به دریاچه ارومیه می‌ریزد. هدف از احداث سد ستارخان تأمین آب مورد نیاز شرب و صنعت شهر اهر و همچنین تأمین نیاز آب کشاورزی اراضی واقع در پایین دست سد ستارخان می‌باشد. سد ستارخان از نوع خاکی و بتنی-سنگریزه‌ای می‌باشد. تراز تاج سد در ارتفاع ۱۵۸۸ متر از سطح آزاد دریا و طول تاج حدود ۳۵۰ متر می‌باشد. مقطع خاکریز بدنه سد شامل هسته آب‌بند رسی، لایه‌های فیلتر و زهکش، پوسته‌های سنگریزه‌ای بالادست و پایین‌دست فرازبند که در داخل بدنه سد قرار می‌گیرد، می‌باشد. هسته آب‌بند رسی در مرکز مقطع سد بالاتر از تاج ۱۵۸۶ متر و با ارتفاع حداکثر ۱۱۶ متر از سنگ بستر قرار دارد که نسبت به محور سد متقارن می‌باشد. شیب شیروانی‌های بالادست و پایین‌دست هسته آب‌بند ۱:۳ (افقی به قائم) است. لایه فیلتر پایین دست به ضخامت افقی ۳ متر هسته آب‌بند رسی را از لایه زهکش جدا می‌سازد. لایه‌های زهکش بالادست و پایین دست سد نیز با ضخامت افقی ۳ متر، آب خرابی تجهیزات سد شده از هسته آب‌بند را به خارج از بدنه سد تخلیه می‌نمایند. پوسته‌های بالادست و پائین دست به ترتیب با شیب‌های شیروانی ۲:۱/۵ (افقی به قائم) و شیب متوسط ۱:۱/۹ (افقی به قائم) از نوع سنگریزه‌ای تعیین شده‌اند.



شکل ۱. موقعیت سد ستارخان

^۱ Metaheuristic


بهینه‌سازی مبتنی بر بهینه‌سازی گروه ذرات مقدار حقیقی
مدل رگرسیون لجستیک

عملکرد تعمیم رگرسیون لجستیک با دقت برآورد و عملکرد بستگی به پارامتر ورود به سیستم دارا می‌باشد که به نحو احسن تنظیم شده است (Chambers, 2019; Feng et al., 2019; Nan et al., 2019). با این وجود، هیچ دستورالعمل کلی برای انتخاب این پارامترها در دسترس نمی‌باشد. در حال حاضر اغلب محققان یک روش استاندارد (آزمون و خطا) را با استفاده از الگوریتم شبکه دنبال می‌کنند، در وهله اول چندین مدل رگرسیون لجستیک را به دلیل مجموعه‌ای از پارامترهای مختلف ایجاد می‌کنند، در مرحله بعد، آنها را به دلیل بدست آوردن پارامترهای بهینه بر روی یک مجموعه اعتبارسنجی آزمایش می‌کنند (Belmokr et al., 2019). بنابراین، در این مطالعه یک الگوریتم بهینه‌سازی شده گروه ذرات مقدار حقیقی را برای جستجوی پارامترهای بهینه رگرسیون لجستیک به منظور بهبود عملکرد پیش‌بینی، اتخاذ گردید. در مدل پیشنهادی الگوریتم بهینه‌سازی شده گروه ذرات مقدار حقیقی-رگرسیون لجستیک، مقادیر پارامترهای

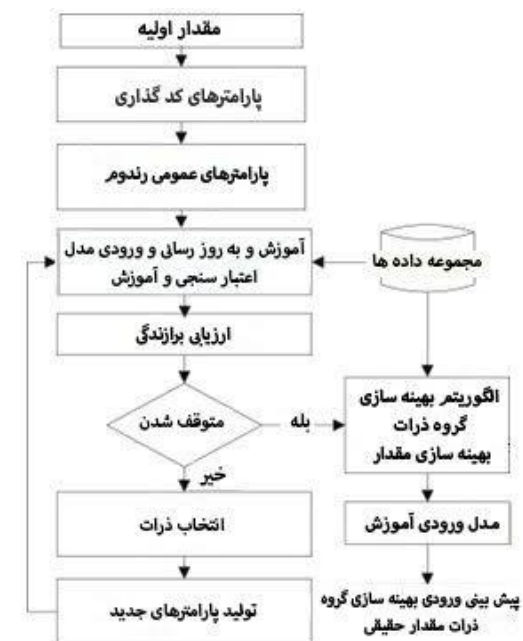
$f(b) \leq a$ برای همه اهداف b در فضای جستجو می‌باشد که به عبارتی a حداقل جهانی می‌باشد. از طرفی S تعداد ذرات موجود در گروه می‌باشد، هرکدام دارای موقعیتی برابر با $x_i \in \mathbb{R}^n$ در فضای جستجو و سرعتی برابر با $v_i \in \mathbb{R}^n$ هستند. همین‌طور p_i شناخته‌شده‌ترین موقعیت ذره i می‌باشد و g شناخته‌شده‌ترین موقعیت کل گروه می‌باشد (Acerbi and Ji, 2017).

رگرسیون لجستیک

اغلب از ضریب همبستگی برای بیان شدت رابطه خطی بین دو متغیر کمی استفاده می‌شود. علاوه بر این، از مدل رگرسیون برای نشان دادن مدل رابطه بین این دو استفاده می‌کنیم. در این بین الگویی برای پیش‌بینی متغیر وابسته (Y) به دلیل متغیر مستقل (X) ایجاد می‌شود. با این وجود، در مدل ایجاد شده، هر دو متغیر مستقل و وابسته کوچک می‌باشند. همچنین، شرایط تداوم این مقادیر در روش رگرسیون نهفته می‌باشد. امکان دارد خواستار رابطه بین یک متغیر مستقل (با مقادیر پیوسته) و یک متغیر وابسته را با مقادیر کیفی بسنجیم (Hussain et al., 2020). در این حالت، روش رگرسیون خطی نرمال کار نمی‌کند و باید از رگرسیون لجستیک استفاده شود. برای تعیین مدل رابطه بین متغیر وابسته و مستقل به جای رابطه خطی، به تابعی نیاز داریم که از ۰ تا ۱ متغیر باشد. روش رگرسیون لجستیک از تابعی به نام تابع لجستیک استفاده می‌کند. به همین خاطر، به این روش رگرسیون، رگرسیون لجستیک گفته می‌شود. در ادامه، این تابع تعریف شده و نمودار مربوط به آن در مورد پارامترهای موجود در (شکل ۲) قابل مشاهده می‌باشد.



شکل ۲. رگرسیون لجستیک



شکل ۳. مدل الگوریتم بهینه‌سازی گروه ذرات مقدار حقیقی - رگرسیون لجستیک

گام ۳ (عملگرهای الگوریتم بهینه‌سازی شده گروه ذرات) در عملگرها، از همگرایی استاندارد برای انتخاب ذرات عالی برای تولیدمثل استفاده می‌شود. یک همگرایی تک نقطه‌ای به‌طور تصادفی برای تبادل ذرات بین دو فاصله اتخاذ می‌شود: احتمال ایجاد ذره جدید برای هر جفت $0/5$ می‌باشد. ضریب یک عمل همگرایی را دنبال می‌کند که تعیین می‌کند آیا ذره‌ای به نسل بعدی برود یا نه. هر ذره در جمعیت جدید با احتمال $0/02$ همگرایی می‌باشد.

گام ۴ (توقف معیار)

اگر جمعیت جدید شرایط توقف را نداشته باشد، مراحل ۳-۴ به‌طور مستمر تا زمانی که مدل‌ها با حداقل خطای مدل برقرار شوند، انجام می‌شوند.

جمع‌آوری داده‌ها و پیش‌فرآیند رفتار سد

اکتساب داده‌ها

پارامترهای مورد استفاده شامل دمای آب، سطح آب، فشار دریچه، میزان رسوب‌گذاری، فشار منافذ، دمای هوا، حجم آب ورودی، مشخصات ویژه سد، شرایط بتن، سطح آب مخزن، تغییر مکان افقی و عمودی، اجزای اتصال انتقالی و شتاب زمین، قدرت، فشار، کشش و تنش بالا با استفاده از اطلاعات موجود در برگ مشخصات فنی و اطلاعات جمع‌آوری شده اعمال می‌شود (Bouaroudj *et al.*, 2019; Chen *et al.*, 2020). داده‌های استفاده شده در این تحقیق شامل ۳۶۵ روز، از $1397/01/31$ تا $1398/01/31$ به طول انجامیده است و همین‌طور فاصله نمونه‌گیری یک ماه می‌باشد. داده‌های رفتار سد برای پیش‌بینی رفتار آن به دو قسمت تقسیم شد: در وهله اول ۶۰۰ مجموعه داده تجهیزات سد برای آموزش مدل‌سازی الگوریتم بهینه‌سازی گروه ذرات مقدار حقیقی-رگرسیون لجستیک و آخرین ۱۲۰ مجموعه داده به‌عنوان داده‌های آزمایشی برای آنالیز عملکرد پیش‌بینی الگوریتم بهینه‌سازی گروه ذرات مقدار حقیقی-رگرسیون لجستیک استفاده شد.

رگرسیون لجستیک مستقیماً با داده‌های ارزش واقعی روی کروموزوم رمزگذاری می‌شوند. مقادیر پارامترهای رگرسیون لجستیک از طریق فرآیند تکامل الگوریتم بهینه‌سازی شده گروه ذرات مقدار حقیقی به‌صورت دینامیکی بهینه می‌شوند و از پارامترهای به‌دست‌آمده برای ساختن یک مدل رگرسیون لجستیک بهینه شده برای بهبود پیش‌بینی استفاده گردید. چارچوب بهینه‌سازی پارامترهای رگرسیون لجستیک با الگوریتم بهینه‌سازی گروه ذرات با مقدار حقیقی در (شکل ۳) نشان داده شده است.

گام ۱ (کدگذاری ذرات)

پارامترهای رگرسیون لجستیک برای تولید ذرات به‌صورت تصادفی و مستقیم کدگذاری می‌شوند (Chambers, 2019; Raj & Ananthi, 2019). دامنه به‌صورت‌های (۱۱۰۰)، (۰/۰۰۰۱، ۰/۰۱) و (۰، ۱) تعریف می‌شود. جمعیت حاوی ۱۰۰ ذره می‌باشد.

گام ۲ (تعریف برازندگی)

محاسبه برازندگی مجموعه داده‌های آموزشی آسان و تمایل به مناسب بودن می‌باشد. این مشکل با استفاده از یک روش اعتبارسنجی متقابل قابل حل می‌باشد. در این زمینه، برای غلبه بر پدیده بیش از حد مناسب، از یک روش اعتبار پنج‌گانه استفاده می‌شود (Rong *et al.*, 2019). تابع رگرسیون ساخته شده با مجموعه‌ای از پارامترهای داده شده می‌باشد و از چهار زیرمجموعه به‌عنوان یک مجموعه آموزش استفاده می‌کند. عملکرد مجموعه پارامترها با خطای ریشه میانگین مربع در زیرمجموعه آخر اندازه‌گیری می‌شود. روش فوق به‌صورت پنج بار تکرار می‌شود به‌طوری‌که از هر زیرمجموعه یک‌بار برای اعتبارسنجی استفاده می‌شود. میانگین بهینه‌سازی گروه ذرات مقدار حقیقی در پنج امتحان آزمایشی خطای تعمیم مورد انتظار برای مجموعه‌های آموزشی می‌باشد.

$$R^2 = \left(1 - \frac{\sum_{i=1}^n (M_i - P_i)^2}{\sum_{i=1}^n (P_i - \bar{P}_i)^2}\right) \quad (1)$$

ریشه میانگین مربعات خطا^۲ (RMSE): برای اولین بار در سال ۱۹۸۰ توسط استیجر و لیند بوجود آمد که مقدار آن شدیداً به تعداد پارامترهای برآورد شده در مدل بستگی دارد. RMSE مشهورترین معیار خطا می‌باشد که خطاهای بزرگ را بیشتر از خطاهای کوچک جذب می‌کند (رابطه ۲).

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

ضریب پراکندگی^۳ (SI): معرف پراکندگی متغیر به صورت مطلق می‌باشد، در واقع میزان پراکندگی داده‌ها از خط بهینه می‌باشد، اگر تمام داده‌ها درست پیش‌بینی شوند میزان پراکندگی صفر می‌باشد (رابطه ۳).

$$SI = \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (P_i - M_i)^2}}{\bar{M}} \quad (3)$$

میانگین خطاهای انحرافی^۴ (MBE): از دیگر پارامترهای آماری مهم می‌باشد که هرچه به عدد صفر نزدیک باشد بهتر است، مقادیر مثبت برای MBE نشان از پیش‌بینی دست بالا و مقادیر منفی نشان از مقادیر دست پایین می‌باشد (رابطه ۴).

$$MBE = \frac{1}{n} \sum_{i=1}^n (P_i - M_i) \quad (4)$$

نتایج و بحث

در این مطالعه جهت آموزش مدل، داده‌ها به دو دسته آموزش و آزمون تقسیم شدند. همچنین جهت شبیه‌سازی مدل با داده‌های آزمون، داده‌ها بر اساس مشخصات داده‌های آموزش نرمال شدند. به همین منظور چندین ترکیب تصادفی برای تفکیک مجموعه‌های آموزش و آزمون انتخاب گردید تا نهایتاً دو مجموعه که از نظر

در اصل، در حالت نرمال و با اشتراک‌گذاری داده‌ها، ورود داده‌های خام به الگوریتم باعث کاهش سرعت و دقت شبکه می‌شود. برای جلوگیری از چنین شرایطی و همچنین برای استانداردسازی مقادیر داده‌ها، داده‌های ورودی قبل از آموزش شبکه عصبی، باید استاندارد شوند، یعنی همه داده‌ها بین ۰ و ۱ برابر می‌شوند. پس از نرمال‌سازی، داده‌ها به دو دسته آموزشی و آزمایشی برای طراحی یک مدل شبکه تقسیم شدند. داده‌های آموزشی برای یافتن رابطه بین ورودی‌ها و خروجی‌های مشاهده‌ای توسط این مدل استفاده می‌شود.

ارزیابی و مقایسه عملکرد مدل پیشنهادی

محققان بسیاری آنالیزهای آماری مختلفی را برای ارزیابی روش‌های داده‌کاوی بکار گرفته‌اند. این‌گونه تحلیل‌ها معیار مناسبی را برای رتبه‌بندی روش‌های مختلف بر اساس دقت پیش‌بینی‌شان فراهم می‌آورند. برای ارزیابی و مقایسه مدل‌های رگرسیون لجستیک اسمی، شبکه عصبی و شبکه عصبی-فازی پیشنهاد شده، پارامترهای آماری مختلفی بکار گرفته شده‌اند. در این مطالعه نیز برای ارزیابی عملکرد روش‌های بکار گرفته شده از معیارهای ارزیابی ضریب تعیین (R^2)، ریشه میانگین مربعات خطا (RMSE)، ضریب پراکندگی (SI) و میانگین خطاهای انحرافی (MBE) استفاده گردید.

ضریب تعیین^۱ (R^2): معیاری برای تعیین همبستگی نسبی بین دو مجموعه متغیر می‌باشد. این پارامتر در مرحله آموزش مدل، نقش مهم‌تری نسبت به مرحله آزمون ایفا می‌کند. ضریب تعیین، معیاری است از این که خط رگرسیون، چقدر خوب خوانده‌ها را معرفی می‌کند. اگر خط رگرسیون از تمام نقاط بگذرد توانائی معرفی همه متغیرها را دارد و هرچه از نقاط دورتر باشد نشان دهنده توانائی کمتر است. این معیار از (رابطه ۱) قابل محاسبه است.

² Root Mean Square Error

³ Scatter Index

⁴ Mean Bias Error

¹ Coefficient Of Determination

معیار برازش برای ورود به انتخاب متغیرهای در (جدول ۳) قابل مشاهده است.

جدول ۳. برازش مدل‌های رگرسیونی ورودی الگوریتم ژنتیک

نسب	کروموزم	مدل رگرسیون	میزان برازش
۰	۰	لجستیک-اسمی	۰/۰۱۶
۰	Best	لجستیک-باینری	۰/۰۰۶
۱	Best	پرویت-فضایی	۰/۰۰۶
۲	Best	ساده-خطی	۰/۰۰۸
۳	Best	چند متغیره	۰/۰۰۷
...
۹۷	Best	ساده-خطی	۰/۰۰۶
۹۸	Best	چند متغیره	۰/۰۰۶
۹۹	Best	لجستیک-اسمی	۰/۰۰۵

نتایج انتخاب پارامترهای مؤثر

به منظور تعیین مهم‌ترین عوامل مؤثر بر رفتار سد از آنالیز حساسیت در روش پیشنهادی استفاده گردید (جدول ۴). هر عامل و متغیری که بیشترین تأثیر در مدل پیشنهادی داشته باشد، حذف آن بر خطا و روند پیش‌بینی مدل تأثیر زیادی دارد. نتایج جدول ۴ بیانگر این است که متغیرهای دمای هوا، فشار منفذی و میزان رسوب بیشتر تأثیر در مدل و کمترین خطا را نشان داده‌اند و رگرسیون منتخب برای هر متغیر با توجه به شرایط حاکم و نوع داده متفاوت است و هیچ‌گونه برتری خاصی در میان رگرسیون‌های انتخاب شده در مدل وجود ندارد.

آماري با هم سازگاري هستند، به دست آیند. با توجه به مطالعات انجام شده تقسيم داده‌ها به آموزش و آزمون به دو صورت ۸۰ به ۲۰ و ۷۰ به ۳۰ صورت می‌پذیرد و انتخاب هر یک از این روش بستگی به تعداد داده‌ها و ورودی‌ها دارد که در این مطالعه، ۸۰٪ از مجموعه داده برای آموزش (۱۳۴۷ داده) و ۲۰٪ از مجموعه داده (۳۳۷ داده) برای آزمون مدل پیشنهادی استفاده شده است. با توجه به فراوانی داده‌ها، جهت آموزش مدل‌ها سعی شد داده‌های آموزش به دسته‌های ۲۰۰، ۴۰۰، ۶۰۰، ۸۰۰، ۱۰۰۰ و ۱۳۴۷ تایی تقسیم و مرحله آموزش انجام شود تا بدین صورت حداقل مقدار داده که منجر به نتایج مناسب می‌شود، مشخص شود. جهت ارزیابی عملکرد مدل نیز از معیارهای آماری استفاده گردید که نتایج آن در (جدول ۲) آورده شده است.

جدول ۲. ارزیابی مدل‌های پیشنهاد شده

تعداد داده‌ها	R ²	RMSE(kPa)	Bias(kPa)	SI%
۲۰۰	۰/۷۵۵	۱۱/۴۷۳	۰/۰۴۵	۹/۹۶۷
۴۰۰	۰/۹۰۵	۱۲/۱۹۰	۰/۰۳۳	۹/۳۵۱
۶۰۰	۰/۹۲۶	۱۲/۷۶۳	۰/۰۲۲	۹/۳۶۹
۸۰۰	۰/۹۲۵	۱۳/۴۸۱	۰/۰۱۶	۸/۸۷۱
۱۰۰۰	۰/۹۶۲	۱۴/۶۵۷	۰/۰۱۱	۸/۴۷۲
۱۳۴۷	۰/۹۶۴	۱۴/۳۴۱	۰/۰۰۶	۷/۹۷۴

نتایج حاصل از مدل ورودی رگرسیون با توجه به

جدول ۴. آنالیز حساسیت مدل پیشنهادی در شناسایی متغیرهای مؤثر بر رفتار سد


متغیر	رگرسیون منتخب	R ²	RMSE	MAE	درصد اهمیت
دمای آب	ساده	۰/۸۸	۰/۰۰۲	۰/۰۰۱	۵
سطح آب	ساده	۰/۸۹	۰/۰۰۱	۰/۰۰۱	۵
میزان رسوب	لوجیت	۰/۹۳	۰/۰۰۱	۰/۰۰۱	۱۲
فشار منفذی	ساده	۰/۹۷	۰/۰۰۱	۰/۰۰۱	۲۰
دمای هوا	لجستیک اسمی	۰/۹۸	۰/۰۰۱	۰/۰۰۱	۲۳
حجم آب ورودی	ساده	۰/۹۲	۰/۰۰۱	۰/۰۰۱	۱۰
مشخصات سد	لوجیت	۰/۸۸	۰/۰۰۲	۰/۰۰۱	۸
وضعیت بتن	پرویت	۰/۹۰	۰/۰۰۲	۰/۰۰۱	۸
سطح آب مخزن	ساده	۰/۹۱	۰/۰۰۱	۰/۰۰۱	۹



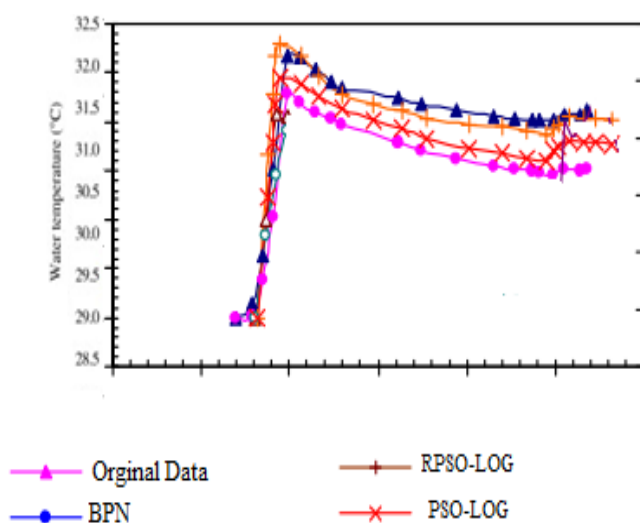
شکل ۴. طرح اولیه نقشه رابطه بین تحلیل فضایی و متغیرهای محلی

در طی آزمایش‌ها، از آنجایی که سطح محلول و دمای آب از مهم‌ترین عوامل تأثیرگذار بر مدل هستند، در این مطالعه دمای محلول آب و دما را تحت عنوان اهداف برای پیش‌بینی رفتار سد انتخاب شدند. برای پیش‌بینی رفتار سد، مقادیر تجهیزات امروزی نظارتی را به عنوان پارامترهای ورودی مدل الگوریتم بهینه‌سازی گروه ذرات مقدار حقیقی-رگرسیون لجستیک برای پیش‌بینی آنها به در نظر گرفتیم و سپس سطح کنترل و دمای آب مقایسه و آنالیز گردید. برای ارزیابی و مقایسه عملکرد روش ترکیبی

طراحی مدل پیش‌بینی تجهیزاتی سد بر اساس الگوریتم بهینه‌سازی گروه ذرات مقدار حقیقی-رگرسیون لجستیک برای مدل رگرسیون لجستیک، هیچ فرآیند استاندارد برای تعیین پارامترهای آزاد وجود ندارد. در نتیجه، مدل پیشنهادی الگوریتم بهینه‌سازی گروه ذرات مقدار حقیقی-رگرسیون لجستیک به صورت دینامیکی مقادیر پارامترهای رگرسیون لجستیک را بهینه می‌کند. در وهله اول الگوریتم بهینه‌سازی گروه ذرات مقدار حقیقی و اعتبارسنجی متقابل پنج‌گانه برای جستجو استفاده شد و ترکیبات بهتری از پارامترهای رگرسیون لجستیک به دست آمد که ارزش اعتبارسنجی پنج‌گانه حداقل باشد. سپس، مدل پیش‌بینی تجهیزاتی سد با توجه به الگوریتم بهینه‌سازی گروه ذرات مقدار حقیقی - رگرسیون لجستیک ساخته می‌شود. سازه سیستم پیش‌بینی رفتار سد آب‌ورزی با توجه به الگوریتم بهینه‌سازی گروه ذرات مقدار حقیقی-رگرسیون لجستیک (در شکل ۴) نشان داده شده است. سیستم پیش‌بینی رفتار سد و تجهیزات آبی شامل اکتساب داده‌ها، پیش‌پردازش استانداردسازی داده‌ها، پیش‌بینی، نتایج آزمایش و کاربرد آن می‌باشد.



شکل ۵. پیش‌بینی مقدار سطح آب



شکل ۶. پیش‌بینی دمای آب

برای هر دو روش خطای ریشه میانگین مربع و خطای درصد میانگین مطلق، روش بهینه‌سازی گروه ذرات مقدار حقیقی- رگرسیون لجستیک توانایی تعمیم بهتر و پیش‌بینی فرآیند اعتبارسنجی را نسبت به روش‌های شبکه عصبی رگرسیون لجستیک و پسر و نشان می‌دهد. با استفاده از شاخص‌های رفتار تجهیزات سد، پیش‌بینی بهتر درجه حرارت آب و سپس سطح آب حاصل می‌شود. این امر بدان دلیل می‌باشد که دمای آب کمتر تحت تأثیر عوامل محیطی خارجی قرار می‌گیرد، درحالی‌که مقدار آب سطحی وابسته به مجموعه‌ای از فرآیندهای فعل و انفعالات فیزیکی-شیمیایی می‌باشد، در نتیجه تأثیرات سایر عوامل با گذشت زمان تغییر می‌کند. در کل، مدل پیش‌بینی بهینه‌سازی گروه ذرات مقدار حقیقی - رگرسیون لجستیک عملکرد بسیار خوبی دارد. این امر بدان دلیل

الگوریتم بهینه‌سازی گروه ذرات مقدار حقیقی- رگرسیون لجستیک، از روش عصبی مرسوم رگرسیون لجستیک و روش پسر و نیز برای مقایسه استفاده شد. برای شبکه عصبی پسر و، میزان یادگیری ۰/۰۸۶ و عملکرد فعال‌سازی سیگموئید می‌باشد. نتایج پیش‌بینی شده در زیر نشان داده شده است (شکل‌های ۵ و ۶).

شکل ۵ بیانگر نتایج پیش‌بینی شده از مقدار آب سطحی پیش‌بینی شده را به مدت نیم ساعت نشان می‌دهد. در این شکل محور قائم سطح آب بر حسب mg/L و محور افقی نمونه‌ای از آموزش زمان نمونه‌گیری می‌باشد. نتایج پیش‌بینی دمای آب به مدت نیم ساعت نیز در (شکل ۶) نشان داده شده است.

نتایج پارامترهای رفتار سد برای سه روش مختلف نشان داده شده است (جداول ۵ و ۶). بر اساس این جداول

جدول ۵. مقایسه شاخص اندازه‌گیری عملکرد برای راهکارهای مختلف (مقدار سطح آب)

شبکه‌های عصبی پسر و مقدار آموزشی برابر با ۰/۰۸۸، سیگموئید			
۲۹/۹۶	۵/۹۱	۳/۶۸	خطای درصد میانگین مطلق %
۰/۲۸۵	۰/۰۵۱۲	۰/۰۲۳۴	خطای ریشه میانگین مربع

جدول ۶. مقایسه شاخص اندازه‌گیری عملکرد برای راهکارهای مختلف (دمای آب)

شبکه‌های عصبی پسر و مقدار آموزشی برابر با ۰/۰۸۸، سیگموئید			
۲۲/۲۷۶	۴/۸۴۷	۱/۸۴۵	خطای درصد میانگین مطلق %
۰/۳۰۵	۰/۰۵۳۴	۰/۰۲۹۵	خطای ریشه میانگین مربع

آموزش دیده است و در پیش‌بینی فشار پیزومتریک در بدنه سد عملکرد قابل قبولی خواهد داشت. همچنین در معیار اول و دوم ارزیابی، نتایج حاصل از مدل شبکه عصبی ارائه شده با ضریب تعیین $R^2 = 0.930$ و $SI = 8/587$ همگرایی قابل قبولی نشان می‌دهد. نتایج مربوط به داده‌های آموزش مدل نیز بیانگر این است که میانگین (μ) و انحراف معیار (σ) مدل ارائه شده، برای داده‌های آموزش به ترتیب برابر با $1/341$ و $1/526$ می‌باشد و برای داده‌های صحت‌سنجی این مقادیر برابر با $1/576$ و $2/247$ می‌باشد که این نشان از عملکرد خوب مدل پیشنهاد شده می‌باشد. در معیار احتمال تجمعی، مدل پیشنهاد شده با $P_{50} = 0.940$ و $P_{90} = 1/742$ مبین این است که نتایج قابل قبول می‌باشد. نسبت مقادیر پیزومتریک پیش‌بینی شده به مقادیر قرائت شده برای حدود ۷۲ درصد داده‌ها در این مدل در حدود یک بوده، که بیانگر آموزش و قدرت پیش‌بینی مناسب این مدل می‌باشد. با توجه به جمع‌آوری مجموعه داده زیاد، مدل فوق به‌خوبی آموزش دید. بنابراین می‌توان این‌گونه نتیجه‌گیری کرد که الگوریتم بهینه‌سازی گروه ذرات مقدار حقیقی - رگرسیون لجستیک برای پیش‌بینی رفتار تجهیزاتی سد عملکرد بهتری از روش‌های شبکه عصبی پسر و رگرسیون لجستیک دارد.

می‌باشد که بهینه‌سازی گروه ذرات مقدار حقیقی - رگرسیون لجستیک در عوض به حداقل رساندن ریسک تجربی که تعمیم عالی برای اندازه‌های نمونه کوچک را فراهم می‌سازد، اصل کاهش ریسک سازه‌ای را اجرا می‌کند. هیچ‌گونه توافقی بر سر توزیع مجموعه داده‌ها وجود ندارد. همچنین می‌تواند باعث تغییر در رویکرد داده‌ها شود؛ بنابراین، هنگامی که داده‌ها یک نوسان بزرگ از خود نشان می‌دهند، خطای پیش‌بینی بهینه‌سازی گروه ذرات مقدار حقیقی - رگرسیون لجستیک نیز کم می‌باشد.

نتیجه‌گیری

در این مطالعه از مدل‌های شبکه عصبی مبتنی بر رگرسیون با الگوریتم ژنتیک (GARANN) برای پیش‌بینی رفتار سد استفاده گردید. داده‌های رفتار سد برای پیش‌بینی رفتار آن به دو گروه طبقه‌بندی شدند که ابتدا ۶۰۰ مجموعه داده تجهیزات سد برای آموزش مدل‌سازی الگوریتم بهینه‌سازی گروه ذرات مقدار حقیقی - رگرسیون لجستیک و در ادامه ۱۲۰ مجموعه داده به‌عنوان داده‌های آزمایشی برای آنالیز عملکرد پیش‌بینی الگوریتم بهینه‌سازی گروه ذرات مقدار حقیقی - رگرسیون لجستیک بکار گرفته شد. به‌منظور ارزیابی عملکرد مدل استفاده شده از معیارهای آماری R^2 , RMSE, SI و MAB استفاده گردید. نتایج نشان داد که مدل استفاده در این تحقیق به‌خوبی

Reference:

- Acerbi, L., & Ji, W. (2017). Practical Bayesian optimization for model fitting with Bayesian adaptive direct search. In: NIPS'17: Proceedings of the 31st International Conference on Neural Information Processing Systems, 1834-1844.
- Belmokre, A., Mihoubi, M. K., & Santillán, D. (2019). Analysis of dam behavior by statistical models: application of the random forest approach. *KSCE Journal of Civil Engineering*, 23(11), 4800-4811.
- Chambers, Lance D., ed. (2019). *Practical handbook of particle swarm optimization algorithms: complex coding systems* (Vol. 3). CRC press.
- Chen, S., Gu, C., Lin, C., Zhang, K. & Zhu, Y. (2021). Multi-kernel optimized relevance vector machine for probabilistic prediction of concrete dam displacement. *Engineering with Computers*, 37(3), 1943-1959.
- Colkesen, I., Sahin, E. K. & Kavzoglu, T. (2016). Susceptibility mapping of shallow landslides using kernel based Gaussian process, support vector machines and RPSO. *Journal of African Earth Sciences*, 118, 53-64.
- Colkesen, I., Sahin, E. K., & Kavzoglu, T. (2016). Susceptibility mapping of shallow landslides using kernel-based Gaussian process, support vector machines, and RPSO. *Journal of African Ea Sciences*, 118, 53-64. doi: 10.22065/jsce.2020.203517.1957. [in Persian]
- Emami, S., Parsa, J., & Emami, H. (2021). Evaluating Cracks in Concrete Dams using Meta-heuristic Algorithms and Artificial Neural Networks. *Journal of Structural and Construction Engineering*, 8(Special Issue 2).
- Feng, J., Liu, L., Wu, D., Li, G., Beer, M., & Gao, W. (2019). Dynamic reliability analysis using the extended support vector regression (X-SVM). *Mechanical Systems and Signal Processing*, 126, 368-391.

- Gitoe, A., Faridi, A., & France, J. (2018). Mathematical models for response to amino acids: estimating the response of broiler chickens to branched-chain amino acids using support vector regression and neural network models. *Neural Computing and Applications*, 30(8), 2499-2508.
- Gu, H., Yang, M., Gu, C., Cao, W., Huang, X. & Su, H. (2020). An analytical approach of behavior changes for concrete dam by panel data model. *Steel and Composite Structures*, 36(5), 521-531.
- Han, H. G., Guo, Y. N., & Qiao, J. F. (2018). Nonlinear system modeling using a self-organizing recurrent radial basis function neural network. *Applied Soft Computing*, 71, 1105-1116.
- Hussain, Z. F., Ibraheem, H. R., Alsajri, M., Ali, A. H., Ismail, M. A., Kasim, S., & Sutikno, T. (2020). A new model for iris data set classification based on linear support vector machine parameter optimization. *International Journal of Electrical and Computer Engineering*, 10(1), 1079-1084.
- Kalita, D. J., Singh, V. P., & Kumar, V. (2020). A Survey on Logistic Regression Hyper-Parameters Optimization Techniques. In: *Social Networking and Computational Intelligence*, Springer, Singapore, 243-256.
- Li, D., Wu, Y., Gao, E., Wang, G., Xu, Y., Zhong, H., & Wu, W. (2020). Simulation of Seawater Intrusion Area Using Feedforward Neural Network in Longkou, China. *Water*, 12(8), 2107. <https://doi.org/10.3390/w12082107>
- Li, M., & Wang, J. (2019). An empirical comparison of multiple linear regression and artificial neural network for concrete dam deformation modeling. *Mathematical Problems in Engineering*. <https://doi.org/10.1155/2019/7620948>.
- Ma, B., and Xia, Y. (2017). A tribe competition-based particle swarm optimization algorithm for feature selection in pattern classification. *Applied Soft Computing*, 58, 328-338.
- Mata, J., Salazar, F., Barateiro, J., & Antunes, A. (2021). Validation of Machine Learning Models for Structural Dam Behaviour Interpretation and Prediction. *Water*, 13(19), 2717. <https://doi.org/10.3390/w13192717>
- Nan, F., Ding, R., Nallapati, R., & Xiang, B. (2019). Topic Modeling with Wasserstein Autoencoders. arXiv preprint arXiv:1907.12374.
- Neshat, M., Tabatabai, M., Zahmati, E., & Shirdel, M. (2016). A hybrid fuzzy knowledge-based system for forest fire risk forecasting. *International Journal of Reasoning-based Intelligent Systems*, 8(3-4), 132-154 [In Persian].
- Oneto, L., Bisio, F., Cambria, E., & Anguita, D. (2016). Statistical learning theory and ELM for big social data analysis. *IEEE Computational Intelligence Magazine*, 11(3), 45-55. <https://doi.org/10.1109/MCI.2016.2572540>
- Peng, K. L., Wu, C. H., & Goo, Y. J. (2004). The development of a new statistical technique for relating financial information to stock market returns. *International Journal of Management*, 21(4), 492-505.
- Raj, J. S., & Ananthi, J. V. (2019). Recurrent neural networks and nonlinear prediction in support vector machines. *Journal of Soft Computing Paradigm (JSCP)*, 1(01), 33-40. <https://doi.org/10.36548/jscp.2019.1.004>
- Reis, L. P., de Souza, A. L., dos Reis, P. C. M., Mazzei, L., Soares, C. P. B., Torres, C. M. M. E., da Silva, L. F., Ruschel, A. R., Rêgo, L. J. S. & Leite, H. G. (2018). Estimation of mortality and survival of individual trees after harvesting wood using artificial neural networks in the amazon rain forest. *Ecological Engineering*, 112, 140-147.
- Rong, M., Gong, D., & Gao, X. (2019). Feature selection and its use in big data: challenges, methods and trends. *IEEE Access*, 7, 19709-19725.
- Samigulina, G., & Massimkanova, Z. (2019). Development of Smart-Technology for Forecasting Technical State of Equipment Based on Modified Particle Swarm Algorithms and Immune-Network Modeling. In: *International Conference on Computational & Experimental Engineering and Sciences*. Springer, Cham, 283-293.
- Schratz, P., Muenchow, J., Iturritxa, E., Richter, J., & Brenning, A. (2018). Performance evaluation and hyperparameter tuning of statistical and machine-learning models using spatial data. arXiv preprint arXiv:1803.11266.
- Shakarami, L., Javdani, H., Sanayei, H. R. Z., & Shams, G. (2019). Numerical investigation of seismically induced crest settlement of earth dams. *Modeling Earth Systems and Environment*, 5(4), 1231-1238.
- Siniscalchi, S. M., & Salerno, V. M. 2016. Adaptation to new microphones using artificial neural networks with trainable activation functions. *IEEE transactions on neural networks and learn systems*, 28(8), 1959-1965. <https://doi.org/10.1109/TNNLS.2016.2550532>.



Print ISSN: 2251-7480
Online ISSN: 2251-7400

Journal of
**Water and Soil
Resources Conservation
(WSRCJ)**

Web site:

<https://wsrcj.srbiau.ac.ir>

Email:

iauwsrcj@srbiau.ac.ir
iauwsrcj@gmail.com

**Vol. 11
No. 4
Summer 2022**

Received:
2021-09-29

Accepted:
2021-12-29

Pages: 115-127

Modeling The Behavior of Concrete Dams using Artificial Neural Network and Logistic Regression Methods

Fardin Saeid¹, Mohsen Irandoust^{2*} and Navid Jalalkamali³

- 1) PhD Candidate, Department of Water Engineering, Kerman Branch, Islamic Azad University, Kerman, Iran.
- 2) Assistant Professor, Department of Water Engineering, Kerman Branch, Islamic Azad University, Kerman, Iran.
- 3) Assistant Professor, Department of Water Engineering, Kerman Branch, Islamic Azad University, Kerman, Iran.

*Corresponding Author email: mohsenirandost@yahoo.com

Abstract:

Background and Aim: Dam measurement and behavior assessment is a new issue that can be due to changes in available parameters to develop a model examining the behavior of individual parameters on the dam as well as on each other and analyze the changes and create the necessary policies. This study aims to propose a hybrid method involving logistic regression with particle swarm optimization algorithm with real value to predict the behavior of dam equipment.

Method: In this study, from 365 days data, from 04/20/2018 to 04/20/2019, of which 600 sets of dam equipment data including parameters of water temperature, water level, valve pressure, sedimentation rate, pore pressure, air temperature, inlet water volume, specific dam characteristics, concrete conditions, reservoir water level, horizontal and vertical displacement, transmission connection components and ground acceleration, strength, pressure, tensile and high stress were used for modeling. Real value-logistic regression and 120 datasets were used for modeling the should be added of particle group optimization algorithm. To evaluate the performance of the proposed method, four statistics including coefficient of determination (R^2), root mean square error (RMSE), scattering coefficient (SI), and means bias error (MBE) were used.

Findings: The results showed that the model has an acceptable performance in predicting piezometric pressure in the dam body. Also, the results of the artificial neural network model show acceptable convergence with $R^2 = 0.930$ and $SSI = 8.587$. The results related to the training data of the model also indicate that the mean (μ) and standard deviation (σ) of the proposed model are equal to 1.341 and 1.526 for the training data and these values for the validation data are equal to 1.576 and 2.247, respectively indicating the good performance of the proposed model. In the cumulative probability criterion, the proposed model with $P_{50} = 0.940$ and $P_{90} = 1.742$ indicates that the results are acceptable.

Results: The results indicate that the real value-logistic regression particle swarm optimization implements the principle of structural risk reduction instead of minimizing the experimental risk that provides excellent generalization for small sample sizes. The ratio of predicted piezometric values to read values for about 72% of the data in this model is about one, indicating the appropriate training and predictive power of this model. Finally, according to the evaluation criteria, the hybrid model performs better than the presented methods.

Keywords: Concrete dam, regression analysis, Particle swarm optimization algorithm, Sattarkhan Dam

