

بهینه‌سازی مدل انفیس توسط الگوریتم ژنتیک برای تخمین عمق آبشستگی در اطراف تکیه‌گاه پل‌ها

احسان یارمحمدی، سعید شعبانلو* و احمد رجیبی^۱

(تاریخ دریافت: ۱۳۹۸/۶/۳۱؛ تاریخ پذیرش: ۱۳۹۹/۵/۱۵)

چکیده

بهینه‌سازی مدل‌های هوش مصنوعی از اهمیت بسزایی برخوردار است زیرا باعث بهبود عملکرد این مدل‌ها و افزایش انعطاف آنها می‌شود. در این مطالعه، عمق آبشستگی در مجاورت تکیه پل‌ها به شکل‌های مختلف توسط مدل ANFIS و ANFIS-Genetic Algorithm (GA) تخمین زده شد. به عبارت دیگر، برای بهینه‌سازی توابع عضویت مدل ANFIS از GA استفاده شد که عملکرد مدل ANFIS به شکل قابل توجهی بهبود یافت. در ابتدا، پارامترهای تأثیرگذار بر روی عمق آبشستگی در اطراف تکیه‌گاه پل‌ها تعریف شدند. سپس با استفاده از این پارامترهای ورودی، یازده مدل مختلف برای هر یک از مدل‌های ANFIS و ANFIS-GA تولید شدند. سپس با تجزیه و تحلیل نتایج این مدل‌ها، مدل برتر برای هر یک از روش‌های ANFIS و ANFIS-GA زنتیک معرفی شدند. به عنوان مثال، مقدار ضریب همبستگی و شاخص پراکندگی برای مدل ANFIS به ترتیب برابر با ۰/۹۷۹ و ۰/۰۷۰ و برای مدل ANFIS-GA نیز به ترتیب مساوی با ۰/۹۸۶ و ۰/۰۵۶ محاسبه شدند. علاوه بر این، نسبت اختلاف متوسط برای مدل‌های برتر ANFIS و ANFIS-GA به ترتیب مساوی با ۰/۹۸۴ و ۰/۹۸۸ بودند. بنابراین نشان داده شد که مدل‌های ترکیبی ANFIS-GA دقت بیشتری در مقایسه با مدل‌های ANFIS داشتند. همچنین، تحلیل حساسیت نشان داد که عدد فرود (Fr) و نسبت عمق جریان به شعاع حفره آبشستگی (h/L) به عنوان مؤثرترین پارامترهای ورودی برای تخمین عمق آبشستگی در مجاورت تکیه‌گاه پل‌ها شناسایی شدند.

واژه‌های کلیدی: انفیس، الگوریتم ژنتیک، بهینه‌سازی، آبشستگی، تکیه‌گاه پل، تحلیل حساسیت

۱. گروه مهندسی آب، واحد کرمانشاه، دانشگاه آزاد اسلامی، کرمانشاه، ایران

*: مسئول مکاتبات: پست الکترونیکی: saeid.shabanlou@gmail.com

مقدمه

تکیه‌گاه‌ها برای نگه‌داشتن پل‌ها در داخل رودخانه‌ها و نواحی ساحلی ساخته می‌شوند. به دلیل وجود جریان‌های شدید در این محیط‌ها احتمال وقوع آبشستگی در مجاورت تکیه‌گاه‌ها وجود دارد. بنابراین پیش‌بینی الگوی آبشستگی در اطراف این نوع از سازه‌ها از اهمیت فراوانی برخوردار است و مطالعات آزمایشگاهی، عددی و تحلیلی بسیاری بر رفتار آبشستگی آنها انجام گرفته است. اثرات اندازه رسوبات و انتقال جانبی اندازه حرکت روی الگوی آبشستگی در مجاورت تکیه‌گاه‌های پل داخل کانال‌های مرکب توسط کوچک‌زاده و تونسن (۱۵) مورد بررسی قرار گرفت. همچنین، کوئیاری و رانجارجو (۱۴) در یک مطالعه تحلیلی عمق حفره آبشستگی در مجاورت آبشکن‌ها و تکیه‌گاه‌های پل را برای کف کانال با شرایط بستر متحرک و شرایط هیدرولیکی آب زلال را مورد مطالعه قرار دادند. الویتو و هاگر (۱۹) با انجام یک مطالعه آزمایشگاهی الگوی آبشستگی در مجاورت پایه‌های پل و تکیه‌گاه‌ها را برای شرایط هیدرولیکی آب زلال را اندازه‌گیری کردند. آنها با آنالیز نتایج آزمایشگاهی خود یک رابطه برای تخمین عمق آبشستگی برحسب مشخصات هیدرولیکی جریان و پارامترهای هندسی ارائه کردند. تغییرات زمانی الگوی آبشستگی در اطراف تکیه‌گاه‌های پل برای شرایط هیدرولیکی آب زلال توسط کلمن و همکاران (۷) به صورت آزمایشگاهی مورد بررسی قرار گرفت. دی و باربویا (۸) الگوی آبشستگی در اطراف تکیه‌گاه‌ها به شکل مختلف و شرایط هیدرولیکی آب زلال برای رسوبات یکنواخت و غیریکنواخت را مورد مطالعه آزمایشگاهی قرار دادند. یانماز و جلیبی (۲۲) یک مدل برای پیش‌بینی آبشستگی اطراف دو نوع تکیه‌گاه به شکل‌های باله‌دار و عمودی در شرایط هیدرولیکی آب زلال توسعه دادند. برای پیش‌بینی تغییرات زمانی عمق حفره آبشستگی اطراف تکیه‌گاه‌ها به شکل مختلف در شرایط آب زلال و رسوبات یکنواخت و غیریکنواخت یک روش تحلیلی توسط دی و باربویا (۹) توسعه داده شد. اولویتو و هاگر (۲۰) در یک مطالعه آزمایشگاهی تغییرات زمانی

آبشستگی در اطراف تکیه‌گاه‌ها و آبشکن‌ها را برای شرایط هیدرولیکی و هندسی مختلف را اندازه‌گیری کردند. در ادامه برکدل و همکاران (۵) مکانیزم آبشستگی در اطراف تکیه‌گاه‌ها پل‌ها را مورد بررسی آزمایشگاهی قرار دادند. بالیو و همکاران (۴) با در نظر گرفتن اثرات تنگ‌شدگی مقطع جریان، الگوی آبشستگی در مجاورت تکیه‌گاه مستطیلی را مورد مطالعه آزمایشگاهی قرار دادند. آنها نشان دادند که اثرات نسبت انسداد بر توسعه زمانی عمق حفره آبشستگی قابل ملاحظه نیست.

در سال‌های اخیر استفاده از محاسبات نرم برای پیش‌بینی مسائل پیچیده و غیرخطی به شکل قابل ملاحظه‌ای گسترش یافته است. از طرف دیگر مطالعات مختلفی نیز برای پیش‌بینی الگوی آبشستگی در اطراف پل‌ها و تکیه‌گاه‌ها انجام گرفته است. ترنت و همکاران (۲۱) الگوی آبشستگی در اطراف پایه‌های پل را در شرایط هیدرولیکی آب زلال و بستر متحرک با استفاده از شبکه عصبی مصنوعی تجزیه و تحلیل کردند. لیریانو و دی (۱۶) توسط مدل‌های شبکه عصبی مصنوعی عمق آبشستگی در خروجی کالورت‌ها را مدل‌سازی کردند. آنها برای تخمین آبشستگی دو مدل مختلف ارائه کردند که با تجزیه و تحلیل نتایج خود نشان دادند که مدل عددی از دقت مناسبی برخوردار است. برای پیش‌بینی عمق آبشستگی در مجاورت گروه پایه‌های پل با استفاده از انفیس، باطنی و جنگ (۶) یک مدل عددی توسعه دادند. آنها نشان دادند که ارتفاع موج و عدد کارپنتر مؤثرترین پارامترها بر عمق آبشستگی هستند. آبشستگی پایه‌های پل دایروی شکل با استفاده از الگوریتم‌های مختلف شبکه عصبی توسط فیرات و گانگور (۱۱) مدل‌سازی شد. برای تکیه‌گاه‌ها به شکل مختلف، موزامیل (۱۷) با استفاده از روش‌های انفیس و شبکه عصبی عمق حفره آبشستگی را شبیه‌سازی کرد. او با تجزیه و تحلیل نتایج مطالعه خود نشان داد که مدل انفیس از دقت بیشتری برخوردار است. عضمت ا. و همکاران (۱) با معرفی چهار مدل مختلف و انجام آنالیز حساسیت نشان داد که پارامتر بدون بعد ضریب شکل و نسبت طول تکیه‌گاه به اندازه متوسط رسوبات مؤثرترین

باشند اما آنها دارای معایبی از قبیل به دام افتادگی در بهینه‌سازی موضعی و افزایش زمان محاسبات هستند. بنابراین استفاده از سایر الگوریتم‌های بهینه‌سازی از قبیل الگوریتم ژنتیک برای غلبه بر این چالش‌ها کاملاً ضروری است. بنابراین، در این مطالعه، عمق حفرة آبستگی در نزدیکی تکیه‌گاه‌های پل‌ها با شکل مختلف با استفاده از مدل‌های ANFIS و روش ترکیبی ANFIS-Genetic Algorithm برای اولین بار مدل‌سازی می‌شود. به بیان دیگر، در این مطالعه، مدل ANFIS توسط الگوریتم ژنتیک بهینه‌سازی خواهد شد. سپس با ترکیب پارامترهای ورودی ۱۱ مدل مختلف برای هر یک مدل‌های ANFIS و ANFIS-GA معرفی می‌شود. در ادامه با تجزیه و تحلیل نتایج مدل‌های مذکور، مدل‌های برتر معرفی می‌شود. همچنین، مؤثرترین پارامتر ورودی برای تخمین آبستگی شناسایی می‌شود.

مواد و روش‌ها

سیستم استنتاج فازی عصبی تطبیقی (ANFIS)

سیستم‌های استنتاج فازی ((Fuzzy Inference System (FIS)، با بهره بردن از قوانین ساده فازی به صورت اگر- آنگاه، می‌توانند بدون احتیاج به تحلیل دقیق پارامترهای ورودی، معلومات و سیستم تصمیم‌گیری انسان در مورد یک مسئله خاص را به صورت کیفی مدل‌سازی کنند. مشکل اساسی که در استفاده از سیستم‌های استنتاج فازی وجود دارد، نحوه تعیین قوانین فازی و همچنین توابع عضویت است. برای رفع این مشکل، استفاده از شبکه‌های عصبی فازی در ترکیب با سیستم استنتاج فازی، برای اولین بار توسط جانگ مطرح شد و روش سیستم استنتاج فازی عصبی تطبیقی Adaptive Neuro Fuzzy Inference Systems (ANFIS) معرفی شد. بخش فازی، رابطه‌ای بین متغیرهای ورودی و خروجی برقرار کرده و پارامترهای مربوط به توابع عضویت بخش فازی، به وسیله شبکه عصبی تعیین می‌شود، بنابراین، خصوصیات هر دو مدل فازی و عصبی در ANFIS نهفته است. سیستم‌های استنتاج فازی دارای

پارامترها هستند. وی عمق آبستگی در اطراف تکیه‌گاه‌ها با شکل مختلف را با استفاده از مدل‌های برنامه‌نویسی بیان ژن و شبکه عصبی مصنوعی مدل‌سازی کرد که بررسی نتایج شبیه‌سازی نشان‌دهنده برتری مدل برنامه‌نویسی بیان ژن است. همچنین نجف‌زاده و همکاران (۱۸) با استفاده از مدل‌های دسته‌بندی گروهی داده‌ها و ماشین بردار پشتیبان عمق آبستگی در نزدیکی تکیه‌گاه‌ها را برای شرایط هیدرولیکی آب زلال و شرایط بستر متحرک تخمین زدند. تجزیه و تحلیل نتایج مطالعه آنها نشان‌دهنده دقت بیشتر مدل دسته‌بندی گروهی داده‌ها است. عظیمی و همکاران (۲) با ترکیب دو الگوریتم تکامل تفاضلی و تجزیه مقادیر منفرد با شبکه انفیس یک مدل ترکیبی برای تخمین عمق آبستگی در مجاورت گروه پایه پل‌ها ارائه کردند. فوجیل و همکاران (۱۲) شبکه عصبی مصنوعی را با استفاده از الگوریتم ژنتیک بهینه‌سازی کردند. آنها این مدل ترکیبی را برای پیش‌بینی عمق آبستگی در مجاورت تکیه‌گاه پل‌ها استفاده کردند. علاوه بر این، عظیمی و همکاران (۳) مدل انفیس را با استفاده از الگوریتم ژنتیک و تجزیه مقادیر منفرد بهینه‌سازی کردند. آنها این روش ترکیبی را برای شبیه‌سازی عمق آبستگی در اطراف تکیه‌گاه پایه پل‌ها توسعه دادند.

از یک طرف، تخمین آبستگی در مجاورت تکیه‌گاه پل‌ها به منظور طراحی صحیح برای مقابله با آبستگی ناشی از جریان و سیلاب از اهمیت بسزایی برخوردار است. از طرف دیگر، مدل‌های هوش مصنوعی کاربرد گسترده‌ای در تخمین و الگوشناسی آبستگی در مجاورت سازه‌های هیدرولیکی دارند. این مدل‌ها نقش بسزایی در کاهش هزینه‌های آزمایشگاهی دارند و در مقابل از دقت و انعطاف خوبی برخوردار هستند. لازم به ذکر است که الگوریتم‌های بهینه‌سازی نقش قابل ملاحظه‌ای در بهبود عملکرد مدل‌های هوش مصنوعی دارد. در بیشتر موارد بهینه‌سازی الگوریتم‌های مختلف هوش مصنوعی یکی از موضوعات مهم در حوزه محاسبات نرم محسوب می‌شود. اگرچه الگوریتم‌های بهینه‌سازی موجود از قبیل حداقل مربعات و افت گرادینان برای آموزش ANFIS می‌توانند مفید

در اینجا x و y ورودی های نمود i ام هستند، A_i و B_i مجموعه فازی مرتبط با این گره است.

لایه دوم (لایه قوانین): همه گره ها در این لایه، ثابت هستند. این لایه، قدرت هر قاعده را با استفاده از ضرب جبری، مطابق رابطه زیر ارائه می کند:

$$O_i^2 = w_i = \mu_{A_i}(x) \mu_{B_i}(y) \quad (5)$$

در لایه دوم، هر گره، از حاصل ضرب مقادیر ورودی در لایه قبلی، به دست می آید. مقدار به دست آمده، نشان دهنده قدرت اجرایی i امین قاعده، جایی که متغیر x_j ارزش زبان شناختی A_i را دارد، است.

لایه سوم (لایه نرمال سازی): در این لایه قدرت قاعده (قانون) همانند رابطه زیر، نرمال سازی می شود:

$$O_i^3 = \bar{w}_i = \frac{w_i}{w_1 + w_2} \quad (6)$$

در رابطه فوق، w_i قدرت اجرایی i امین قاعده است. تعداد گره های این لایه مانند لایه قبلی است. لایه سوم قدرت اجرایی قاعده را برای مجموع قواعد قدرت اجرایی، محاسبه می کند.

لایه چهارم (لایه انطباقی): هر گره در این لایه، یک تابع خطی است و ضرایب این تابع از طریق ترکیبی از تقریب حداقل مربعات و پس انتشار تعدیل می شود.

$$O_i^4 = \bar{w}_i z_i = \bar{w}_i (p_i x + q_i y + r_i) \quad (7)$$

لایه پنجم (لایه خروجی): نتایج این لایه، به صورت مجموعه ای از خروجی گره های لایه قبلی به دست آمده می آید:

$$O_i^5 = \sum_i \bar{w}_i z_i = \frac{\sum_i w_i z_i}{\sum_i w_i} \quad (8)$$

در رابطه فوق، $\bar{w}_i z_i$ ، خروجی گره i ام در لایه قبلی است، خروجی کلی، خطی است. اگرچه پارامترها، از لحاظ منطقی، غیرخطی هستند. فرایند آموزش ANFIS، برای تنظیم تمام پارامترهای قابل تنظیم (پارامترهای تابع عضویت) به دنبال به دست آوردن مقادیر خروجی است که بیشترین تطابق را با داده های آموزشی داشته باشد. پس از آموزش ANFIS، با

کاربردهای گسترده ای هستند؛ با توجه به نوع عملیات استنباطی بر قانون If-Then، به دو دسته مدل های فازی ممدانی (Mamdani)، مدل های فازی TSK (تاکاگی - سوگنو و مدل های فازی تسوکاموتو) تقسیم بندی می شود. روش TSK با استفاده از توابع خطی یا ثابت ساده عمل می کند، درحالی که روش ممدانی از توابع عضویت فازی استفاده می کند. با توجه به دقت بالا و مدل به نسبت کوچک TSK در مطالعه حاضر از استنتاج فازی تاکاگی - سوگنو استفاده می شود.

مدل فازی سوگنو، برای توسعه یک سیستم قانون مند، در راستای ایجاد قواعد فازی با توجه به مجموعه داده های ورودی - خروجی عمل می کند. قاعده کلی مدل فازی سوگنو در معادله زیر ارائه شده است:

$$\text{Rule 1: If } x \text{ is } A \text{ and } y \text{ is } B; \text{ Then } z = f(x, y) \quad (1)$$

به عنوان مثال، یک سیستم استنتاج فازی ساده با دو ورودی x و y و خروجی z در نظر گرفته می شود. فرض کنید که مبنای قواعد، شامل دو قانون فازی If-Then مطابق رابطه زیر است:

Rule 1: If x is A_1 and y is B_1 , Then

$$z_1 = p_1 x + q_2 y + r_1 \quad (2)$$

Rule 2: If x is A_2 and y is B_2 , Then

$$z_2 = p_2 x + q_2 y + r_2 \quad (3)$$

در هر دو معادله بالا، If بخش مقدم فازی و Then بخش نتیجه است و تابعی از متغیر مقدم است. به طور کلی، سیستم ANFIS، پنج لایه دارد که در ادامه، عملکرد هر لایه به طور خلاصه بیان می شود.

لایه اول (لایه ورودی): در این لایه، درجه های عضویت مربوط به هر یک از مجموعه های فازی، به عنوان ورودی توابع عضویت شناخته می شود. تابع عضویت مورد استفاده در این مطالعه از نوع گوسی است که عملکرد خوبی در مطالعات مختلف مهندسی داشته است و به عنوان یکی از پرکاربردترین توابع عضویت، شناخته شده است. در این لایه، خروجی هر گره به صورت زیر تعیین می شود.

$$\begin{aligned} O_i^1 &= \mu_{A_i}(x) \\ O_i^1 &= \mu_{B_i}(x) \end{aligned} \quad (4)$$

بر اساس تورنمنت (Tournament Selection) و انتخاب بر اساس مکانیسم چرخ گردان (Roulette Wheel) تقسیم می‌شود.

روش ترکیبی ANFIS-GA

در این مطالعه، برای تعیین مقدار توابع عضویت انفیس که منجر به آموزش بهینه این شبکه می‌شود، از الگوریتم ژنتیک استفاده می‌شود. مزیت این روش کاهش هزینه‌های محاسباتی برای یک توپولوژی مشخص است. در این قسمت الگوریتم ارائه شده در این مقاله برای ارائه روش ترکیبی نروفازی و الگوریتم ژنتیک که به صورت شکل ۱ است، به صورت مرحله به مرحله توضیح داده می‌شود:

در ابتدا با استفاده از یک ماتریس که داده‌های مربوط آبستگی در آن ارائه شده است، داده‌های شبکه تعیین می‌شود. داده‌ها به دو قسمت داده‌های آموزش و تست تقسیم می‌شوند. درصد قابل توجهی از داده‌های آموزش برای صحت‌سنجی مدل در حین آموزش مورد استفاده قرار می‌گیرد. با استفاده از داده‌های مرتب شده، آموزش انفیس شروع می‌شود. روند آموزش به سیستم این امکان را می‌دهد که پارامترهای تعریف شده به عنوان ورودی و یا خروجی مدل را تنظیم کند. روند آموزش زمانی متوقف می‌شود که معیارهای تعیین شده برای توقف برنامه، اقلان شوند. بعد از تعیین داده‌های آموزش، نوع توابع عضویت و سیستم استنتاج فازی با استفاده از تطبیق پارامترهای تابع عضویت بهینه می‌شوند که در این مطالعه از الگوریتم ژنتیک برای تعیین پارامترهای وابسته به توابع عضویت در سیستم استنتاج فازی استفاده می‌شود.

در ادامه یک بردار که دارای N بعد مختلف بوده (N تعداد توابع عضویت است) تعریف می‌شود. این بردار شامل پارامترهای تابع عضویت است که با استفاده از الگوریتم ژنتیک مقدار آنها بهینه می‌شود. مقدار تابع شایستگی تعریف شده در این مطالعه به صورت تابع میانگین مربعات خطا (MSE) است. در ابتدا پارامترهای مربوط به الگوریتم ژنتیک به صورت تصادفی تعیین می‌شوند و در ادامه با استفاده از الگوریتم، مقادیر

معرفی داده‌های مختلف می‌توان خروجی را به شکل زیر، به دست آورد:

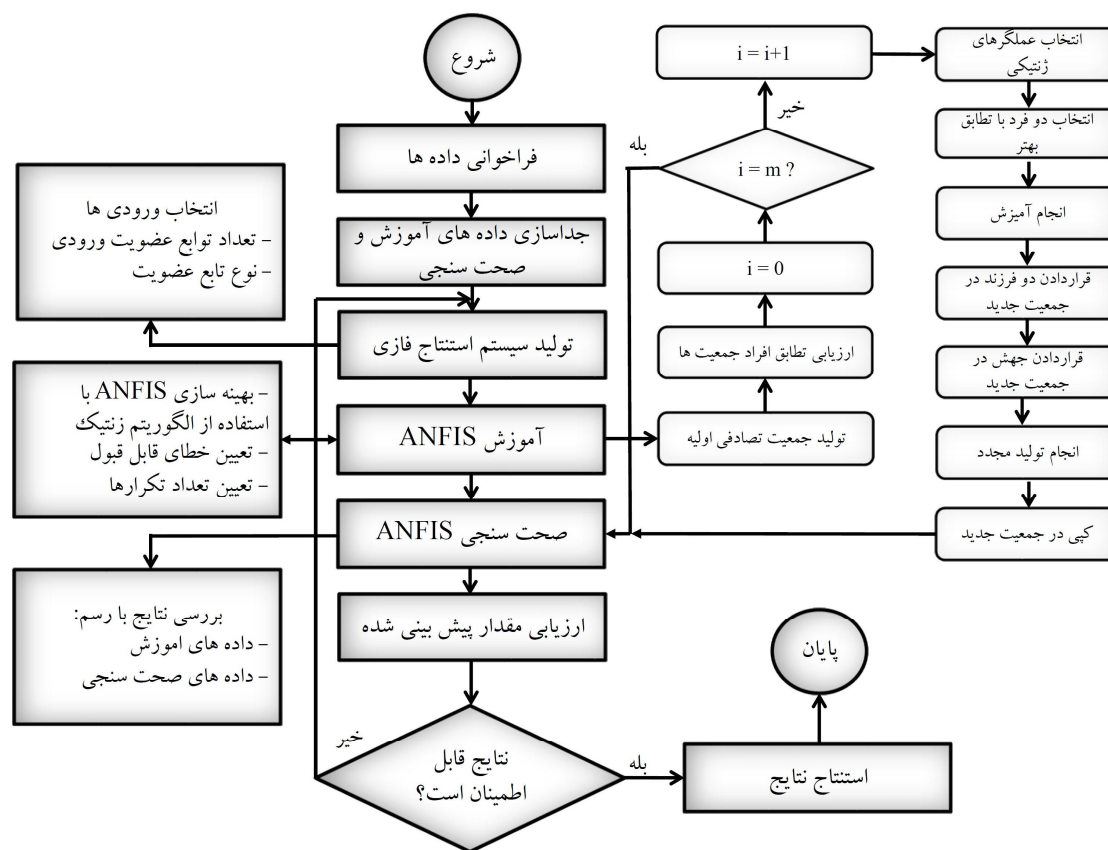
$$Z = \frac{w_1}{w_1 + w_2} z_1 + \frac{w_2}{w_1 + w_2} z_2 \quad (9)$$

$$= \bar{w}_1 (p_1 x + q_1 y + r_1) + \bar{w}_2 (p_2 x + q_2 y + r_2)$$

در حقیقت Z ، ترکیب خطی از پارامترهای نتیجه ($p_1, q_1, r_1, p_2, q_2, r_2$) است. همان‌طور که گفته شد، ANFIS ترکیبی از شبکه عصبی و یک سیستم استنتاج فازی است. الگوریتم یادگیری شبکه عصبی در روش ANFIS، برای تعیین پارامترهای سیستم استنتاج فازی استفاده می‌شود. در بخش سیستم فازی، ANFIS همیشه داده‌ها را به صورت If-Then تفسیر می‌کند و هر تابع واقعی را با هر دقتی تقریب می‌زند. هدف یافتن تابعی است که بتواند با ایجاد شرایط واقعی، عملکرد مطلوب‌تری ارائه دهد.

الگوریتم ژنتیک (GA)

الگوریتم ژنتیک، یکی از شناخته شده‌ترین نوع از الگوریتم‌های تکاملی است که هالند (Holland) آن را در سال ۱۹۷۵ ابداع کرد. الگوریتم ژنتیک، جستجو را با جمعیتی از راه حل‌های اولیه تصادفی شروع می‌کند. هرگاه معیارهای نهایی اقلان نشود به کمک عملگرهای ژنتیکی همچون پیوند (Crossover)، جهش (Mutation) و انتخاب (Selection) جمعیت‌های جدیدی تولید می‌شود. با هر تکرار از این سه اپراتور (عملگر) ژنتیکی، یک نسل به وجود می‌آید. جمعیت‌های اولیه به صورت رشته‌ای تعریف می‌شوند و هر رشته را تحت عنوان کروموزوم توصیف می‌کنند. در عملگر پیوند ژن‌های دو والدین با یکدیگر ترکیب می‌شوند و دو فرزند جدید ایجاد می‌شود. در عملگر جهش، یک تغییر ناگهانی در ژن صورت می‌گیرد. در عملگر انتخاب، جمعیت‌ها را به کمک تابع برازندگی مورد ارزیابی قرار می‌دهند. جمعیت‌های دارای برازندگی کمتر حذف شده و جمعیت‌ها به سمت پاسخ بهینه سوق داده می‌شوند. روش‌های انتخاب جمعیت‌ها برای اعمال اپراتورهای ژنتیکی به سه دسته انتخاب به صورت قطعی (Deterministic Selection)، انتخاب



شکل ۱. روندنمای روش ANFIS-GA

در اینجا ρ چگالی سیال، v ویسکوزیته سینماتیکی، U سرعت متوسط جریان، h عمق جریان، L شعاع حفره آبخستگی، K_s ضریب شکل تکیه گاه، d_{50} قطر متوسط رسوبات، σ_g انحراف استاندارد هندسی توزیع ذرات رسوب، ρ_s چگالی رسوبات و g شتاب گرانش است. چگالی رسوبات، چگالی سیال و ویسکوزیته سینماتیکی ثابت در نظر گرفته می شود. همچنین عدد فرود برابر $Fr = U/\sqrt{g \cdot y}$ در نظر گرفته می شود. بنابراین در این مطالعه اثر پارامترهای بدون بعد: عدد فرود $(U/\sqrt{g \cdot y})$ ، نسبت قطر متوسط رسوبات به شعاع حفره آبخستگی (d_{50}/L) نسبت عمق جریان به شعاع حفره آبخستگی (h/L) و انحراف استاندارد هندسی توزیع ذرات رسوب (σ_g) بر پارامتر بدون بعد عمق حفره آبخستگی (d_s/L) مورد بررسی قرار می گیرد. بنابراین و معادله زیر نتیجه می شود:


$$d_s/L = f(Fr, h/L, d_{50}/L, \sigma_g) \quad (11)$$

تعیین شده بروزرسانی می شوند. در هر مرحله از تکرار، یکی از پارامترهای تابع عضویت بروزرسانی می شود و این مراحل برای تمامی پارامترها ادامه می یابد و پس از اینکه تمامی پارامترها یکبار بروزرسانی شدند، در تکرار بعدی، پارامتر اول برای بار دوم آپدیت می شود. بنابراین به صورت تکرار به تکرار تمامی پارامترها برای رسیدن به نقطه بهینه بروزرسانی می شوند. به طور کلی، الگوریتم ژنتیک برای بهینه سازی توابع عضویت شبکه انفیس مورد استفاده قرار می گیرد.

آبخستگی اطراف تکیه گاه ها

آبخستگی در اطراف تکیه گاه ها برای رسوبات غیریکنواخت برحسب پارامترهای هیدرولیکی جریان، هندسه تکیه گاه و مشخصات رسوبات بستر است (۱۸):

$$d_s = f(\rho, v, U, h, L, K_s, d_{50}, \sigma_g, \rho_s, g) \quad (10)$$



شکل ۲. طرح نمادین مدل آزمایشگاهی

جدول ۱. مقادیر حداقل، حداکثر، متوسط مقادیر آزمایشگاهی

پارامتر	حداقل	حداکثر	میانگین
ds/L	۰/۶۴۶	۴/۳۵۰	۱/۸۳۵
Fr	۰/۰۵۶	۰/۳۹۶	۰/۱۴۰
h/L	۰/۳۸۵	۶/۲۵۰	۲/۴۳۹
d50/L	۰/۰۰۲	۱۴/۵۲۲	۰/۰۱۴
σg	۰/۷۵	۹۸/۷۵	۱۳/۵۲۲

۳ قابل مشاهده است. هدف اصلی از توسعه و تعریف یازده مدل متمایز اجرای تحلیل حساسیت انجام شده در متن مقاله است. با انجام این تحلیل حساسیت: (۱) مدل برتر انتخاب می‌شود. مدل برتر مدلی است که در کلیه شاخص‌های آماری برتری نسبی دارد و (۲) مؤثرترین پارامتر ورودی برای تخمین عمق آبستنگی توسط مدل‌های انفیس و مدل هوش مصنوعی ترکیبی شناسایی می‌شود.


بحث و نتایج

در این مطالعه برای بررسی دقت مدل‌های عددی از شاخص‌های آماری خطای نسبی مطلق میانگین (MARE)، خطای مربع میانگین ریشه (RMSE)، شاخص BIAS، ضریب همبستگی (R)، شاخص پراکندگی (SI) و شاخص ρ استفاده می‌شود:

$$MARE = \frac{1}{n'} \sum_{i=1}^{n'} \left(\frac{|d_s/L(\text{Predicted})_i - d_s/L(\text{Observed})_i|}{d_s/L(\text{Observed})_i} \right) \quad (12)$$

برای اعتبارسنجی نتایج مدل‌های ANFIS و ANFIS-GA از اندازه‌گیری‌های آزمایشگاهی دی و باربویا (۹) استفاده می‌شود. مدل آزمایشگاهی متشکل از یک فلوم مستطیلی به طول ۲۰، عرض ۰/۹ و ارتفاع ۰/۷ متر است. آنها عمق حفزه آبستنگی در نزدیکی تکیه‌گاه به شکل‌های قائم، نیمه‌دایره ای و ۴۵ درجه در شرایط آب زلال و برای رسوبات یکنواخت و غیریکنواخت اندازه‌گیری کردند. شکل ۲ طرح نمادین مدل آزمایشگاهی را نشان می‌دهد. همچنین مقادیر حداکثر، حداقل و متوسط اندازه‌گیری‌های آزمایشگاهی در جدول ۱ مرتب شده است.

برای مدل‌سازی آبستنگی در نزدیکی تکیه‌گاه‌ها از ۲۷۶ اندازه‌گیری آزمایشگاهی استفاده می‌شود که ۷۰ درصد آنها برای آموزش مدل‌ها و ۳۰ درصد باقی‌مانده برای تست شبیه‌سازی‌ها استفاده می‌شود. در ادامه ۱۱ مدل مختلف برای هر یک مدل‌های ANFIS و ANFIS-GA معرفی می‌شود که این ترکیب‌ها در شکل



شکل ۳. ترکیب پارامترهای ورودی برای مدل‌های ANFIS و ANFIS-GA

$$TSx = \frac{Y_x}{n'} \times 100 \quad (18)$$

در اینجا Y_x برابر مقادیر پیش‌بینی شده توسط مدل‌های عددی است که مقدار خطای آنها کوچک‌تر از %x است.

در مطالعه حاضر، با توجه به عملکرد خوب روش انتخاب بر اساس مکانیسم چرخ گردان در مطالعات اخیر (۱۰ و ۱۳). از این روش استفاده می‌شود. علاوه بر این، مقادیر دو عملگر جهش و پیوند نیز در طی فرایند سعی و خطا، به دست می‌آید. با در نظر گرفتن مقادیر ۰/۰۱ تا ۰/۱ به فواصل ۰/۰۵ برای عملگر جهش و مقادیر ۰/۰۵ تا ۱ به فواصل ۰/۰۵ برای عملگر پیوند، در نظر گرفته شد. پس از آن، تمامی حالت‌های ممکن با در نظر گرفتن مقادیر مختلف هر یک از این دو پارامتر، اقدام به مدل‌سازی شد (مدل ۱ در شکل ۳). با بررسی نتایج مربوط به شاخص‌های مختلف، مشخص شد که بهترین نتیجه زمانی حاصل می‌شود که مقدار جهش و پیوند به صورت ۰/۰۵ و ۰/۷ (به ترتیب) در نظر گرفته شود:

در جدول ۲ مقادیر RMSE، MARE، BIAS، R، SI و ρ برای کلیه مدل‌های ANFIS و ANFIS-GA در حالت تست مرتب شده است. در همچنین در شکل ۴ توزیع خطا برای مدل‌های ANFIS و ANFIS-GA برای حالت تست به تصویر کشیده شده است.

Model 1 تنها مدلی است که عمق آبخستگی را برحسب کلیه

$$RMSE = \sqrt{\frac{1}{n'} \sum_{i=1}^{n'} (d_s/L_{(Predicted)_i} - d_s/L_{(Observed)_i})^2} \quad (13)$$

$$BIAS = \frac{1}{n'} \sum_{i=1}^{n'} (d_s/L_{(Predicted)_i} - d_s/L_{(Observed)_i}) \quad (14)$$

$$SI = \frac{RMSE}{d_s/L_{(Observed)}} \quad (15)$$

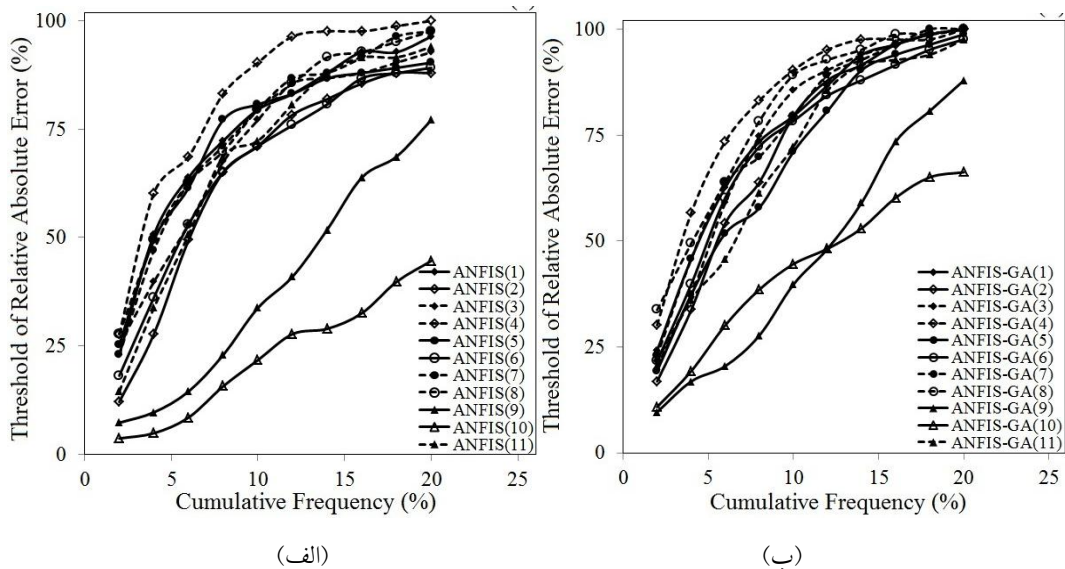
$$\rho = \frac{SI}{1+R} \quad (16)$$

$$R = \frac{\sum_{i=1}^{n'} (d_s/L_{(Observed)_i} - \overline{d_s/L_{(Observed)}})}{\sqrt{\sum_{i=1}^{n'} (d_s/L_{(Observed)_i} - \overline{d_s/L_{(Observed)}})^2}} \quad (17)$$

در اینجا مقدار $d_s/L_{(Observed)_i}$ نسبت عمق آبخستگی به شعاع حفره آبخستگی آزمایشگاهی، $d_s/L_{(Predicted)_i}$ نسبت عمق آبخستگی به شعاع حفره آبخستگی پیش‌بینی شده توسط مدل‌های عددی، $\overline{d_s/L_{(Observed)_i}}$ میانگین نسبت عمق آبخستگی به شعاع حفره آبخستگی آزمایشگاهی و n' برابر تعداد مقادیر آزمایشگاهی است. شاخص‌های آماری بالا، اختلاف بین مقادیر آبخستگی آزمایشگاهی و پیش‌بینی شده را ارائه می‌کنند و توضیحات اضافی در ارتباط با توزیع خطا توسط مدل‌های عددی ارائه نمی‌دهند. بنابراین برای محاسبه نحوه توزیع خطا توسط مدل‌های، شاخص TSx پیشنهاد می‌شود. در این مطالعه، شاخص TSx مقادیر MARE برای مدل‌های عددی محاسبه می‌شود:

جدول ۲. مقادیر MARE، RMSE، BIAS، R، SI، ρ برای کلیه مدل‌های ANFIS و ANFIS-GA در حالت تست

Model	ANFIS						ANFIS-GA					
	MARE	RMSE	BIAS	R	SI	ρ	MARE	RMSE	BIAS	R	SI	ρ
1	۰/۰۶۴	۰/۱۷۳	۰/۱۱۹	۰/۹۶۶	۰/۰۹۱	۰/۰۴۶	۰/۰۵۸	۰/۱۲۵	۰/۱۰۱	۰/۹۸۱	۰/۰۶۶	۰/۰۳۳
2	۰/۰۸۵	۰/۲۱۷	۰/۱۶۳	۰/۹۴۱	۰/۱۱۵	۰/۰۵۹	۰/۰۶۴	۰/۱۳۸	۰/۱۱۵	۰/۹۷۷	۰/۰۷۲	۰/۰۳۷
3	۰/۰۷۳	۰/۱۸۴	۰/۱۳۰	۰/۹۵۹	۰/۰۹۷	۰/۰۴۹	۰/۰۵۸	۰/۱۲۸	۰/۱۰۵	۰/۹۸۰	۰/۰۶۷	۰/۰۳۴
4	۰/۰۴۶	۰/۱۳۲	۰/۰۸۹	۰/۹۷۹	۰/۰۷۰	۰/۰۳۵	۰/۰۴۵	۰/۱۰۵	۰/۰۸۱	۰/۹۸۶	۰/۰۵۶	۰/۰۲۸
5	۰/۰۷۰	۰/۲۴۲	۰/۱۳۹	۰/۹۲۷	۰/۱۲۷	۰/۰۶۶	۰/۰۷۱	۰/۱۹۱	۰/۱۴۱	۰/۹۵۶	۰/۱۰۱	۰/۰۵۲
6	۰/۰۷۹	۰/۱۹۴	۰/۱۴۴	۰/۹۵۴	۰/۱۰۲	۰/۰۵۲	۰/۰۶۴	۰/۱۳۹	۰/۱۱۲	۰/۹۷۶	۰/۰۷۳	۰/۰۳۷
7	۰/۰۶۳	۰/۱۵۳	۰/۱۱۲	۰/۹۷۰	۰/۰۸۱	۰/۰۴۱	۰/۰۵۷	۰/۱۲۵	۰/۰۹۹	۰/۹۸۱	۰/۰۶۶	۰/۰۳۳
8	۰/۰۶۰	۰/۲۰۲	۰/۱۱۷	۰/۹۶۱	۰/۱۰۶	۰/۰۵۴	۰/۰۴۹	۰/۱۰۹	۰/۰۸۵	۰/۹۸۶	۰/۰۵۸	۰/۰۲۹
9	۰/۱۴۱	۰/۳۱۶	۰/۲۶۸	۰/۸۷۹	۰/۱۶۷	۰/۰۸۹	۰/۱۲۱	۰/۲۸۲	۰/۲۳۱	۰/۹۰۲	۰/۱۴۹	۰/۰۷۸
10	۰/۲۶۲	۰/۵۵۶	۰/۴۶۴	۰/۵۹۲	۰/۲۹۳	۰/۱۸۴	۰/۱۶۰	۰/۴۰۳	۰/۲۹۸	۰/۷۶۹	۰/۲۱۳	۰/۱۲۰
11	۰/۰۹۰	۰/۴۱۱	۰/۱۹۰	۰/۸۵۹	۰/۲۱۷	۰/۱۱۷	۰/۰۷۱	۰/۱۸۴	۰/۱۳۷	۰/۹۵۹	۰/۰۹۷	۰/۰۴۹




شکل ۴. توزیع خطا برای مدل‌های (الف) ANFIS و (ب) ANFIS-GA در حالت تست

نسبت عمق جریان به شعاع حفره آبهستگی (h/L) و انحراف استاندارد هندسی توزیع ذرات رسوب (σ_g) مدل‌سازی می‌کند. مدل ANFIS(1) تقریباً ۷۹ درصد نتایج را با خطایی کمتر از ۱۰


پارامترهای ورودی معرفی شده در معادله (۲) تخمین می‌زند. Model 1 عمق آبهستگی را به عنوان تابعی از عدد فرود (Fr)، نسبت قطر متوسط رسوبات به شعاع حفره آبهستگی (d_{50}/L)،

اثرات عدد فرود نادیده گرفته شده است. در بین مدل‌های با سه پارامتر ورودی هر دو مدل ANFIS(5) و ANFIS-GA(5) دارای کمترین مقدار ضریب همبستگی هستند. مقدار R برای ANFIS(5) و ANFIS-GA(5) به ترتیب مساوی ۰/۹۲۷ و ۰/۹۵۶ محاسبه شده است. Models 6 to 11 مقادیر آبهستگی‌ها را با ترکیبی از دو پارامتر ورودی مدل‌سازی می‌کنند. هر دوی مدل‌های ANFIS(6) و ANFIS-GA(6) عمق حفره آبهستگی در اطراف تکیه‌گاه‌ها را برحسب عدد فرود و نسبت قطر متوسط رسوبات به شعاع حفره آبهستگی محاسبه می‌کنند. تقریباً ۷۲ درصد نتایج مدل‌سازی‌ها توسط ANFIS(6) دارای خطایی کمتر از ۱۰ درصد هستند. همچنین حدوداً ۱۷ درصد داده‌ها خطایی بین ۱۰ تا ۲۰ درصد دارند. آبهستگی توسط ANFIS(7) و ANFIS-GA(7) برحسب Fr و h/L پیش‌بینی می‌شود. مقدار SI برای ANFIS(7) و ANFIS-GA(7) به ترتیب برابر ۰/۰۸۱ و ۰/۹۸۱ به دست آمده است. همچنین تقریباً ۷۹ درصد آبهستگی‌های پیش‌بینی شده توسط ANFIS(7) مقدار خطایی کمتر از ۱۰ درصد دارند. مقادیر RMSE و BIAS برای ANFIS(7) به ترتیب تقریباً ۱۸ و ۱۱ درصد کمتر از ANFIS(7) پیش‌بینی شده است. Models 8 تابعی از Fr و σ_g است. مقدار ضریب همبستگی برای ANFIS(8) و ANFIS-GA(8) به ترتیب برابر ۰/۹۶۱ و ۰/۹۸۶ به دست آمده است. ANFIS(8) تقریباً ۱۷ درصد داده‌ها را با خطایی بین ۱۰ تا ۲۰ درصد مدل‌سازی می‌کند. در مقابل ANFIS-GA(8) حدوداً ۹۱ درصد نتایج آبهستگی را با خطایی کمتر از ۱۰ درصد محاسبه می‌کند. مقدار BIAS برای ANFIS(8) و ANFIS-GA(8) به ترتیب برابر ۰/۹۷۹ و ۰/۹۸۶ است. برای هر دو مدل تقریباً ۹۱ درصد نتایج مدل‌سازی شده، دارای خطایی کمتر از ۱۰ درصد هستند. هر دوی این مدل‌ها عمق حفره آبهستگی را برحسب عدد فرود (Fr)، نسبت عمق جریان به شعاع حفره آبهستگی (h/L) و پارامتر انحراف استاندارد هندسی توزیع ذرات رسوب (σ_g) پیش‌بینی می‌کنند. ANFIS(5) و ANFIS-GA(5) آبهستگی تکیه‌گاه را به عنوان تابعی از h/L ، d_{50}/L و σ_g مدل‌سازی می‌کند. برای هر دوی این مدل‌ها

درصد پیش‌بینی می‌کند. این مدل حدوداً ۱۷ درصد آبهستگی‌ها را با خطایی بین ۱۰ تا ۲۰ درصد مدل‌سازی کرده و تنها ۴ درصد داده‌ها خطایی بیشتر از ۲۰ درصد به خود اختصاص داده‌اند. بر اساس جدول ۲ مدل ANFIS-GA(1) مقدار MARE و RMSE را به ترتیب حدوداً ۱۰ و ۲۸ درصد کمتر از مدل ANFIS(1) پیش‌بینی کرده است. همان‌گونه که مشاهده می‌شود، در کلیه شاخص‌های آماری مدل ANFIS-GA(1) برتر از مدل ANFIS(1) است. Models 2 to 5 مقادیر آبهستگی‌ها را با ترکیبی از سه پارامتر ورودی مدل‌سازی می‌کنند. Models 2 آبهستگی‌ها را برحسب عدد فرود، نسبت قطر متوسط رسوبات به شعاع حفره آبهستگی و نسبت عمق جریان به شعاع حفره آبهستگی تخمین می‌زند. در مدل ANFIS(2) حدوداً ۱۲/۰ نتایج خطایی بیشتر از ۲۰ درصد دارند و تقریباً ۷۱ درصد داده‌ها با خطایی کمتر از ۱۰ درصد مقدار حفره آبهستگی را پیش‌بینی می‌کند. این در حالی است که تقریباً ۸۰ درصد نتایج مدل‌سازی توسط این مدل خطایی کمتر از ۱۰ درصد دارند. مقدار ضریب همبستگی (R) برای ANFIS-GA(2) تقریباً ۴ درصد بیشتر از R محاسبه شده برای ANFIS(2) است. ANFIS(3) و ANFIS-GA(3) مقادیر آبهستگی‌ها را برحسب پارامترهای ورودی Fr ، d_{50}/L و σ_g تخمین می‌زند. همچنین حدود ۷ درصد مدل‌سازی‌ها توسط این مدل مقدار خطایی بیشتر از ۲۰ درصد به خود اختصاص داده‌اند. در بین مدل‌های با سه پارامتر ورودی ANFIS(4) و ANFIS-GA(4) دارای بیشترین دقت هستند. مقدار ضریب همبستگی برای ANFIS(4) و ANFIS-GA(4) به ترتیب برابر ۰/۹۷۹ و ۰/۹۸۶ است. برای هر دو مدل تقریباً ۹۱ درصد نتایج مدل‌سازی شده، دارای خطایی کمتر از ۱۰ درصد هستند. هر دوی این مدل‌ها عمق حفره آبهستگی را برحسب عدد فرود (Fr)، نسبت عمق جریان به شعاع حفره آبهستگی (h/L) و پارامتر انحراف استاندارد هندسی توزیع ذرات رسوب (σ_g) پیش‌بینی می‌کنند. ANFIS(5) و ANFIS-GA(5) آبهستگی تکیه‌گاه را به عنوان تابعی از h/L ، d_{50}/L و σ_g مدل‌سازی می‌کند. برای هر دوی این مدل‌ها



شکل ۵. مقادیر آبشستگی آزمایشگاهی و عددی برای مدل ۴: الف) ANFIS و ب) ANFIS-GA در حالت تست



شکل ۶. نمودارهای پراکندگی برای مدل‌های برتر

در بین مدل‌های ANFIS، مدل ANFIS(4) و در بین مدل‌های ANFIS-GA مدل ANFIS-GA(4) به‌عنوان مدل‌های برتر معرفی می‌شوند.

در ادامه به بررسی پروسه شبیه‌سازی توسط مدل‌های برتر پرداخته می‌شود. در شکل ۵ مقایسه مقادیر آبشستگی آزمایشگاهی و عددی ANFIS(4) و ANFIS-GA(4) برای حالت تست نشان داده شده است. همان‌گونه که مشاهده می‌شود، ANFIS(4) و ANFIS-GA(4) مقادیر آبشستگی را با دقت قابل قبولی پیش‌بینی کرده‌اند هر چند که ANFIS-GA(4) مقادیر آبشستگی‌ها را با دقت بیشتری مدل‌سازی کرده است. ANFIS(4) برای مقادیر بزرگ آبشستگی دارای عملکردی بیشتر از واقعی است. در مقابل ANFIS-GA(4) برای مقادیر کوچک آبشستگی دارای عملکردی کمتر از واقعی و برای آبشستگی‌های بزرگ عملکردی بیشتر از واقعی است. شکل ۶ نمودار

مجاورت تکیه‌گاه توسط 10 Models برحسب d_{50}/L و σ_g مدل‌سازی می‌شود. مقدار MARE و R برای ANFIS(10) به‌ترتیب مساوی ۰/۲۶۲ و ۰/۵۹۲ و برای ANFIS-GA(10) به‌ترتیب برابر ۰/۱۶۰ و ۰/۷۶۹ محاسبه شده است. در بین کلیه مدل‌ها، ANFIS(10) و ANFIS-GA(10) دارای کمترین دقت هستند. ANFIS(11) و ANFIS-GA(11) مقادیر آبشستگی در مجاورت تکیه‌گاه را به‌عنوان تابعی h/L و σ_g تخمین می‌زند. مقدار Scatter Index و ρ برای ANFIS(11) به‌ترتیب مساوی ۰/۲۱۷ و ۰/۱۱۷ به‌دست آمده است. تقریباً ۷۲ درصد مقادیر آبشستگی‌های پیش‌بینی شده توسط ANFIS(11) دارای خطایی کمتر از ۱۰ درصد هستند و حدوداً ۶ درصد داده‌ها نیز خطایی بیشتر از ۲۰ درصد دارند. با توجه به تجزیه و تحلیل نتایج شبیه‌سازی آبشستگی در مجاورت تکیه‌گاه، در کلیه مدل‌ها دقت مدل‌های ANFIS-GA بیشتر از ANFIS است. از طرف دیگر

جدول ۳. مقادیر DR(max)، DR(min) و DR(ave) برای کلیه مدل‌های ANFIS و ANFIS-GA

Model	ANFIS			ANFIS-GA		
	DRmax	DRmin	DRave	DRmax	DRmin	DRave
1	۱/۲۱۱	۰/۵۱۶	۰/۹۸۶	۱/۱۹۷	۰/۸۳۱	۰/۹۸۲
2	۱/۲۷۸	۰/۷۰۱	۰/۹۸۰	۱/۱۹۶	۰/۸۳۵	۰/۹۸۴
3	۱/۳۵۴	۰/۶۶۹	۰/۹۸۷	۱/۱۷۳	۰/۷۹۱	۰/۹۸۸
4	۱/۱۲۳	۰/۷۴۶	۰/۹۸۴	۱/۱۹۹	۰/۸۷۰	۰/۹۸۸
5	۱/۲۶۶	۰/۵۷۹	۰/۹۸۱	۱/۲۱۲	۰/۸۱۴	۰/۹۸۶
6	۱/۲۷۴	۰/۷۲۴	۰/۹۷۲	۱/۲۲۷	۰/۷۹۸	۰/۹۸۶
7	۱/۳۰۵	۰/۷۷۹	۰/۹۹۱	۱/۱۶۵	۰/۸۲۳	۰/۹۸۴
8	۱/۳۳۲	۰/۸۱۸	۰/۹۹۰	۱/۱۵۵	۰/۸۱۱	۰/۹۸۱
9	۱/۳۰۷	۰/۶۷۲	۰/۹۹۵	۱/۲۸۷	۰/۷۰۲	۰/۹۹۳
10	۱/۹۱۶	۰/۰۲۷	۱/۰۳۲	۱/۶۱۴	۰/۶۰۸	۱/۰۳۸
11	۱/۸۲۶	۰/۸۱۵	۱/۰۰۷	۱/۲۸۴	۰/۸۳۴	۰/۹۸۳

نتیجه‌گیری

در این مطالعه، ابتدا مدل ANFIS توسط الگوریتم ژنتیک (GA) بهینه‌سازی شد و سپس عمق آبه‌سستگی در مجاورت تکیه‌گاه پل‌ها شبیه‌سازی شد. به‌طور کلی، مدل ANFIS در مقایسه با سایر مدل‌های هوش مصنوعی برای شبیه‌سازی پدیده‌های مختلف از عملکرد قابل قبولی برخوردار است. علاوه بر این، الگوریتم‌های مختلفی برای بهینه‌سازی ANFIS استفاده شده‌اند. در این مطالعه، با استفاده از الگوریتم بهینه‌سازی GA و مدل ANFIS، یک مدل فرا ابتکاری نوین برای شبیه‌سازی عمق آبه‌سستگی در مجاورت تکیه‌گاه پل‌ها برای اولین بار توسعه داده می‌شود. الگوریتم ژنتیک توابع عضویت مدل ANFIS را به‌شکل قابل توجهی بهینه‌سازی

پیش‌بینی به نتایج آزمایشگاهی است. مقادیر حداکثر (DR(max))، حداقل (DR(min)) و متوسط (DR(ave)) برای همه مدل‌ها در جدول ۳ مرتب شده است. در بین مدل‌های ANFIS بیشترین مقدار DR(max) برای ANFIS(10) و مساوی ۱/۹۱۶ محاسبه شده است. همچنین کمترین مقدار DR(min) برابر ۰/۰۲۷ و برای ANFIS(10) به‌دست آمده است. در مقابل بیشترین و کمترین مقدار DR(ave) به‌ترتیب برای ANFIS(10) و ANFIS(6) محاسبه شده است. همچنین در بین مدل‌های ANFIS-GA کمترین مقدار DR(min) و بیشترین مقدار DR(max) نیز برای ANFIS-GA(10) پیش‌بینی شده است. برای این مدل‌ها نزدیک‌ترین مقدار DR(min) برای ANFIS-GA(9) و برابر ۰/۹۹۳ محاسبه شده است.

ورودی برای شبیه‌سازی عمق حفره آبشستگی شناسایی شدند. به‌عنوان مثال، ضریب همبستگی و شاخص پراکندگی برای مدل برتر ANFIS-GA مساوی با ۰/۹۸۶ و ۰/۰۵۶ بودند. همچنین، توزیع خطا نشان داد که تقریباً ۸۳ درصد نتایج مدل ANFIS-GA برتر خطایی کمتر از ۸ درصد داشت. علاوه بر این، عدد فرود جریان و پارامتر بدون بعد نسبت عمق جریان به شعاع حفره آبشستگی به‌عنوان مؤثرترین پارامترهای ورودی شناسایی شدند.

کرد و دقت این مدل هوش مصنوعی را افزایش داد. به‌گونه‌ای که دقت مدل‌های ANFIS-GA متناظر با ANFIS بیشتر بود. به‌عنوان مثال، مقدار شاخص آماری RMSE برای مدل‌های ANFIS و ANFIS-GA به‌ترتیب مساوی با ۰/۱۳۲ و ۰/۱۰۵ محاسبه شدند. علاوه بر این، توسط پارامترهای مؤثر بر عمق حفره آبشستگی، یازده مدل متمایز برای هر یک از مدل‌های ANFIS و ANFIS-GA تعریف شد. سپس با اجرای یک تحلیل حساسیت دقیق، نتایج این مدل‌ها مورد ارزیابی قرار گرفتند و مدل‌های برتر و مؤثرترین پارامترهای

منابع مورد استفاده

1. Azamathulla, H. M. 2012. Gene-expression programming to predict scour at a bridge abutment. *Journal of Hydroinformatics* 14(2): 324-331.
2. Azimi, H., H. Bonakdari, I. Ebtehaj, S. H. A. Talesh, D. G. Michelson and A. Jamali. 2017. Evolutionary Pareto optimization of an ANFIS network for modeling scour at pile groups in clear water condition. *Fuzzy Sets and Systems* 319: 50-69.
3. Azimi, H., H. Bonakdari, I. Ebtehaj, S. Shabanlou, S. H. A. Talesh and A. Jamali. 2019. A Pareto design of evolutionary hybrid optimization of ANFIS model in prediction abutment scour depth. *Sādhanā* 44(7): 169.
4. Ballio F., A. Teruzzi and A. Radice. 2009. Constriction effects in clear-water scour at abutments. *Journal of Hydraulic Engineering* 135(2): 140-145.
5. Barkdoll, B. D., B. W. Melville and R. Ettema. 2006. A Review of bridge abutment scour countermeasures. Proceedings of the 2006 World Environmental and Water Resources Congress, May 21-25, 2006, Omaha, Nebraska.
6. Bateni, S. M. and D. S. Jeng. 2007. Estimation of pile group scour using adaptive neuro-fuzzy approach. *Ocean Engineering* 34(8): 1344-1354.
7. Coleman, S. E., C. S. Lauchlan and B. W. Melville. 2003. Clear-water scour development at bridge abutments. *Journal of Hydraulic Research* 41(5): 521-531.
8. Dey, S. and A. K. Barbhuiya. 2004. Clear water scour at abutments. In Proceedings of the Institution of Civil Engineers-Water Management 157(2): 77-97.
9. Dey, S. and A. K. Barbhuiya. 2005. Time variation of scour at abutments. *Journal of Hydraulic Engineering* 131(1): 11-23.
10. Ebtehaj, I. and H. Bonakdari. 2014. Comparison of genetic algorithm and imperialist competitive algorithms in predicting bed load transport in clean pipe. *Water Science and Technology* 70(10): 1695-1701.
11. Firat, M. and M. Gungor. 2009. Generalized regression neural networks and feed forward neural networks for prediction of scour depth around bridge piers. *Advances in Engineering Software* 40(8): 731-737.
12. Fujail, A. K. Md., S. A. Begum and A. K. Barbhuiya. 2018. Genetic algorithm-based neural network for estimation of scour depth around bridge abutment. *International Journal of Computer Sciences and Engineering* 6(7): 1544-1554.
13. Gholami, A., H. Bonakdari, I. Ebtehaj, M. Mohammadian, B. Gharabaghi and S. R. Khodashenas. 2018. Uncertainty analysis of intelligent model of hybrid genetic algorithm and particle swarm optimization with ANFIS to predict threshold bank profile shape based on digital laser approach sensing. *Measurement* 121: 294-303.
14. Kothyari, U. C. and K. G. Ranga Raju. 2001. Scour around spur dikes and bridge abutments. *Journal of Hydraulic Research* 39(4): 367-374.
15. Kouchakzadeh, S. and R. D. Townsend. 2000. Bridge abutment scour in compound river channels. *Journal of Agricultural Science and Technology* 2: 95-106.
16. Liriano, S. L., and R. A. Day. 2001. Prediction of scour depth at culvert outlets using neural networks. *Journal of Hydroinformatics* 3(4): 231-238.
17. Muzzammil, M. 2010. ANFIS approach to the scour depth prediction at a bridge abutment. *Journal of Hydroinformatics* 12(4): 474-485.

18. Najafzadeh, M., G. A. Barani and M. R. Hessami Kermani. 2013. Abutment scour in clear-water and live-bed conditions by GMDH network. *Water Science & Technology* 67(5): 1121-1128.
19. Oliveto, G. and W. H. Hager. 2002. Temporal evolution of clear-water pier and abutment scour. *Journal of Hydraulic Engineering* 128(9): 811-820.
20. Oliveto, G. and W. H. Hager. 2005. Further results to time-dependent local scour at bridge elements. *Journal of Hydraulic Engineering* 131(2): 97-105.
21. Trent, R., N. Gagarin and J. Rhodes. 1993. Estimating pier scour with artificial neural networks. *Journal of Hydraulic Engineering* 1043-1048.
22. Yanmaz, A. M. and T. Celebi. 2004. Evaluation of Scouring Reliability at Bridge abutments. In CD-ROM Proceedings World Water and Environmental Resources Congress, ASCE, Salt Lake City, ABD.

Optimization of ANFIS Model using Genetic Algorithm for Estimation of Scour Depth around Bridge Abutments

E. Yarmohammadi, S. Shabanlou* and A. Rajabi¹

(Received: September 22-2019 ; Accepted: August 5-2020)

Abstract

Optimization of artificial intelligence (AI) models is a significant issue because it enhances the performance and flexibility of the numerical models. In this study, scour depth around bridge abutments with different shapes was estimated by means of ANFIS and ANFIS-Genetic Algorithm. In other words, the membership functions of the ANFIS model were optimized using the genetic algorithm, finding that the performance of ANFIS model was increased. Firstly, effective input parameters on the scour depth around bridge abutments were defined. Then, by using the input parameters, eleven ANFIS and ANFIS-GA models were produced. Next, the superior ANFIS and ANFIS-GA models were introduced by analyzing the numerical results. For example, the correlation coefficient and scatter index for ANFIS model were calculated to be 0.979 and 0.070; for ANFIS-GA, these were 0.986 and 0.056, respectively. In addition, the average discrepancy ratio (DR_{ave}) for ANFIS and ANFIS-GA models was 0.984 and 0.988, respectively. Also, it was shown that the ANFIS-GA models had more accuracy, as compared to the ANFIS models. Moreover, a sensitivity analysis showed that Froude number (Fr) and ratio of flow depth to radius of scour hole (h/L) were the most influential input parameters for simulating the scour depth around bridge abutments.

Keywords: ANFIS, Algorithm genetic, Optimization, Scour, Bridge abutment, Sensitivity analysis

1. Department of Water Engineering, Kermanshah Branch, Islamic Azad University, Kermanshah, Iran.
Corresponding author, Email: saeid.shabanlou@gmail.com