

پیش‌بینی ضریب فشار آب حفره‌ای در بدنه سدهای خاکی در زمان ساخت با استفاده از الگوریتم

هیبریدی WCA-ANN

حسین حکیمی‌خانسر^{۱*}

جواد پارسا^۲

علی حسین زاده دلیر^۳

جلال شیرینی^۴

چکیده

در این مطالعه قابلیت الگوریتم هیبریدی WCA-ANN در زمینه مدل‌سازی ضریب فشار آب حفره‌ای در بدنه سد کبودوال (مطالعه موردی) در زمان ساخت و تعیین ویژگی‌های مؤثر بر آن ارزیابی شده است. در این راستا پنج ویژگی شامل تراز خاک ریزی، زمان ساخت سد، تراز مخزن (آبگیری)، سرعت آبگیری و سرعت خاک ریزی در طول دوره آماری ۴ ساله به عنوان ورودی مدل هیبریدی انتخاب شدند. با اجرای الگوریتم هیبریدی و روش انتخاب ویژگی، دو ویژگی تراز خاک ریزی و زمان ساخت در نقاط $Ru_{19.1}$ و $Ru_{19.2}$ بیش‌ترین تأثیر را بر مدل‌سازی ضریب فشار آب حفره‌ای خاک دارند. علاوه بر دو ویژگی فوق، در نقاط محور میانی و مرکز مقطع عرضی، ویژگی‌های سرعت خاک ریزی و تراز آبگیری با مقدار خطا (MSE) برابر $0/00006$ و در نقاط نزدیک مخزن ویژگی‌های تراز آبگیری و سرعت آبگیری با مقدار خطا برابر $0/00004$ ، بر مدل‌سازی ضریب فشار آب حفره‌ای مؤثر هستند. در نهایت می‌توان گفت که در نقاط نزدیک به محور سد، تراز خاک ریزی و در نقاط واقع در قسمت‌های دورتر از محور میانی و نزدیک مخزن زمان ساخت، با ضریب حساسیت بالا به عنوان مهم‌ترین ویژگی‌ها در مدل‌سازی ضریب فشار آب حفره‌ای با مدل‌های هوش مصنوعی شناخته می‌شوند.

واژه‌های کلیدی:

سد خاکی، الگوریتم چرخه آب، شبکه عصبی مصنوعی، انتخاب ویژگی، ضریب فشار آب حفره‌ای

۱ دانشجوی دکترا، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران
۲ استادیار، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران
۳ استاد، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران
۴ دانشیار، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران

مقدمه

جدید علمی است که مدل‌سازی، تحلیل و در نهایت کنترل سیستم‌های پیچیده را به آسانی و با موفقیت زیاده‌تر امکان‌پذیر می‌سازند (نورانی و همکاران، ۱۳۹۴). مدل‌های هوش مصنوعی روش‌هایی موثر برای بررسی و مدل‌سازی مقادیر زیادی از داده‌های دینامیک، غیرخطی و دارای خطا ارائه می‌دهند (شرقی و همکاران، ۱۳۹۷). فرایند انتخاب ویژگی برای دو حالت تخمین و طبقه‌بندی ویژگی‌ها استفاده می‌شود (وو^۲ و همکاران، ۲۰۱۴). در این فرآیند، تخمین زیرمجموعه ویژگی‌ها، همیشه نظارت شده است، در صورتی که طبقه‌بندی ویژگی‌ها را می‌توان نظارت شده و یا در برخی موارد غیر نظارت شده انجام داد (کوکلی و همکاران^۳، ۲۰۱۵). با استفاده از تکنیک‌های انتخاب ویژگی می‌توان محاسبات ضروری و دقت پیش‌بینی را بهبود بخشید و زمان اجرای محاسبات را کاهش داد (چنراشکار و شاهین^۴، ۲۰۱۴).

(رانوکویچ^۵ و همکاران، ۲۰۱۴) رفتار یک سد بتنی را با استفاده از رگرسیون بردار پشتیبان مدل‌سازی کردند که نتایج بیانگر این بود که مدل‌های هوش مصنوعی نتایج دقیقی را ارائه می‌دهد. (نواکوویچ^۶ و همکاران، ۲۰۱۴) از یک مدل فازی-عصبی برای تخمین هد پیزومتریک سد آبرون گیت^۷ استفاده نموده که مقایسه مقادیر پیش‌بینی‌شده توسط مدل شناسایی بر اساس SVR با داده‌های مشاهداتی حاکی از آن بود که مدل شناسایی SVR نتایج دقیقی ارائه می‌دهد. (نورانی^۸ و همکاران، ۲۰۱۲) برای بررسی هد پیزومتریک یک سد خاکی در ایران، مدل‌های ANN با استفاده از داده‌های تراز آب بالادست-پایین دست سد ایجاد نموده و نتایج به دست آمده را با نتایج مدل FEM مقایسه کردند و به این نتیجه رسیدند که مدل ANN می‌تواند جایگزین مناسبی برای مدل عددی FEM باشد. (تایفو^۱ و همکاران، ۲۰۰۵) مقدار نشت سد دی^۹ در کشور لهستان را به روش المان محدود و

به دلیل اهمیت سد از نظر اقتصادی و خطرات ناشی از شکست و خرابی آن، ایمنی و ریسک خرابی سدها از دیرباز مورد توجه پژوهشگران قرار گرفته است. سدها و مخازن ذخیره آب نقشی اساسی در توسعه اقتصادی و تأمین آب در کشور دارند (ابراهیم‌زاده و همکاران، ۱۳۸۹) و (نورانی و همکاران، ۲۰۱۲). سدهای خاکی در بین انواع مختلف سدها به دلیل صرفه‌های اقتصادی، آسانی در اجرا، در دسترس بودن مصالح اجرایی و عملکرد مطلوب سازه‌ای اهمیت زیادی دارند (وفاییان، ۱۳۹۱). معمولاً ابزار گذاری در زمان ساخت سد خاکی برای بررسی ایمنی، کم کردن هزینه‌های ساخت، کنترل روش و برنامه ساخت، فراهم کردن محافظت قانونی و اطلاعات برای اندازه‌گیری کمیت‌ها مورد استفاده قرار می‌گیرد (سلماسی و همکاران، ۱۳۹۷). از دیدگاه ژئوتکنیک و روش ساخت، سدهای خاکی به دو گروه تقسیم‌بندی می‌شوند که تقریباً همه آن‌ها در گروه غلتکی (کوبیدنی) قرار می‌گیرند (وفاییان، ۱۳۹۱). فشار آب منفذی، تنش‌های ایجادشده و نشست، مهم‌ترین عواملی هستند که در دوران ساخت باید دائماً بررسی شوند (حکیمی خانسر و همکاران، ۱۳۹۲). ضریب فشار آب حفره‌ای در بدنه سد خاکی در زمان ساخت به عواملی مثل مدت زمان ساخت سد، تراز و سرعت خاک ریزی، تراز و سرعت آب‌گیری و ... بستگی دارد که توزیع آن در هر پروژه تصادفی است؛ بنابراین با توجه به پیچیدگی و وجود عدم قطعیت‌های زیاد در این پدیده، استفاده از مدل‌های هوش مصنوعی که ورودی و خروجی مشاهداتی را دریافت نموده و فرایند مورد نظر را تخمین می‌زنند، می‌تواند در بهبود مدل‌سازی این پدیده مفید باشد (نورانی و همکاران، ۲۰۱۲) و (تایفو^۱ و همکاران، ۲۰۰۵). به دلیل گسترش دانش و پیچیده‌تر شدن تصمیم‌گیری، استفاده از دانش‌های نوین از جمله هوش مصنوعی اهمیت زیادی دارد. مدل‌های هوش مصنوعی حاصل تلاش‌های

⁶ Novakovic

⁷ Iron Gate2

⁸ Nourani

⁹ Day

¹ Tayfu

² Wu

³ Cucci

⁴ Chandrashekar and Sahin

⁵ Rankovic

تعیین استفاده شد که نتایج هم‌خوانی حدود ۸۵ درصدی بین داده‌های مشاهداتی و پیش‌بینی‌شده را نشان داد. در پژوهش حاضر از الگوریتم چرخه‌ی آب (WCA) به عنوان یکی از روش‌های فرا ابتکاری به منظور انتخاب ویژگی (انتخاب بهترین ترکیب از ویژگی‌های ورودی) در مدل شبکه عصبی مصنوعی برای پیش‌بینی ضریب فشار آب حفرهای در بدنه سد خاکی کبودوال در زمان ساخت استفاده شده است. همچنین ورودی‌های جدید در مدل‌سازی هوش مصنوعی برای این منظور پیشنهاد گردیده است.

الگوسازی نظری یا تجربی

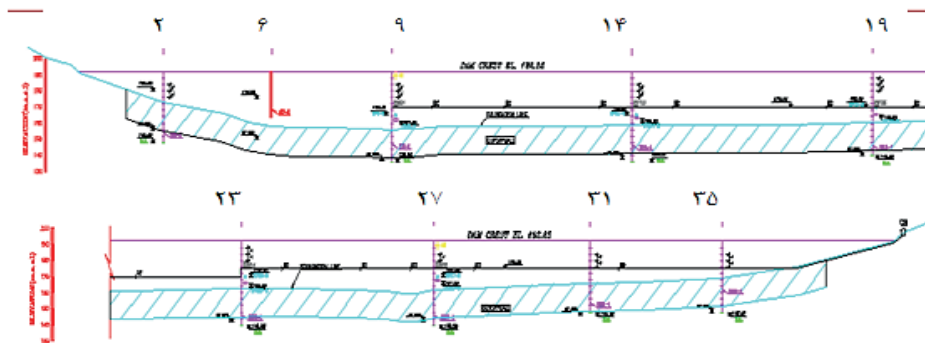
سد مورد مطالعه

سد کبودوال (قره‌سو زرین گل) در اطراف شهر علی‌آباد و در ۴۰ کیلومتری شرق گرگان واقع در مسیر گرگان - مشهد قرار گرفته است. این سد در استان گلستان در شمال شرق ایران و در حد فاصل طول جغرافیایی ۵۴ درجه و ۴۰ دقیقه تا ۵۴ درجه و ۵۶ دقیقه شرقی و عرض‌های جغرافیایی ۳۶ درجه و ۵۴ دقیقه تا ۳۷ درجه و ۶۰ دقیقه شمالی قرار دارد. سد کبودوال همگن و دارای فیلتر و زهکش مایل است (گزارش فنی، ۱۳۹۲). شکل (۱) موقعیت جغرافیایی و مقاطع مختلف سد کبودوال را نشان می‌دهد.

شبکه عصبی بررسی کردند. آن‌ها سطح آب در بالادست و پایین‌دست سد را به عنوان ورودی‌های مدل هوشمند و سطح آب در داخل پیزومتر را به عنوان خروجی آن قراردادند. نتایج نشان داد که نتایج حاصل از مدل‌سازی شبکه عصبی دقیق‌تر از مدل‌سازی توسط المان محدود است و به این نتیجه رسیدند که مدل‌سازی توسط شبکه عصبی برای بررسی سطح آب در داخل خاک، نتایج مناسبی را ارائه می‌دهد. (نورانی و باباخانی، ۲۰۱۳) برای مدل‌سازی نشت از سدها، شبکه مصنوعی را با روش RBF ترکیب کردند. آن‌ها به این نتیجه رسیدند که شبکه عصبی به سبب انعطاف پذیری آن قادر به پیش‌بینی مناسبی از مقادیر نشت خواهد بود. سلماسی و همکاران سال (۱۳۹۹) به تخمین رفتار سد کبودوال^۱ در حین ساخت با مدل‌سازی عددی سه بعدی پرداختند و مقادیر حاصل از شبیه‌سازی عددی با تحلیل برگشتی با مقادیر نظیر داده‌های ابزار دقیق سد مقایسه کردند. نتایج نشان داد که بیشینه افزایش فشار آب حفرهای، تنش، نشست و جابجایی افقی در بخش میانی رخ می‌دهد و مقدار آن در محور و بخش مرکزی سد بیشتر از طرفین آن است. کماسی و بیرانوند (۱۳۹۹) به بررسی جابجایی‌های قائم و افقی سد خاکی ایوشان با استفاده از ابزار دقیق و مدل عددی پرداختند. به منظور تطبیق داده‌های مشاهداتی و پیش‌بینی‌شده از رگرسیون چند متغیره و از معیار ضریب



^۱ Kaboud-val



شکل (۱): موقعیت جغرافیایی و مقاطع مختلف سد کبودوال

$$R_U = \frac{U}{\sigma_v} \quad (1)$$

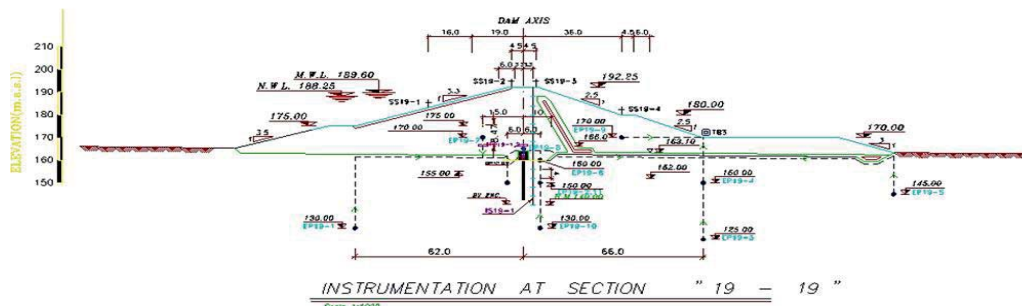
فشار قائم خاک از حاصل ضرب وزن مخصوص خاک ضرب در ارتفاع خاک ریزی به دست می‌آید. ثبات نسبی ضریب فشار آب حفره‌ای در طول عملیات خاک ریزی و نیز قبل و بعد از آن آبیگری سد نشان‌دهنده مناسب بودن سرعت عملیات خاک ریزی و غیر محتمل بودن بروز پدیده شکست هیدرولیکی است؛ بنابراین مقدار این پارامتر در این مقطع از فرمول‌های زیر به دست آمده است.

$$Ru_{19.1} = \frac{EP19.7}{TPC19.1} \quad (2)$$

$$Ru_{19.2} = \frac{EP19.8}{TPC19.2} \quad (3)$$

در این پژوهش، مدل‌سازی و تعیین ویژگی‌های برتر در دو نقطه سد کبودوال که دارای سلول تنش سنجی و پیزومتر الکتریکی است، بررسی خواهد شد. نقطه $Ru_{19.1}$ در بالادست سد نزدیک مخزن و نقطه $Ru_{19.2}$ در مرکز مقطع عرضی سد نزدیک پی و هر دو نقطه در تراز ۱۷۰ متر قرار دارند (شکل ۲).

به دلیل حساسیت پی و بدنه سد کبودوال در خصوص نحوه و سرعت بارگذاری در زمان ساخت سد، ارزیابی رفتار پی و بدنه سد به خصوص در بخش میانی بدنه برای تغییر شکل‌پذیری پی، از مقطع عرضی ۱۹ (بزرگترین مقطع عرضی بخش میانی بدنه و پی سد) برای بررسی ضریب فشار آب حفره‌ای در زمان ساخت سد، استفاده شد (شکل ۱). همچنین از داده‌های ابزار دقیق سد کبودوال، اخذشده از شرکت آب منطقه‌ای استان گلستان، در طول دوره آماری ۴ ساله استفاده شده است (گزارش فنی، ۱۳۹۲). چون فشارسنج TPC19.1 در مجاورت پیزومتر EP19.7 و فشارسنج TPC19.2 در مجاورت پیزومتر EP19.8 نصب شده است (شکل ۲)، از محاسبه نسبت فشار آب حفره‌ای ثبت‌شده به فشار خاک اندازه‌گیری شده، می‌توان ضریب Ru را در دو موقعیت بالادست و محور سد این مقطع به دست آورد. ضریب فشار آب حفره‌ای شاخص مهم در ارزیابی فشار آب حفره‌ای و تنش ایجادشده در بدنه سد است. از محاسبه نسبت ضریب فشار آب حفره‌ای ثبت‌شده (U) به فشار خاک اندازه‌گیری شده (σ_v)، می‌توان ضریب R_U را برای دوران ساخت با توجه به رابطه ۱ تعیین نمود.



شکل (۲): مقطع تیپ و جا نمایی ابزار دقیق در مقطع عرضی ۱۹

در کاربردهای مهندسی شبکه‌های عصبی مصنوعی، شبکه‌های چند لایه پیشرو با الگوریتم یادگیری پس انتشار بسیار رایج است،

شبکه‌های عصبی مصنوعی (ANN)

به عنوان رود و مابقی قطرات باران به عنوان نهرها در نظر گرفته می‌شوند که به طرف رودخانه‌ها و دریا جریان دارند. در یک مسئله‌ی بهینه‌سازی چندبعدی، یک قطره باران، آرایه‌ای به شکل $1 * N_{Var}$ است. این آرایه با رابطه (۵) تعریف می‌شود:

$$Raindrop = [X_1, X_2, X_2, \dots, X_{Var}] \quad (5)$$

که در آن، X_1 تا X_{Var} متغیرهای تصمیم هستند. در ابتدا، یک نمونه از ماتریس قطرات باران به اندازه‌ی $N_{POP} * N_{Var}$ به طور تصادفی ایجاد می‌شود:

$$Population \ Raindrop = \begin{bmatrix} Raindrop1 \\ Raindrop2 \\ \vdots \\ Raindrop_{N_{pop}} \end{bmatrix} = \begin{bmatrix} X_1^1 & X_2^1 & \dots & X_{N_{Var}}^1 \\ \vdots & \vdots & \dots & \vdots \\ X_1^{N_{pop}} & X_2^{N_{pop}} & \dots & X_{N_{Var}}^{N_{pop}} \end{bmatrix} \quad (6)$$

که N_{POP} و N_{Var} به ترتیب تعداد قطرات باران (جمعیت اولیه) و تعداد متغیرهای طراحی است. مقادیر تابع هدف (C) از رابطه‌ی (۷) به دست خواهد آمد:

$$C_i = Cost_i = f(X_1, X_2, X_2, \dots, X_{Var}), i = 1, 2, 3 \dots N_{pop} \quad (7)$$

که در آن، C_i مقدار تابع هدف هر قطره است. در گام نخست، به تعداد N_{POP} قطره‌ی باران ایجاد شده و سپس به تعداد N_{SR} از بهترین قطرات (حداقل ارزش) به عنوان دریا ورود انتخاب می‌شوند. در مسائل کمینه‌سازی، قطره‌ی باران با حداقل مقدار به عنوان دریا در نظر گرفته می‌شود. N_{SR} مجموع تعداد رودها و یک دریا از رابطه‌ی (۸) و مابقی جمعیت (نهرهایی که ممکن است به رودخانه‌ها و یا به طور مستقیم به دریا بریزند) با استفاده از رابطه‌ی (۹) محاسبه می‌شوند.

$$N_{SR} = Number \ of \ Rivers + \overset{Sea}{\uparrow} \quad (8)$$

$$N_{Raindrop} = N_{pop} - N_{SR} \quad (9)$$

ثابت شده است که مدل شبکه پس انتشار با سه لایه برای پیش‌بینی و شبیه‌سازی در هر گونه مسائل مهندسی نتایج قابل قبولی را ارائه می‌دهد (نورانی^۱ و همکاران، ۱۹۹۸) و (هورنیک^۲، ۱۹۸۸). مقدار خروجی یک شبکه سه لایه پیشرو با الگوریتم پس انتشار به صورت رابطه (۴) بیان می‌شود (نورانی و همکاران، ۲۰۱۲).

$$\hat{y}_k = f_0 \left[\sum_{j=1}^{M_n} W_{kj} * f_h \left(\sum_{i=1}^{N_n} W_{ji} x_i + W_{j0} \right) + W_{k0} \right] \quad (4)$$

که در آن W_{ji} وزن در لایه میانی متصل‌کننده نرون i -ام در لایه ورودی و نرون j -ام در لایه میانی، W_{j0} بایاس j -ام در لایه میانی، f_h تابع محرک نرون میانی، W_{kj} وزن در لایه خروجی متصل‌کننده نرون j -ام در لایه میانی و نرون k -ام در لایه خروجی، W_{k0} بایاس نرون k -ام در لایه خروجی، f_0 تابع محرک برای نرون خروجی، x_i متغیر ورودی i -ام برای لایه ورودی، \hat{y}_k و y به ترتیب متغیرهای خروجی محاسباتی و اندازه‌گیری شده و M_n و N_n به ترتیب تعداد نرون در لایه ورودی و پنهان هستند. وزن‌ها در لایه‌های میانی و خروجی با هم فرق داشته، و مقادیر آن‌ها می‌تواند در طول فرآیند آموزش شبکه تغییر نماید. تعداد نرون‌های موجود در لایه‌های ورودی و خروجی با توجه به ماهیت مسئله‌ی مورد بررسی، تعیین شده، درحالی‌که تعداد نرون‌های موجود در لایه‌های پنهانی و هم چنین تعداد این لایه‌ها با سعی و خطا در جهت کاهش مقدار خطا مشخص می‌گردد (مقدم نیا و همکاران، ۲۰۰۹). در این پژوهش نوع شبکه‌ی عصبی مصنوعی پرسپترون چند لایه^۳ (MLP) با الگوریتم پس انتشار خطا انتخاب شده است (شکل ۳).

الگوریتم بهینه‌سازی چرخه آب^۴ (WCA)

الگوریتم چرخه آب مانند تمام الگوریتم‌های فرا ابتکاری با جمعیت اولیه‌ی (اصطلاح قطرات باران) شروع می‌شود. در ابتدا، فرض بر این است که باران یا دیگر انواع بارش وجود دارند. بهترین فرد (بهترین قطره‌ی آب) به عنوان دریا انتخاب می‌گردد. سپس، برخی از قطرات (که باران خوب نام دارند)

⁴ Water Cycle Algorithm (WCA)

¹ Nourani

² Hornik

³ Multi Layer Perceptron

است که رود به دریا رسیده است. در این وضعیت، فرآیند تبخیر اثر می‌کند، و همانند طبیعت، بعد از تبخیر کافی، باران (بارش) شروع خواهد شد. d_{max} شدت جستجو را در نزدیکی دریا (راه حل بهینه) تنظیم می‌کند. مقدار d_{max} با توجه به رابطه‌ی (۱۵) در هر مرحله کاهش می‌یابد:

$$d_{max}^{i+1} = d_{max}^i - \frac{d_{max}^i}{\max iteration} \quad (15)$$

پس از برآورده شدن فرآیند تبخیر، فرآیند بارندگی اعمال خواهد شد. در فرآیند بارندگی، قطرات باران جدید نهرها را در مکان‌های مختلف تشکیل می‌دهند (مانند عملگر جهش در الگوریتم GA). برای تعیین مکان جدید نهرهای تازه شکل گرفته، از رابطه‌ی (۱۶) استفاده خواهد شد.

$$X_{Stream}^{new} = LB \times randn \times (UB - LB) \quad (16)$$

در رابطه بالا، LB و UB به ترتیب، کران پایین و بالایی مسئله تعریف شده است. بهترین قطرات باران جدید تشکیل شده به عنوان رود، و بقیه‌ی قطرات باران جدید به عنوان نهرهای جدید، که به سمت رودخانه‌ها در جریان‌اند، و یا ممکن است به طور مستقیم به دریا برسند، در نظر گرفته می‌شوند. به منظور افزایش سرعت همگرایی و عملکرد محاسباتی الگوریتم برای مسائل مقید از رابطه‌ی زیر استفاده می‌شود:

$$X_{Stream}^{new} = X_{Sea} + \sqrt{\mu} \times rand(1, N_{Var}) \quad (17)$$

که در این رابطه μ ضریبی است که محدوده‌ی جستجو در نزدیکی دریا را بیان می‌کند. $randn$ عدد تصادفی توزیع نرمال است. مقادیر بزرگ μ امکان خروج از منطقه‌ی امکان‌پذیر را افزایش می‌دهد، و مقادیر کوچک μ منجر به جستجوی الگوریتم در منطقه‌ی کوچک‌تر در نزدیکی دریا می‌شوند. معمولاً مقدار مناسب μ ، $0/1$ تعیین شده است (اسکندر و همکاران، ۲۰۱۲). معیار همگرایی در این مقاله رسیدن به تعداد تکرار برابر، ۱۰۰۰ در نظر گرفته شده است.

برای تعیین یا اختصاص قطرات باران به رودها و دریا، بسته به شدت جریان از رابطه‌ی (۱۰) استفاده خواهد شد:

$$NS_n = round \left\{ \left| \frac{Cost_n}{\sum_{i=1}^{N_{SR}} Cost_i} \right| \times N_{Var} \right\}$$

$$, n = 1, 2, 3 \dots N_{SR} \quad (10)$$

که در آن، NS_n تعدادی از نهرهایی است که به رودهای خاص و یا دریا می‌ریزند. یک نهر جریان تا رسیدن به رودخانه در امتداد خط اتصال بین آن‌ها با استفاده از یک فاصله، که به طور تصادفی انتخاب شده، جریان می‌یابد که این فاصله با رابطه‌ی (۱۱) مشخص می‌شود.

$$X \in (0, c \times d), \quad c > 1 \quad (11)$$

که در آن c مقداری بین یک و دو (نزدیک به دو) دارد و بهترین مقدار برای c عدد ۲ است (اسکندر و همکاران، ۲۰۱۲). فاصله‌ی فعلی بین نهر و رودخانه با d نشان داده شده است. مقدار X در رابطه (۱۱) متناظر با یک عدد تصادفی توزیع شده (یکنواخت و یا ممکن است هر توزیع مناسب دیگر) بین صفر و $(c \times d)$ است. موقعیت جدید نهرها و رودخانه‌ها را می‌توان با روابط (۱۲) و (۱۳) به دست آورد:

$$X_{Stream}^{i+1} = X_{Stream}^i + rand \times C \times (X_{River}^i - X_{Stream}^i) \quad (12)$$

$$X_{River}^{i+1} = X_{River}^i + rand \times C \times (X_{Sea}^i - X_{River}^i) \quad (13)$$

در این روابط، $rand$ یک عدد تصادفی یکنواخت توزیع شده بین صفر و یک است. اگر راه حل ارائه شده به وسیله‌ی یک نهر، بهتر از رودخانه متصل به آن باشد، موقعیت رودخانه و نهر باهم عوض می‌شود. این جابه‌جایی نیز می‌تواند برای رودخانه‌ها و دریا نیز رخ دهد. یکی از مهم‌ترین عواملی که از همگرایی سریع الگوریتم (همگرایی نابالغ)، و به دام افتادن در بهینه‌های محلی جلوگیری می‌کند، فرآیند تبخیر است. این فرآیند باعث خواهد شد که آب دریا با تبخیر به صورت جریان رودها و یا نهرها دوباره به دریا بریزد. رابطه‌ی (۱۴) نشان می‌دهد که آیا رود به دریا می‌ریزد یا نه.

$$\text{If } |X_{Sea}^i - X_{River}^i| < d_{max}, i = 1, 2, 3, \dots, N_{SR} - 1$$

تبخیر و بارش فرایند \rightarrow

پایان \rightarrow (۱۴)

که در آن، d_{max} عدد کوچکی (نزدیک به صفر) است، بنابراین، اگر فاصله‌ی بین رود و دریا از d_{max} کمتر باشد، بیانگر آن

با بررسی داده‌های مربوط به پیزومترها و تنش سنج‌ها در مقطع ۱۹ از سد کبودوال، تراز خاک ریزی (F) بر حسب (m.a.s.l)، تراز آب مخزن (R) بر حسب (m.a.s.l)، زمان ساخت سد (T) بر حسب (day)، سرعت خاک ریزی بر حسب $\frac{\text{m.a.s.l}}{\text{day}}$ و سرعت آبیگری بر حسب $\frac{\text{m.a.s.l}}{\text{day}}$ به عنوان ورودی و فشار آب حفره‌ای (P) بر حسب (kp) ایجاد شده بر بدنه سد خاکی در زمان ساخت، به عنوان خروجی مدل هیبریدی، انتخاب شده است. در الگوریتم هیبریدی WCA-ANN داده‌ها به طور تصادفی به دو بخش داده‌های آموزشی (۷۰ درصد) و آزمون (۳۰ درصد) تقسیم شدند و از میانگین وزنی خطاهای آموزشی و آزمون به صورت رابطه ۱۸، برای محاسبه خطای مدل، استفاده شده است:

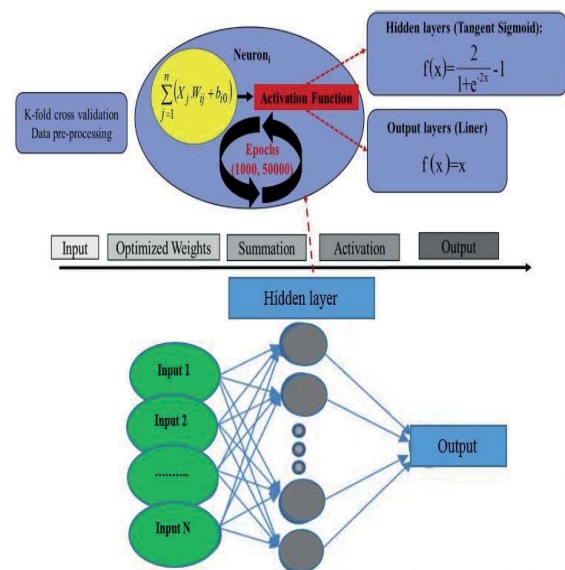
$$\text{Error}_f = 0.8\text{error}_{tr} + 0.2\text{error}_{te}$$

(۱۸)

در رابطه بالا، Error_f ، error_{tr} و error_{te} به ترتیب خطای نهایی مدل به ازای ترکیب‌های متفاوت از ویژگی‌ها، خطای در بخش‌های آموزشی و آزمون هستند. شاخص خطای MSE انتخاب شده است. از آنجا که در فرایند انتخاب ویژگی هدف، تشخیص دادن ویژگی‌های موثر بر متغیر خروجی است و نه پیش‌بینی آن، بنابراین خطای مربوط به داده‌های آموزشی اهمیت بیشتری دارد، زیرا رابطه بین ویژگی‌های ورودی و خروجی مدل با توجه به داده‌های آموزشی به دست می‌آید.

آنالیز حساسیت

در پژوهش حاضر، آنالیز حساسیت به روش هیل^۲ (۱۹۹۸) برای ویژگی‌های ورودی، انجام گرفته است. در این روش، با تغییر هر یک از متغیرها ورودی، به یک مقدار معین (مثلاً ۱۰ درصد)، تأثیر آن‌ها بر خروجی مدل محاسبه می‌شود و مقدار حساسیت مدل هوش مصنوعی نسبت به متغیر ورودی مورد نظر به دست می‌آید (هیل، ۱۹۹۸). آنالیز حساسیت به ترتیب بهترین ویژگی‌ها را در مدل‌سازی نشان می‌دهد ولی



شکل (۳): ساختار شبکه عصبی مصنوعی در تحقیق

ترکیب الگوریتم چرخه آب- شبکه عصبی مصنوعی الگوریتم‌های فرا ابتکاری زیرمجموعه‌ای از محاسبات تکاملی بوده و در شاخه هوش مصنوعی قرار دارند. به طور کلی، سه روش استفاده از الگوریتم‌های تکاملی برای ترکیب با مدل ANN وجود دارد. اولین روش به کارگیری الگوریتم تکاملی به منظور پیدا کردن ترکیب وزن‌ها، بایاس بهینه گره‌های خروجی برای داشتن کمترین مقدار خطا در این شبکه است. دومین شیوه استفاده از این الگوریتم‌ها به منظور یافتن ساختار مناسب شبکه‌ی عصبی در یک مسئله‌ی خاص است و آخرین شیوه شامل به کارگیری الگوریتم تکاملی به منظور یافتن بهترین زیرمجموعه از بین تعداد ویژگی‌های ورودی در این شبکه‌ها است (آقا ابراهیمی و همکاران، ۱۳۹۳). انتخاب ویژگی، روشی است که برای انتخاب زیرمجموعه‌ای از ویژگی‌های مرتبط با یک هدف خاص به کار می‌رود و مهم‌ترین اصل در این فرایند، انتخاب ویژگی‌های پایدار و حذف داده‌های مازاد است (کومار و مینز^۱، ۲۰۱۴). بر این اساس، الگوریتم چرخه آب انواع ترکیب‌های متفاوت ویژگی‌ها را با شبکه عصبی (شکل ۳) مدل‌سازی نموده و در پایان بهترین ترکیب که دارای کمترین خطا (MSE) است را به عنوان مدل بهینه شبکه عصبی معرفی می‌نماید.

² Hill

¹ Kumar and Minz

در مورد بهترین ترکیب ویژگی‌ها اطلاعاتی به ما نمی‌دهد، بنابراین در این پژوهش از فرآیند انتخاب ویژگی استفاده شده است.

در مورد بهترین ترکیب ویژگی‌ها اطلاعاتی به ما نمی‌دهد، بنابراین در این پژوهش از فرآیند انتخاب ویژگی استفاده شده است.

ارزیابی مناسب بودن مدل و نرمال سازی داده‌ها در این پژوهش از شاخص‌های آماری جذر میانگین مربعات خطا ($RMSE$)، ضریب تبیین (R^2)، میانگین خطای مطلق (MAE)، نش ساتکلیف (NS) و نیز میانگین هندسی نسبت خطا ($GMER$) برای بررسی و ارزیابی دقت مدل‌ها استفاده شده است. این شاخص‌های با استفاده از روابط زیر به دست می‌آیند:

در مورد بهترین ترکیب ویژگی‌ها اطلاعاتی به ما نمی‌دهد، بنابراین در این پژوهش از فرآیند انتخاب ویژگی استفاده شده است.

ارزیابی مناسب بودن مدل و نرمال سازی داده‌ها در این پژوهش از شاخص‌های آماری جذر میانگین مربعات خطا ($RMSE$)، ضریب تبیین (R^2)، میانگین خطای مطلق (MAE)، نش ساتکلیف (NS) و نیز میانگین هندسی نسبت خطا ($GMER$) برای بررسی و ارزیابی دقت مدل‌ها استفاده شده است. این شاخص‌های با استفاده از روابط زیر به دست می‌آیند:

$$R^2 = \left(\frac{\sum_{i=1}^n (O_i - \bar{O}_i)(P_i - \bar{P}_i)}{\sqrt{\sum_{i=1}^n (O_i - \bar{O}_i)^2 \sum_{i=1}^n (P_i - \bar{P}_i)^2}} \right)^2 \quad (19)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (P_i - O_i)^2}{N}} \quad (20)$$

$$MAE = \text{Exp} \left[\frac{1}{N} \sum_{i=1}^n \ln \left(\frac{P_i}{O_i} \right) \right] \quad (21)$$

$$NS = \left| 1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (O_i - \bar{O}_i)^2} \right| \quad (22)$$

$$GMER = \text{Exp} \left[\frac{1}{N} \sum_{i=1}^n \ln \left(\frac{P_i}{O_i} \right) \right] \quad (23)$$

در روابط بالا به ترتیب P_i مقدار محاسبه شده، O_i مقدار مشاهداتی از ابزار دقیق سد، \bar{O}_i مقادیر میانگین مشاهداتی، \bar{P}_i میانگین مقادیر محاسبه و N نمایانگر تعداد داده‌ها است.

شاخص نش ساتکلیف^۱ نشان‌دهنده کارایی مدل است. هر چه این شاخص و ضریب تبیین (R^2) به عدد یک نزدیک شوند، نشان‌دهنده کارایی مناسب مدل و تطابق داده‌های

$$x_n = \left(0.8 * \left(\frac{x - x_{min}}{x_{max} - x_{min}} \right) \right) + 0.1 \quad (24)$$

در رابطه بالا مقادیر x ، x_n ، x_{min} ، x_{max} به ترتیب داده‌های نرمال شده، داده‌های مشاهداتی، کمینه و بیشینه داده‌ها است.

نتایج و بحث

آنالیز همبستگی

آنالیز همبستگی برای تصمیم‌گیری درباره تأخیر زمانی داده‌های ورودی انجام شده است. در شکل‌های (۴) و (۵) در همبستگی متقابل برای داده‌ها از تأخیرهای زمانی (۰ تا ۱۰) و محدوده اطمینان ۹۵ درصد استفاده گردیده است. با توجه به این شکل‌ها در شکل‌های A تا C واضح است که در نقطه Ru19.1 سرعت خاکریزی و در نقطه Ru19.2 سرعت آبیگری به علت همبستگی پایین با ضریب فشار آب حفره‌ای و قرار نگرفتن در محدوده اطمینان در مدل‌سازی نادیده

³ Karunanithi

¹ Coefficient of Nash -Sutcliffe

² Can and Yerdelen

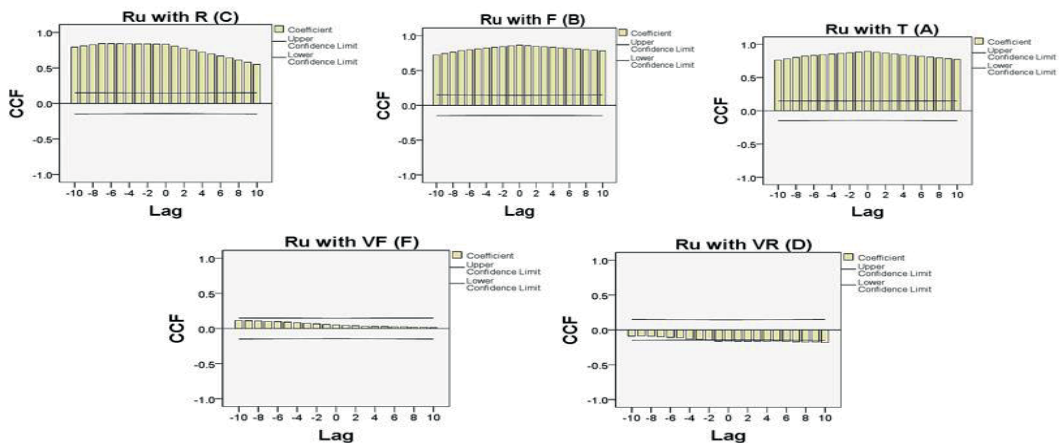
گرفته‌شده‌اند. این نتایج با نتایج حاصل از روش انتخاب ویژگی همخوانی دارد.

انتخاب ویژگی با استفاده از الگوریتم هیبریدی

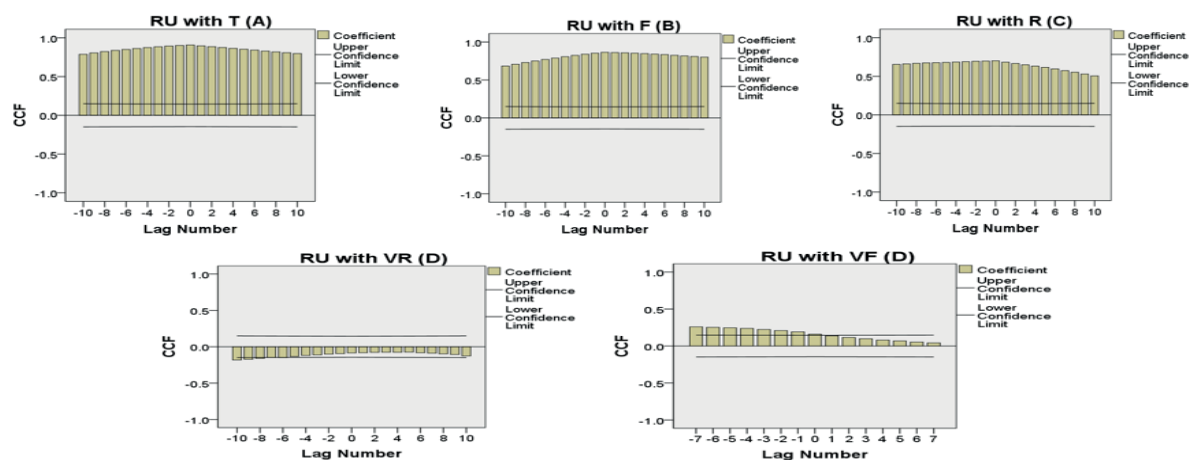
WCA-ANN

در فرایند انتخاب ویژگی، ویژگی‌هایی که در مدل‌سازی متغیر هدف مهم و تأثیرگذارند، استخراج می‌شوند (امیری میجان و همکاران، ۱۳۹۸). نتایج استفاده از الگوریتم هیبریدی WCA-ANN در شکل (۵) برای دو نقطه مورد مطالعه در مقطع ۱۹ نشان داده شده است. همان طور که گفته شد $Ru_{19.1}$ که از حاصل تقسیم مقادیر پیژومتر EP19.7 که در تراز ۱۷۰ متر و نزدیک مخزن قرار

دارد بر مقادیر سلول فشارسنجی TPC19.1 در همان تراز به دست آمده است. نتایج به دست آمده از الگوریتم هیبریدی WCA-ANN در شکل (۵) و در نقطه Ru19.1 نشان می‌دهد که ترکیب چهارتایی در این نقطه، کمترین خطا را در مدل‌سازی ضریب فشار آب حفره‌ای دارد. همچنین زیرمجموعه تک ورودی نیز تقریباً خطایی مشابه زیرمجموعه ۴ تایی دارد، ولی انتخاب زیرمجموعه ۲، ۳ و ۵ تایی باعث بهبود نتایج نشده است.




شکل (۴): آنالیز همبستگی داده‌های مورد استفاده در پیژومتر Ru19.1: شکل (A) همبستگی متقابل بین زمان ساخت و ضریب فشار آب حفره‌ای، شکل (B) همبستگی متقابل بین تراز خاکریزی و ضریب فشار آب حفره‌ای، شکل (C) همبستگی متقابل بین تراز آب مخزن و ضریب فشار آب حفره‌ای، شکل (D) همبستگی متقابل بین سرعت آب گیری و ضریب فشار آب حفره‌ای، شکل (E) همبستگی متقابل بین سرعت خاکریزی و ضریب فشار آب حفره‌ای.




شکل (۵): آنالیز همبستگی داده‌های مورد استفاده در پیژومتر Ru19.2: شکل (A) همبستگی متقابل بین زمان ساخت و ضریب فشار آب حفره‌ای، شکل (B) همبستگی متقابل بین تراز خاکریزی و ضریب فشار آب حفره‌ای، شکل (C) همبستگی متقابل بین تراز آب مخزن و ضریب فشار آب حفره‌ای، شکل (D) همبستگی متقابل بین سرعت آب گیری و ضریب فشار آب حفره‌ای، شکل (E) همبستگی متقابل بین سرعت خاکریزی و ضریب فشار آب حفره‌ای.

نمودار ویژگی-خطا در این نقطه متفاوت تر از نقطه $Ru_{19.1}$ است، که دلیل آن به خاطر متفاوت بودن محل نصب آن‌ها، دورتر بودن نقطه $Ru_{19.2}$ از مخزن سد و قرارگیری آن در مرکز محور سد است. مقادیر بهینه الگوریتم WCA در نقاط مورد مطالعه در جدول (۲) آورده شده است. همچنین شکل (۷) روند همگرایی الگوریتم WCA در نقاط $Ru_{19.1}$ و $Ru_{19.2}$ برای ترکیب ویژگی‌های برتر را نشان می‌دهد.



شکل (۶): مقادیر خطا ویژگی‌ها در روش انتخاب ویژگی



شکل (۷): روند همگرایی الگوریتم WCA در نقاط $RU_{19.1}$ و $RU_{19.2}$ برای ترکیب ویژگی‌های برتر

جدول ۲. مقادیر بهینه الگوریتم WCA

dmax	nvars	کران پایین و بالا	تعداد رودخانه‌ها و دریا Nsr	تعداد قطرات باران Npop	تعداد تکرار max_it
1e-16	۵	LB=-3; UB=3	۴	۵۰	۱۰۰۰

حفره‌ای خاک دارند. تأثیر ترکیب باهم این چهار ویژگی، نشان‌دهنده این واقعیت است که این ویژگی‌ها بر مقدار ضریب فشار آب حفره‌ای در این نقطه موثر می‌باشند. بر اساس نتایج حاصل از آنالیز حساسیت در شکل (۸) و در نقطه $Ru_{19.2}$ که در قسمت میانی سد و محور سد قرار دارد، از بین ۵ ویژگی اندازه‌گیری شده، چهار ویژگی به ترتیب شامل زمان سخت، تراز خاک ریزی، تراز آبگیری و سرعت خاک ریزی بیش‌ترین تأثیر را در مدل‌سازی ضریب فشار آب حفره‌ای خاک دارند، بنابراین در مجموع ضریب



بررسی اهمیت متغیرها با استفاده از آنالیز حساسیت به منظور تعیین درجه اهمیت هر کدام از ویژگی‌های استخراج‌شده از فرایند انتخاب ویژگی، آنالیز حساسیت انجام شده است (امیری میجان و همکاران، ۱۳۹۸). بر اساس نتایج حاصل از آنالیز حساسیت در شکل (۸)، در نقطه $Ru_{19.1}$ که در تراز ۱۷۰ متر و نزدیک مخزن قرار دارد، از بین ۵ ویژگی اندازه‌گیری شده، چهار ویژگی به ترتیب شامل زمان ساخت سد، تراز خاک ریزی، تراز آب مخزن و سرعت آبگیری بیش‌ترین تأثیر را در مدل‌سازی ضریب فشار آب

باشد، آب با سرعت بیشتری وارد خاک می‌شود که این امر باعث افزایش بیشتر ضریب فشار آب حفره‌ای خواهد شد. تأثیر ویژگی‌های تراز آب مخزن (آبگیری) و سرعت آبگیری در نقاط نزدیک مخزن بیشتر از نقاط دیگر سد است و هرچه از مخزن دورتر شویم تأثیر این ویژگی بر مدل‌سازی ضریب فشار آب حفره‌ای کاهش می‌یابد. ویژگی سرعت خاک ریزی در پیرومتر نصب‌شده در محور میانی و مرکزی سد تأثیر بیشتری بر مدل‌سازی ضریب فشار آب حفره‌ای دارد.

مدل‌سازی ضریب فشار آب حفره‌ای با استفاده از ویژگی‌های انتخاب‌شده با روش ANN

به منظور مدل‌سازی متغیر هدف (ضریب فشار آب حفره‌ای) با استفاده از شبکه عصبی مصنوعی پرسپترون چند لایه (MLP)، ویژگی‌های حاصل از مدل هیبریدی، به عنوان متغیرهای ورودی انتخاب شده است (جدول ۲). تابع انتقال شامل توابع *purelin* و *tansig* به ترتیب برای لایه پنهان و خروجی بوده است و تابع آموزش *Levenberg-Marquardt* انتخاب شده است. در توسعه مدل ANN از ۷۰٪ داده‌ها به طور تصادفی برای آموزش، ۱۰٪ برای اعتبار سنجی و ۲۵٪ برای مرحله آزمون استفاده شده است.

فشار آب حفره‌ای بیش‌ترین حساسیت را در نقطه واقع در قسمت میانی و نزدیک به محور سد به تراز خاک ریزی و در نقطه واقع در قسمت‌های دورتر از محور میانی به زمان ساخت دارد. احتمالاً دلیل آن این است که پیرومترها و سلول‌های نزدیک به محور سد تغییرات مشابهی با روند بارگذاری بدنه سد از خود نشان می‌دهند؛ درحالی‌که اگر از محور سد دور شویم به دلیل انتقال تنش‌ها به صورت مایل (چرخش المان تنش) تأثیر کمتری از روند خاک ریزی می‌گیرند، که باعث می‌شود ضریب فشار آب حفره‌ای و تنش کل کمتری نسبت به پیرومتر و سلول‌های نصب‌شده در محور سد تولید کند. ویژگی زمان هم احتمالاً به این دلیل تأثیر دارد که در سدهای خاکی با افزایش خاک ریزی و ساخت لایه‌ای بدنه سد، زمانی را برای تحکیم خاک بدنه سد مدنظر قرار می‌دهند، اگر تراز آبگیری و خاک ریزی افزایش پیدا کند و زمانی را برای تحکیم خاک مدنظر قرار ندهیم، نتایج متفاوت به دست خواهد آمد. دلیل تأثیر ویژگی تراز آبگیری نیز این است که با افزایش تراز آب مخزن، میزان آب در خاک افزایش بیشتری پیدا می‌کند که این امر باعث افزایش ضریب فشار آب حفره‌ای در بدنه سد می‌شود. ویژگی سرعت آبگیری هم به این دلیل بر مدل‌سازی ضریب فشار آب حفره‌ای موثر است که هر چه قدر سرعت آبگیری بیشتر



شکل (۸): آنالیز حساسیت ویژگی‌های ورودی با استفاده از روش انتخاب ویژگی

برآورد مدل، استفاده شد. همان‌طور که از جدول (۳) استنباط می‌شود، در داده‌های آموزش و آزمون $Ru_{19.1}$ و $Ru_{19.2}$ بیش برآورد جزئی رخ داده است.

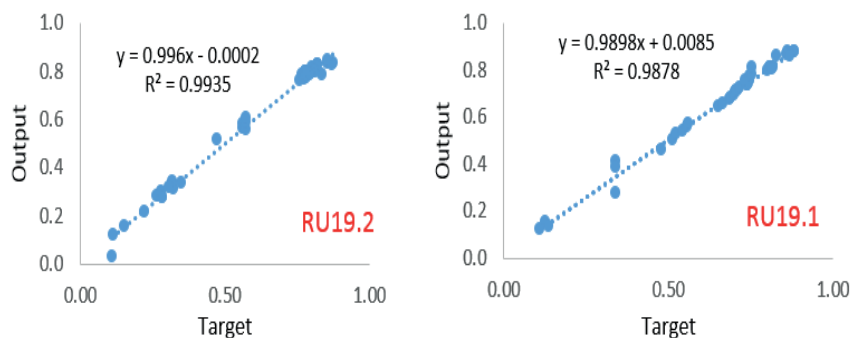
همان‌طور که در جدول ۳ مشاهده می‌شود با توجه به مؤلفه‌های آماری مربوط، مدل ANN در دوره آموزش و آزمون به خوبی توانسته عمل مدل‌سازی متغیر هدف (ضریب فشار آب حفره‌ای) را انجام دهد. از شاخص میانگین هندسی نسبت خطا (GMER) برای مشخص نمودن بیش برآورد و یا کم

جدول (۳): مؤلفه‌های آماری مربوط به نقاط $Ru_{19.1}$ و $Ru_{19.2}$ در دوره آموزش و آزمون مدل ANN

ساختار	آزمون					آموزش					ورودی‌ها	نقاط
	GMRE	NS	MAE	RMSE	R^2	GMRE	NS	MAE	RMSE	R^2		
MLP 4-9-1	۱/۰۱۳۰	۰/۷۵۰۰	۰/۰۱۷۲	۰/۰۲۴۶	۰/۹۸۷۸	۱/۰۰۵۷	۰/۸۹۹۴	۰/۰۱۳۳	۰/۰۱۹۸	۰/۹۹۳۳	F, T, R, VR	$Ru_{19.1}$
MLP 4-9-1	۱/۰۱۱۷	۰/۸۱۶۴	۰/۰۱۰۹	۰/۰۱۹۳	۰/۹۹۳۵	۱/۰۰۰۳	۰/۹۰۱۲	۰/۰۰۶۶	۰/۰۰۹۴	۰/۹۹۸۴	F, T, R, VF	$Ru_{19.2}$

سدهای خاکی در زمان ساخت، با دقت قابل قبولی استفاده کرد. همچنین با توجه به شاخص‌های آماری

همان‌گونه که در شکل (۹) دیده می‌شود، با توجه به ضرایب رگرسیونی پیش‌بینی مقادیر ضریب فشار آب حفره‌ای در بدنه سدهای خاکی در زمان ساخت با مدل ANN بسیار نزدیک به مقادیر واقعی است لذا می‌توان از این مدل در پیش‌بینی ضریب فشار آب حفره‌ای در بدنه



شکل (۹): مقادیر رگرسیون در دوره آزمون $Ru_{19.1}$ و $Ru_{19.2}$

آب مخزن را به عنوان ورودی مدل ANN استفاده نمودند. در این تحقیق ۴ ورودی جدید علاوه بر آن مورد بررسی قرار گرفت. همچنین اهمیت هر یک از این ویژگی‌ها در نقاط مختلف سد بررسی شد.

نتیجه‌گیری

هدف از این پژوهش، تعیین مؤثرترین ویژگی‌ها در مدل‌سازی ضریب فشار آب حفره‌ای در بدنه سدهای خاکی در طول ساخت به صورت مطالعه موردی (سدکبودال) با استفاده از الگوریتم هیبرید چرخه آب-شبکه عصبی مصنوعی است. پنج ویژگی شامل تراز خاک ریزی، زمان ساخت سد، تراز مخزن (آبگیری)، سرعت آبگیری و سرعت خاک ریزی به عنوان ورودی مدل هیبریدی انتخاب شدند. به طور خلاصه می‌توان نتایج حاصل از این مطالعه

مدل ANN در $Ru_{19.2}$ با R^2 , RMSE, MAE و NS به ترتیب برابر با ۰/۹۹۳۵, ۰/۰۱۹۳, ۰/۰۱۰۹ و ۰/۸۱۶۴ دارای عملکرد بهتری نسبت به $Ru_{19.1}$ با R^2 , RMSE, MAE و NS به ترتیب برابر با ۰/۹۸۷۸, ۰/۰۲۴۶, ۰/۰۱۷۲ و ۰/۷۵۰۰ دارد.

بسیاری از مطالعات از روش عددی برای مدل‌سازی رفتار سدهای خاکی در حین ساخت استفاده نموده‌اند به عنوان مثال: (سلماسی و حکیمی خانسر، ۱۳۹۹؛ رشیدی و حایری، ۲۰۱۷؛ مویوکس^۱ و همکاران، ۲۰۱۸؛ نوتسون^۲ و همکاران، ۲۰۱۸؛ سلماسی و همکاران، ۲۰۱۹؛ اسدی و صبا، ۲۰۲۰؛ کماسی و بیرانوند، ۲۰۲۰)، اما روش‌های هوش مصنوعی از نظر تعمیم‌پذیری دارای محدودیت‌های ذاتی هستند، بنابراین اعتبار نتایج آن‌ها قابل‌اعتماد نیست. بر اساس مطالعات تایفو^۳ همکاران (۲۰۰۵) توانایی ANN در تخمین میزان فشار آب حفره‌ای اثبات شده است. آن‌ها سطح

³ Tayfu

¹ Mouyeaux

² Knutsson

است. بنابراین، توصیه می شود قبل از اجرا در سایر سدها، این مدل ارزیابی شود. یکی از موضوعات قابل توجه در ساخت سدهای خاکی تغییر در پارامترهای ژئوتکنیکی خاک است. مدل ANN در این مطالعه ممکن است در شرایط تغییر ژئوتکنیک دقیق نباشد، بنابراین ارزیابی عملکرد مدل ANN در شرایط تغییر ژئوتکنیک نتایج را بهبود می بخشد.

مراجع

- ۱- ابراهیم زاده، ع.، زرغامی، م. و نورانی، و. (۱۳۸۹). ارزیابی ریسک روگذری سدهای خاکی با مدل پویایی سیستم‌ها تحت شبیه‌سازی مونت کارلو و روش آبرمکعب لاتین، مطالعه موردی: سد حاجیلرچای. تحقیقات منابع آب ایران، ۱۵(۱)، ۱۴-۳۱.
- ۲- آقاابراهیمی، م. ر. طاهریان؛ ح. ناظر کاخکی؛ س.ا. فرشاد؛ ف. گلدانی، س.ر. (۱۳۹۳). پیشبینی کوتاه مدت قیمت در بازار برق با در نظر گرفتن تاثیر تولید واحدهای بادی. هوش محاسباتی در مهندسی برق، ۵(۴)، ۱۰۵-۱۲۲.
- ۳- امیری میجان، ف. شیرانی، ح. اسفندیارپور، ع. بسالت پور، ع.ا. شکفته، ح. (۲۰۱۹). مدلسازی شاخص S و تعیین عوامل مؤثر بر آن با استفاده از الگوریتم هیبرید شبیه‌سازی تبرید- شبکه عصبی مصنوعی در خاکهای آهکی جنوبشرق ایران. نشریه علوم آب و خاک (علوم و فنون کشاورزی و منابع طبیعی)، ۲۳(۳)، ۳۸۱-۳۹۴.
- ۴- حکیمی خانسر، ح. گلمایی، س. ح. شیداییان، م. (۱۳۹۲). ارزیابی رفتار سد خاکی کبودوال (قره سو زربنگل) در طول ساخت به روش اجزای محدود با نرم افزار PLAXIS و مقایسه با مقادیر واقعی حاصل از داده های ابزار دقیق. دو فصلنامه تخصصی علوم و مهندسی آب، ۴(۹)، ۳۳-۴۹.
- ۵- سلماسی، ف. حکیمی خانسر، ح. (۱۳۹۹). شبیه سازی رفتار سد کبودوال در زمان ساخت با مدلسازی عددی سه بعدی. عمران امیر کبیر، (DOI): 10.22060/ceej.2020.18172.6790.
- ۶- سلماسی، ف. حکیمی خانسر، ح. نورانی، ب. (۱۳۹۷). بررسی نشست بدنه سد خاکی در دوران ساخت و مقایسه آن با نتایج تحلیلی با استفاده از نرم افزار PLAXIS (مطالعه موردی سد کبودوال). علوم آب و خاک ۲۲(۴)، ۱۵۵-۱۷۱.
- ۷- شرقی، ا. نورانی، و. بهفر، ن. (۱۳۹۷). ارزیابی و کاربرد مدل های ترکیبی هوش مصنوعی برای تخمین هد پیژومتریک سد خاکی. تحقیقات منابع آب ایران، ۱۴(۴)، ۱۰۶-۱۶۹.
- ۸- کامسی، م. بیرانوند، ب. (۱۳۹۹). بررسی جابجاییهای قائم و افقی سد خاکی ایوشان با استفاده از ابزار دقیق و تحلیل عددی. مجله تحقیقات آب و خاک ایران، ۵۱(۱)، ۲۴۵-۲۵۶.
- ۹- گزارش فنی. (۱۳۹۲). رفتار سنجی سد کبودوال. گلستان: شرکت سهامی آب منطقه ای گلستان.

جهت پیشبینی ضریب RU سد کبودوال را این گونه نتیجه‌گیری کرد که:

۱. از بین بردن دو محدودیت فقدان یک مدل جامع برای همه سدها و کمبود اطلاعات ژئوتکنیک در ایران باعث شد تا از مدل‌های هوش مصنوعی در این تحقیق استفاده شود.
۲. نتایج استفاده از الگوریتم هیبریدی WCA-ANN برای نقاط $Ru_{19.1}$ و $Ru_{19.2}$ در مقطع ۱۹ سد کبودوال نشان داد که زیرمجموعه چهارتایی در این نقاط کمترین خطا را در مدل‌سازی ویژگی هدف (ضریب فشار آب حفره‌ای) دارد.
۳. روند نمودار ویژگی-خطا در دو نقطه $Ru_{19.1}$ و $Ru_{19.2}$ باهم تفاوت داشته است، که دلیل آن به خاطر متفاوت بودن محل قرارگیری و نصب آنها است.
۴. خطای مدل‌سازی در نقطه‌ای که در مرکز مقطع سد قرار دارد ($Ru_{19.2}$) کمتر از نقطه‌ای است که از مرکز مقطع دورتر و نزدیک مخزن ($Ru_{19.1}$) است.
۵. علاوه بر تراز نصب، محل قرارگیری و دوری و نزدیکی بودن از مخزن سد، بر روند انتخاب ویژگی تأثیرگذار است.
۶. ضریب فشار آب حفره‌ای بیشترین حساسیت را در نقاط واقع در قسمت میانی و نزدیک به محور سد به تراز خاک ریزی و در نقطه واقع در قسمت‌های دورتر از محور میانی به زمان ساخت دارد.
۷. تأثیر ویژگی‌های تراز آب مخزن (آبگیری) و سرعت آبگیری در نقاط نزدیک مخزن بیشتر از نقاط دیگر است. ویژگی سرعت خاک ریزی در نقاط محور میانی تأثیر بیشتری بر مدل‌سازی ضریب فشار آب حفره‌ای نسبت به نقاط دورتر از این ناحیه و نزدیک مخزن دارد.
۸. مدل‌سازی ضریب فشار آب حفره‌ای در بدنه سدهای خاکی در زمان ساخت با مدل ANN با توجه شاخص‌های آماری، بسیار نزدیک به مقادیر واقعیت است. نتایج به دست آمده منطقی و قابل تفسیر است.
۹. به دلیل پیچیدگی مدل‌های جعبه سیاه (به عنوان مثال ANN)، گسترش این مدل‌ها در سایر سدها دشوار

- ۱۰- نورانی، (۱۳۹۴). مبانی هیدروآفورماتیک. تبریز: دانشگاه تبریز.
- ۱۱- نوری، م. سلماسی، ف. (۲۰۱۷). برآورد مقادیر نشت از سدهای خاکی با استفاده از روش های هوش مصنوعی. علوم و مهندسی آبیاری، ۴۲(۱)، ۸۳-۹۷.
- ۱۲- وفائیان، م. (۱۳۹۱). سدهای خاکی و سنگریز. اصفهان: جهاد دانشگاهی (دانشگاه صنعتی اصفهان).
- 13- Asadi, A., Saba, H. (2020). Evaluation of the Effect of Modulus of Elasticity in Clay Core on the Arching in the Crest of Earth Dams. Computational Engineering and Physical Modeling, 12-20. Doi: 10.22115/cepm.2020.225075.1096
- 14- Can, I. Yerdelen, I.C. (2007). Stochastic modeling of Karasu River (Turkey) using the methods of Artificial Neural Networks. Hydrology Days, 138-144.
- 15- Chandrashekar, G. and Sahin, F. (2014). A survey on feature selection methods. Computers and Electrical, 40, 16-28.
- 16- Cucci, G. Lacolla, G. Pagliai, M. and Vignozzi, N. (2015). Effect of reclamation on the structure of silty-clay soils. International Agrophysics Journal, 29, 23-30.
- 17- Eskandar, H., Sadollah, A., Bahreininejad, A. (2012). Water cycle algorithm -A novel metaheuristic optimization method for solving constrained engineering optimization problems. Computers and Structures, 110(111), 151-166
- 18- Hill, M. C. (1998). Methods and Guidelines for Effective Model Calibration. U.S. Geological Survey Water
- 19- Karunanithi, N. Grenney, W.J. Whitley, D. Bovee, K. (1994). Neural networks for river flow prediction. Journal of Computing in Civil Engineering, 201-220.
- 20- Hornik, K. (1988). Multilayer feed-forward networks are universal approximators. Neural Networks, 2(5), 359-366
- 21- Kumar V and Minz S. (2014). Feature selection, a literature review. Smart Computing Review, 4(3), 211-229.
- 22- 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.
- 23- Knutsson, K., Viklander, P., and Knutsson, S. (2018). Benefits of Advanced Constitutive Modeling when Estimating Deformations in a Tailings Dam. Journal of Earth Sciences and Geotechnical Engineering, 8(1), 1-
- 24- Nourani, V. Kisi, o and Komasi, M. (2011). Two hybrid artificial intelligence approaches for modeling rainfall-runoff process. Journal of Hydrology, 402, 41-59.
- 25- Nourani, V. and 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(1), pp.183-195.
- 26- Nourani, V. Sharghi, E. Aminfar, M.H. (2012). Integrated ANN model for earthfill dams seepage analysis: Sattarkhan dam in Iran. Artificial Intelligence Research, 1(2), 22-37. Novakovic, A. Rankovic, V.
- 27- 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.
- 28- Rankovic, V. Grujovic, N. Divac, D. Milivojevic, N. (2014). Development of support vector regression. Structural Safety, 48, 33-39
- 29- 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.
- 30- 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). JWSS, 22(4), 155-171.
- 31- Moghaddamnia, A. Ghafari Gousheh, M. Piri, J. Amin, S. and Han, D. (2009). Evaporation estimation using artificial neural networks and adaptive neuro-fuzzy inference system techniques. Advances in Water Resources, 32, 88-97.
- 32- Mouyeaux, A., Carvajal, C., Bressolette, P., Peyras, L., Breul, P., Bacconnet, C. (2018). Probabilistic stability analysis of an earth dam by Stochastic Finite Element Method based on field data. Computers and Geotechnics, 101, 34-47.
- 33- Tayfu, G., Swiate, D., Wita, A. and Singh, V., (2005). Case Study: Finite Element Method and Artificial Neural Network Models for Flow through Jeziorsko Earth fill Dam in Poland. Journal of Hydraulic Engineering, 131(3), 431-440.
- 34- Wu, K. Soci, C. Shum, P.P. Zheludev, I. (2014). Computing matrix inversion with optical networks. Optics Express, 22(1), 295-304.

Pore water pressure coefficient forecasting in the body of earth dams at the time of construction and determination of its effective features using WCA-ANN hybrid algorithm

Hossein Hakimi Khansar^{۱*}
Javad Parsa^۲
Ali Hosseinzadeh Dalir^۳
Jalal Shiri^۴

ABSTRACT

In this study, the ability of WCA-ANN hybrid algorithm to model the pore water pressure coefficient in the body of Kabudwal dam at the time of construction was investigated and the effective features were identified. Therefore, five features including fill level, time, reservoir level, dewatering rate and fill speed during the 4-year statistical period were selected as the input of the model. By running the hybrid algorithm and feature selection method, the two features of fill level and time at points $Ru_{19,1}$ and $Ru_{19,2}$ have the greatest impact on modeling the pore water pressure coefficient. In addition to the above two features, in the points of the middle axis, the features of fill speed and reservoir level with error value (MSE) equal to 0.00006 and in points close to the dam reservoir, dewatering level and dewatering rate with error value equal to 0.00004 are effective in modeling the pore water pressure coefficient. The results showed that at points close to the dam axis, the fill level and at points farther from the middle axis construction time (with high sensitivity coefficient) was recognized as the most important features in modeling the pore water pressure coefficient with artificial intelligence models.

KEYWORDS:

Earthen dam, water cycle algorithm, artificial neural network, feature selection, pore water pressure coefficient.

¹ Ph.D Candidate, University of Tabriz / Department of Water Engineerin

² Associate Professor, University of Tabriz /Department of Water Engineering

³ Professore, Department of Water Engineering, University of Tabriz, Iran

⁴ Assistant Professor, University of Tabriz /Department of Water Engineering