

پیش‌بینی عمق آبستگي در مجاورت سرریزهای سنگی با استفاده از ساختار تعمیم‌یافته روش گروه دسته‌بندی داده‌ها

ابراهیم شهبازیگی^۱، فریبرز یوسفوند^{۲*}، بهروز یعقوبی^۳، سعید شعبانلو^۴ و احمد رجبی^۵

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

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

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

(۴) دانشیار گروه مهندسی آب، واحد کرمانشاه، دانشگاه آزاد اسلامی، کرمانشاه، ایران.

(۵) استادیار گروه مهندسی آب، واحد کرمانشاه، دانشگاه آزاد اسلامی، کرمانشاه، ایران.

* ایمیل نویسنده مسئول: fariborzosefvand@gmail.com

تاریخ پذیرش: ۱۴۰۰/۰۲/۲۶

تاریخ دریافت: ۱۳۹۹/۰۸/۱۰

چکیده:

در این مطالعه، برای اولین بار الگوی آبستگي در مجاورت سرریزهای سنگی با شکل‌های U، I و J درون کانال‌های خم توسط یک روش هوش مصنوعی نوین تحت عنوان ساختار تعمیم‌یافته روش گروه دسته‌بندی داده‌ها (GSGMDH) شبیه‌سازی شد. در مقایسه با روش (GMDH) گروه دسته‌بندی داده‌ها روش GSGMDH یک روش منعطف‌تر و دقیق‌تر است که در آن گره‌ها می‌توانند از لایه‌های غیرهمجوار ورودی بگیرند. در ابتدا، کلیه پارامترهای موثر بر روی عمق آبستگي در مجاورت سرریزهای سنگی شناسایی گردید و سپس با استفاده از این پارامترها، برای هر یک از روش‌های GMDH و GSGMDH مدل مختلف تعریف گردید. سپس داده‌ها به دو دسته آموزش و تست تقسیم‌بندی شدند. به عبارت دیگر، ۷۰ درصد داده‌ها برای آموزش مدل‌های هوش مصنوعی و ۳۰ درصد باقیمانده برای تست آنها استفاده گردید. با تجزیه و تحلیل نتایج مدل‌های هوش مصنوعی مدل‌های برتر معرفی گردید. مدل‌های برتر GMDH و GSGMDH مقادیر آبستگي‌ها را بر حسب کلیه پارامترهای ورودی تخمین زدند. علاوه بر این، دقت مدل‌های GSGMDH از مدل‌های GMDH بیشتر بود. به عنوان مثال، برای مدل‌های برتر GMDH و GSGMDH مقدار شاخص عملکرد در وضعیت تست به ترتیب مساوی با ۷۳/۰۷۵ و ۸۶/۴۰۸ محاسبه شدند. همچنین، مدل برتر مقادیر تابع هدف را با دقت خوبی پیش‌بینی نمود. به عنوان مثال، مقادیر ضریب همبستگی (R)، شاخص پراکندگی (SI) و ضریب نش (NSC) برای مدل برتر GSGMDH در شرایط آموزش به ترتیب مساوی با ۰/۹۱۳، ۰/۲۱۴ و ۰/۸۰۰ تخمین زده شدند. با توجه به نتایج تحلیل حساسیت، پارامترهای ضریب شکل سرریزهای سنگی (φ)، نسبت اختلاف عمق جریان در بالادست و پائین‌دست تله سنگی برابر به ارتفاع سازه (y/h_شΔ) و عدد فرود تراکمی (F_d) به عنوان موثرترین پارامترهای ورودی معرفی گردیدند. تحلیل عدم قطعیت نشان داد که مدل GSGMDH برتر دارای یک عملکرد کمتر از واقعی بود.

کلید واژه‌ها: سرریز سنگی؛ آبستگي؛ مدل‌سازی؛ دسته‌بندی گروهی داده‌ها؛ تحلیل عدم قطعیت؛ تحلیل حساسیت مشتق نسبی

مقدمه

رودخانه‌های می‌سی‌سی‌پی، یانگ تسه، نیل و آمازون در طول تاریخ ایجاد شده‌اند. محافظت از کناره‌ها و بستر رودخانه‌ها در برابر فرسایش و آبستگي یکی از مهمترین موضوعات مهندسی رودخانه محسوب می‌شود. روش‌های

به‌طور کلی رودخانه‌ها یک نقش کلیدی در توسعه شهرها و تمدن‌های بزرگ ایفا کرده‌اند. به عنوان مثال، شهرهای مهم و قطب‌های صنعتی بزرگی در مجاورت

دادند که این روابط از دقت قابل قبولی برخوردار بودند. کردستانی و پاگلیارا (۹) الگوی آبشستگی در مجاورت سازه‌های مختلف محافظت کننده بستر از قبیل سرریزهای تنه درختی در قالب یک تحقیق آزمایشگاهی با همدیگر مقایسه نمودند. آنها با استفاده از تئوری باکینگهام یک تحلیل ابعادی بر روی پارامترهای تاثیرگذار بروی عمق حفره آبشستگی انجام دادند. همچنین، پاگلیارا و همکاران (۱۸) یک مطالعه آزمایشگاهی بر روی الگوی آبشستگی در اطراف سرریزهای تنه درختی های چوبی انجام دادند. آنها عمق حفره آبشستگی را در شرایط هیدرولیکی و هندسی مختلف اندازه‌گیری نمودند و بیان کردند که عمق پایاب مهمترین پارامتر هیدرولیکی جریان بر روی تشکیل عمق حفره آبشستگی بود. لازم به ذکر است که پاگلیارا و کردستانی (۱۳) ابعاد حفره آبشستگی در پائین دست سازه‌های سنگی J شکل درون کانال‌های خم را به صورت آزمایشگاهی اندازه‌گیری نمودند. آنها بیان کردند که با توجه به شرایط هیدرولیکی جریان انواع مورفولوژی‌های مختلفی در پائین دست این نوع از سازه‌ها تشکیل شد. در ادامه، پاگلیارا و همکاران (۱۱) در یک مطالعه آزمایشگاهی مقادیر آبشستگی‌ها در مجاورت سرریزهای تنه درختی درون کانال‌های مستقیم افقی در شرایط آب زلال را اندازه‌گیری نمودند. آنها این سازه‌های محافظت کننده را برای شرایط هندسی و هیدرولیکی مختلف مورد ارزیابی قرار دادند. علاوه بر این، پاگلیارا و همکاران (۱۶) آبشستگی به دلیل وجود ارتفاع مانع سنگی درون کانال‌های افقی و خم روباز را به صورت آزمایشگاهی مورد ارزیابی قرار دادند. آنها کلیه آزمایش‌ها را درون کانال‌های افقی در شرایط آب زلال اجرا کردند. در این مطالعه چند رابطه تجربی مفید برای بررسی مورفولوژی بستر توسط نویسندگان ارائه شد. همچنین، پاگلیارا و کردستانی (۱۴) مقادیر آبشستگی در مجاورت سرریزهای تنه درختی را به صورت آزمایشگاهی مورد مطالعه قرار دادند. آنها الگوی آبشستگی در اطراف این نوع از سازه‌ها را برای آرایش-

مختلفی برای محافظت کناره‌ها و بستر رودخانه‌ها در برابر آبشستگی استفاده گردیده است که یکی از این روش‌ها استفاده از سرریزهای سنگی است. سرریزهای سنگی در مقایسه با سایر سازه‌های محافظ بستر رودخانه‌ها از اهمیت بیشتری برخوردار است زیرا آنها؛ با توجه به جنس این نوع از سازه که از سنگ است کاملاً با ساختار رودخانه‌ها سازگار بوده و باعث آلودگی زیست محیطی نمی‌شوند. با استفاده از آنها محل عبور ماهی‌ها در کلیه بخش‌های جریان کاملاً حفظ می‌شود. علاوه بر این، کاهش هزینه‌های ساخت و نگهداری در مقایسه با سازه‌های محافظ معمولی از مهمترین مزایای سرریزهای سنگی محسوب می‌شوند. بنابراین، با توجه به اهمیت این نوع از سازه‌های محافظ مطالعات آزمایشگاهی و تئوریک فراوانی بر روی الگوی جریان در مجاورت آنها صورت گرفته است (پاگلیارا و همکاران ۱۷). به عنوان مثال، پاگلیارا و همکاران (۱۷) ابعاد حفره آبشستگی در مجاورت سرریزهای سنگی J شکل درون یک کانال مستطیلی روباز در شرایط آب زلال به صورت آزمایشگاهی اندازه‌گیری کردند. آنها روابطی را برای تخمین حداکثر عمق حفره آبشستگی ارائه کردند و نشان دادند که این روابط دارای دقت خوبی بودند. در ادامه، پاگلیارا و کردستانی (۱۲) با انجام یک تحقیق آزمایشگاهی، مقدار آبشستگی در پائین دست سرریزهای سنگی به شکل I و U درون کانال‌های با سطح مقطع مستطیلی روباز را اندازه‌گیری کردند. آنها با انجام یک تحلیل ابعادی پارامترهای موثر بر روی عمق حفره آبشستگی را معرفی کردند و نشان دادند که مورفولوژی بستر رسوبی بر اساس شرایط هیدرولیکی جریان تغییر می‌کند. پاگلیارا و همکاران (۱۵) ابعاد حفره آبشستگی در مجاورت cross-vane structure به شکل W را در قالب یک تحقیق آزمایشگاهی اندازه‌گیری کردند. آنها با انجام تحلیل ابعادی، روابطی را برای محاسبه حداکثر عمق و طول حفره آبشستگی ارائه نمودند و با مقایسه نتایج روابط مذکور با مقادیر آزمایشگاهی نشان

مدل ANFIS، الگوریتم ژنتیک و تجزیه مقادیر منفرد مقادیر آبشستگی در مجاورت تکیه‌گاه پل با شکل‌های مختلف را شبیه‌سازی نمودند. آنها نشان دادند که عدد فرود جریان موثرترین پارامتر ورودی بر روی الگوی آبشستگی بود.

با بررسی مطالعات گذشتگان مشخص شد که به دلیل اهمیت موضوع محافظت از بستر و کرانه‌های رودخانه‌ها مطالعات آزمایشگاهی و تحلیلی مختلفی بر روی عمق حفره آبشستگی در مجاورت سرریزهای سنگی با شکل‌های مختلف انجام شده است. علاوه بر این، تاکنون عمق آبشستگی در اطراف سرریزهای سنگی با شکل‌های I، J و U درون کانال‌های خم با استفاده از مدل‌های هوش مصنوعی و محاسبات نرم انجام نشده است. به‌عنوان نوآوری این مطالعه، عمق آبشستگی در مجاورت سرریزهای سنگی با شکل‌های I، J و U درون کانال‌های خم با استفاده از یک روش نوین هوش مصنوعی تحت عنوان ساختار تعمیم‌یافته روش گروه دسته‌بندی داده‌ها (GSGMDH) برای اولین بار شبیه‌سازی می‌شود. این روش جدید در مقایسه با روش روش گروه دسته‌بندی داده‌ها (GMDH) دارای دقت بیشتر و انعطاف‌پذیری بهتری است به‌گونه‌ای که گره‌های لایه‌های میانی این روش می‌توانند از گره‌های غیر همجوار نیز ورودی بگیرند. با شبیه‌سازی عمق آبشستگی، مدل برتر معرفی خواهد شد و با انجام تحلیل حساسیت موثرترین پارامترهای ورودی شناسایی می‌گردند. همچنین، یک رابطه برای تخمین عمق آبشستگی ارائه می‌شود.

مواد و روش‌ها

روش دسته‌بندی گروهی داده‌ها (GMDH¹)

GMDH یک روش خودسازمانده² است که با استفاده از مجموعه‌ای از نرون‌ها، مدل‌های مختلفی را ارائه می‌دهد. این نرون‌ها از طریق یک چند جمله‌ای درجه دوم


های مختلف سازه‌های محافظ اندازه‌گیری نمودند. در ادامه، کردستانی و پاگلپارا (۸) الگوی آبشستگی در پائین-دست سرریزهای سنگی به شکل U را درون کانال‌های خم مورد مطالعه آزمایشگاهی قرار دادند. آنها با تجزیه و تحلیل نتایج آزمایشگاهی خود آبشستگی در مجاورت این نوع از سازه‌ها را به سه نوع مورفولوژی مختلف تقسیم‌بندی نمودند. کردستانی و همکاران (۷) با استفاده از یک مدل عددی الگوی جریان و مورفولوژی بستر رسوبی درون کانال‌های خم دارای سرریز سنگی را شبیه‌سازی نمودند. آنها برای شبیه‌سازی میدان جریان از یک مدل بر مبنای معادلات ناویر استوکس متوسط‌گیری شده رینولدز در شرایط غیردائمی استفاده کردند. آنها نتایج مدل عددی را با مقادیر مشاهداتی اعتبارسنجی نمودند.

در سال‌های اخیر الگوریتم‌های مختلف هوش مصنوعی برای مدل‌سازی پدیده‌های مختلفی مورد استفاده قرار گرفته‌اند. همچنین این مدل‌های عددی توانایی قابل قبولی در تخمین و شبیه‌سازی ابعاد حفره آبشستگی در مجاورت سازه‌های مختلف مانند پایه‌های پل، تکیه‌گاه‌ها، صفحات مستغرق و غیره دارند. به‌عنوان مثال، نجفی زاده (۱۰) با استفاده از روش دسته‌بندی گروهی داده‌ها عمق حفره آبشستگی در اطراف گروه پایه‌های پل در شرایط آب زلال را شبیه‌سازی کرد. علاوه بر این، عظیمی و همکاران (۴) یک روش هوش مصنوعی ترکیبی برای شبیه‌سازی عمق آبشستگی در مجاورت پایه‌های پل دایروی شکل توسعه دادند. آنها مدل ANFIS را با استفاده از تکامل تفاضلی و تجزیه مقادیر منفرد بهینه‌سازی نمودند و نشان دادند که این مدل توانایی خوبی در تخمین پدیده آبشستگی داد. علاوه بر این، شعبانلو و همکاران (۱۹) الگوی آبشستگی در پائین‌دست صفحات مستغرق را توسط مدل برنامه‌نویسی بیان ژن شبیه‌سازی نمودند. آنها نتایج مدل هوش مصنوعی را با مقادیر آزمایشگاهی مقایسه نمودند و یک رابطه برای محاسبه عمق آبشستگی ارائه دادند. در ادامه نیز عظیمی و همکاران (۳) با ترکیب

¹ Group Method of Data Handling (GMDH)

² self-organize

ضرایب رابطه فوق (a_i) با استفاده از روش‌های رگرسیونی به گونه‌ای محاسبه می‌شوند که اختلاف بین خروجی واقعی (y) و مقدار محاسبه شده \hat{y} برای هر جفت متغیر ورودی x_i and x_j حداقل شود (ایواخنینکو (۵). بنابراین، مجموعه ضرایبی از چند جمله‌ای‌های درجه دو ارائه شده به صورت رابطه (۵)، محاسبه می‌شود. این ضرایب برای هر تابع G_i (هر نون ساخته شده در مدل-سازی) به منظور حداقل کردن خطای کل نرون‌ها برای بهینه شدن ورودی‌ها بر تمام جفت مجموعه‌های چند ورودی، یک خروجی بدست می‌آید. شکل کلی شماتیک یک شبکه عصبی از نوع GMDH به شرح زیر می‌باشد.



شکل ۱. شماتیک شبکه عصبی GMDH

در واقع روند مدل‌سازی به گونه‌ای ادامه می‌یابد که رابطه زیر حداقل شود:

$$E = \frac{1}{M} \sum_{i=1}^M (y_i - G_i)^2 \rightarrow \text{Min} \quad (6)$$

در شکل پایه الگوریتم GMDH، تمامی نرون‌ها از n متغیر ورودی ساخته می‌شوند و ضرایب مجهول کلیه نرون‌ها با استفاده از روش حداقل مربعات^۲ بدست می‌آیند. بنابراین تعداد $\binom{n}{2} = \frac{n(n-1)}{2}$ نرون در اولین لایه مخفی به این صورت ساخته می‌شود.

$$\{(y_i, x_{ip}, x_{iq}) \mid (i=1,2,\dots,M) \& (p,q \in \{1,2,\dots,n\})\}$$

به یکدیگر متصل هستند که منجر به تولید نرون در لایه-های بعد می‌شود. هدف اصلی GMDH یافتن تابع تقریبی \hat{f} با خروجی \hat{y} برای مجموعه‌ای از ورودی‌ها به صورت $x = (x_1, x_2, \dots, x_n)$ است بطوریکه تابع ارائه شده مقادیر \hat{y} را با کمترین مقدار خطا نسبت به مقادیر واقعی y برآورد کند. برای M داده آزمایشگاهی که شامل n متغیر ورودی و یک خروجی می‌باشد، مقدار خروجی واقعی (y_i) به صورت زیر می‌باشد:

$$y_i = f(x_{i1}, x_{i2}, \dots, x_{in}) \quad (i=1,2,\dots,M)$$

مقادیر خروجی شبکه GMDH در مرحله آموزش

مدل به صورت رابطه زیر بیان می‌شود:

$$\hat{y}_i = \hat{f}(x_{i1}, x_{i2}, \dots, x_{in}) \quad (i=1,2,\dots,M) \quad (2)$$

در ادامه جهت رسیدن به یک جواب بهینه، باید مربع خطای ناشی از اختلاف مقادیر واقعی و آموزش دیده، به صورت رابطه زیر حداقل شود:

$$E = \sum_{i=1}^M (\hat{f}(x_{i1}, x_{i2}, \dots, x_{in}) - y_i)^2 \rightarrow \text{Min} \quad (3)$$

در شبکه GMDH ارتباط بین متغیرهای ورودی و خروجی را می‌توان به صورت چند جمله‌های پیچیده‌ای موسوم به چند جمله‌ای کولموگراف-گابور^۱ به صورت زیر بیان کرد:

$$\hat{y} = a_0 + \sum_{i=1}^m a_i x_i + \sum_{i=1}^m \sum_{j=1}^m a_{ij} x_i x_j + \sum_{i=1}^m \sum_{j=1}^m \sum_{k=1}^m x_j a_{ijk} x_i x_j x_k + \dots \quad (4)$$

بازنویسی رابطه فوق با استفاده از دو نرون، منجر به ارائه یک رابطه ساده به صورت زیر می‌شود:

$$\hat{y} = G(x_i, x_j) = a_0 + a_1 x_i + a_2 x_j + a_3 x_i^2 + a_4 x_j^2 + a_5 x_i x_j \quad (5)$$

² least square

¹ Kolmogorv-Gabor Polynomial

می‌شود. در محاسبه بردار ضرایب با استفاده از روش حداقل مربعات، احتمال بروز خطای ناشی از گرد کردن خطا و یا تکینی در معادلات وجود دارد. در نتیجه، جهت حل مسائله حداقل مربعات در این مطالعه، از روش تجزیه مقدار منفرد استفاده می‌شود. در روش تجزیه مقدار منفرد ماتریس $A \in R^{M \times 6}$ به صورت زیر تعریف می‌شود:

(۱۳)

$$A = UWV^T$$

ماتریس فوق شامل سه ماتریس متعامد ($V \in R^{6 \times 6}$)، ماتریس متعامد ستونی ($U \in R^{M \times 6}$)، و یک ماتریس غیرمنفی قطری ($W \in R^{6 \times 6}$) است. جهت برآورد ضرایب رابطه ۵، شکل اصلاح شده معکوس ماتریس W به شکل زیر تعیین می‌شود:

(۱۴)

$$a = V \left[\text{diag} \left(\frac{1}{W_j} \right) \right] U^T Y$$

ساختار تعمیم‌یافته روش گروه دسته‌بندی داده‌ها (GSGMDH)^۱

هر چند که GMDH از توانایی بالا در مدل‌سازی مسائل غیرخطی برخوردار است، اما این روش نیز مانند هر روشی در کنار مزیت‌هایی که دارد، دارای معایبی نیز می‌باشد. وجود معایب موجود در GMDH تاثیر قابل توجهی بر نتایج ارائه شده توسط این مدل دارد بطوری‌که بعضاً به طور قابل توجهی دقت مدل‌سازی را کاهش می‌دهد. از جمله مهمترین معایب این روش، می‌توان موارد زیر را بیان کرد:

- ۱) ساختار چند جمله‌ای تعریف شده (رابطه ۷). این چند جمله‌ای از مرتبه دو می‌باشد بطوری‌که در هر چند جمله‌ای، تنها دو نرون ورودی قرار دارد.
- ۲) نرون‌های ورودی در هر لایه، تنها از لایه‌های مجاور انتخاب می‌شوند.

بنابراین در رابطه ۵، برای هر تعداد M داده سه‌گانه به صورت زیر است:

(۷)

$$\begin{bmatrix} x_{1p} & x_{1q} & \vdots & y_1 \\ x_{2p} & x_{2q} & \vdots & y_2 \\ \dots & \dots & \dots & \dots \\ x_{Mp} & x_{Mq} & \vdots & y_M \end{bmatrix}$$

برای هر ردیف، می‌توان ماتریس معادلات زیر را نوشت:

(۸)

$$Aa = y$$

که در آن:

(۹)

$$a = \{a_0, a_1, a_2, a_3, a_4, a_5\}$$

$$y = \{y_1, y_2, \dots, y_M\}^T$$

(۱۰)

$$A = \begin{bmatrix} 1 & x_{1p} & x_{1q} & x_{1p}x_{1q} & x_{1p}^2 & x_{1q}^2 \\ 1 & x_{2p} & x_{2q} & x_{2p}x_{2q} & x_{2p}^2 & x_{2q}^2 \\ 1 & x_{3p} & x_{3q} & x_{3p}x_{3q} & x_{3p}^2 & x_{3q}^2 \\ \dots & \dots & \dots & \dots & \dots & \dots \\ 1 & x_{Mp} & x_{Mq} & x_{Mp}x_{Mq} & x_{Mp}^2 & x_{Mq}^2 \end{bmatrix}$$

روش حداقل مربعات با استفاده از آنالیز رگرسیون چندگانه، ضرایب رابطه درجه دو (a_i) را به شکل زیر ارائه می‌دهد:

(۱۲)

$$a = (A^T A)^{-1} A^T Y$$

با استفاده از رابطه فوق بردار ضرایب مجهول چند جمله‌ای ارائه شده به صورت رابطه ۵ برای مجموعه‌ای از M ردیف سه‌تایی محاسبه می‌شود. این روند برای هر نرون و با توجه به شکل و ساختار شبکه عصبی تکرار

¹ Generalized structure of GMDH

علاوه بر این، روش GSGMDH توانایی اینکه ورودی های یک نرون را از لایه غیرمجاور (non-adjacent) انتخاب کند را داراست. شکل زیر، نمونه ای از مدلسازی GSGMDH که در آن ورودی یک نرون از لایه غیر مجاور می باشد را نشان می دهد. مشاهده می شود که نرون x_6 دارای ۳ ورودی و نرون x_7 دارای دو ورودی است. علاوه بر این، نرون x_8 که خروجی مساله است، سه ورودی x_3 ، x_7 and x_6 را می پذیرد. واضح است که x_3 از یک لایه غیرمجاور گرفته شده است.

معیارهای بررسی دقت مدل های عددی

در مطالعه حاضر به منظور ارزیابی دقت مدل های عددی معرفی شده از شاخص های آماری ضریب همبستگی (R)، شاخص عملکرد (VAF)، خطای مربعات میانگین ریشه ($RMSE$)، شاخص پراکندگی (SI)، خطای مطلق میانگین (MAE) و ضریب بهره وری نش ساتکلیف (NSC) به صورت زیر استفاده می گردد:

(۱۶)

$$R = \frac{\sum_{i=1}^n (F_i - \bar{F})(O_i - \bar{O})}{\sqrt{\sum_{i=1}^n (F_i - \bar{F})^2 \sum_{i=1}^n (O_i - \bar{O})^2}}$$

(۱۷)

$$VAF = \left(1 - \frac{\text{var}(F_i - O_i)}{\text{var}(F_i)}\right) \times 100$$

(۱۸)

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (F_i - O_i)^2}$$

(۱۹)

$$SI = \frac{RMSE}{O}$$

(۲۰)

$$MAE = \frac{1}{n} \sum_{i=1}^n |F_i - O_i|$$

(۲۱)

به توجه به دو مورد بیان شده، برای مسائلی که دارای پیچیدگی زیادی می باشند، استفاده از چند جمله ای ها با مرتبه دو ممکن است نتایج قابل قبولی را ارائه ندهد. همچنین در نظر گرفتن دو ورودی برای هر نرون، منجر به افزایش تعداد نرون ها جهت دستیابی به مدل قابل قبول می شود. استفاده از نرون های لایه مجاور (adjacent) سبب افزایش تعداد چند جمله های تولید شده می شود. بنابراین، وجود این مسائل تاثیر قابل توجهی بر دقت و سادگی مدل های ارائه شده دارد. از این رو در این مطالعه، اقدام به ارائه مدلی تحت عنوان ساختار تعمیم یافته (GSGMDH) می شود. مدل GSGMDH در محیط نرم افزار MATLAB کدنویسی شده است. مدل ارائه شده ساختار کلی GMDH را تغییر می دهد بطوریکه این مدل به طور همزمان تمامی حالات ممکن در دستیابی به بهترین و ساده ترین مدل موجود با استفاده از چند جمله ای هایی از مرتبه ۲ و ۳ و همچنین استفاده از دو و سه ورودی در هر نرون را مورد بررسی قرار می هد و در نهایت با استفاده از شاخص AIC_C بهترین مدل را انتخاب می کند. در واقع چهار حالت می تواند اتفاق بیفتد: (۱) چندجمله ای مرتبه دو با دو ورودی، (۲) چندجمله ای مرتبه دوم با سه ورودی، چندجمله ای مرتبه سوم با دو ورودی و (۴) چندجمله ای مرتبه سوم با سه ورودی، در میان این چهار حالت، حالت اول عینا همان رابطه ارائه شده برای convectional GMDH (رابطه ۷) می باشد. بنابراین، شکل کلی چند جمله ای تعریف شده در این مطالعه به شکل زیر بیان می شود:

(۱۵)

$$y = v_0 + v_1 * x_{ik} + v_2 * x_{iq} + v_3 * x_{ip} + v_4 * x_{iq} * x_{ik} + v_5 * x_{ip} * x_{ik} + v_6 * x_{ip} * x_{iq} + v_7 * x_{ik} * x_{ik} + v_8 * x_{iq} * x_{iq} + v_9 * x_{ip} * x_{ip} + v_{10} * x_{ip} * x_{iq} * x_{ik} + v_{11} * x_{iq} * x_{ik} * x_{ik} + v_{12} * x_{iq} * x_{iq} * x_{ik} + v_{13} * x_{ip} * x_{ik} * x_{ik} + v_{14} * x_{ip} * x_{iq} * x_{iq} + v_{15} * x_{ip} * x_{ip} * x_{ik} + v_{16} * x_{ip} * x_{ip} * x_{iq} + v_{17} * x_{ik} * x_{ik} * x_{ik} + v_{18} * x_{iq} * x_{iq} * x_{iq} + v_{19} * x_{ip} * x_{ip} * x_{ip}$$


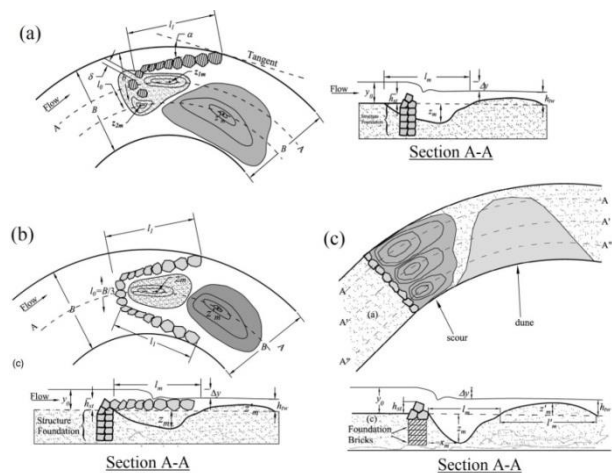

بهره گرفته می‌شود. مدل‌های آزمایشگاهی سرریزهای سنگی با شکل U و I درون یک کانال منحنی با سطح مقطع مستطیلی به طول ۱۵ متر ارتفاع ۰/۵ متر و عرض (B) مساوی ۰/۵ متر است. آنها در مطالعه خود مبادرت به اندازه‌گیری عمق آبستگي (Zm) در پائین‌دست تله سنگی با ارتفاع h_{st} و عرض b برای عدد فرودهای تراکمی مساوی F_d نمودند. همچنین اختلاف عمق جریان در بالادست و پائین‌دست تله سنگی برابر Δy است. طرح کلی مدل آزمایشگاهی مذکور در شکل ۲ قابل مشاهده است. لازم به ذکر است که پاگلیارا و کردستانی (۱۳)، پاگلیارا و همکاران (۱۶) و کردستانی و پاگلیارا (۸) بیان کرده‌اند که مقادیر آزمایشگاهی در شرایط جریان زلال اندازه‌گیری شده‌اند.

$$NSC = 1 - \frac{\sum_{i=1}^n (O_i - F_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2}$$

در اینجا O_i مقادیر مشاهداتی، F_i مقادیر تراز پیش-بینی شده به‌وسیله مدل‌های عددی، \bar{O} میانگین مقادیر مشاهداتی و n برابر تعداد مقادیر مشاهداتی است. در بخش‌های بعدی، در ابتدا توابع فعال‌سازی مختلف مورد بررسی قرار می‌گیرند. سپس با انجام یک تحلیل حساسیت، مدل برتر و موثرترین پارامترهای ورودی شناسایی می‌شوند. علاوه بر این، مدل برتر GSGMDH با مدل GMDH مقایسه می‌گردد.


مدل فیزیکی

برای صحت‌سنجی نتایج مدل‌های عددی از مقادیر آزمایشگاهی اندازه‌گیری شده توسط پاگلیارا و کردستانی (۱۳)، پاگلیارا و همکاران (۱۶) و کردستانی و پاگلیارا (۸)



شکل ۲. طرح کلی مدل آزمایشگاهی سرریزهای سنگی درون کانال منحنی (a) شکل J (b) شکل U (c) شکل I

ترکیب پارامترهای بدون بعد معادله ۱۸ نشان داده شده است. لازم به ذکر است که برای آموزش مدل‌های عددی از ۷۰ درصد داده‌ها و برای تست آنها از ۳۰ درصد مقادیر مشاهداتی استفاده گردیده است.



شکل ۳. نحوه ترکیب پارامترهای ورودی برای توسعه مدل‌های عددی مختلف

بحث و نتایج

نتایج مدل‌های GMDH

در این قسمت به بررسی کلیه مدل‌های عددی GMDH پرداخته می‌شود. همان‌گونه که در قسمت قبل بیان شد، برای شناسایی مدل برتر و موثرترین پارامتر ورودی، با استفاده از پارامترهای ورودی شش مدل هوش مصنوعی مختلف تعریف شد. نتایج کلیه شاخص‌های آماری محاسبه شده برای کلیه مدل‌های GMDH در قالب شکل ۴ به تصویر کشیده شده است. مدل 1 GMDH مقادیر آبهستگی‌ها را بر حسب کلیه پارامترهای ورودی $(h_{tw}/h_{st}, F_d, \Delta y/h_{st}, B/R, \varphi)$ شبیه‌سازی می‌کند. این مدل دارای دقت بالاتری در مقایسه با سایر مدل‌های GMDH است. به‌عنوان مثال، در وضعیت آموزش برای مدل 1 GMDH مقادیر VAF، MAE و NSC به ترتیب مساوی با 0.233، 0.646 و 74.451 محاسبه شده‌اند. این در حالی است که برای شرایط تست این مدل، مقادیر شاخص‌های آماری RMSE و SI به ترتیب مساوی با ۰/۲۷۷ و ۰/۲۵۲ بدست آمده‌اند. برای مدل 2 GMDH مقادیر SI، RMSE و MAE در شرایط تست به ترتیب

عمق آبهستگی در مجاورت سرریزهای سنگی

پاگیلارا و کردستانی (۱۳)، پاگیلارا و همکاران (۱۶) و کردستانی و پاگیلارا (۸) در مطالعه آزمایشگاهی بیان نمودند پارامترهایی که بر روی آبهستگی در پائین دست تله‌های سنگی موثر می‌باشند عبارتند از: عمق آبهستگی (Z_m) ، ارتفاع تله سنگی (h_{st}) ، عمق پایاب (h_{tw}) ، طول سرریز سنگی (l) ، عرض کانال (B) ، اختلاف عمق جریان در بالادست و پائین دست تله سنگی برابر (Δy) ، دبی جریان (Q) ، چگالی رسوب و آب (ρ_s, ρ) ، شتاب گرانش (g) و قطر متوسط رسوبات (d_{50}) ، شعاع خم کانال (R) بنابراین رابطه ۴-۱ به صورت زیر بیان نوشته می‌شود:

$$(22)$$

$$f(Z_m, h_{st}, h_{tw}, l, B, \Delta y, Q, \rho_s, \rho, g, d_{50}, R) = 0$$

آنها با آنالیز ابعادی نشان داد که آبهستگی در پائین دست سازه سنگی تابعی از پارامترهای بدون بعد زیر است:

$$(23)$$

$$Z_m/h_{st} = f(l/B, h_{tw}/h_{st}, F_d, \Delta y/h_{st}, B/R)$$

در مطالعات آزمایشگاهی انجام شده توسط پاگیلارا و کردستانی (۱۳)، پاگیلارا و همکاران (۱۶) و کردستانی و پاگیلارا (۸) مقدار پارامتر l گزارش نشده است. علاوه بر این، ضریب شکل سرریزهای سنگی با شکل I و U نیز با φ نشان داده می‌شود. بنابراین معادله ۱۷ به صورت زیر بازنویسی می‌شود:


$$(24)$$

$$Z_m/h_{st} = f(h_{tw}/h_{st}, F_d, \Delta y/h_{st}, B/R, \varphi)$$


در اینجا F_d عدد فرود تراکمی می‌باشد بنابراین در این مطالعه، پارامترهای معادله 20 به‌عنوان پارامترهای ورودی در نظر گرفته می‌شود. به بیان دیگر در این مطالعه ۶ مدل عددی با استفاده از ترکیب‌های مختلف به منظور شناسایی پارامتر موثر معرفی می‌شود. در شکل ۳ نحوه

تخمین زده شده‌اند. برای شبیه‌سازی مقادیر آبستگي‌ها توسط مدل GMDH 4 از پارامترهای بدون بعد $h_{tw}/h_{st}, F_d, B/R, \varphi$ استفاده می‌شود و تاثیر پارامتر بدون بعد $\Delta y/h_{st}$ حذف گردیده است. لازم به ذکر است که برای مدل GMDH 5 مقادیر شاخص‌های آماری RMSE, VAF و SI در شرایط آموزش به ترتیب با ۰/۵۷۲, ۶/۵۰۷ و ۰/۵۲۹ تخمین زده شده است. علاوه بر این، برای وضعیت تست این مدل مقادیر MAE و NSC به ترتیب مساوی 0.516 و -0.914 بدست آمده است. برای تخمین مقادیر آبستگي توسط مدل GMDH 5 از پارامترهای بدون بعد $h_{tw}/h_{st}, \Delta y/h_{st}, B/R, \varphi$ استفاده می‌گردد و تاثیر پارامتر F_d نادیده گرفته شده است. در مقابل، مدل GMDH 6 مقادیر تابع هدف را توسط پارامترهای ورودی شامل $F_d, \Delta y/h_{st}, B/R, \varphi$ شبیه‌سازی می‌نماید و برای مدل مذکور تاثیر پارامتر h_{tw}/h_{st} حذف شده است. برای مدل مذکور در وضعیت تست مقادیر MAE و SI به ترتیب مساوی با ۰/۵۶۱ و ۰/۶۱۲ محاسبه شده است.

برابر با ۰/۵۴۱, ۰/۵۹۴ و ۰/۵۱۱ تخمین زده شده‌اند. علاوه بر این برای وضعیت آموزش این مدل مقادیر NSC و VAF به ترتیب برابر با -۰/۹۱۱ و -۱۱/۵۱۷ هستند. لازم به ذکر است که برای شبیه‌سازی آبستگي توسط این مدل پارامترهای ضریب شکل یا φ حذف شده و این مدل تابعی از $h_{tw}/h_{st}, F_d, \Delta y/h_{st}, B/R$ می‌باشد. همچنین برای وضعیت آموزش مدل GMDH 3 مقادیر RMSE و MAE به ترتیب مساوی با ۰/۵۸۲ و ۰/۴۳۹ تخمین زده شده‌اند. در مقابل، برای وضعیت تست این مدل هوش مصنوعی، مقادیر VAF, SI و NSC به ترتیب مساوی با ۹/۳۴۳, ۰/۵۷۴ و -۰/۳۸۴ بدست آمده‌اند. مدل GMDH 3 مقادیر تابع هدف را توسط پارامترهای $h_{tw}/h_{st}, F_d, \Delta y/h_{st}, \varphi$ پیش‌بینی نموده است و تاثیر پارامتر B/R برای آن نادیده گرفته شده است. این در حالی است که برای مدل GMDH 4 در شرایط آموزش مقادیر VAF و RMSE به ترتیب مساوی با ۳۱/۳۸۴ و ۰/۵۰۲ هستند و مقادیر شاخص‌های MAE و NSC برای شرایط تست نیز به ترتیب برابر با ۰/۵۴۳ و -۰/۵۹۴



شکل ۴: نتایج شاخص‌های آماری محاسبه شده برای مدل‌های مختلف GMDH

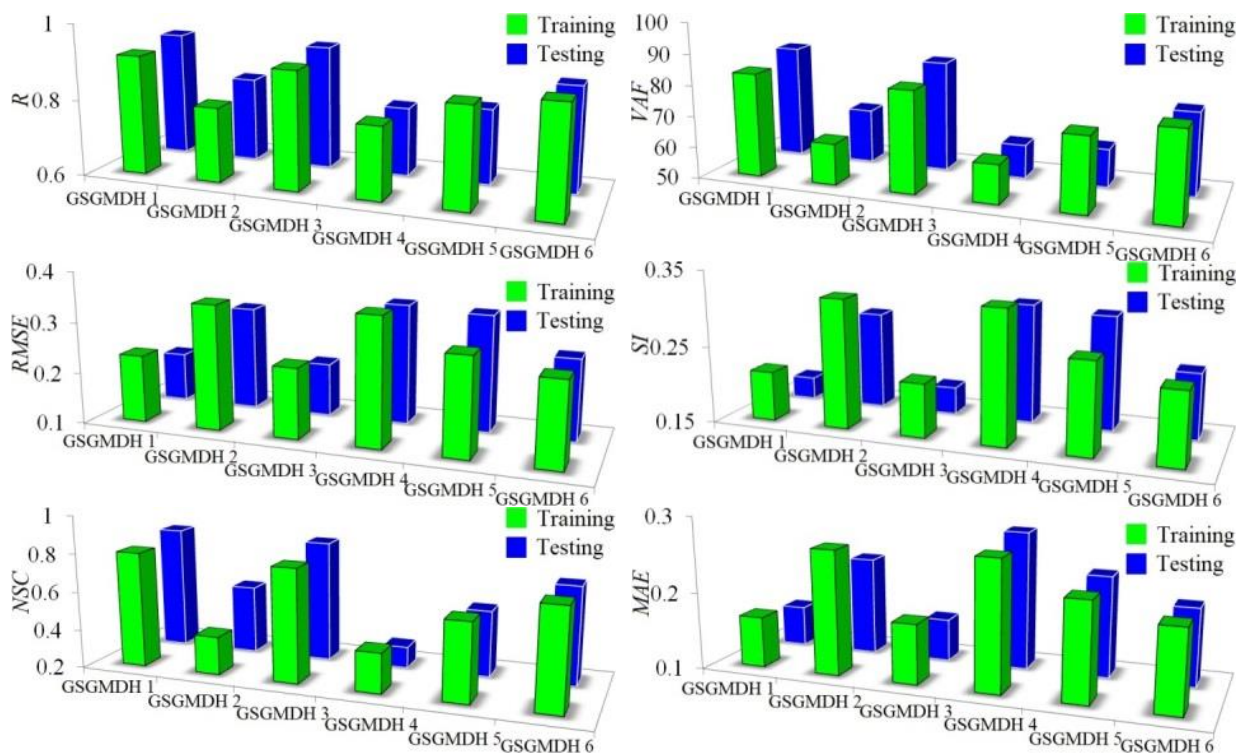


شکل ۵. مقایسه مقادیر آبستگي شبیه‌سازی شده توسط مدل برتر GMDH با مقادیر مشاهداتی

مدل‌های GSGMDH

در این بخش به ارزیابی دقت مدل‌های GSGMDH مختلف پرداخته می‌شود. مقایسه کلیه شاخص‌های آماری محاسبه شده مدل‌های GSGMDH در قالب شکل ۶ قابل مشاهده است. لازم به ذکر است که در میان کلیه مدل‌های GSGMDH، مدل 1 GSGMDH دارای بیشترین دقت و کمترین خطا است. علاوه بر این، مقادیر RMSE، MAE و SI برای شرایط آموزش این مدل به ترتیب برابر با ۰/۲۳۲، ۰/۱۶۶ و ۰/۲۱۴ محاسبه شده‌اند. مقدار شاخص VAF مدل 1 GSGMDH برای وضعیت آموزش در مقایسه با مدل 1 GMDH حدوداً 12 درصد بهبود یافته است. همچنین مقادیر NSC این مدل در وضعیت تست مساوی با ۰/۸۴۲ تخمین زده شده است. برای وضعیت آموزش مدل 2 GSGMDH مقادیر NSC و MAE به ترتیب برابر با 0.397 و 0.263 بدست آمده است. لازم به ذکر است که شاخص VAF برای وضعیت آموزش مدل 2 GSGMDH در مقایسه با مدل 2 GMDH به شکل قابل توجهی افزایش یافت. علاوه بر این، برای مدل 3 GSGMDH در شرایط تست، مقادیر شاخص‌های آماری NSC، SI و MAE به ترتیب برابر با ۰/۸۲۹، ۰/۱۸۶ و ۰/۱۵۵ بدست آمده‌اند. این در حالی است که شاخص VAF در شرایط آموزش مدل 3 GSGMDH در مقایسه با مدل 3 GMDH حدوداً ۴۱ برابر بهبود یافته است. باید خاطر نشان شود که در میان کلیه مدل‌های GSGMDH، مدل 4 GSGMDH دارای بیشترین خطا و کمترین دقت

در شکل ۵ نیز به ترتیب مقایسه مقادیر آبستگي‌های شبیه‌سازی شده توسط مدل برتر GMDH با مقادیر مشاهداتی و نمودارهای پراکندگی این مدل‌ها قابل مشاهده است. بر اساس نتایج مدل‌سازی‌ها، مدل GMDH 1 دارای بیشترین دقت و کمترین خطا در میان کلیه مدل‌های GMDH است. برای مدل 1 GMDH مقدار ضریب همبستگی (R) در شرایط آموزش و تست به ترتیب مساوی با 0.863 و 0.855 بدست آمده است. این در حالی است که مقدار شاخص آماری R برای مدل‌های GMDH 2، 3 و 4 در شرایط تست به ترتیب مساوی با ۰/۱۹۱، ۰/۴۲۵ و ۰/۴۰۹ محاسبه شده‌اند. در مقابل برای وضعیت آموزش مدل‌های 5 GMDH و 6 GMDH مقدار ضریب همبستگی به ترتیب برابر با ۰/۳۷۱ و ۰/۴۲۳ تخمین زده شده است. بنابراین بر اساس نتایج مدل‌سازی تخمین عمق آبستگي در مجاورت سرریزهای سنگی درون کانال‌های خم توسط مدل GMDH، مدل 2 GMDH دارای کمترین مقدار همبستگی و بیشترین مقدار خطا است. علاوه بر این مدل 1 GMDH به عنوان مدل برتر معرفی می‌شود که مقادیر تابع هدف را بر حسب کلیه پارامترهای ورودی تخمین می‌زند. همچنین با توجه به نتایج مدل‌های GMDH، پارامترهای بدون ضریب شکل سرریزهای سنگی (ρ) و عدد فرود تراکمی به عنوان موثرترین پارامترهای ورودی شناسایی شدند.




شکل ۶. شاخص‌های آماری محاسبه شده برای مدل‌های مختلف GSGMDH

می‌باشد. به عبارت دیگر، مقادیر RMSE و MAE در وضعیت تست این مدل به ترتیب برابر با ۰/۳۳۵ و ۰/۲۷۹ در نظر گرفته شده‌اند. هر چند که مقدار شاخص VAF در وضعیت آموزش این مدل در مقایسه با مدل GMDH 4 تقریباً دو برابر شده است. همچنین، مقادیر شاخص‌های آماری NSC، MAE و SI برای مدل GSGMDH 5 شرایط تست به ترتیب برابر با ۰/۵۴۲، ۰/۲۳۱ و ۰/۲۹۸ هستند. این مدل در مقایسه با مدل GMDH 5 عملکرد بهتری برخوردار است به گونه‌ای که مقدار VAF آن برای وضعیت آموزش در مقایسه با GMDH 5 حدوداً ۱۱ برابر افزایش داشته است. برای مدل GSGMDH 6 در شرایط تست، مقادیر SI، MAE و RMSE به ترتیب برابر با ۰/۲۳۵، ۰/۲۰۱ و ۰/۲۵۹ تخمین زده شده‌اند. این در حالی است که شاخص آماری VAF در وضعیت آموزش و تست برای مدل GSGMDH 6 به ترتیب مساوی با ۷۸/۴۲۷ و ۷۶/۴۲۹ تخمین زده شده‌اند. بنابراین با توجه به نتایج مدل‌های GSGMDH، پارامترهای بدون بعد

به عنوان موثرترین پارامترهای ورودی مدل‌های GSGMDH شناسایی می‌شوند. در شکل ۷ نیز مقایسه مقادیر آبستگی‌های شبیه‌سازی شده و مشاهداتی و نمودارهای پراکندگی‌های کلیه مدل برتر GSGMDH به تصویر کشیده شده است. لازم به ذکر است که مقدار ضریب همبستگی برای مدل GSGMDH 1 در هر دو وضعیت آموزش و تست به ترتیب مساوی با ۰/۹۱۳ و ۰/۹۳۰ محاسبه گردیده است. علاوه بر این، برای شرایط تست مدل‌های GSGMDH 2 و GSGMDH 3 نیز مقدار شاخص آماری R به ترتیب مساوی با ۰/۸۲۱ و ۰/۹۲۴ تخمین زده شده‌اند. همچنین، مقدار R برای مدل‌های GSGMDH 4، GSGMDH 5 و GSGMDH 6 در شرایط آموزش به ترتیب برابر با ۰/۷۹۰، ۰/۸۶۰ و ۰/۸۸۶ بدست آمده‌اند. بنابراین، با توجه به نتایج مدل‌های هوش مصنوعی، کلیه مدل‌های GSGMDH در مقایسه با مدل‌های GMDH از عملکرد بهتری برخوردار هستند و مقادیر تابع هدف را با دقت بیشتری پیش‌بینی

می‌باشد. به عبارت دیگر، مقادیر RMSE و MAE در وضعیت تست این مدل به ترتیب برابر با ۰/۳۳۵ و ۰/۲۷۹ در نظر گرفته شده‌اند. هر چند که مقدار شاخص VAF در وضعیت آموزش این مدل در مقایسه با مدل GMDH 4 تقریباً دو برابر شده است. همچنین، مقادیر شاخص‌های آماری NSC، MAE و SI برای مدل GSGMDH 5 شرایط تست به ترتیب برابر با ۰/۵۴۲، ۰/۲۳۱ و ۰/۲۹۸ هستند. این مدل در مقایسه با مدل GMDH 5 عملکرد بهتری برخوردار است به گونه‌ای که مقدار VAF آن برای وضعیت آموزش در مقایسه با GMDH 5 حدوداً ۱۱ برابر افزایش داشته است. برای مدل GSGMDH 6 در شرایط تست، مقادیر SI، MAE و RMSE به ترتیب برابر با ۰/۲۳۵، ۰/۲۰۱ و ۰/۲۵۹ تخمین زده شده‌اند. این در حالی است که شاخص آماری VAF در وضعیت آموزش و تست برای مدل GSGMDH 6 به ترتیب مساوی با ۷۸/۴۲۷ و ۷۶/۴۲۹ تخمین زده شده‌اند. بنابراین با توجه به نتایج مدل‌های GSGMDH، پارامترهای بدون بعد



شکل ۷. مقایسه مقادیر آبخستگی شبیه‌سازی شده توسط مدل برتر GSGMDH با مقادیر مشاهداتی

می‌کنند. همچنین، در میان همه مدل‌های عددی، مدل GSGMDH 1 به‌عنوان مدل برتر شناسایی می‌شود. این مدل مقادیر آبخستگی‌ها را با استفاده از کلیه پارامترهای ورودی تخمین می‌زند. بر اساس تجزیه و تحلیل نتایج مدل‌های هوش مصنوعی، پارامترهای φ ، $\Delta y/h_{st}$ و عدد فرود تراکمی به‌عنوان موثرترین پارامترهای ورودی معرفی می‌شوند.

تحلیل عدم قطعیت

در این قسمت با انجام یک تحلیل عدم قطعیت نحوه عملکرد مدل‌های برتر مورد ارزیابی قرار خواهد گرفت. به‌طورکلی تحلیل عدم قطعیت یک تحلیل مفید جهت بررسی عملکرد مدل‌های عددی مورد استفاده قرار گرفته است (کریاسی و عظمت اله ۶، عظیمی و همکاران ۲، عظیمی و همکاران ۱). به عبارت دیگر، تحلیل عدم قطعیت برای سنجش خطای پیش‌بینی شده توسط مدل‌های عددی و بررسی نحوه عملکرد این مدل‌ها اجرا می‌شود. به طور کلی خطای پیش‌بینی شده توسط مدل عددی برابر است با مقادیر شبیه‌سازی شده توسط مدل عددی (P_i) منهای مقادیر مشاهداتی (O_i) است $(e_i = P_i - O_i)$. همچنین، میانگین خطای پیش‌بینی شده به صورت $\bar{e} = \sum_{i=1}^n e_i$ محاسبه می‌شود. همچنین، انحراف استاندارد مقادیر خطای پیش‌بینی شده به صورت

$$S_e = \sqrt{\sum_{i=1}^n (e_i - \bar{e})^2 / n - 1}$$

منفی بودن مقدار \bar{e} نشان می‌دهد که مدل عددی دارای عملکردی کمتر از مقدار واقعی است و مثبت بودن \bar{e} به معنای بیشتر از مقدار واقعی بودن مدل عددی است. همچنین، با استفاده از پارامترهای \bar{e} و S_e یک باند اطمینان در اطراف مقادیر خطای پیش‌بینی توسط روش ویلسون بدون اصلاح پیوسته ایجاد می‌شود. سپس با استفاده از $\pm 1/64 S_e$ به‌صورت تقریبی منجر به باند اطمینان می‌گردد. پارامترهای تحلیل عدم قطعیت مدل‌های برتر در در جدول ۱ قابل مشاهده است. در این جدول عرض باند عدم قطعیت با WUB و ۹۵ درصد خطای پیش‌بینی با PEI ۹۵٪ نشان داده می‌شود. با توجه به نتایج تحلیل عدم قطعیت، هر دو مدل GMDH 1 و GSGMDH 1 دارای عملکردی کمتر از مقدار واقعی هستند. همچنین، عرض باند عدم قطعیت برای مدل‌های GMDH 1 و GSGMDH 1 به‌ترتیب مساوی با ۰.۰۴۹- و ۰.۰۳۸- محاسبه شده است. علاوه بر این، PEI ۹۵٪ برای مدل GMDH 1 بین ۰/۰۴۹ تا ۰/۰۴۹- محاسبه گردیده است. این در حالی است که PEI ۹۵٪ برای مدل GSGMDH 1 بین ۰/۰۳۸ تا ۰/۰۳۸- تخمین زده شده است.

سال یازدهم / شماره ۱ / پاییز ۱۴۰۰

جدول ۱. نتایج تحلیل عدم قطعیت مدل‌های GMDH و GSGMDH

Model	Number of samples	\bar{e}	S_e	WUB	95% PEI
GMDH 1	۱۳۲	-۷/۳۱۷E-۱۷	۰/۲۸۵	-۰/۰۴۹	-۰/۰۴۹ تا ۰/۰۴۹
GSGMDH 1	۱۳۲	-۱/۲۰۰E-۰۵	۰/۲۲۳	-۰/۰۳۸	-۰/۰۳۸ تا ۰/۰۳۸

نتیجه‌گیری

با ۰/۱۹۶، ۰/۹۳۰ و ۰/۸۴۲ محاسبه شدند. تحلیل حساسیت نشان داد که موثرترین پارامترهای ورودی شامل ضریب شکل سرریزهای سنگی (ϕ)، نسبت اختلاف عمق جریان در بالادست و پائین‌دست تله سنگی برابر به ارتفاع سازه ($\Delta y/h_{st}$) و عدد فرود تراکمی (F_d) بودند. علاوه بر این، با توجه به نتایج تحلیل عدم قطعیت مدل‌های GMDH و GSGMDH دارای عملکرد کمتر از واقعی بودند. اگر چه مدل هوش مصنوعی استفاده شده در مطالعه حاضر، مقادیر آبشستگی در مجاورت سرریزهای سنگی را با دقت مناسبی تخمین زد، پیشنهاد می‌شود که مدل هوش مصنوعی ارائه شده برای تخمین آبشستگی در مجاورت سایر سازه‌ها نیز استفاده شود. علاوه بر این پیشنهاد می‌شود که در مطالعات آتی، از الگوریتم‌های بهینه‌سازی برای بهبود عملکرد مدل‌های هوش مصنوعی جهت شبیه‌سازی عمق آبشستگی استفاده گردد.

در این مقاله، برای اولین بار، یک روش هوش مصنوعی نوین با عنوان ساختار تعمیم یافته روش دسته‌بندی گروهی داده‌ها (GSGMDH) برای شبیه‌سازی عمق آبشستگی در مجاورت سرریزهای سنگی با شکل‌های I، U و J درون کانال‌های خم مورد استفاده قرار گرفت. این مدل جدید در مقایسه با روش کلاسیک GMDH از دقت بیشتر و انعطاف پذیری بهتری برای تخمین عمق آبشستگی برخوردار بود زیرا گره‌های لایه‌های میانی قادر بودند که از لایه غیر همجوار ورودی بگیرند. برای انجام شبیه‌سازی عمق آبشستگی، ابتدا با استفاده از مقادیر ورودی برای هر یک از مدل‌های GMDH و GSGMDH شش مدل متمایز تولید شد که تجزیه و تحلیل این مدل‌ها نشان داد که عملکرد مدل‌های GSGMDH بهتر بود. به عنوان مثال، مقادیر RMSE، R و NSC برای وضعیت تست مدل GMDH برتر به ترتیب مساوی با ۰/۲۷۷، ۰/۸۵۵ و ۰/۶۵۵ و برای مدل GSGMDH برتر به ترتیب مساوی

منابع مورد استفاده

- Azimi, H., Bonakdari, H. and Ebtehaj, I. 2019. Gene expression programming-based approach for predicting the roller length of a hydraulic jump on a rough bed. *ISH Journal of Hydraulic Engineering*, 1-11.
- Azimi, H., Bonakdari, H., Ebtehaj, I., Gharabaghi, B. and Khoshbin, F. 2018. Evolutionary design of generalized group method of data handling-type neural network for estimating the hydraulic jump roller length. *Acta Mechanica*, 229(3): 1197-1214.
- Azimi, H., Bonakdari, H., Ebtehaj, I., Shabanlou, S., Talesh, S.H.A. and Jamali, A. 2019. A pareto design of evolutionary hybrid optimization of ANFIS model in prediction abutment scour depth. *Sādhanā*, 44(7): 169.
- Azimi, H., Bonakdari, H., Ebtehaj, I., Talesh, S.H.A., Michelson, D.G. and Jamali, A. 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.
- Ivakhnenko, A.G. 1976. The group method of data handling in prediction problems. *Soviet Automatic Control*, 9(6): 21-30.
- Karbasi, M. and Azamathulla, H.M. 2016. GEP to predict characteristics of a hydraulic jump over a rough bed. *KSCE Journal of Civil Engineering*, 20(7): 3006-3011.
- Khosronejad, A., Kozarek, J.L., Diplas, P., Hill, C., Jha, R., Chatanantavet, P., Heydari, N. and Sotiropoulos, F. 2018. Simulation-based optimization of in-stream structures design: rock vanes. *Environmental Fluid Mechanics*, 18(3): 695-738.

- Kurdistani, S.M. and Pagliara, S. 2017. Experimental study on cross-vane scour morphology in curved horizontal channels. *Journal of Irrigation and Drainage Engineering*, 143(7): 04017013.
- Kurdistani, S.M. and Pagliara, S. 2015. Scour characteristics downstream of grade-control structures: Log-vane and log-deflectors comparison. In *World Environmental and Water Resources Congress, (1831-1840)*.
- Najafzadeh, M. 2015. Neuro-fuzzy GMDH systems based evolutionary algorithms to predict scour pile groups in clear water conditions. *Ocean Engineering*, 99: 85-94.
- Pagliara, S., Hassanabadi, L. and Kurdistani, S.M. 2015b. Clear water scour downstream of log deflectors in horizontal channels. *Journal of Irrigation and Drainage Engineering*, 141(9): 04015007.
- Pagliara, S. and Kurdistani, S.M. 2013. Scour downstream of cross-vane structures. *Journal of hydro-environment research*, 7(4): 236-242.
- Pagliara, S. and Kurdistani, S.M. 2015. Clear water scour at J-Hook Vanes in channel bends for stream restorations. *Ecological engineering*, 83: 386-393.
- Pagliara, S. and Kurdistani, S.M. 2017. Flume experiments on scour downstream of wood stream restoration structures. *Geomorphology*, 279: 141-149.
- Pagliara, S., Kurdistani, S.M. and Cammarata, L. 2013b. Scour of clear water rock W-weirs in straight rivers. *Journal of Hydraulic Engineering*, 140(4): 06014002.
- Pagliara, S., Kurdistani, S. M., Palermo, M. and Simoni, D. 2016. Scour due to rock sills in straight and curved horizontal channels. *Journal of hydro-environment research*, 10: 12-20.
- Pagliara, S., Kurdistani, S.M. and Santucci, I. 2013a. Scour downstream of J-Hook vanes in straight horizontal channels. *Acta Geophysica*, 61(5): 1211-1228.
- Pagliara, S., Sagvand Hassanabadi, L. and Mahmoudi Kurdistani, S. 2015a. Log-vane scour in clear water condition. *River Research and Applications*, 31(9): 1176-1182.
- Shabanlou, S., Azimi, H., Ebtehaj, I. and Bonakdari, H. 2018. Determining the scour dimensions around submerged vanes in a 180 bend with the gene expression programming technique. *Journal of Marine Science and Application*, 17(2): 233-240.



Prediction of Scour Around Cross-Vane Structures Using Generalized Structure of Group Method of Data Handling

Ebrahim Shahbazbigi¹, Fariborz Yosefvand^{2*}, Behrouz Yaghoubi³, Saeid Shabanlou⁴ and Ahmad Rajabi⁵

- 1) Ph.D. Candidate, Department of Water Engineering, Kermanshah Branch, Islamic Azad University, Kermanshah, Iran
2) Assistance Professor, Department of Water Engineering, Kermanshah Branch, Islamic Azad University, Kermanshah, Iran
3) Assistance Professor, Department of Water Engineering, Kermanshah Branch, Islamic Azad University, Kermanshah, Iran
4) Associate Professor, Department of Water Engineering, Kermanshah Branch, Islamic Azad University, Kermanshah, Iran
5) Assistance Professor, Department of Water Engineering, Kermanshah Branch, Islamic Azad University, Kermanshah, Iran
*Corresponding author email: fariborzosefvand@gmail.com

Received: 31-10-2020

Accepted: 16-05-2021

Abstract

In this study, for the first time, the scour pattern in the vicinity of cross-vane structures with I, U and J shapes in bending channels is simulated by a new artificial intelligence method called the "generalized structures group method of data handling" (GSGMDH). Compared to the group method of data handling (GMDH), the GSGMDH method is more flexible and accurate in which nodes can derive inputs from non-adjacent layers. Initially, all the parameters affecting the scour depth in the vicinity of cross-vane structures are identified and then using these parameters, six different models are defined for each of the GMDH and GSGMDH methods. After that, the data are divided into two main groups: training and test. In other words, 70% of the data are used to train artificial intelligence models and the remaining 30% are utilized to test them. By analyzing the results yielded by the artificial intelligence models, the superior models are introduced. The GMDH and GSGMDH superior models estimate the scour values in terms of all input parameters. In addition, the accuracy of the GSGMDH models is higher than the GMDH ones. For example, for the GMDH and GSGMDH superior models, the values of "variance accounted for" in the test, mode are calculated at 73.075 and 86.408, respectively. Also, the superior model forecasts the objective function values with acceptable accuracy. For example, the correlation coefficient (R), the scatter index (SI), and the Nash-Sutcliffe model efficiency coefficient (NSC) for the GSGMDH superior model in the training mode are approximated 0.913, 0.214 and 0.800, respectively. Based to the results of the sensitivity analysis, the shape factor (ϕ) of cross-vane structures, the ratio of the difference between the upstream and downstream flow depths to the height of the structure ($\Delta y/h_{st}$) and the densimetric Froude number (F_d) are introduced as the most effective input parameters. An uncertainty analysis exhibits that the GSGMDH superior model has an underestimated performance.

Keywords: Cross-Vane Structures, Scour, Modeling, Group Method of Data Handling, Uncertainty analysis, Partial derivative sensitivity analysis