

مدل‌سازی و تخمین ابعاد کانال‌های آبرفتی پایدار با استفاده از محاسبات نرم

بابک شاهی‌نژاد^{۱*}، عباس پارسائی^۲، علی حقی‌زاده^۳، آزاده ارشیا^۱ و زهرا شمسی^۱

(تاریخ دریافت: ۱۴۰۰/۵/۲۷؛ تاریخ پذیرش: ۱۴۰۰/۸/۲۶)

چکیده

در این پژوهش به منظور تخمین ابعاد هندسی کانال‌های آبرفتی پایدار شامل عرض سطح کانال (w)، عمق جریان (h) و شیب طولی (S) آنها از مدل‌های محاسبات نرم شامل مدل رگرسیون اسپلاین تطبیقی چندگانه (MARS) و مدل دسته‌بندی گروهی داده‌ها (GMDH) استفاده شد و نتایج مدل‌های توسعه داده شده با مدل شبکه عصبی چندلایه (MLP) مقایسه شد. برای توسعه مدل‌ها، پارامترهای دبی جریان (Q)، اندازه متوسط ذرات در کف و بدنه (d_{50}) و همچنین میزان تنش برشی (τ) به عنوان ورودی و از پارامترهای عرض سطح آب (w)، عمق جریان (h) و شیب طولی (S) به عنوان پارامترهای خروجی استفاده شد. مدل‌های محاسبات نرم در دو سناریو بر اساس پارامترهای خام و فرم بی‌بعد پارامترهای مستقل و وابسته، توسعه داده شدند. نتایج نشان داد که با توجه به مشخصات آماری در تخمین w عملکرد مربوط به مدل MARS است که شاخص‌های آماری دقت آن در مرحله آموزش عبارت از $R^2=0.902$, $RMSE=1.666$ و در مرحله آزمایش عبارت از $R^2=0.844$, $RMSE=2.317$ است. در تخمین عمق کانال، عملکرد هر دو مدل MLP و MARS تقریباً برابر است که هر دو بر اساس فرم بی‌بعد دبی جریان به عنوان متغیر ورودی، توسعه داده شدند. شاخص‌های آماری هر دو مدل در مرحله آموزش عبارت از $R^2 \approx 0.90$, $RMSE \approx 8.15$ و در مرحله آزمایش عبارت از $R^2 \approx 0.90$, $RMSE \approx 7.40$ است. بهترین عملکرد مدل‌های توسعه داده شده در تخمین شیب طولی کانال نیز مربوط به هر دو مدل MARS و GMDH است که البته به صورت جزئی، دقت مدل GMDH با شاخص‌های آماری $R^2=0.942$, $RMSE=0.0011$ در مرحله آموزش و $R^2=0.925$, $RMSE=0.0014$ در مرحله آزمایش بیشتر از مدل MARS است.

واژه‌های کلیدی: شبکه عصبی مصنوعی، مدل GMDH، مدل MARS، کانال فرسایشی، مدل رگرسیونی هوشمند

۱. گروه مهندسی آب، دانشکده کشاورزی و منابع طبیعی، دانشگاه لرستان، ایران

۲. گروه سازه های آبی، دانشکده مهندسی آب و محیط زیست، دانشگاه شهید چمران اهواز، اهواز، ایران

۳. گروه مهندسی آبخیزداری، دانشکده کشاورزی و منابع طبیعی، دانشگاه لرستان، ایران

*: مسئول مکاتبات: پست الکترونیکی: shahinejad.b@lu.ac.ir

مقدمه

رودخانه‌ها یک سیستم دینامیک (فعال) پایدار هستند که تغییرات سطح مقطع و عمق جریان در آنها و شیب طولی آنها در طول زمان به یک حالت تعادل می‌رسد. به رودخانه‌ها در این وضعیت، رودخانه‌هایی که فرایند رسوب‌گذاری و فرسایش در آنها به حالت تعادل رسیده است، رودخانه‌های رژیم هستند (۲).

شرایط رژیم بیانگر وجود یک تعادل دینامیکی در متوسط ابعاد آبراهه با زمان است. ابعاد هندسی کانال‌های پایدار به پارامترهای هیدرولیکی مختلفی مانند دبی جریان، اندازه ذرات رسوبات و خصوصیات رسوباتی که در بدنه یا کف کانال قرار گرفته‌اند، بستگی دارد که طراحی کانال‌های پایدار خاکی (فرسایش پذیر) را پیچیده می‌کند. مهم‌ترین پارامترهای هیدرولیکی مؤثر بر پایداری کانال‌های خاکی عبارت از عرض سطح آب، عمق متوسط جریان و شیب طولی کانال است (۱۹). روش‌های مختلف تجربی و تحلیلی توسط پژوهشگران مختلف به منظور تخمین ابعاد هندسی کانال‌های خاکی پایدار پیشنهاد شده است. در همه این روابط از عرض سطح آب و عمق جریان و شیب طولی کانال به عنوان خروجی استفاده شده است. سیمونز و آلبرتسون (۲۷) به ارزیابی مفهوم کانال آبرفتی پایدار با فرموله کردن عرض، عمق و شیب کانال برای رودخانه‌های مورد مطالعه با استفاده از روش‌های تجربی و آماری پرداختند. چانگ (۷) به مدل‌سازی رابطه بین عرض، عمق و شیب طولی کانال‌های آبرفتی با دبی جریان و اندازه متوسط ذرات (d_{50}) با استفاده از یک رابطه نمایی ریاضی پرداخت. افضل‌مهر (۱) به بررسی دقت روابط مختلف پیشنهاد شده برای تخمین ابعاد هندسی کانال‌های پایدار پرداخت. بدین منظور او داده‌های مربوط به ۲۸۰ رودخانه که در وضعیت پایدار قرار دارند را جمع‌آوری کرده و ۹ رابطه تجربی که به منظور تخمین ابعاد کانال‌های آبرفتی پایدار پیشنهاد شده‌اند را ارزیابی کرد و اظهار داشت که استفاده از دبی جریان غالب و اندازه متوسط ذرات برای تخمین عرض، عمق و به‌ویژه شیب طولی کافی نیست و

توصیه کرد که استفاده از تئوری لایه مرزی به‌منظور تخمین پارامتر شیلدز و ابعاد کانال آبرفتی پایدار قابل قبول است. افضل‌مهر و حیدرپور (۳) با استفاده از یک رگرسیون غیرخطی به تخمین ابعاد هندسی یک کانال آبرفتی شامل عرض، عمق و شیب طولی با استفاده از پارامترهای دبی، اندازه متوسط ذرات (d_{50}) و تنش برشی (τ) پرداختند. نتایج آنها نشان داد که روش‌های نظری نمی‌توانند روابط دقیق را فراهم کنند و خطاهای زیادی در پیش‌بینی دارند. اگرچه روابط رژیم توسط بسیاری از محققان ارائه شده است، اما این روابط برای یک آبراه خاص استخراج شده‌اند و با خطاهای زیادی برای سایر شرایط هیدرولیکی همراه هستند. در سال‌های اخیر، استفاده از مدل‌های محاسبات نرم در مدل‌سازی مسائل مهندسی هیدرولیک بسیار گسترش یافته است (۸، ۹، ۱۷، ۱۸). به‌عنوان مثال در مدل‌سازی و تخمین ابعاد هندسی چاله‌های آبشستگی در پایین‌دست سازه‌های آبی مثل پرتاب‌کننده‌های جامی شکل و لوله‌های انتقال آب (۱۵، ۱۶ و ۲۱)، دبی جریان در رودخانه‌ها بر پایه مفاهیم کانال مرکب (۲۰ و ۲۲) اشاره کرد. غلامی و همکاران (۱۱، ۱۲، ۱۳ و ۱۴) به‌طور گسترده، کاربرد مفهوم آنتروپی شانون و تسالیس را در تخمین شکل مشخصات بانکی کانال‌های پایدار بررسی کرده و به توانایی بالای آنتروپی در مقایسه با روش‌های قبلی اشاره کردند. غلامی و همکاران (۱۱) به مدل‌سازی و تخمین ابعاد هندسی کانال‌های آبرفتی پایدار (D ، W و S) با استفاده از روش دسته‌بندی گروهی داده‌ها (GMDH) بر اساس متغیرهای ورودی Q ، d_{50} و τ پرداختند. در مطالعات آنها دقت بالای مدل GMDH در مقایسه با تعداد زیادی از فرمول‌های تجربی مورد توجه قرار گرفت. آنها همچنین اظهار داشتند که روش یادگیری ماشین مانند GMDH می‌تواند گزینه‌ای مناسب به‌جای فرمول‌های تجربی باشد. سیدیان و همکاران (۲۳) به پیش‌بینی مشخصات هندسی کانال‌های پایدار با استفاده از مدل‌های محاسبات نرم شامل مدل شبکه عصبی نرو فازی و ماشین بردار پشتیبان پرداختند. نتایج تحقیقات آنها نشان داد که هر دو مدل به‌کار گرفته شده دارای

مواد و روش ها

در پژوهش حاضر به منظور تخمین ابعاد هندسی کانال های آبرفتی پایدار شامل عرض (W)، عمق جریان (h) و شیب طولی (S) از اطلاعات مربوط به دبی جریان (Q)، اندازه متوسط ذرات خاک (آبرفت) (d_{50}) و پارامتر شیلدز (τ) استفاده شده است (رابطه ۱). این رابطه در بسیاری از فرمول های تجربی و مدل های محاسبات نرم استفاده شده است:

$$w, h, S = f(Q, d_{50}, \tau) \quad (1)$$

بری (۶)، رابطه ۲ را برای کانال های آبرفتی در وضعیت رژیم توسعه داد:

$$\frac{w}{d_{50}}, \frac{h}{d_{50}}, S = f\left(\frac{Q}{(G_s - 1)^{0.5} g^{0.5} d_{50}^{2.5}}\right) \quad (2)$$

در این رابطه g شتاب ثقل و G_s چگالی نسبی است. به منظور تخمین پارامترهای نام برده شده، فرمول های تجربی و مدل های هوش مصنوعی مختلفی پیشنهاد شده است. در این پژوهش به منظور تخمین ابعاد هندسی کانال های آبرفتی پایدار از مدل های محاسبات نرم شامل مدل MARS و مدل GMDH استفاده شد و نتایج آنها با فرمول های تجربی و مدل شبکه عصبی به عنوان مدل پایه هوش مصنوعی در مطالعات مهندسی آب مقایسه شد.

به منظور توسعه مدل های محاسبات نرم تعداد ۸۵ داده از پژوهش منتشر شده در منابع علمی (۳) جمع آوری شد. مشخصات آماری داده های جمع آوری شده در جدول ۱ ارائه شده است.

شبکه عصبی چندلایه (MLP)

ساختار شبکه عصبی، ورودی های اعمال شده، تعداد لایه های مخفی، تعداد نورون های لایه ها، نحوه آموزش و تعداد بردارهای خروجی هر شبکه در ارزیابی عملکرد مدل، مؤثر است. در شبکه های از نوع انتشار برگشتی، قاعده مشخصی برای انتخاب لایه های پنهان و همچنین تعداد نورون ها در لایه پنهان وجود دارد و انتخاب تعداد نورون ها در لایه پنهان و همچنین تعداد لایه های پنهان با توجه به نوع مسئله تغییر می کند. در حل مسائل با توجه به تغییرات شدید داده ها، اغتشاش حاکم بر

دقت قابل قبولی در تخمین عرض، عمق و شیب طولی کانال های آبرفتی پایدار دارند. شقاقی و همکاران (۲۴، ۲۵ و ۲۶) به توسعه و ارزیابی مدل GMDH بر اساس دو الگوریتم بهینه ساز مختلف شامل الگوریتم ژنتیک (GA) و الگوریتم بهینه سازی ازدحام ذرات (PSO) پرداختند. آنها عملکرد مدل GMDH را با مدل برنامه نویسی بیان ژن (GEP) بر اساس ترکیب ورودی مختلف Q ، d_{50} و τ مقایسه کرد. آنها همچنین عملکرد تخمین مدل M5 Tree و ماشین بردار گرسیون پشتیبان (LSSVR) را در تخمین W ، D و S در کانال های پایدار بررسی کردند و به توانایی بالای مدل M5 Tree با میزان خطای کمتری نسبت به دو مدل دیگر در پیش بینی ابعاد کانال پایدار اشاره کردند. حفر کانال های آبرفتی و تقسیم دبی سیلاب بین رودخانه های موجود در سطح یک حوضه یکی از راه های کنترل سیلاب به شمار می آید؛ این عمل اصطلاحاً پخش بار سیلاب گفته می شود. طراحی و تخمین ابعاد این گونه کانال ها به موفقیت بیشتر پروژه های پخش و کنترل سیلاب، کمک فراوانی می کند. طراحی و تخمین ابعاد کانال های آبرفتی در محدوده وسیعی از پروژه های مهندسی آب و آبخیزداری اهمیت و کاربرد دارد. با توجه به اندرکنش جریان و رسوب در طراحی کانال های آبرفتی و همچنین پیچیده بودن این مسئله، استفاده از مدل های محاسبات نرم در مدل سازی و تخمین ابعاد هندسی کانال های آبرفتی پایدار اجتناب ناپذیر است. بررسی ها نشان می دهد که تاکنون عملکرد مدل های هوش مصنوعی شامل مدل رگرسیون اسپلاین تطبیقی چندگانه (MARS) و مدل دسته بندی گروهی داده ها (GMDH) در تخمین ابعاد هندسی کانال آبرفتی پایدار ارزیابی نشده است؛ لذا در پژوهش حاضر تلاش شده است که با استفاده از مدل های MARS و GMDH به مدل سازی و تخمین ابعاد هندسی کانال های آبرفتی پرداخته شود. گفتنی است که نتایج مدل های توسعه داده شده با مدل شبکه عصبی به عنوان یک مدل هوش مصنوعی پایه در مطالعات مهندسی آب مقایسه خواهد شد.

جدول ۱. مشخصات و دامنه پارامترهای هندسی در کانال پایدار

s	h	w	τ	d_{50}	
۸۵	۸۵	۸۵	۸۵	۸۵	تعداد مقادیر
۰	۰/۱۸	۵/۵۰	۰	۰	حداقل
۰/۰۳	۰/۵۷	۲۷	۰/۸۱	۰/۱۳	حداکثر
۰/۰۱	۰/۳۴	۱۴/۵۷	۰/۱۲	۰/۰۳	میانگین
۰	۰/۲۶	۱۰	۰/۰۱	۰/۰۱	چارک اول
۰/۰۱	۰/۴۰	۱۹	۰/۱۵	۰/۰۵	ربع سوم
۰	۰/۰۹	۵/۳۸	۰/۱۶	۰/۰۳	انحراف معیار

ریاضی رابطه پنهان بین متغیرهای ورودی و خروجی می‌پردازد. این نوروها از طریق یک چندجمله‌ای درجه دوم به یکدیگر متصل هستند که منجر به تولید نوروها در لایه‌های شبکه GMDH می‌شوند. هدف اصلی GMDH یافتن تابع تقریب f با خروجی \tilde{y} برای مجموعه‌ای از ورودی‌های به صورت $x = (x_1, x_2, \dots, x_n)$ است به طوری که تابع ارائه شده مقادیر \tilde{y} را با کمترین خطا نسبت به مقادیر y برآورد کند. برای m داده آزمایشگاهی که شامل n متغیر ورودی و یک خروجی واقعی (y_i) به صورت رابطه (۳) است.

$$y_i = f(x_{1i}, x_{2i}, \dots, x_{ni}) \quad (i=1, 2, \dots, n) \quad (3)$$

مقادیر خروجی شبکه GMDH در مرحله آموزش به صورت رابطه زیر بیان می‌شود:

$$\tilde{y}_i = \tilde{f}(x_{1i}, x_{2i}, \dots, x_{ni}) \quad (i=1, 2, \dots, n) \quad (4)$$

در ادامه برای رسیدن به یک جواب بهینه باید اختلاف بین مقادیر مشاهداتی و خروجی GMDH به صورت رابطه زیر کمینه شود:

$$\text{Error}_{\min} = \sum_{i=1}^m (\tilde{y}_i - y_i)^2 \quad (5)$$

همان‌طور که گفته شد در شبکه GMDH ارتباط بین متغیرهای ورودی و خروجی در نوروها توسط یک چندجمله‌ای درجه دو به صورت زیر مدل‌سازی می‌شود:


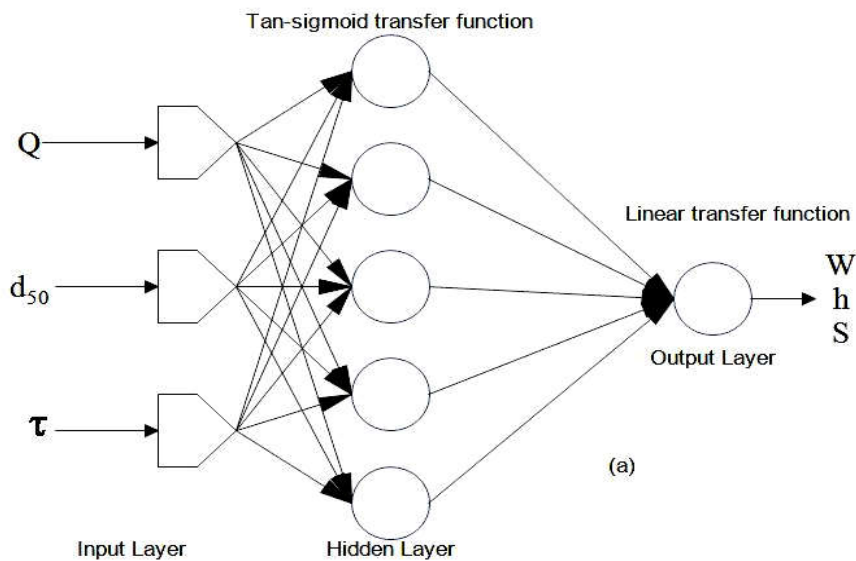
$$\tilde{y} = \varphi(x_1, x_2) = w_0 + w_1x_1 + w_2x_2 + w_3x_1^2 + w_4x_2^2 + w_5x_1x_2 \quad (6)$$

که البته ایده این چندجمله‌ای درجه دوم از چندجمله‌ای

داده‌ها، استفاده از شبکه‌های از نوع پس انتشار خطا به دلیل قابلیت انعطاف‌پذیری بالا با معماری منطبق بر تجربه و آزمون و خطا استفاده می‌شود. تعداد لایه‌های مخفی و تعداد نوروهای لایه‌های مخفی به روش آزمون و خطا و مقایسه عملکرد خطای آنها انتخاب می‌شوند. در بیشتر مطالعاتی که مورد بررسی قرار گرفت از شبکه‌های پرسپترون چندلایه با الگوریتم آموزشی پس انتشار خطا به منظور حل مسائل مهندسی آب استفاده شده است (۴). ساختار بهینه‌ترین آرایش شبکه عصبی پرسپترون چندلایه از بین تمامی آرایش‌ها و دیگر توابع محرک که بهترین عملکرد را دارند در هنگام شروع آموزش شبکه، وزن‌ها دارای یک مقدار اولیه بوده که یا توسط مقادیری اتفاقی و یا توسط نتایج آزمایشگاهی پیشین، مقداردهی می‌شوند. معمولاً در MLP تابع فعال کننده سیگموئیدی در نظر گرفته می‌شود و توسط تکنیک Levenberg-marquardt به علت قدرت و سرعت بیشتر نسبت به روش گرادیان شیب، آموزش داده شده است. به طور اساسی ایجاد ساختار مناسب شبکه در یک مسئله، توسط سه مرحله تثبیت ساختار، آموزش شبکه و کنترل شبکه انجام می‌شود. در شکل ۱ ساختار مدل شبکه عصبی توسعه داده شده در این پژوهش، نشان داده شده است.

روش دسته‌بندی گروهی داده‌ها

مدل دسته‌بندی گروهی داده‌ها یک روش خودسازمان‌ده است که با استفاده از مجموعه‌ای از نوروها، به تقریب و مدل‌سازی



شکل ۱. ساختار شبکه عصبی چندلایه توسعه داده شده برای تخمین ابعاد هندسی کانال‌های آبرفتی پایدار

معناست که ساختار مدل قبل از مدل‌سازی معلوم نیست؛ این مدل از تمام داده‌های مربوطه به صورت یکجا استفاده نمی‌کند، بلکه داده‌ها را به زیرمجموعه‌هایی تقسیم کرده و سپس مدل‌سازی را برای هر کدام از این زیرمجموعه‌ها انجام می‌دهد که اصطلاحاً به آن مدل محلی اطلاق می‌شود. در مدل یاد شده این امکان وجود دارد تا بتوان الگوی غیرخطی پنهان در مجموعه داده‌های با تعداد متغیر زیاد را آشکار کرد؛ بنابراین ضمن به‌کارگیری یک روش، امکان تعریف تابع تخمین ممکن می‌شود و ضرورتی به تلفیق چندین روش آماری وجود نخواهد داشت. اساس این روش، مبتنی بر توابعی به نام توابع مبنا است که برای هر متغیر توضیحی به صورت رابطه γ تعریف می‌شود:

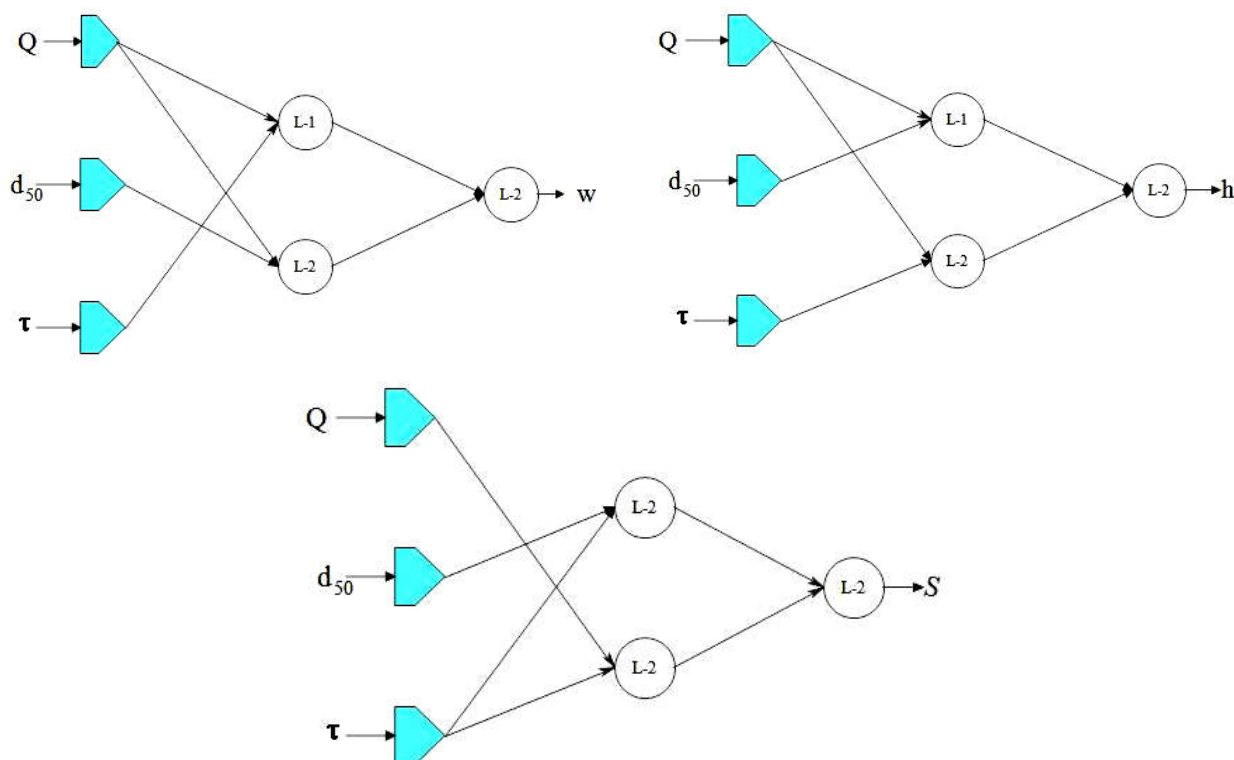
$$\max \{0, x-t\} \text{ and } \max \{0, t-x\} \quad (7)$$

که در آن t گره نامیده شده و در عمل یکی از مشاهدات آن متغیر توضیحی است. این توابع موسوم به توابع اسپلاین هستند که در گره t زوج منعکس یافته‌ای هستند. شکل کلی مدل

کلوموگروف-گابور گرفته شده است. ضرایب w در رابطه بالا با استفاده از روش‌های کمترین مربعات خطا می‌تواند محاسبه شوند. توسعه لایه‌های شبکه GMDH بر اساس دقت نورون‌ها در لایه قبلی است که این دقت می‌تواند بر اساس یکی از معیارهای خطا مانند RMSE تعیین شوند. در این مدل در لایه اول به تعداد جفت‌های متغیرهای ورودی نورون تشکیل می‌شود ولی در لایه‌های بعدی بر اساس شاخص‌های آماری آنهایی که دارای دقت مناسب هستند شرکت داده می‌شوند. نمونه‌ای از ساختار مدل GMDH توسعه داده شده در این تحقیق در شکل ۲ نشان داده شده است.

معرفی روش MARS

مدل اسپلاین تطبیقی چندگانه (MARS) نخستین بار توسط فردمن (۱۰) به منظور پیش‌بینی خروجی‌های عددی پیوسته ارائه شده است و یکی از مدل‌های ناپارامتریک محلی است. ترم ناپارامتریک به این



شکل ۲. ساختار مدل GMDH توسعه داده شده برای تخمین عرض، عمق و شیب طولی کانال آبرفتی پایدار

تأثیرگذاری کمتری در تخمین برخوردار هستند، حذف می‌شوند. سرانجام بهترین مدل بر مبنای کمینه بودن معیاری به نام اعتبارسنجی تقاطعی تعمیم‌یافته (GCV) انتخاب می‌شود. فرض کنید GCV_k مقدار GCV برای k امین مدل در مرحله حذفی باشد. این کمیت توسط رابطه ۹ تعریف می‌شود:

$$GCV_k = \frac{1}{n} \sum_{i=1}^n \left(y_i - \hat{f}_k(x_i) \right)^2 \Big/ (1 - C(k)/n) \quad (9)$$

که \hat{f}_k مدل برآورد شده در گام k ام مرحله حذفی پس‌رو و تعداد جملات مدل در مرحله k $mC_k + m$ که m معرف تعداد گره‌های توابع اسپلاین موجود در مدل و در عمل معمولاً بین ۲ تا ۴ انتخاب می‌شود (۲۰).

استراتژی‌های مدل‌سازی

به‌منظور تخمین ابعاد هندسی کانال‌های آبرفتی پایدار در این پژوهش، دو استراتژی در نظر گرفته شد. استراتژی اول شامل توسعه مدل‌های محاسبات نرم یاد شده بر اساس رابطه ۱ و

مارس به‌صورت زیر تعریف می‌شود (رابطه ۸):

$$\hat{Y} = C_0 + \sum_{k=1}^M G_k B_k(X) \quad (8)$$

که در این معادله \hat{Y} مقدار تخمین متغیر مورد پاسخ، X بردار متغیرهای توضیحی، B_k تابع مبنا و C_k ضرایبی هستند که با کمینه‌سازی مجموع مربعات باقیمانده‌ها تعیین می‌شوند. هر تابع مبنا ممکن است به‌صورت یک تابع خطی اسپلاین یا حاصل ضرب دو یا چند تا از آنها باشد که مبین اثرات متقابل است (۱۰). مدل اسپلاین تطبیقی چندگانه، فضای متغیرهای توضیحی را با گره‌هایی خاص به تعدادی ناحیه مجزا تفکیک می‌کند که آن گره‌ها باعث بیشترین کاهش در مجموع مربعات خطا شده‌اند. برازش مدل MARS در دو مرحله انجام می‌گیرد. در مرحله پیش‌رو، تعداد زیادی از توابع مبنا با گره‌های متفاوت به‌طور پی‌درپی به مدل اضافه می‌شوند؛ این عمل، مدلی را تولید می‌کند که پیچیده بوده و موجب بیش‌برازش می‌شود. در مرحله دوم یا مرحله حذف پس‌رو، توابع مبنایی که از اهمیت و

شده بر اساس آنها توسعه داده شدند. در سناریو دوم مدل‌ها بر اساس رابطه ۲ یعنی فرم بی‌بعد پارامترها توسعه داده می‌شوند.

مدل‌سازی و تخمین عرض کانال‌های آبرفتی پایدار

در این قسمت نتایج حاصل از مدل‌سازی و تخمین عرض کانال‌های آبرفتی با استفاده از مدل MARS ارائه می‌شود. شاخص‌های آماری دقت مدل MARS در مراحل مختلف توسعه شامل آموزش و آزمایش در جدول ۳ ارائه شده است. مدل مستخرج از مدل MARS در رابطه (۱۳) و توابع پایه مربوط به آن در جدول ۴ ارائه شده است. در مدل‌سازی، مقدار شاخص CSV برابر با ۷/۲۷۸ حاصل شد. نتایج مدل MARS توسعه داده شده در مراحل آموزش و آزمایش در شکل (۴) نشان داده شده است.

$$W = 13.444 + \sum_{M=1}^{10} \beta_m F_i(x) \quad (13)$$

ساختار مدل GMDH توسعه داده شده برای تخمین عرض کانال بر اساس سناریو اول در شکل ۲ نشان داده شده است. همان‌طور که از این شکل مشخص است، مدل GMDH توسعه داده شده دو لایه است. در لایه اول دو نورون و در لایه دوم یک نورون که بر اساس میانگین جواب‌های دو نورون در لایه قبلی توسعه یافته است. شاخص‌های آماری خطای مدل GMDH در مراحل آموزش و آزمایش در جدول ۳ آورده شده است. ضرایب نورون‌های موجود در مدل GMDH توسعه داده شده در جدول ۵ ارائه شده است. عملکرد مدل GMDH توسعه داده شده در این مرحله (سناریو اول) در شکل ۴ نشان داده شده است.

بررسی ساختار مدل GMDH توسعه داده شده نشان می‌دهد که این مدل برای تخمین عرض کانال از پارامتر دبی جریان (Q) بیشتر استفاده کرده است که اهمیت این پارامتر را در تخمین عرض کانال می‌رساند. این یافته تطابق خوبی با ساختار مدل MARS توسعه داده شده دارد. مقایسه عملکرد مدل MARS و GMDH نشان می‌دهد که دقت مدل MARS در هر دو

استراتژی دوم توسعه مدل‌ها بر اساس رابطه ۲ است. تخصیص داده‌ها به منظور آموزش و توسعه مدل‌ها، ۸۰ درصد داده‌ها به آموزش و ۲۰ درصد مابقی آنها به آزمایش تخصیص داده شد. اختصاص داده‌ها به هر یک از دسته‌های آموزش و آزمایش به صورت تصادفی انجام گرفت. به منظور ارزیابی مدل‌های توسعه داده شده از شاخص‌های آماری ضریب تبیین (R^2) و ریشه میانگین مربعات خطا (RMSE) و میانگین درصد مطلق خطا (MAPE) استفاده شده است (رابطه‌های ۱۰ تا ۱۲):

$$R^2 = \left(\frac{\sum_{i=1}^n (O_i - \bar{O})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^n (O_i - \bar{O})^2} \sqrt{\sum_{i=1}^n (P_i - \bar{P})^2}} \right)^2 \quad (10)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (O_i - P_i)^2}{n}} \quad (11)$$


$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{O_i - P_i}{O_i} \right| \times 100 \quad (12)$$

که O معرف مقادیر مشاهداتی و P معرف مقادیر پیش‌بینی شده یا خروجی مدل‌ها و n تعداد نمونه‌ها است.

نتایج و بحث

به منظور بررسی رابطه میان متغیرهای ورودی و خروجی، مقادیر آنها در مقابل مقادیر ورودی در شکل ۳ ترسیم و میزان همبستگی متغیرهای دخیل در جدول ۲ آورده شده است. همان‌طور که از این جدول مشخص است عمق و عرض سطح آب با دبی جریان، رابطه و شیب طولی نیز با تنش برشی نیز رابطه مستقیم دارد که منطقی به نظر می‌رسد. هیستوگرام متغیرها ترسیم شد و در شکل ۳ نشان داده شده است.

در ادامه با توجه به رابطه‌های ۱ و ۲ دو سناریو برای تخمین ابعاد هندسی کانال‌های آبرفتی پایدار در نظر گرفته شد. در سناریوی اول با توجه به رابطه ۱ پارامترهای دخیل در مسئله به صورت خام در نظر گرفته شد و مدل‌های محاسبات نرم یاد



شکل ۳. هیستوگرام و پراکندگی پارامترهای دخیل در تخمین ابعاد هندسی کانال‌های آبرفتی پایدار

جدول ۲. همبستگی متغیرهای دخیل در تخمین ابعاد هندسی کانال‌های آبرفتی پایدار

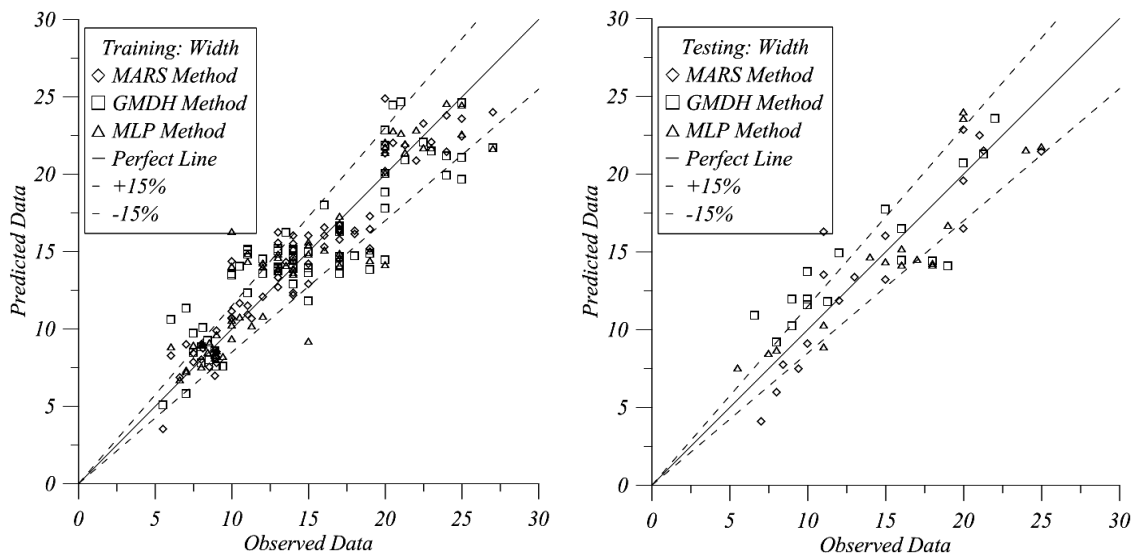
s	h	w	τ	d50	Q
					1
				1	-0.26
			1	-0.52	0.08
		1	0.01	-0.39	0.80
	1	0.42	0.29	-0.08	0.51
1	0.12	0.01	0.85	-0.32	0.08

جدول ۳. مشخصات آماری دقت مدل در تخمین عرض آبراهه آبرفتی پایدار در مراحل آموزش و آزمایش: سناریو اول

مدل	Test			Train		
	MAPE%	RMSE	R ²	MAPE%	RMSE	R ²
MARS	۱۴/۹۸	۲/۳۱۷	۰/۸۸۴	۱۰/۰۲	۱/۶۶	۰/۹۰۲
GMDH	۱۸/۶۷	۲/۵۴۱	۰/۷۶۸	۱۵/۶۷	۲/۶۰	۰/۷۷۲
MLP	۱۴/۱۰	۲/۴۳۸	۰/۸۱۵	۱۰/۶۷	۲/۰۹۸	۰/۸۴۴

جدول ۴. توابع پایه و ضرایب آنها در مدل MARS برای تخمین عرض سطح کانال آبرفتی پایدار

ضریب	توابع اساسی
۳/۵	$BF1 = \max(0, Q - 3.04)$
-۹۷/۸۵	$BF2 = \max(0, d50 - 0.0245)$
۲۱۵۲/۳۷	$BF3 = \max(0, 0.0245 - d50) * \max(0, \tau - 0.0961)$
-۲۱۶/۱۹	$BF4 = \max(0, 0.0245 - d50) * \max(0, Q - 2.75)$
۲۶۳۸/۹۵	$BF5 = \max(0, 0.0245 - d50) * \max(0, 2.75 - Q)$
-۱۰۳/۹۳	$BF6 = \max(0, 0.1114 - \tau) * \max(0, 4.3 - Q)$
-۴۱/۳۲	$BF7 = \max(0, \tau - 0.212)$
-۲۶۸۵/۱۵	$BF8 = \max(0, 0.0245 - d50) * \max(0, 2.87 - Q)$
-۱۷۳۳/۴۴	$BF9 = \max(0, 0.0068 - d50)$
۵۱/۲۶	$BF10 = \max(0, 0.1465 - \tau) * \max(0, 5.37 - Q)$



شکل ۴. نتایج مدل های MARS، GMDH و MLP در تخمین عرض سطح کانال آبرفتی پایدار

جدول ۵. ضرایب نوروها در مدل GMDH توسعه داده شده بری تخمین عرض کانال آبرفتی پایدار

b0	b1	b2	b3	b4	b5	b6		
-۰/۶۰۴	۵/۸۱۰	۱۸/۸۷۴	-۰/۳۱۱	۳/۳۹۲	-۶/۶۰۵	-۰/۶۰۴	N1	لایه ۱
۶/۵۰۱	۳/۰۷۷	-۱۱/۶۲۶	-۰/۲۹۴	-۱۴۱۷/۳۳۹	۴۲/۶۴۴	۶/۵۰۱	N2	
۱/۹۲۲	۰/۶۳۹	۰/۰۴۵	-۰/۰۳۹	-۰/۰۰۱	۰/۰۵۲	۱/۹۲۲	N3	لایه ۲

شد. طراحی ساختار مدل شبکه عصبی مصنوعی یک فرایند سعی و خطا است، اما استفاده از تجربیات پژوهشگران در توسعه ساختار آنها میزان عملیات سعی و خطا را به شکل قابل توجهی کاهش می دهد. در

مرحله آموزش و آزمایش برای تخمین عرض کانال آبرفتی پایدار بیشتر از مدل GMDH است. برای تخمین عرض کانال آبرفتی پایدار از مدل شبکه عصبی چندلایه (MLP) نیز توسعه داده

سناریو توسعه داده شدند. مدل MARS توسعه داده شده برای تخمین عمق کانال بر اساس سناریوی اول در رابطه ۱۵ ارائه شده است. توابع پایه و ضرایب آن نیز در جدول ۸ ارائه شده است. این مدل دارای دو تابع پایه است و هر سه پارامتر دخیل در آن شامل دبی جریان و تنش برشی و اندازه میانگین ذرات در آن نقش دارند:

$$h = 0.355 + \sum_{M=1}^2 \beta_m F_i(x) \quad (15)$$

عملکرد مدل توسعه داده شده در مرحله آموزش و آزمایش در شکل ۵ نشان داده شده است. شاخص‌های آماری مدل‌های توسعه داده شده به ترتیب در این مراحل عبارت از $R^2 = 0.317$, $RMSE = 0.074$ و $R^2 = 0.322$, $RMSE = 0.074$ است. بررسی و قضاوت مهندسی شاخص‌های آماری خطای مدل توسعه داده شده نشان از دقت کم این مدل در تخمین عمق جریان دارد. در ادامه عملکرد مدل MARS بر اساس سناریو دوم بررسی می‌شود. مدل MARS توسعه داده شده و توابع پایه و ضرایب آن در رابطه ۱۶ نشان داده شده است. عملکرد آن در مرحله آموزش عبارت از $R^2 = 0.897$, $RMSE = 7.874$ و در مرحله آزمایش عبارت از $R^2 = 0.895$, $RMSE = 9.270$ است. بررسی و مقایسه عملکرد مدل MARS هر دو سناریو نشان داد که استفاده از فرم بی‌بعد پارامترها دقت مدل را در تخمین عمق کانال بسیار افزایش خواهد داد.

$$h = 16.346 + \sum_{M=1}^2 \beta_m F_i(x) \quad (16)$$

$$BF1 = \max(0, 129224.496 - x1) \quad -0.0003$$

$$BF2 = \max(0, x1 - 122743.016) \quad 0.0001$$

در ادامه، تخمین و مدل‌سازی عمق کانال با استفاده از مدل GMDH انجام شد. ساختار مدل GMDH توسعه داده شده در شکل ۲ نشان داده شده است. این مدل نیز دارای دولایه پنهان است. عملکرد مدل GMDH توسعه داده شده در مراحل آموزش و آزمایش در جدول ۹ آمده است. بررسی دقت مدل GMDH نشان می‌دهد که این مدل، دقت مناسب برای تخمین عمق کانال آبرفتی پایدار ندارد. ضرایب مدل GMDH توسعه داده شده در جدول ۱۰ آورده شده است.

در ادامه، عمق کانال با استفاده از مدل شبکه عصبی MLP تخمین زده شد. شاخص‌های مدل شبکه عصبی در مرحله آموزش

این پژوهش از تجربیات ارائه شده توسط عظمت‌اله و همکاران (۴) استفاده شده است. تابع تانژانت هایپربولیک به عنوان تابع انتقال حاکم بر نوروها در نظر گرفته شد. عملکرد مدل MLP توسعه داده شده نیز در شکل ۴ نشان داده شده است. شاخص‌های آماری دقت این مدل در مرحله آموزش و در مرحله آزمایش در جدول ۳ آورده شده است. مقایسه دقت این مدل با مدل‌های MARS و GMDH نشان می‌دهد که دقت این مدل در مراحل آموزش و آزمایش کمتر از مدل MARS است اما بیشتر از مدل GMDH است. در سناریوی دوم، همان‌طور که گفته شد، فرم بی‌بعد پارامترهای عمق، عرض کانال و همچنین شیب طولی آن تابعی از پارامتر بی‌بعد دبی جریان است. در این سناریو چون فقط یک پارامتر ورودی وجود دارد لذا نمی‌توان از مدل GMDH استفاده کرد، زیرا حداقل تعداد متغیرهای ورودی در این مدل دو است. در ادامه نتایج حاصل از مدل‌سازی و تخمین عرض جریان با استفاده از مدل‌های MARS و MLP ارائه می‌شود. مدل MARS توسعه داده شده بر اساس سناریو دوم در رابطه ۱۴ و توابع پایه و ضرایب آن در جدول ۶ ارائه شده است. شاخص‌های آماری خطای مدل MARS توسعه داده شده بر اساس سناریو دوم در جدول ۷ آمده است.

$$W = 8731.427 + \sum_{M=1}^6 \beta_m F_i(x) \quad (14)$$

مقایسه دقت مدل MARS توسعه داده شده در حالت سناریو دوم با سناریو اول نشان می‌دهد که افزایش دقت مدل در حالت سناریو دوم قابل ملاحظه نیست. در تخمین عرض سطح کانال مدل شبکه عصبی MLP نیز بر اساس سناریو دوم توسعه داده شد. ساختار مدل MLP توسعه داده شده در شکل ۱ نشان داده شده است. نتایج شاخص‌های آماری آن در مراحل مختلف توسعه (آموزش و آزمایش) در جدول ۷ آمده است. مقایسه عملکرد مدل MLP در هر دو سناریو نشان می‌دهد که تغییرات دقت مدل قابل ملاحظه نیست.

مدل‌سازی و تخمین عمق کانال‌های آبرفتی پایدار

در ادامه، پارامترهای عمق و شیب طولی کانال‌های آبرفتی پایدار با استفاده از مدل‌های محاسبات نرم استفاده شده در این تحقیق، مدل‌سازی و تخمین زده شدند. بدین منظور مدل‌ها بر اساس هر دو

جدول ۶. توابع پایه و ضرایب آنها در مدل MARS برای تخمین عرض سطح کانال آبرفتی پایدار

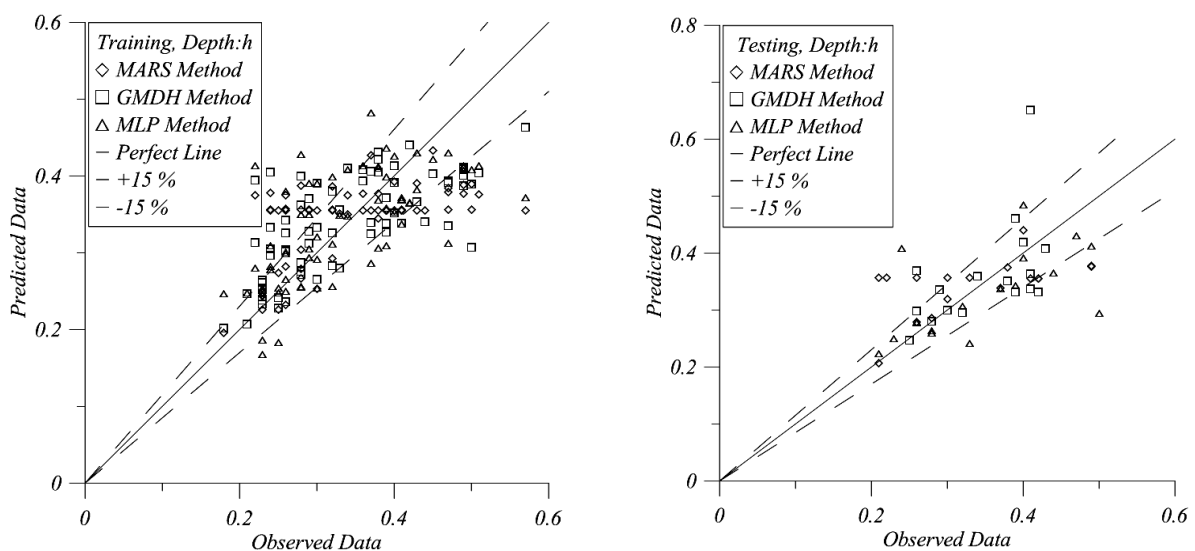
ضریب	توابع اساسی
-۰/۰۵۶	$BF1 = \max(0, x1 - 17404.393)$
۰/۰۹۱	$BF2 = \max(0, x1 - 140118.147)$
-۰/۰۰۸	$BF3 = \max(0, x1 - 214699.006)$
۰/۰۲۵	$BF4 = \max(0, 96566.813 - x1)$
-۰/۰۸۳	$BF5 = \max(0, 132465.235 - x1)$
-۰/۰۲۶	$BF6 = \max(0, x1 - 118286.999)$

جدول ۷. مشخصات آماری دقت مدل‌ها در تخمین عرض آبراهه آبرفتی پایدار در مراحل آموزش و آزمایش: سناریو دوم

مدل	Train			Test		
	R ²	RMSE	MAPE%	R ²	RMSE	MAPE%
MARS	۰/۹۳۳	۲۱۲/۱۳۱	۲/۹۴	۰/۹۵۲	۳۵۱/۰۸۷	۴۰/۳۶
MLP	۰/۹۲۲	۲۵۶/۵۰	۲۵/۲۱	۰/۹۱۵	۲۹۱/۵۵۰	۴۷/۴۱

جدول ۸. توابع پایه و ضرایب آنها در مدل MARS برای تخمین عمق کانال آبرفتی پایدار: سناریو اول

ضریب	توابع اساسی
-۱/۸۶۹	$BF1 = \max(0, 0.0453 - \tau) * \max(0, 4.04 - Q)$
۴/۷۲۵	$BF2 = \max(0, d_{50} - 0.0068) * \max(0, 0.2324 - \tau)$



شکل ۵. نتایج مدل‌های MARS، GMDH و MLP در تخمین عمق کانال آبرفتی پایدار: سناریو اول

جدول ۹. مشخصات آماری دقت مدل‌ها در تخمین عمق آبراهه آبرفتی پایدار در مراحل آموزش و آزمایش: سناریو اول

مدل	Train			Test		
	MAPE%	RMSE	R ²	MAPE%	RMSE	R ²
MARS	۱۷/۷۱	۰/۷۴	۰/۳۲۲	۱۷/۳۸	۰/۰۷۴	۰/۳۱۷
GMDH	۱۷/۰۹	۰/۰۷۰	۰/۴۵	۱۵/۱۵	۰/۰۷۹	۰/۳۰
MLP	۱۶/۶۵	۰/۰۶۸	۰/۴۳	۱۸/۲۰	۰/۰۷۸	۰/۳۶

جدول ۱۰. ضرایب نوروں مدل GMDH برای تخمین عمق کانال آبرفتی پایدار: سناریو اول

	b0	b1	b2	b3	b4	b5	b6
لایه ۱	۰/۰۵۱	۰/۱۳۱	۰/۱۴۵	-۰/۰۱۳	-۱/۶۶۰	۰/۱۵۷	۰/۰۵۱
	۰/۰۸۷	۰/۱۰۷	۰/۵۹۲	-۰/۰۰۹	۰/۳۴۵	-۰/۱۸۷	۰/۰۸۷
لایه ۲	۰/۱۷۱	۵/۳۴۲	-۵/۵۶۵	۶/۷۵۷	۲۰/۸۵۱	-۲۵/۶۷۵	۰/۱۷۱

ساختار این مدل مشخص است، تنش برشی بیشترین تأثیر را در مدل‌سازی و تخمین شیب طولی کانال‌های آبرفتی پایدار دارد. عملکرد مدل MARS توسعه داده شده در مرحله آموزش و آزمایش در شکل ۶ نشان داده شده است.

$$S = 0.036 + \sum_{M=1}^5 \beta_m F_i(x) \quad (17)$$

مدل GMDH نیز برای تخمین شیب طولی کانال‌ها بر اساس سناریو اول توسعه داده شد. ساختار مدل GMDH توسعه داده شده در شکل ۲ نشان داده شده است. همان‌طور که از این شکل مشخص است، پارامتر تنش برشی بیشترین تأثیر را در شیب طولی دارد. شاخص‌های آماری دقت مدل GMDH توسعه داده شده در مراحل آموزش و آزمایش در جدول ۱۱ آمده است. عملکرد مدل GMDH توسعه داده شده در مراحل آموزش و آزمایش در شکل ۷ نشان داده شده است. ضرایب نوروں‌های موجود در شبکه GMDH توسعه داده شده در جدول ۱۳ ارائه شده است.

در ادامه، مدل شبکه عصبی نیز برای تخمین شیب طولی مورد بررسی و ارزیابی قرار گرفت که نتایج آن در شکل ۷ نشان داده شده است و شاخص‌های آماری خطای مدل MLP توسعه داده شده در مراحل آموزش و آزمایش در جدول ۱۱ آورده

عبارت از $RMSE = 0.068$, $R^2 = 0.43$ و در مرحله آزمایش عبارت از $RMSE = 0.078$, $R^2 = 0.36$ است. بررسی شاخص‌های آماری نشان می‌دهد که این مدل دقت مناسب در تخمین عمق کانال را ندارد. در ادامه عملکرد مدل MLP برای تخمین عمق آبراهه آبرفتی پایدار بر مبنای سناریو دوم بررسی می‌شود. شاخص‌های آماری مدل MLP بر مبنای سناریوی دوم در مرحله آموزش عبارت از $RMSE = 8.417$, $R^2 = 0.902$ و در مرحله آزمایش عبارت از $RMSE = 5.470$, $R^2 = 0.899$ است. بررسی عملکرد مدل MLP در هر دو سناریو نشان داد که استفاده از فرم بی‌بعد می‌تواند دقت مدل‌سازی را به نحو چشمگیری افزایش دهد.

مدل‌سازی و تخمین شیب طولی کانال‌های آبرفتی پایدار

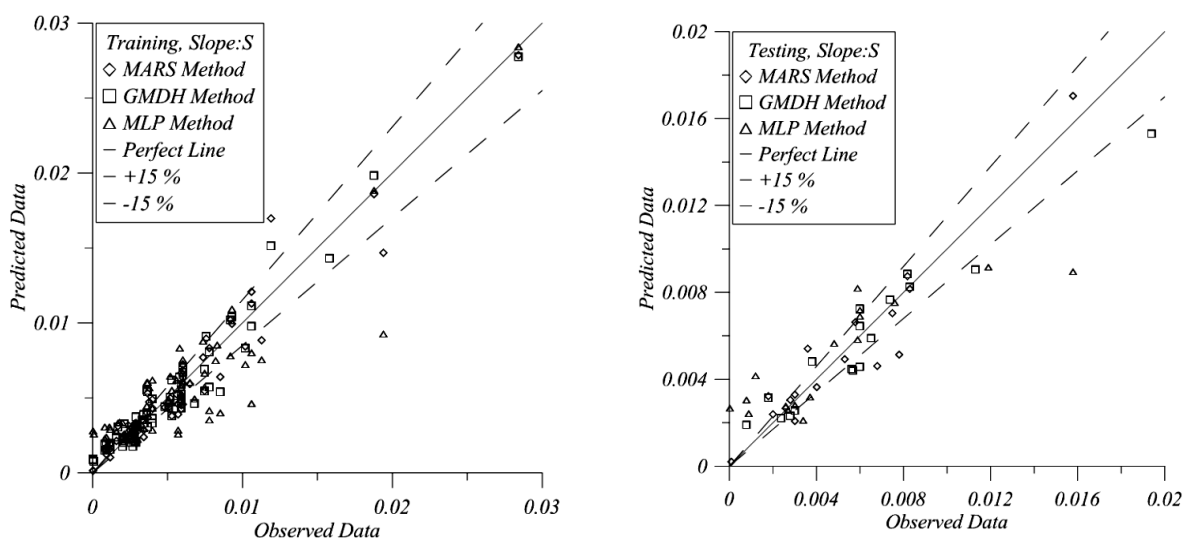
در این قسمت نتایج حاصل از تخمین و مدل‌سازی شیب طولی کانال آبرفتی پایدار با استفاده از مدل‌های MARS، GMDH و MLP ارائه می‌شود. مدل ریاضی مستخرج از مدل MARS برای تخمین شیب طولی کانال‌های آبرفتی پایدار در رابطه ۱۷ ارائه شده است. شاخص‌های خطای این مدل در مراحل آموزش و آزمایش در جدول ۱۱ آمده است. توابع پایه و ضرایب آن در جدول ۱۲ ارائه شده است. همان‌طور که از

جدول ۱۱. مشخصات آماری دقت مدل‌ها در شیب طولی آبراهه آبرفتی پایدار در مراحل آموزش و آزمایش: سناریو اول

Test			Train			مدل
MAPE%	RMSE	R ²	MAPE%	RMSE	R ²	
۶۶/۴۹	۰/۰۰۱۱	۰/۹۰۸	۵۷/۲۵	۰/۰۰۱۲	۰/۹۳۰	MARS
۲۰/۵۸	۰/۰۰۱۴	۰/۹۲۵	۲۹/۸۲	۰/۰۰۱۱	۰/۹۴۲	GMDH
۳۰/۹۲	۰/۰۰۲۳	۰/۷۲۶	۴۴/۷۶	۰/۰۰۲۲	۰/۷۷۷	MLP

جدول ۱۲. توابع پایه و ضرایب آنها در مدل MARS برای تخمین شیب طولی کانال آبرفتی پایدار: سناریو اول

ضریب	توابع اساسی
۲/۵۵	$BF1 = \max(0, \tau - 0.0228) * \max(0, 0.0085 - d_{50})$
-۶/۴۷	$BF2 = \max(0, \tau - 0.0087) * \max(0, 0.0272 - d_{50})$
۰/۱۵	$BF3 = \max(0, \tau - 0.2365)$
-۰/۱۵	$BF4 = \max(0, 0.2365 - \tau)$
۰/۰۱	$BF5 = \max(0, d_{50} - 0.009) * \max(0, 4.37 - Q)$



شکل ۶. نتایج مدل‌های MARS، GMDH و MLP در تخمین شیب کانال آبرفتی پایدار: سناریو اول

جدول ۱۳. ضرایب نوروں مدل GMDH برای تخمین شیب طولی کانال آبرفتی پایدار: سناریو اول

b0	b1	b2	b3	b4	b5	b6		
۰/۰۰۲	-۰/۰۲۱	-۰/۰۰۳	۰/۱۱۶	۰/۰۰۴	۳/۷۵۱	۰/۰۰۲	N-1	لایه ۱
۰/۰۰۳	۰/۰۰۰	-۰/۰۰۶	۰/۰۰۰	-۰/۰۰۹	۰/۰۱۰	۰/۰۰۳	N-2	
۰/۰۰۰	-۱/۲۹۰	-۰/۱۰۸	-۳۴/۰۳۷	-۳۱/۷۱۵	۹۰/۸۱۸	۰/۰۰۰	N-1	لایه ۲

و شیب طولی آن با استفاده از مدل‌های محاسبات نرم شامل مدل رگرسیون اسپلاین تطبیقی چندگانه (MARS)، مدل دسته‌بندی گروهی داده‌ها (GMDH) و مدل شبکه عصبی چندلایه (MLP) مدل‌سازی و تخمین زده شد. به‌منظور تخمین پارامترهای نامبرده شده از مقادیر دبی جریان، تنش برشی و اندازه متوسط ذرات رسوبی به دو صورت خام و بی‌بعد به‌عنوان ورودی مدل‌ها استفاده شد. گفتنی است که بی‌بعدسازی پارامترها بر اساس تحقیقات بری (۶) و با تقسیم پارامترهای نامبرده شده بر اندازه میانگین ذرات انجام گرفت. نتایج این تحقیق نشان که در تخمین عرض آبراهه آبرفتی پایدار بهترین عملکرد مربوط به مدل MARS با شاخص‌های آماری $R^2 = 0.844$, $RMSE = 2.317$ در مرحله آموزش است هرچند که دو مدل دیگر MLP و GMDH دارای دقت قابل قبولی هستند. در تخمین عمق جریان بر اساس پارامترهای خام دقت هر سه مدل ضعیف بوده درحالی که استفاده از فرم بی‌بعد در مدل‌سازی دقت آنها را افزایش چشمگیر و تا حد قابل قبول از نظر مهندسی رسانده است. در تخمین عمق آبراهه بر اساس پارامترهای بی‌بعد عملکرد هر دو مدل MARS و MLP تقریباً باهم برابر است شاخص‌های آماری مدل‌ها تقریباً برابر با $R^2 = 0.90$, $RMSE = 5.50$ در مرحله آزمایش گزارش محاسبه شد. در تخمین شیب طولی نیز بهترین عملکرد مربوط به مدل GMDH با شاخص‌های آماری $R^2 = 0.94$, $RMSE = 0.0011$ است هرچند که عملکرد مدل MARS نیز نزدیک به آن است. بررسی ساختار مدل‌های توسعه داده شده MARS و GMDH نشان داد که تخمین عرض آبراهه دبی و اندازه میانگین ذرات و در تخمین شیب طولی تنش برشی و اندازه میانگین ذرات بیشترین تأثیر را دارند.

شده است. مقایسه عملکرد مدل‌های محاسبات نرم توسعه داده شده نشان می‌دهد که هر دو مدل GMDH و MARS دارای عملکردی مناسب و تقریباً برابر با هم هستند حال آنکه دقت مدل MLP کمتر از آن دو است.

مقایسه با تحقیقات پیشین

در این بخش، نتایج مدل‌های محاسبات نرم توسعه داده شده در این پژوهش با نتایج سایر پژوهشگران مقایسه می‌شود. بنکداری و همکاران (۵) با استفاده از مدل برنامه‌نویسی بیان ژن (GEP: Gene Expression Programming) و مدل رگرسیون چندجمله‌ای تکاملی (Evolutionary Polynomial Regression: EPR) به مدل‌سازی و تخمین ابعاد هندسی کانال‌های آبرفتی پایدار پرداختند. آنها اظهار داشتند که شاخص‌های آماری مدل EPR در تخمین عرض کانال‌های آبرفتی پایدار برابر با $R^2 = 0.925$, $RMSE = 0.4$ و مدل GEP عبارت از $R^2 = 0.918$, $RMSE = 0.45$ است. آنها همچنین اظهار داشتند که پارامتر شیلدز در مدل‌سازی شیب بسیار مؤثر است که این با یافته‌های این تحقیق و مبانی هیدرولیک مجاری آبرفتی کاملاً سازگار است. دقت مدل‌های توسعه داده شده توسط آنها نیز در تخمین عرض هم‌تراز مدل MARS است. شقاقی و همکاران (۲۴) به توسعه مدل GMDH ساختاریافته برای تخمین ابعاد هندسی کانال‌های آبرفتی پایدار پرداختند. آنها آموزش و کالیبراسیون مدل خود را با استفاده از الگوریتم ازدحام ذرات انجام دادند. نتایج تحقیقات آنها نشان داد که مقادیر شاخص‌های آماری خطای مدل توسعه داده عبارت از $R^2 = 0.79$, $RMSE = 0.075$ است که دقت مدل GMDH توسعه داده شده در این پژوهش هم با آن همخوانی دارد.

نتیجه‌گیری

در این مطالعه ابعاد هندسی کانال‌های آبرفتی شامل عرض، عمق

منابع مورد استفاده

1. Afzalimehr, H. 2001. Design of sustainable canals in sandy bed. *Soil and Water Sciences (Agricultural Sciences and Technologies and Natural Resources)* 5(3): 17-31. (in Farsi)
2. Afzalimehr, H., M. Abdolhosseini and V. P. Singh. 2010. Hydraulic geometry relations for stable channel design, *Journal of Hydrologic Engineering* 15(10): 859-864.
3. Afzalimehr, H. and S. Heidarpour. 2006. Dream theory and its application for uniform and non-uniform flows. *Soil and Water Sciences (Agricultural Sciences and Technologies and Natural Resources)* 10(1): 1-13. (in Farsi).
4. Azamathulla, H. M., A. H., Haghiabi and A. Parsaie. 2016. Prediction of side weir discharge coefficient by support vector machine technique, *Water Science and Technology. Journal of Water Supply* 16(4): 1002-1016.
5. Bonakdari, H., A. Gholami, A. M. A. Sattar and B. Gharabaghi. 2020. Development of robust evolutionary polynomial regression network in the estimation of stable alluvial channel dimensions. *Geomorphology* 350: 106895.
6. Bray, D. 1982. Regime equations for gravel-bed rivers.'Gravel bed rivers, PP. 517-552. In: Hey, R. D., J. C. Bathurst and C. R. Thome (Eds.), Wiley, Chichester.
7. Chang, H. H. 1980. Stable alluvial canal design. *Journal of the Hydraulics Division* 106 (ASCE 15420).
8. Daneshfaraz, R., E. Aminvash, A. Ghaderi, J. Abraham and M. Bagherzadeh. 2021. SVM performance for predicting the effect of horizontal screen diameters on the hydraulic parameters of a vertical drop. *Applied Sciences* 11(9): 4238.
9. Daneshfaraz, R., M. Bagherzadeh, R. Esmaeeli, R. Norouzi and J. Abraham. 2021. Study of the performance of support vector machine for predicting vertical drop hydraulic parameters in the presence of dual horizontal screens. *Water Supply* 21(1): 217-231.
10. Friedman, J. H. 1991. Multivariate Adaptive Regression Splines, *The Annals of Statistics* 1-67.
11. Gholami, A., H. Bonakdari, I. Ebtehaj, S. Shaghaghi and F. Khoshbin. 2017. Developing an expert group method of data handling system for predicting the geometry of a stable channel with a gravel bed. *Earth Surface Processes and Landforms* 42(10): 1460-1471.
12. Gholami, A., H. Bonakdari and M. Mohammadian. 2019. Enhanced formulation of the probability principle based on maximum entropy to design the bank profile of channels in geomorphic threshold. *Stochastic Environmental Research and Risk Assessment* 33(4): 1013-1034.
13. Gholami, A., H. Bonakdari, M. Mohammadian, A. H. Zaji and B. Gharabaghi. 2019. Assessment of geomorphological bank evolution of the alluvial threshold rivers based on entropy concept parameters. *Hydrological Sciences Journal* 64(7): 856-872.
14. Gholami, A., H. Bonakdari, P. Samui, M. Mohammadian and B. Gharabaghi. 2019. Predicting stable alluvial channel profiles using emotional artificial neural networks. *Applied Soft Computing* 78: 420-437.
15. Haghiabi, A. 2017. Prediction of river pipeline scour depth using multivariate adaptive regression splines. *Journal of Pipeline Systems Engineering and Practice* 8(1): 04016015.
16. Haghiabi, A. 2017. Estimation of scour downstream of a ski-jump bucket using the multivariate adaptive regression splines. *Journal of Scientia Iranica* 24(4): 1789-1801.
17. Kargar, K., M. J. S. Safari, M. Mohammadi and S. Samadianfard. 2019. Sediment transport modeling in open channels using neuro-fuzzy and gene expression programming techniques. *Water Science and Technology* 79(12): 2318-2327.
18. Majedi-Asl, M., R. Daneshfaraz, M. Fuladipanah, J. Abraham and M. Bagherzadeh. 2020. Simulation of bridge pier scour depth base on geometric characteristics and field data using support vector machine algorithm. *Journal of Applied Research in Water and Wastewater* 7(2): 137-143.
19. Mujadzadeh Tabatabai, M., A. Tahershamsi and R. Shirkhani. 2011. Evaluation of regime theories in estimating the stable width of sandy rivers. *Iranian Journal of Watershed Management Science and Engineering* 5(15): 25-34. (in Farsi).
20. Parsaie, A. and A. H. Haghiabi. 2017. Mathematical expression of discharge capacity of compound open channels using MARS technique. *Journal of Earth System Science* 126: 1-15.
21. Parsaie, A., A. H. Haghiabi and A. Moradinejad. 2019. Prediction of scour depth below river pipeline using support vector machine. *KSCE Journal of Civil Engineering* 23(6): 2503-2513.
22. Parsaie, A., H. Yonesi and S. Najafian. 2017. Prediction of flow discharge in compound open channels using adaptive neuro fuzzy inference system method. *Flow Measurement and Instrumentation* 54: 288-297.
23. Seyedian, S. M., M. Farasati, A. Heshmatpoor and A. Fathabadi. 2016. Predicting the characteristics of stable canals using soft computing. *Journal of Soil and Water Conservation Research* 23(4): 119-135. (in Farsi).

24. Shaghaghi, S., H. Bonakdari, A. Gholami, I. Ebtehaj and M. Zeinolabedini. 2017. Comparative analysis of GMDH neural network based on genetic algorithm and particle swarm optimization in stable channel design. *Applied Mathematics and Computation* 313: 271-286.
25. Shaghaghi, S., H. Bonakdari, A. Gholami, O. Kisi, J. Shiri, A. D. Binns and B. Gharabaghi. 2018. Stable alluvial channel design using evolutionary neural networks. *Journal of Hydrology* 566: 770-782.
26. Shaghaghi, S., H. Bonakdari, A. Gholami, O. Kisi, A. Binns and B. Gharabaghi. 2019. Predicting the geometry of regime rivers using M5 model tree, multivariate adaptive regression splines and least square support vector regression methods. *International Journal of River Basin Management* 17(3): 333-352.
27. Simons, D. B. and M. L. Albertson. 1963. Uniform water conveyance channels in alluvial material. *Transactions of the American Society of Civil Engineers* 128(1): 65-107.

Modeling and Estimating the Dimensions of Stable Alluvial Channels using Soft Calculations

B. Shahinejad^{1*}, A. Parsaie², A. Haqizadeh³, A. Arshia¹
and Z. Shamsi¹

(Received: August 18-2021 ; Accepted: November 17-2021)

Abstract

In this research, soft computational models including multiple adaptive spline regression model (MARS) and data group classification model (GMDH) were used to estimate the geometric dimensions of stable alluvial channels including channel surface width (w), flow depth (h), and longitudinal slope (S) and the results of the developed models were compared with the multilayer neural network (MLP) model. To develop the models, the flow rate parameters (Q), the average particle size in the floor and body (d_{50}) as well as the shear stress (τ) as input and the parameters of water surface width (w), flow depth (h), and longitudinal slope (S) were used as output parameters. Soft computing models were developed in two scenarios based on raw parameters and dimensionless form independent and dependent parameters. The results showed that the statistical characteristics in estimating w , the best performance is related to the MARS model, whose statistical indicators of accuracy in the training stage are $R^2 = 0.902$, RMSE=1.666 and in the test phase is $R^2 = 0.844$, RMSE=2.317. In estimating the channel depth, the performance of both GMDH and MARS models is approximately equal, both of which were developed based on the dimensionless form of flow rate as the input variable. The statistical indicators of both models in the training stage are $R^2 \approx 0.90$, RMSE ≈ 8.15 and in the test phase is $R^2 \approx 0.90$, RMSE = 7.40. The best performance of the developed models in estimating the longitudinal slope of the channel was related to both MARS and GMDH models, although, in part, the accuracy of the GMDH model with statistical indicators $R^2 = 0.942$, RMSE = 0.0011 in the training phase and $R^2 = 0.925$, RMSE = 0.0014 in the experimental stage is more than the MARS model.

Keywords: Artificial neural network, GMDH model, MARS model, Erosion channel, Intelligent regression model

1. Department of Water Engineering, Faculty of Agriculture and Natural Resources, Lorestan University, Iran.

2. Department of Water Engineering, Shahid Chamran University, Ahvaz, Iran.

3. Department of Watershed Management, Faculty of Agriculture and Natural Resources, Lorestan University, Iran.

*: Corresponding author, Email: shahinejad.b@lu.ac.ir