

شبیه‌سازی روزنه‌های جانبی مستطیلی و دایروی توسط ماشین آموزش نیرومند

سعید شهبانو* (دانشیار)

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

حسن شرفی (استادیار)

گروه مهندسی عمران، دانشگاه رازی کرمانشاه

مجید حیدری (استادیار)

گروه علوم و مهندسی آب، دانشگاه بوعلی سینا همدان

سعید کردار (استادیار)

گروه معماری، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی

مهندسی عمران شریف، تابستان (۱۳۹۹)
دربی ۲، ۳۶-۲، شماره ۲/۲، ص. ۹۳-۱۰۳

در مطالعه‌ی حاضر، با استفاده از ماشین آموزش نیرومند، ضریب دبی روزنه‌های جانبی مستطیلی و دایروی تخمین زده شده است. برای ارزیابی دقت مدل‌سازی از شبیه‌سازی‌ها مونت‌کارلو و جهت صحت‌سنجی از روش اعتبارسنجی چندلایه برای $k=5$ استفاده شده است. ابتدا بهینه‌ترین تعداد نرون‌های لایه‌ی مخفی مساوی 3^0 انتخاب شده است. همچنین نتایج کلیدی توابع فعال‌سازی مدل ماشین آموزش نیرومند بررسی و تابع فعال‌سازی sigmoid برای شبیه‌سازی انتخاب شده است. سپس، توسط پارامترهای ورودی، ۲ ترکیب مدل‌سازی و ۵ مدل ماشین آموزش نیرومند توسعه داده شده است. تجزیه و تحلیل نتایج مدل‌سازی‌ها نشان داد مدلی که شامل پارامتر ضریب شکل بود، دقت بیشتری داشته است. به عنوان مثال، مقادیر R و $MAPE$ برای مدل مذکور به ترتیب مساوی با 0.99 و 0.223 تخمین زده شده است. نتایج مدل برتر با روابط تجربی نیز مقایسه و نشان داده شد که مدل اخیر، دقت بیشتری داشته است. همچنین برای کلیدی پارامترهای ورودی، تحلیل حساسیت مشتق نسبی اجرا شده است.

واژگان کلیدی: روزنه‌ی جانبی، ضریب دبی، تحلیل حساسیت مشتق نسبی، اعتبارسنجی چندلایه، شبیه‌سازی مونت‌کارلو.

saeid.shabanlou@gmail.com
h-sharafi@razi.ac.ir
mheydari@basu.ac.ir
saeid.kardar@gmail.com

۱. مقدمه

روزنه‌های جانبی به شکل گسترده‌ی در شبکه‌های زهکشی - آبیاری، سیستم‌های جمع‌آوری فاضلاب و سایر اهداف هیدرولیکی استفاده می‌شوند. مطالعات آزمایشگاهی و تئوری فراوانی توسط پژوهشگران مختلف بر روی رفتار جریان و دبی عبوری از روزنه‌های جانبی انجام و رفتار هیدرولیکی روزنه‌های جانبی ارزیابی شده است. [۱-۶] حسین و همکاران (۲۰۱۱) نیز در مطالعه‌ی آزمایشگاهی رفتار هیدرولیکی روزنه‌های جانبی مستطیلی، برای محاسبه‌ی ضریب آبگذری روزنه‌های مذکور یک معادله را ارائه کردند که ضریب دبی را با دقت مناسبی پیش‌بینی می‌کند. همچنین معادله‌ی اخیر مقادیر ضریب دبی را بر حسب عدد فرود (F_r) و نسبت قطر روزنه‌ی جانبی به عرض کانال اصلی (B/D) پیش‌بینی کرده است. [۷]

در دهه‌ی اخیر، روش‌های گوناگون شبکه‌ی عصبی و هوش مصنوعی در

* نویسنده مسئول

تاریخ: دریافت ۱۳۹۷/۱۰/۲۳، اصلاحیه ۱۳۹۷/۱۲/۱۱، پذیرش ۱۳۹۸/۲/۱۰

DOI:10.24200/J30.2019.52307.2465

پیش‌بینی و الگوشناسی پدیده‌های پیچیده، مشکل و غیرخطی علوم مختلف توسط بسیاری از پژوهشگران استفاده شده است. امیراگو و همکاران (۲۰۱۰)، [۸] رابطه‌ی برای محاسبه‌ی ضریب دبی سرریزهای جانبی کنگره‌ی مثلثی واقع بر یک کانال مستطیلی در شرایط جریان زیر بحرانی را با استفاده از روش نو - فازی انفیس^۱ ارائه کردند. همچنین دورسان و همکاران (۲۰۱۲)، با استفاده از مدل انفیس، معادله‌ی برای محاسبه‌ی ضریب دبی سرریزهای جانبی نیمه‌بیضوی واقع بر کانال‌های مستطیلی در شرایط جریان زیر بحرانی ارائه کردند که تابعی از عدد فرود بالادست سرریز جانبی، نسبت طول دهانه‌ی سرریز جانبی به عرض کانال اصلی، طول دهانه‌ی سرریز جانبی به طول تاج سرریز، ارتفاع تاج سرریز جانبی به عمق جریان در ابتدای بالادست سرریز جانبی و شعاع کوچک به شعاع بزرگ سرریز جانبی بیضوی بوده است. [۹] کیسی و همکاران (۲۰۱۲)، نیز مشخصات جریان انحرافی از روی سرریزهای جانبی مثلثی کنگره‌ی را با استفاده از الگوریتم‌های مختلف هوش مصنوعی تحلیل رگرسیون خطی و غیرخطی پیش‌بینی کردند و با تجزیه و تحلیل نتایج مدل‌سازی‌ها نشان

دادند که مدل RBNN^۲ در مقایسه با سایر الگوریتم‌ها، دقت بالاتری در پیش‌بینی ظرفیت آبگذری سرریزهای جانبی اخیر دارد.^[۱۰]

عظمت‌اله و احمد (۲۰۱۳)، هم با استفاده از مدل برنامه‌نویسی بیان ژن، دبی عبوری از میان دریچه‌های جانبی مستطیلی شکل را پیش‌بینی کردند.^[۱۱] در ادامه، اقبالزاده و همکاران (۲۰۱۶)، با استفاده از شبکه‌ی عصبی مصنوعی، مقادیر ضریب دبی روزنه‌های جانبی را شبیه‌سازی کردند و یک معادله برای محاسبه‌ی این نوع از سازه‌های انحرافی جریان پیشنهاد کردند.^[۱۲] علاوه بر این، عظیمی و همکاران (۲۰۱۷)، با استفاده از روش‌های انقیس و الگوریتم ژنتیک، یک مدل ترکیبی برای تخمین روزنه‌های جانبی مستطیلی توسعه دادند و نتایج مدل هوش مصنوعی را با مدل دینامیک سیال‌های محاسباتی مقایسه و بیان کردند که مدل هیبریدی، دقت بیشتری دارد.^[۱۳]

با مرور مطالعات پیشین مشاهده می‌شود که تاکنون ضریب دبی روزنه‌های جانبی توسط ماشین آموزش نیرومند شبیه‌سازی نشده است. همچنین در مطالعه‌ی حاضر، برای اولین بار با استفاده از روش‌های مونت‌کارلو و اعتبارسنجی چندلایه، ضریب دبی سازی‌های انحرافی مذکور شبیه‌سازی شده است. ضریب شکل روزنه‌ی جانبی نیز به صورت دقیقی ارزیابی و تأثیر آن در ترکیب‌های مدل‌سازی متنوع مطالعه و بهینه‌ترین تعداد نرون‌های لایه‌ی مخفی و بهترین تابع فعال‌سازی انتخاب شده است. علاوه بر این، در مطالعه‌ی حاضر، برای اولین بار تحلیل حساسیت مشتق نسبی برای مدل برتر اجرا و در انتها، یک معادله جهت محاسبه‌ی ضریب دبی روزنه‌های جانبی پیشنهاد داده شده است.

۲. ماشین آموزش نیرومند

ماشین آموزش نیرومند (ELM)^۳ یک شبکه‌ی عصبی پیشخور^۴ و نسل اول آن تک‌لایه است، که توسط هوانگ^۵ و همکاران در سال ۲۰۰۴ ارائه شده است.^[۱۴] مدل ELM، وزن‌های ورودی را به صورت تصادفی و وزن‌های خروجی را به صورت تحلیلی^۶ تعیین می‌کند. تفاوت ELM با شبکه‌ی عصبی پیشخور تک‌لایه (SLFFNN)^۷، عدم استفاده از بایاس^۸ برای نرون خروجی است. نرون‌های لایه‌ی ورودی با همه‌ی نرون‌های لایه‌ی مخفی در ارتباط است. نرون‌های لایه‌ی مخفی با استفاده از یک بایاس به وجود می‌آیند. تابع فعال‌سازی نرون‌های مخفی می‌تواند به صورت تابع پیوسته‌ی تکه‌یی^۹ باشد، در حالی که برای نرون‌های لایه‌ی خروجی به صورت خطی است. مدل ELM از الگوریتم‌های مختلفی جهت محاسبه‌ی وزن‌ها و بایاس‌ها استفاده می‌کند، که در نتیجه کاهش قابل توجه زمان آموزش شبکه را به همراه دارد. توصیف ریاضی شبکه‌ی عصبی پیشخور تک‌لایه با تعداد n گره مخفی، به صورت رابطه‌ی ۱ بیان می‌شود:

$$f_n(x) = \sum_{i=1}^n \beta_i G(a_i, b_i, x) \quad (1)$$

که در آن، β_i وزن بین گره مخفی i ام و گره خروجی، a_i ($a_i \in R^n$) و b_i عامل‌های آموزش گره‌های مخفی و $G(a_i, b_i, x)$ خروجی گره i ام برای ورودی x است. تابع فعال‌سازی $g(x)$ (که انواع مختلفی دارند) را می‌توان برای گره مخفی افزایشدهنده^{۱۰} $G(a_i, b_i, x)$ به شکل رابطه‌ی ۲ بازنویسی کرد:

$$G(a_i, b_i, x) = g(a_i \cdot x + b_i) \quad (2)$$

از توابع فعال‌سازی به منظور محاسبه‌ی خروجی پاسخ نرون‌ها نیز استفاده می‌شود. رفتار نرون‌ها از ۲ بخش تشکیل شده است که شامل مجموع وزنی ورودی‌ها و تابع فعال‌سازی است. زمانی که مجموعه‌ی سیگنال ورودی وزن‌دار اعمال می‌شود، برای به دست آوردن پاسخ از توابع فعال‌سازی استفاده می‌شود. همچنین برای نرون‌های لایه‌های یکسان از توابع فعال‌سازی یکسان استفاده می‌شود که ممکن است خطی و یا غیرخطی باشند. در توابع خطی، یک گراف خطی مستقیم کشیده می‌شود و در توابع غیرخطی یک خط منحنی‌دار ترسیم می‌شود و با توجه به اینکه در توابع غیرخطی، میزان متغیرهای ورودی و خروجی ثابت نیستند، مشکلات طبقه‌بندی در آن‌ها معمول است.^[۱۵] توابع فعال‌سازی غیرخطی ELM که در مطالعه‌ی حاضر بررسی شده‌اند، عبارت‌اند از: پله‌یی^{۱۱}، سیگموئید^{۱۲} (sig)، سینوسی (sin)، بایاس مثلثی^{۱۳} و بایاس شعاعی^{۱۴}. در مدل ELM، وزن‌ها و بایاس‌ها بین نرون‌های لایه‌ی ورودی و مخفی به صورت تصادفی اختصاص داده می‌شوند. فعال‌سازی نرون‌های لایه‌ی مخفی برای هر نمونه‌ی آموزشی در یک شبکه‌ی ELM با تعداد z نرون در لایه‌ی مخفی، i نرون ورودی، و تعداد k نمونه‌ی آموزشی، از رابطه‌ی ۳ محاسبه می‌شود:

$$H_{j k} = g\left(\sum (W_{ji} X_{ik}) + B_j\right) \quad (3)$$

که در آن، $g(\cdot)$ می‌تواند هر تابع فعال‌سازی غیرخطی پیوسته باشد، W_{ji} وزن نرون ورودی i ام و نرون لایه‌ی مخفی j ام، B_j بایاس نرون لایه‌ی مخفی j ام، X_{ik} ورودی نرون ورودی برای k امین نمونه‌ی آموزشی و H_{ik} ماتریس فعال‌سازی i امین نرون لایه‌ی مخفی برای k امین نمونه‌ی آموزشی است، به طوری که فعال‌سازی همه‌ی نرون‌های لایه‌ی مخفی برای نمونه‌های مورد استفاده در آموزش توسط ماتریس مذکور ارائه می‌شود و در آن، z ستون و k ردیف است. ماتریس H به عنوان ماتریس لایه‌ی مخفی خروجی شبکه‌ی عصبی بیان می‌شود. وزن‌های بین نرون‌های لایه‌ی مخفی و خروجی با استفاده از برازش کمینه‌ی مربعات برای مقادیر هدف در حالت آموزش در برابر خروجی‌های نرون‌های لایه‌ی مخفی برای هر نمونه‌ی آموزشی به کار برده می‌شود که معادل ریاضی آن را می‌توان به شکل روابط ۴ و ۵ بیان کرد:

$$H\beta = T \quad (4)$$

$$\beta = (\beta_1, \dots, \beta_j)_{j \times 1} \quad (5)$$

که در آن، β نشان‌دهنده‌ی وزن بین نرون‌های لایه‌ی خروجی و نرون‌های لایه‌ی مخفی و T بردار نشان‌دهنده‌ی مقادیر هدف برای نمونه‌های آموزش است که به صورت رابطه‌ی ۶ بیان می‌شود:

$$T = (T_1, \dots, T_k)_{k \times 1} \quad (6)$$

نهایتاً وزن‌ها را می‌توان از رابطه‌ی ۷ محاسبه کرد:

$$\beta = H^+ T \quad (7)$$

که در آن H و β از روابط ۸ و ۹ به دست می‌آیند:

$$H(\tilde{a}, \tilde{b}, \tilde{x}) = \begin{bmatrix} G(a_1, b_1, x_1) & \dots & G(a_L, b_L, x_1) \\ \vdots & \ddots & \vdots \\ G(a_1, b_1, x_N) & \dots & G(a_L, b_L, x_N) \end{bmatrix}_{N \times L} \quad (8)$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_L^T \end{bmatrix}_{L \times m} \quad \text{and} \quad T = \begin{bmatrix} T_1^T \\ \vdots \\ T_L^T \end{bmatrix}_{L \times m} \quad (9)$$

با توجه به اینکه عدد فرود جریان عبارت است از $F_r = \frac{V_1}{\sqrt{g \cdot Y_m}}$ ، مقدار چگالی، ویسکوزیته و شتاب جاذبه ثابت در نظر گرفته می‌شود و در مقابل مقادیر W ، B و Y_m به طول روزنه‌ی جانبی مستطیلی بدون بُعد می‌شوند. بنابراین معادله‌ی ۱۰ به صورت رابطه‌ی ۱۱ نوشته می‌شود:


$$C_d = f_1 \left(\frac{B}{D}, \frac{W}{D}, \frac{Y_m}{D}, F_r, \phi \right) \quad (11)$$

همچنین در مطالعه‌ی حاضر، تأثیر شکل روزنه‌ی جانبی نیز بررسی شده است. برای در نظر گرفتن آثار شکل روزنه‌ی جانبی، پارامتر ϕ معرفی شده است. برای روزنه‌ی جانبی مستطیلی، مقدار پارامتر ϕ برابر ۱ و برای روزنه‌ی جانبی دایروی، مقدار پارامتر ϕ مساوی ۲ در نظر گرفته شد. بنابراین ترکیب پارامترهای ورودی به صورت معادله‌ی ۱۲ نوشته می‌شود:

$$C_d = f_2 \left(\frac{B}{D}, \frac{w}{D}, \frac{Y_m}{D}, F_r, \phi \right) \quad (12)$$

بنابراین برای مدل‌سازی ضریب دبی روزنه‌های جانبی از پارامترهای بدون بُعد معادله‌ی ۱۲ استفاده شد. در شکل ۱، نحوه‌ی ترکیب پارامترهای ورودی مدل‌های مختلف ماشین آموزش نیرومند در دو حالت ترکیب‌های ۱ و ۲ مشاهده می‌شود، که دو ترکیب متفاوت اخیر برای شناسایی میزان تأثیر ضریب شکل در مدل‌سازی ضریب دبی هستند. همچنین به منظور شناسایی مؤثرترین پارامتر ورودی در هر یک از ترکیب‌های مختلف، تأثیر پارامترهای بدون بُعد ورودی به صورت تک به تک حذف و مدل‌سازی اجرا شده است.

همچنین در مطالعه‌ی حاضر، برای ارزیابی توانایی مدل‌های ماشین آموزش نیرومند از شبیه‌سازی مونت‌کارلو^{۱۷} استفاده شده است. شبیه‌سازی مونت‌کارلو، یک طبقه‌بندی گسترده از الگوریتم‌های محاسباتی است که از نمونه‌گیری تصادفی برای محاسبه‌ی نتایج عددی استفاده می‌کند. ایده‌ی اصلی روش مونت‌کارلو بر مبنای استفاده از تصمیم‌گیری تصادفی مسائلی که ممکن است در اصل قطعی باشند، را حل می‌کند. روش‌های مونت‌کارلو معمولاً برای شبیه‌سازی سیستم‌های فیزیکی و ریاضی، که اغلب حل آن‌ها با استفاده از روش‌های دیگر مقدور نیست، استفاده می‌شود. شبیه‌سازی مونت‌کارلو به‌طور کلی به‌وسیله‌ی توزیع احتمالی برای حل مسائل مختلف، از قبیل: بهینه‌سازی و انتگرال‌گیری عددی استفاده می‌شود. علاوه بر این، از روش اعتبارسنجی چندلایه‌ی^{۱۸} برای بررسی عملکرد مدل‌های مذکور استفاده شده است. در روش اعتبارسنجی چندلایه‌ی، نمونه‌ی اصلی به‌طور تصادفی به k نمونه‌ی فرعی به اندازه‌ی مساوی تقسیم می‌شود. در بین نمونه‌های فرعی k ، یک نمونه‌ی فرعی به‌عنوان داده‌های اعتبارسنجی و باقی‌مانده‌ی آن‌ها به‌عنوان داده‌های آزمون



شکل ۱. ترکیب مدل‌های مختلف در شرایط متفاوت.

که در آن، $\vec{a} = a_1, \dots, a_L$ ، $\vec{b} = b_1, \dots, b_L$ ، $\vec{x} = x_1, \dots, x_L$ وزن بین نرون‌های لایه‌های مخفی و لایه‌ی پنهان و H^+ شبه‌معکوس Moore-Penrose ماتریس H است. T بردار بین وزن‌های نمونه‌های آموزشی است. با توجه به توضیحات ارائه شده می‌توان گفت که آموزش ELM شامل دو مرحله است: مرحله‌ی اول، اختصاص تصادفی وزن‌ها و بایاس‌ها به نرون‌های لایه‌ی پنهان و محاسبه‌ی خروجی لایه‌ی پنهان ماتریس H و مرحله‌ی دوم، محاسبه‌ی وزن‌های خروجی با استفاده از شبه‌معکوس Moore-Penrose ماتریس H و مقادیر هدف برای نمونه‌های آموزشی مختلف است. روند آموزش جهت پیدا کردن شبه معکوس Moore-Penrose ماتریس لایه‌ی پنهان (H) سریع است؛ به‌طوری که سرعت بالاتری نسبت به الگوریتم‌های مبتنی بر تکرار رایج مانند لوبنبرگ - مارکوآردت^{۱۵} که در آن هیچ نوع روالی از بهینه‌سازی غیرخطی را در بر نمی‌گیرد، دارد. بنابراین زمان آموزش شبکه به‌طور قابل توجهی کاهش می‌یابد (هوآنگ ۲۰۰۶). مدل ELM با استفاده از تعداد زیادی از پیش‌بینی فضای ورودی تصادفی غیرخطی کار می‌کند، به‌طوری که هر نرون با یک نمونه‌ی تصادفی منفرد در ارتباط است. لازم به یادآوری است که اجرای مدل‌سازی توسط ELM در محیط نرم‌افزار متلب^{۱۶} انجام شده است.

۳. مدل آزمایشگاهی

در مطالعه‌ی حاضر، برای اعتبارسنجی نتایج شبیه‌سازی عددی از مقادیر آزمایشگاهی اندازه‌گیری شده توسط حسین و همکاران (۲۰۱۰ و ۲۰۱۱)^[۷،۶] استفاده شده است. این مدل آزمایشگاهی شامل یک کانال مستطیلی به طول، عرض و ارتفاع ۹/۱۵، ۰/۵ و ۰/۶ متر بوده و روزنه‌های دایروی و مستطیلی شکل در فاصله‌ی ۵ متری از ورودی کانال اصلی بر روی دیواره‌ی جانبی نصب شده است. محدوده‌ی اندازه‌گیری‌های آزمایشگاهی در جدول ۱ مرتب شده است.

۴. ضریب دبی روزنه‌های جانبی

حسین و همکاران (۲۰۱۰ و ۲۰۱۱)^[۷،۶] ظرفیت آنگذری سرریزهای جانبی مستطیلی (C_d) را به‌عنوان تابعی از طول و عرض روزنه‌ی جانبی مستطیلی یا قطر روزنه‌ی دایروی (D)، عرض کانال اصلی (B)، ارتفاع کف روزنه‌ی جانبی از بستر کانال اصلی (W)، سرعت جریان داخل کانال اصلی (V_1)، عمق جریان درون کانال اصلی (Y_m)، چگالی سیال (ρ)، ویسکوزیته جریان (μ)، و شتاب جاذبه (g) را در نظر گرفتند (رابطه‌ی ۱۰):

$$C_d = f_1(L, b, B, W, V_1, Y_m, \rho, \mu, g) \quad (10)$$

جدول ۱. محدوده‌ی اندازه‌گیری‌های آزمایشگاهی حسین و همکاران (۲۰۱۰ و ۲۰۱۱).

پارامتر	بیشینه	کمینه	میانگین
B/D	۱۱/۳۶۴	۳/۳۳۳	۶/۶۷۵
W/D	۴/۵۴۵	۰/۳۳۳	۱/۶۴۷
Y_m/d	۱۲/۷۶۴	۱/۷۴۳	۵/۲۰۲
Fr	۰/۵۱۹	۰/۰۳۶	۰/۲۲۵
ϕ	۲	۱	۱/۵۴۸

$$R = \frac{\sum_{i=1}^n ((R)_{(Observed)_i} - (\bar{R})_{(Observed)})((R)_{(Predicted)_i} - (\bar{R})_{(Predicted)})}{\sqrt{\sum_{i=1}^n ((R)_{(Observed)_i} - (\bar{R})_{(Observed)})^2 \sum_{i=1}^n ((R)_{(Predicted)_i} - (\bar{R})_{(Predicted)})^2}} \quad (15)$$

۲.۵. تعیین تعداد نرون‌های لایه‌ی مخفی (NHLN)

در مرحله‌ی نخست، باید نرون‌های لایه‌ی مخفی تعیین شود. این کار با افزایش تعداد نرون‌های لایه‌ی مخفی (NHLN) و محاسبه‌ی مقادیر مختلف شاخص‌های آماری انجام می‌شود. به بیان دیگر، مقدار نرون‌های لایه‌ی مخفی افزایش می‌یابد و شاخص‌های آماری محاسبه می‌شود؛ این کار تا زمانی ادامه می‌یابد که مقادیر خطا ثابت شود. تغییرات تعداد نرون‌های لایه‌ی مخفی برای شاخص‌های آماری خطای مطلق میانگین (MAE)، خطای جذر میانگین مربعات ($RMSE$)، ضریب همبستگی (R) و درصد میانگین مطلق خطا ($MAPE$) در شکل ۳ مشاهده می‌شود که مطابق آن بعد از انتخاب نرون‌های لایه‌ی مخفی مساوی ۳۰، مقادیر خطا تقریباً ثابت شده‌اند. به عنوان مثال، مقدار MAE ، $RMSE$ و ضریب همبستگی برای شرایطی که تعداد نرون‌های لایه‌ی مخفی مساوی ۳۰ انتخاب شده است، به ترتیب برابر ۰/۰۰۱، ۰/۰۰۶، و ۰/۹۹۰ هستند. همچنین مقدار درصد میانگین مطلق خطا مساوی با ۰/۲۲۳ محاسبه شده است. این مقادیر خطا با افزایش تعداد نرون‌های لایه‌ی مخفی به‌طور محسوسی تغییر نکرده‌اند. بنابراین در مطالعه‌ی حاضر، تعداد نرون‌های لایه‌ی مخفی مساوی ۳۰ انتخاب شده است.

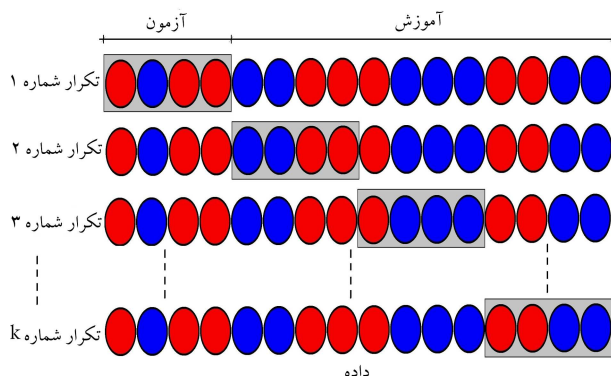
۳.۵. تعیین توابع فعال‌سازی مدل ماشین آموزش نیرومند

در ابتدا برای مدل ماشین آموزش نیرومند (ELM) به بررسی توابع فعال‌سازی پرداخته شده است. در بخش حاضر، کلیه‌ی توابع فعال‌سازی ارزیابی و در ادامه، تابع فعال‌سازی برتر معرفی شده است. همچنین تغییرات شاخص‌های آماری متفاوت برای توابع فعال‌سازی مدل ماشین آموزش نیرومند (ELM) در شکل ۴ مشاهده می‌شود. به عنوان مثال، مقادیر R ، $RMSE$ و MAE برای تابع فعال‌سازی سیگموئید (sigmoid) به ترتیب برابر ۰/۹۹۰، ۰/۰۰۶، و ۰/۰۰۱ محاسبه شده است. علاوه بر این، مقدار $MAPE$ برای تابع فعال‌سازی سیگموئید (sigmoid) مساوی ۰/۲۲۳ تخمین زده شده است. همچنین شاخص آماری R برای توابع فعال‌سازی سین (Sin) و هاردلیمت (Hardlim) به ترتیب مساوی ۰/۹۷۳ و ۰/۷۹۴ محاسبه شده است. علاوه بر این، مقادیر $RMSE$ و $MAPE$ برای تابع فعال‌سازی رادیال بیس (Radbas) به ترتیب مساوی ۰/۰۰۹ و ۰/۳۴۱ تخمین زده شده است. این در حالی است که شاخص‌های آماری MAE و R برای تابع تری‌انگلر بیس (Tribas) به ترتیب برابر ۰/۱۲ و ۰/۸۵۱ به دست آمده است. بنابراین همان‌گونه که مشاهده می‌شود، تابع فعال‌سازی سیگموئید (sigmoid) مقادیر ضریب دبی را با دقت بیشتری شبیه‌سازی می‌کند. همچنین نتایج ضریب دبی شبیه‌سازی شده برای ۵ تابع فعال‌سازی ذکر شده در شکل ۵ مشاهده می‌شود.

۶. مدل‌های ماشین آموزش نیرومند (ELM)

۱.۶. ترکیب یک

در ادامه، به بررسی تحلیل حساسیت مدل‌های ۱ تا ۵ ماشین آموزش نیرومند در حالت ترکیب یک پرداخته شده است. نتایج شاخص‌های آماری برای مدل‌های



شکل ۲. نحوه‌ی برخورد با داده‌ها در روش اعتبارسنجی چندلایه.

مدل مذکور استفاده می‌شوند. سپس روند اعتبارسنجی چندلایه، k بار تکرار می‌شود (برابر تعداد لایه‌ها)، هر کدام از نمونه‌های فرعی k دقیقاً یک بار به عنوان داده‌های اعتبارسنجی استفاده می‌شوند. نتایج به دست آمده از k لایه‌ی مذکور متوسط‌گیری و به عنوان یک تخمین ارائه می‌شود. مزیت روش اخیر، تکرار تصادفی نمونه‌های فرعی در روند آزمون و آموزش برای کلیه‌ی مشاهده‌هاست و هر مشاهده دقیقاً یک بار برای اعتبارسنجی استفاده می‌شود. در مطالعه‌ی حاضر، مقدار k برابر با ۵ فرض شده است. طرح کلی روش اعتبارسنجی چندلایه نیز در شکل ۲ مشاهده می‌شود.

۵. بحث و نتیجه‌گیری

۱.۵. معیارهای بررسی دقت مدل‌های عددی

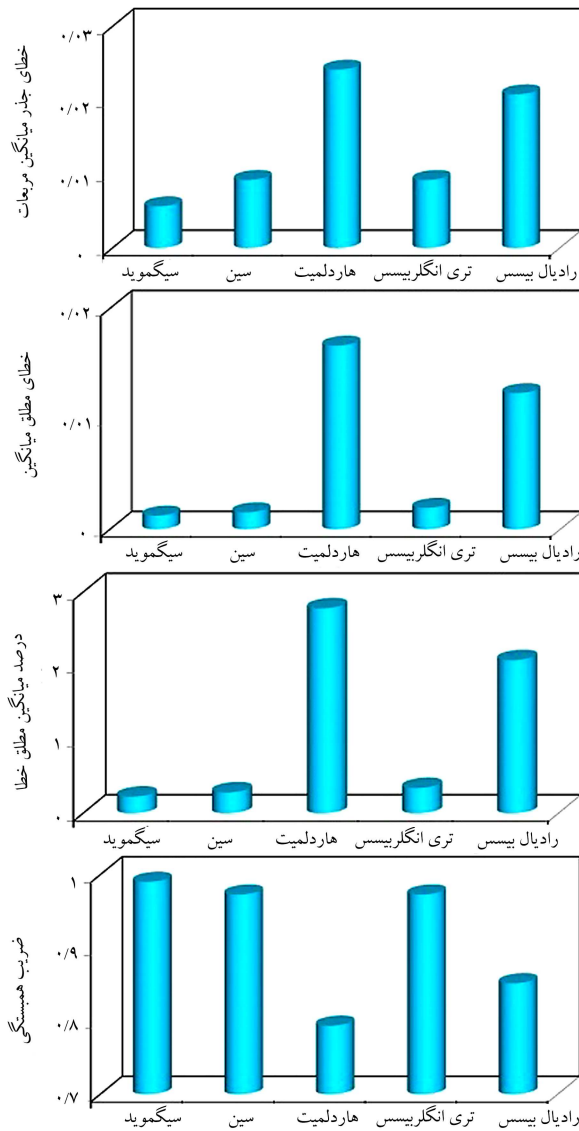
در مطالعه‌ی حاضر، جهت بررسی دقت مدل‌های ماشین آموزش نیرومند (ELM) از شاخص‌های آماری خطای مطلق میانگین (MAE)، خطای جذر میانگین مربعات ($RMSE$)، ضریب همبستگی (R)، و درصد میانگین مطلق خطا ($MAPE$) به صورت روابط ۱۳ الی ۱۶ استفاده شده است:

$$MAE = \frac{1}{n} \sum_{i=1}^n |(R)_{(Predicted)_i} - (R)_{(Observed)_i}| \quad (13)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (R)_{(Predicted)_i} - R_{(Observed)_i})^2} \quad (14)$$

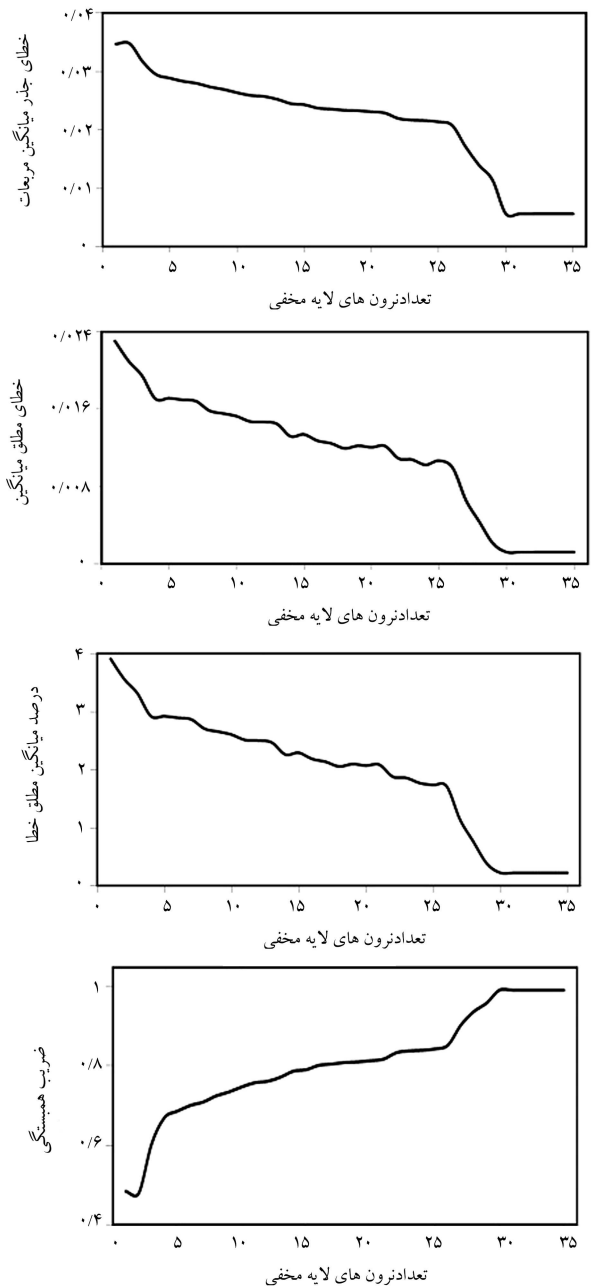
$$MAPE = \frac{1}{n} \sum_{i=1}^n \left(\frac{|(R)_{(Predicted)_i} - (R)_{(Observed)_i}|}{(R)_{(Observed)_i}} \right) \times 100 \quad (16)$$

در معادلات اخیر، مقادیر $(R)_{(Observed)_i}$ ، $(R)_{(Predicted)_i}$ ، $(\bar{R})_{(Observed)}$ و n به ترتیب برابر مقادیر آزمایشگاهی، نتایج پیش‌بینی شده توسط مدل‌های عددی، میانگین مقادیر آزمایشگاهی و تعداد اندازه‌گیری‌های آزمایشگاهی هستند.



شکل ۴. تغییرات شاخص‌های آماری متفاوت برای توابع فعال‌سازی مدل ماشین آموزش نیرومند (ELM).


مدل ۱ بیشترین همبستگی با مقادیر آزمایشگاهی را دارد. چهار مدل بعدی، مقدار ضریب دبی را با ترکیبی از ۴ پارامتر ورودی تخمین می‌زنند. علاوه بر این، در کلیه مدل‌های مذکور، تأثیر پارامتر شکل (φ) در نظر گرفته شده است. به عنوان مثال، مدل ۲ تابعی از پارامترهای $B/D, W/D, Y_m/D, \varphi$ است. همچنین برای مدل ۲، مقادیر $RMSE, MAPE$ و MAE به ترتیب مساوی با $0.014, 0.006, 0.007$ به دست آمده است. برای مدل ۲، مقدار شاخص آماری R نیز مساوی با 0.935 است. این در حالی است که در میان مدل‌های با ۴ پارامتر ورودی، مدل ۳، کمترین دقت را دارد. برای مدل ۳، مقادیر R و MAE به ترتیب مساوی با 0.892 و 0.011 تخمین زده شده است. همچنین مقدار $RMSE$ برای مدل ۳ برابر 0.018 و مقدار $MAPE$ برابر با 0.018 بوده و تأثیر پارامتر بدون بعد Y_m/D حذف شده است. همچنین مدل ۴، مقادیر تابع هدف را بر حسب پارامترهای $B/D, Y_m/D, F_r, \varphi$ شبیه‌سازی می‌کند. برای مدل اخیر، مقادیر شاخص‌های آماری خطای مطلق میانگین، خطای جذر میانگین مربعات و ضریب همبستگی به ترتیب مساوی با $0.008, 0.015$ و 0.932



شکل ۳. تغییرات شاخص‌های آماری مختلف با افزایش تعداد نرون‌های لایه مخفی.

مذکور در شکل ۶ مشاهده می‌شود. همچنین نمودارهای پراکندگی پنج مدل اخیر نیز در شکل ۷ نشان داده شده است. علاوه بر این، نمودار توزیع خطا برای مدل‌های مختلف در شکل ۸ به تصویر کشیده شده است، که در آن نحوه توزیع مقدار خطای تجمعی مدل‌های عددی مشاهده می‌شود. به عنوان مثال، مدل‌های ۱ و ۳ به ترتیب کمترین و بیشترین مقدار خطای تجمعی را دارند.


در مدل ۱، مقادیر ضریب دبی بر حسب کلیه پارامترهای ورودی ($B/D, W/D, Y_m/D, F_r, \varphi$) شبیه‌سازی و مقادیر $RMSE$ و MAE به ترتیب مساوی با 0.001 و 0.006 محاسبه شده است. این در حالی است که مقدار ضریب همبستگی و درصد میانگین مطلق خطا برای مدل ۱ به ترتیب برابر با 0.990 و 0.223 محاسبه شده است. در میان کلیه روش‌های شبیه‌سازی با ترکیب یک،



شکل ۶. شاخص‌های آماری مختلف برای مدل‌های ماشین آموزش نیرومند در شرایط ترکیب یک.


۲.۶. ترکیب دو

در بخش حاضر، مدل‌هایی با ترکیب دو ارزیابی شده‌اند. در این حالت پارامتر شکل، جزء پارامترهای ورودی نیست. به عنوان مثال، مدل ۱ در ترکیب دو، مقادیر ضریب دبی را بر حسب پارامترهای بدون بُعد B/D , F_r , $Y_m/DW/D$ شبیه‌سازی می‌کند. برای مدل ۱ مقادیر R و MAE به ترتیب 0.969 و 0.005 محاسبه شده‌اند. با توجه به نتایج مدل‌سازی، مدل ۱، بیشترین دقت و بالاترین مقدار همبستگی را با مقادیر آزمایشگاهی دارد. همچنین برای مدل ۱، مقادیر $MAPE$ و $RMSE$ به ترتیب مساوی با 0.010 و 0.002 به دست آمده است. این در حالی است که چهار مدل ۲ الی ۵، مقدار تابع هدف را با ترکیبی از ۳ پارامتر ورودی تخمین می‌زنند. به عنوان مثال، مدل ۲، تابعی از پارامترهای W/D , B/D , Y_m/D بوده و برای آن تأثیر عدد فرود حذف شده است. برای مدل ۲، مقادیر ضریب همبستگی، $RMSE$ و $MAPE$ به ترتیب مساوی با 0.9857 ، 0.0020 و 0.0024 محاسبه شده است. در میان مدل‌های با سه پارامتر ورودی، مدل ۳، بالاترین مقدار خطا را دارد. برای

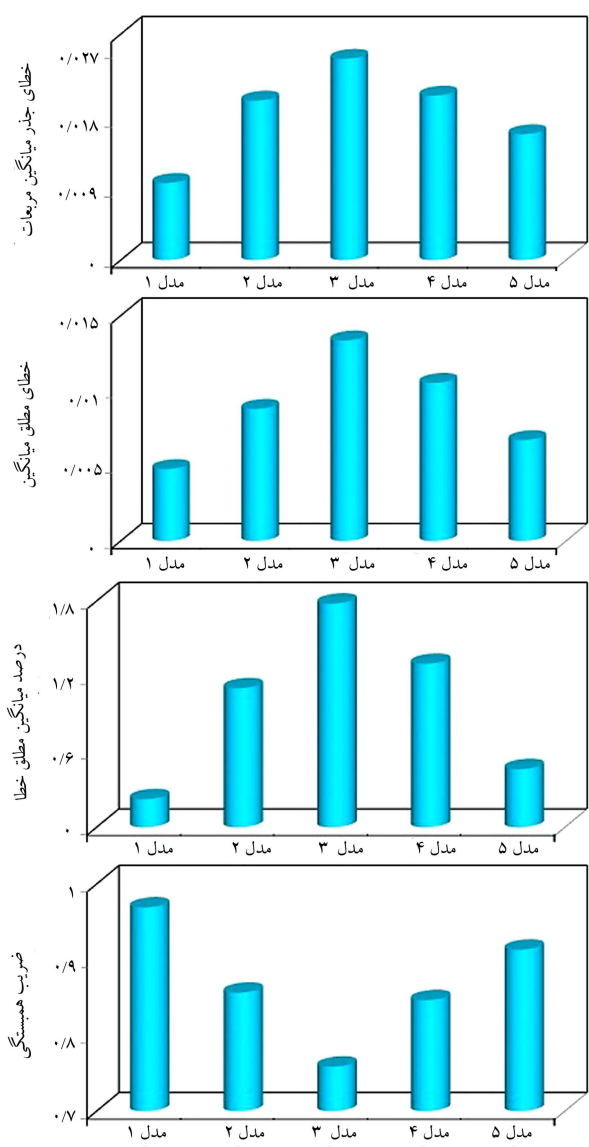


شکل ۵. مقایسه‌ی مقادیر ضریب دبی شبیه‌سازی شده توسط توابع فعال‌سازی مختلف با مقادیر آزمایشگاهی.

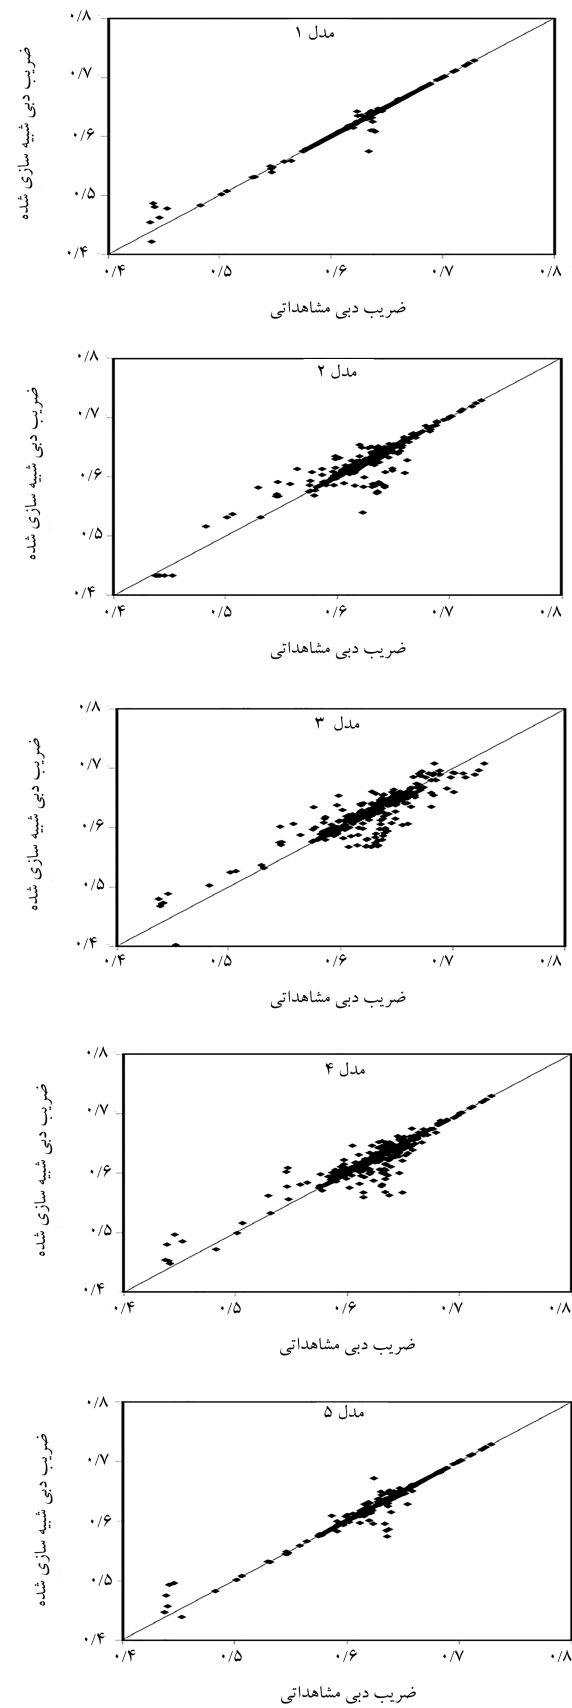
مقدار $MAPE$ برابر با 0.030 بوده است. برای شبیه‌سازی ضریب دبی روزنه‌های جانبی توسط مدل ۵، تأثیر B/D نادیده گرفته شده است. مدل ۵، تابعی از پارامترهای W/D , Y_m/D , F_r , φ بوده و در میان مدل‌های با ۴ پارامتر ورودی، کمترین مقدار خطا را داشته است. مقادیر $MAPE$ و $RMSE$ برای مدل ۵ مساوی 0.0462 و 0.0080 و مقادیر شاخص‌های آماری R و MAE به ترتیب 0.9978 و 0.0030 بوده است. در ترکیب یک، مدل $ELM \setminus$ به عنوان مدل برتر معرفی شده است. مدل $ELM \setminus$ مقادیر ضریب دبی را بر حسب کلیه پارامترهای ورودی شبیه‌سازی کرده است. همچنین براساس نتایج مدل‌سازی، در حالتی که پارامترهای ورودی با ترکیب یک استفاده شوند، پارامتر Y_m/D به عنوان مؤثرترین پارامتر ورودی شناخته می‌شود.




شکل ۸. نمودار توزیع خطا برای مدل‌های پنج‌گانه ماشین آموزش نیرومند برای شرایط ترکیب شماره ۱.



شکل ۹. شاخص‌های آماری مختلف برای مدل‌های ماشین آموزش نیرومند در شرایط ترکیب دو.



شکل ۷. نمودارهای پراکنندگی برای مدل‌های پنج‌گانه‌ی ماشین آموزش نیرومند برای شرایط ترکیب یک.



شکل ۱۱. نمودار توزیع خطا برای مدل‌های پنج‌گانه‌ی ماشین آموزش نیرومند برای شرایط ترکیب یک.


مدل ۳، شاخص‌های آماری $RMSE$ و $MAPE$ به ترتیب مساوی 0.26% و 2.29% به دست آمده‌اند. همچنین مدل ۳ تابعی از پارامترهای $B/D, W/D, Fr$ بوده و برای محاسبه‌ی ضریب دبی در آن، تأثیر پارامتر بدون بُعد Y_m/D نادیده گرفته شده است. برای مدل ۳، مقدار شاخص آماری R نیز مساوی با 0.759 تخمین زده شده است. همچنین مقادیر $MAE, R, MAPE$ برای مدل ۴ برابر با 0.11% ، 0.847% و 1.807% به دست آمده و تأثیر پارامتر W/D حذف شده است. همچنین مدل ۵، مقادیر تابع هدف را با ترکیبی از ۳ پارامتر بدون بُعد $W/D, Y_m/D, Fr$ شبیه‌سازی کرده است. برای مدل ۵ مقادیر شاخص‌های آماری ضریب همبستگی و خطای مطلق میانگین به ترتیب مساوی با 0.913% و 0.007% محاسبه شده است. نتایج شاخص‌های آماری و نمودارهای پراکنندگی برای ترکیب دو، مدل‌های مختلف ماشین آموزش نیرومند در شکل‌های ۹ و ۱۰ نشان داده شده است. همچنین نمودار توزیع خطا مدل‌های ۱ الی ۵ در شکل ۱۱ مشاهده می‌شود، که مطابق آن در حالتی که از ترکیب دو برای شبیه‌سازی ضریب دبی روزه‌های جانبی استفاده می‌شود، مدل ۱، مقادیر تابع هدف را با دقت بالاتری شبیه‌سازی می‌کند. علاوه بر این، بر اساس نتایج تحلیل حساسیت، پارامتر بدون بُعد Y_m/D به عنوان مؤثرترین پارامتر در نظر گرفته شده است.

لازم به ذکر است که در هر دو ترکیب مدل‌سازی یک و دو، مدل ۳، کمترین دقت در شبیه‌سازی ضریب دبی روزه‌های جانبی را داشته است. برای تخمین ضریب دبی توسط مدل ۳، پارامتر Y_m/D حذف شد و به تبع آن دقت مدل‌سازی به شکل قابل توجهی کاهش یافت. پارامتر بدون بُعد Y_m/D ، در مقایسه با سایر پارامترهای ورودی، اهمیت بیشتری دارد، زیرا به‌طور هم‌زمان تأثیر مشخصات هیدرولیکی جریان (Y_m) و هندسی مدل آزمایشگاهی (D) را در نظر گرفته است.

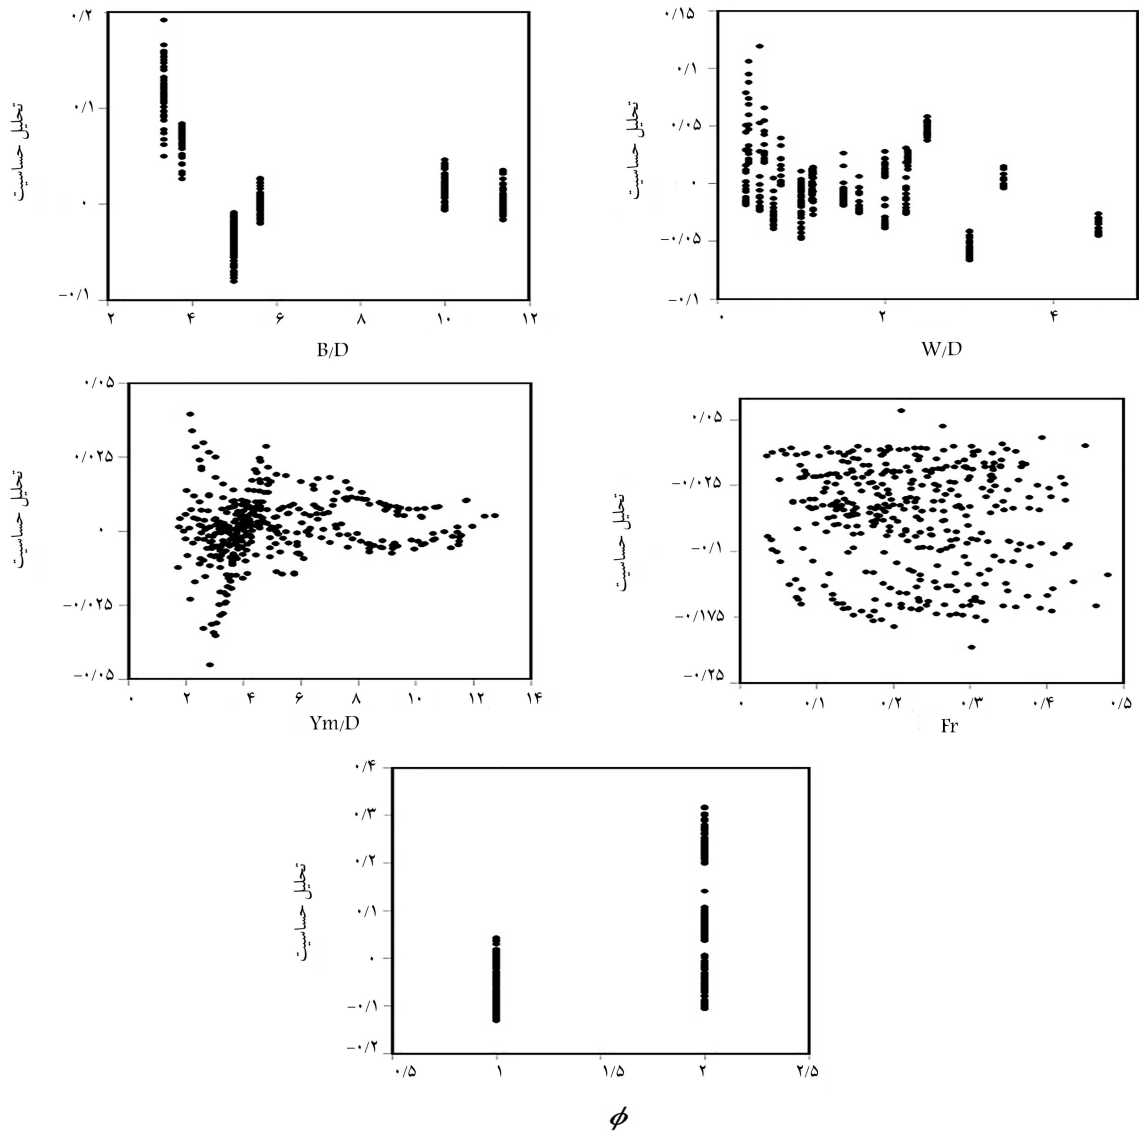
بنابراین، با توجه به نتایج مدل‌سازی، ضریب دبی روزه‌های جانبی مستطیلی و دایروی کلیه‌ی مدل‌هایی که پارامتر بدون بُعد ضریب شکل را در ترکیب پارامترهای ورودی خود دارند، مقادیر تابع هدف را با دقت بیشتری تخمین می‌زنند.

در بخش کنونی، دقت معادله‌های پیشنهادی توسط حسین و همکاران (۲۰۱۱)، [۷] و همکاران (۲۰۱۶)، [۱۲] و $(C_d = 0.670 - 0.076Fr - 0.136(D/B))$

با $(C_d = 1.108\phi^{-0.23}(Y_m/D)^{0.52}(W/D)^{-0.12}Re^{-0.51}Fr^{0.19})$ مدل‌های برتر ELM مقایسه و نتایج شاخص‌های آماری در جدول ۲ ارائه شده



شکل ۱۰. نمودارهای پراکنندگی برای مدل‌های پنج‌گانه‌ی ماشین آموزش نیرومند برای شرایط ترکیب دو.



شکل ۱۲. نتایج تحلیل حساسیت مشتق نسبی برای پارامترهای ورودی مدل برتر.

۷. تحلیل حساسیت مشتق نسبی

در ادامه، به انجام تحلیل حساسیت مشتق نسبی (PDSA)^{۱۹} برای مدل برتر و واسنجی پارامترهای ورودی پرداخته شده است. PDSA یکی از مهم‌ترین روش‌ها برای شناسایی الگوی تغییرات پارامترهای ورودی است.^[۱۶-۱۸] به‌طور کلی، PDSA مثبت به معنای افزایش تابع هدف (ضریب دبی) و در مقابل، منفی بودن آن به معنی کاهش یافتن مقدار خروجی است. نتایج PDSA برای پارامترهای ورودی در شکل ۱۲ نشان داده شده است. به‌عنوان مثال، برای پارامتر B/D تقریباً قریب به اتفاق نتایج PDSA مثبت محاسبه شده و با افزایش پارامتر B/D ، مقدار PDSA کاهش یافته است. این در حالی است که بیشتر مقادیر sensitivity analysis برای عدد فرود منفی به‌دست آمده و از یک الگوی خاص افزایشی یا کاهش‌ی پیروی نکرده است. همچنین، با افزایش پارامتر W/D ، مقدار تحلیل حساسیت با کاهش همراه بوده است. این در حالی است که برای بقیه‌ی

جدول ۲. نتایج شاخص‌های آماری معادله‌ی ۱ و مدل‌های برتر ELM.

مدل‌ها	MAPE	RMSE	MAE
حسین و همکاران (۲۰۱۱)	۳٫۹۷۴	۰٫۸۱۹	۰٫۰۶۴
اقبال‌زاده و همکاران (۲۰۱۶)	۸٫۳۹۵	۰٫۸۱۹	۰٫۰۹۱
ELM۱-TYPE۱	۰٫۲۲۳	۰٫۰۰۶	۰٫۰۰۱
ELM۲-TYPE۲	۰٫۸۰۲	۰٫۰۱۰	۰٫۰۰۵

است که مطابق آن، مقادیر MAE ، $RMSE$ و $MAPE$ برای معادله‌ی ۱ به ترتیب مساوی ۰٫۰۶۴، ۰٫۸۱۹، ۳٫۹۷۴ محاسبه شده است. این در حالی است که مقدار شاخص‌های آماری $MAPE$ و $RMSE$ برای معادله‌ی ۲ به ترتیب برابر با ۰٫۸۱۹ و ۸٫۳۹۵ به‌دست آمده است. با توجه نتایج مدل‌های عددی، مدل ELM۱ با ترکیب‌های مختلف در مقایسه با معادله‌های تجربی، دقت بیشتری دارد.

ابتدا بهینه‌ترین تعداد نرون‌های لایه‌ی مخفی و دقیق‌ترین تابع فعال‌سازی انتخاب و سپس با استفاده از پارامترهای ورودی، ۵ مدل ماشین آموزش نیرومند توسعه داده شد. همچنین ضریب شکل روزه‌ی جانبی به عنوان یک پارامتر مجزا در شبیه‌سازی‌ها استفاده شد. تجزیه و تحلیل نتایج مدل‌سازی‌ها نشان می‌دهد که مدل با پارامتر ضریب شکل روزه‌ی جانبی، دقت بیشتری دارد. سپس تحلیل حساسیت نشان داد که پارامتر عمق جریان به قطر روزه‌ی جانبی (Y_m/D) به عنوان مؤثرترین پارامتر ورودی شناسایی شده است. علاوه بر این، تحلیل حساسیت مشتق نسبی برای کلیه‌ی پارامترهای ورودی اجرا شده است.

پارامترها نیز بخشی از نتایج PDSA مثبت و بخش دیگر منفی تخمین زده شده است.

۸. نتیجه‌گیری

در مطالعه‌ی حاضر، برای اولین بار توسط مدل جدید ماشین آموزش نیرومند (ELM)، ضریب دبی روزه‌های جانبی مستطیلی و دایروی شبیه‌سازی شده است.

پانوشتها

1. Anfis
2. radial bases neural networks (RBNN)
3. extreme learning machine (ELM)
4. feed-forward
5. Huang
6. analytical
7. single layer feed forward neural network
8. bias
9. piecewise continuous function
10. additive
11. hardlim
12. sigmoid
13. tribas
14. radbas
15. Levenberg-Marquardt
16. Matlab
17. Monte Carlo simulation
18. k-fold cross validation
19. the partial derivative sensitivity analysis

منابع (References)

1. Carballada, B.L. "Some characteristics of lateral flows", Thesis, Concordia Univ. Montreal, PQ (1979).
2. Ramamurthy, A.S., Udoyara, S.T. and Serraf, S. "Rectangular lateral orifices in open channel", *Journal of Environmental Engineering*, **135**(5), pp. 292-298 (1986).
3. Ramamurthy, A.S., Udoyara, S.T. and Rao, M.V.J. "Weir orifice units for uniform flow distribution", *Journal of Environmental Engineering*, **113**(1), pp. 155-166 (1987).
4. Swamee, P.K., Pathak, S.K. and Ali, M.S. "Analysis of rectangular side sluice gate", *Journal of Irrigation and Drainage Engineering*, **119**(6), pp. 1026-1035 (1993).
5. Ghodsian, M. "Flow through side sluice gate", *Journal of Irrigation and Drainage Engineering*, **129**(6), pp. 458-462 (2003).
6. Hussein, A., Ahmad, Z. and Asawa, G.L. "Discharge characteristics of sharp-crested circular side orifices in open channels", *Flow Measurement and Instrumentation*, **21**(3), pp. 418-424 (2010).
7. Hussein, A., Ahmad, Z. and Asawa, G.L. "Flow through sharp-crested rectangular side orifices under free flow condition in open channels", *Agricultural Water Management*, **98**, pp. 1536-1544 (2011).
8. Emiroglu, M.E., Kisi, O. and Bilhan, O. "Predicting discharge capacity of triangular labyrinth side weir located on a straight channel by using an adaptive neuro-fuzzy technique", *Advances in Engineering Software*, **41**(2), pp. 154-160 (2010).
9. Dursun, O.F., Kaya, N. and Firat, M. "Estimating discharge coefficient of semi-elliptical side weir using ANFIS", *Journal of Hydrology*, **426-427**, pp. 55-62 (2012).
10. Kisi, O., Emiroglu, M.E., Bilhan, O. and et al. "Prediction of lateral outflow over triangular labyrinth side weirs under subcritical conditions using soft computing approaches", *Expert Systems with Applications*, **39**(3), pp. 3454-3460 (2012).
11. Azamathulla, H.M. and Ahmad, Z. "Computation of discharge through side sluice gate using gene-expression programming", *Irrigation and Drainage*, **62**(1), pp. 115-119 (2013).
12. Eghbalzadeh, A., Javan, M., Hayati, M. and et al. "Discharge prediction of circular and rectangular side orifices using artificial neural networks", *KSCE Journal of Civil Engineering*, **20**(2), pp. 990-996 (2016).
13. Azimi, H., Shabanlou, S., Ebtehaj, I. and et al. "Combination of computational fluid dynamics, adaptive neuro-fuzzy inference system, and genetic algorithm for predicting discharge coefficient of rectangular side orifices", *Journal of Irrigation and Drainage Engineering*, **143**(7), 04017015-1:04017015-11 (2017).
14. Huang, G-B., Zhu, Q-Y. and Siew, C-K. "Extreme learning machine: a new learning scheme of feedforward neural networks", *Proc. Int. Joint Conf. Neural Netw.*, 2, pp. 985-990 (2004).
15. Pandey, P. and Govind, R. "Analysis of randomized performance of bias parameters and activation function

- of extreme learning machine”, *International Journal of Computer Applications*, **135**(1), pp. 23-28 (2016).
16. Ebtehaj, I., Bonakdari, H. and Shamshirband, S. “Extreme learning machine assessment for estimating sediment transport in open channels”, *Engineering with Computers*, **32**(4), pp. 691-704 (2016).
 17. Ebtehaj, I. and Bonakdari, H. “A Comparative study of extreme learning machines and support vector machines in prediction of sediment transport in open channels”, *International Journal of Engineering-Transactions B: Applications*, **29**(11), pp. 1499 (2016).
 18. Azimi, H., Bonakdari, H. and Ebtehaj, I. “Sensitivity analysis of the factors affecting the discharge capacity of side weirs in trapezoidal channels using extreme learning machines”, *Flow Measurement and Instrumentation*, **54**, pp. 216-223 (2017).