

مقاله پژوهشی

شبیه‌سازی ضریب دبی دریاچه جانبی توسط مدل نوین ماشین آموزش نیرومند خارج از محدوده

فرزاد حسنی^۱، سعید شهبانلو^{۲*}

تاریخ دریافت: ۱۳۹۹/۰۱/۲۸ تاریخ پذیرش: ۱۴۰۰/۰۱/۲۱

۱- دانشجوی دکتری منابع آب، گروه مهندسی آب، واحد کرمانشاه، دانشگاه آزاد اسلامی، کرمانشاه، ایران

۲- دانشیار گروه مهندسی آب، واحد کرمانشاه، دانشگاه آزاد اسلامی، کرمانشاه، ایران

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

چکیده

در این مطالعه برای اولین بار ضریب دبی دریاچه جانبی توسط یک روش نوین هوش مصنوعی تحت عنوان ماشین آموزش نیرومند خارج از محدوده (ORELM) شبیه‌سازی شد. برای اینکار، ابتدا پارامترهای موثر بر روی ضریب دبی شامل نسبت عرض کانال اصلی به طول دریاچه جانبی (B/L)، نسبت ارتفاع تاج دریاچه جانبی به طول دریاچه جانبی (W/L)، نسبت عمق جریان به طول دریاچه جانبی (Y_m/L) و عدد فرود (Fr) شناسایی شدند و پنج مدل ORELM با استفاده از این پارامترها توسعه داده شدند (ORELM 1 to ORELM 5). سپس داده‌های آزمایشگاهی به دو دسته آموزش (۷۰ درصد) و آزمون (۳۰ درصد) تقسیم شدند. در ادامه با انجام یک تحلیل حساسیت مدل برتر و موثرترین پارامترهای ورودی شناسایی شدند. مدل برتر (ORELM 3) مقادیر ضریب دبی را بر حسب W/L ، B/L و Fr شبیه‌سازی کرد. لازم به ذکر است که مدل ORELM 3 مقادیر ضریب دبی را با دقت مناسبی پیش‌بینی نمود. به‌عنوان مثال، مقادیر ضریب همبستگی (R)، شاخص پراکندگی (SI) و ضریب بهره‌وری نش-ساتکیف (NSC) در وضعیت آزمون برای مدل ORELM 3 به ترتیب مساوی با ۰/۹۳۶، ۰/۰۴۹ و ۰/۸۵۲ بدست آمدند. تجزیه و تحلیل نتایج شبیه‌سازی نشان داد که W/L و Fr موثرترین پارامترهای ورودی برای شبیه‌سازی ضریب دبی بودند. علاوه بر این نتایج تحلیل عدم قطعیت نشان داد که مدل ORELM 3 عملکردی کمتر از واقعی داشت.

واژه‌های کلیدی: تحلیل حساسیت، تحلیل مشتق نسبی، تحلیل عدم قطعیت، دریاچه جانبی، ضریب دبی، ماشین آموزش نیرومند خارج از محدوده.

Simulation of Discharge Coefficient of Side Slots Using a Novel Outlier Robust Extreme Learning Machine

F Hasani¹, S Shabanlou^{2*}

Received: April 16, 2020

Accepted: April 10, 2021

1- Ph.D. Candidate, Dept. of Water Eng., Kermanshah Branch, Islamic Azad Univ., Kermanshah, Iran.

2- Assoc. Prof., Dept. of Water Eng., Kermanshah Branch, Islamic Azad Univ., Kermanshah, Iran.

*Corresponding Author, E-mail: saeid.shabanlou@gmail.com

Abstract

In this paper, the discharge coefficient of side slots is simulated for the first time by a modern artificial intelligence technique entitled "Outlier Robust Extreme Learning Machine (ORELM)". To this end, initially, the parameters influencing the discharge coefficient including the ratio of the main channel width to the side slot length (B/L), the ratio of the side slot crest height to the side slot length (W/L), the ratio of the flow depth to the side slot length (Y_m/L) and the Froude number (Fr) are detected and five ORELM models (ORELM1 to ORELM5) are developed using these parameters. After that, experimental data are classified into two groups including training (70 percent) and testing (30 percent). Then, the superior model and also the most influencing input parameters are introduced through the conduction of a sensitivity analysis. The superior model (ORELM3) simulates discharge coefficient values in terms of B/L , W/L and Fr . It should be noted that the ORELM3 model forecasted discharge coefficient values with reasonable accuracy. For example, the correlation coefficient (R), the scatter index (SI) and the Nash–Sutcliffe efficiency (NSC) index for the ORELM3 model were obtained in the testing mode to be 0.936, 0.049 and 0.852, respectively. Analyzing the simulation results indicated that W/L and Fr are the most effective input parameters for modeling the discharge coefficient. Furthermore, the results of the uncertainty analysis exhibited that the ORELM3 model has an underestimated performance.

Keywords: Discharge coefficient, Extreme learning machine, Outlier robust partial derivative sensitivity analysis, Sensitivity analysis, Side slots, Uncertainty analysis,

مقدمه

دریچه جانبی و ضریب دبی آنها انجام گرفته است. در سال‌های اخیر، استفاده از مدل‌های هوش مصنوعی و تکنیک‌های محاسبات نرم مختلف به دلیل توانایی بالا در مدل‌سازی پدیده‌های پیچیده و غیرخطی به شکل قابل توجهی افزایش یافته است. این مدل‌ها سرعت بالایی در شبیه‌سازی پدیده‌های مختلف دارند و از انعطاف‌پذیری مناسبی نیز برخوردار هستند. به دلیل این مزایا، مطالعات مختلفی برای شبیه‌سازی ضریب دبی سرریزهای جانبی، روزنه‌های جانبی و دریچه جانبی توسط مدل‌های هوش مصنوعی ارائه شده است. به عنوان مثال، ابتهاج و همکاران (۲۰۱۵) با استفاده از مدل تکاملی GEP ضریب دبی سرریزهای قرار گرفته بر روی مجاری مستطیلی را شبیه‌سازی نمودند. آنها با تجزیه و تحلیل نتایج شبیه‌سازی‌ها یک رابطه برای تخمین ضریب دبی ارائه کردند. علاوه بر این، ابتهاج و همکاران (۲۰۱۵)

به طور کلی دریچه جانبی به شکل یک شکاف بر روی دیواره کانال‌های اصلی برای هدایت و کنترل آب‌های زائد در داخل شبکه‌های زهکشی و کانال‌های آبیاری نصب می‌شوند. برای افزایش راندمان یک دریچه جانبی، شناسایی پارامترهای تاثیرگذار بر روی مقدار آبگذری از اهمیت بسزایی برخوردار است. لازم به ذکر است که ضریب دبی مهمترین پارامتر برای طراحی بهینه یک دریچه جانبی است. این ضریب دبی تابع پارامترهای هیدرولیکی و هندسی مختلفی است که تعیین میزان اهمیت هر کدام از این پارامترها نقش بسیار کلیدی در طراحی بهینه این نوع از سازه‌های انحراف جریان ایفا خواهد کرد. به دلیل اهمیت بالای دریچه جانبی مطالعات بسیاری بر روی هیدرولیک جریان عبوری از داخل

معرفی مدل برتر (ترکیبی از مهمترین پارامترهای ورودی) و مؤثرترین پارامتر ورودی بود که توسط تجزیه و تحلیل نتایج مدل ORELM انجام گردید. در ابتدا با استفاده از پارامترهای تأثیرگذار بر روی ضریب دبی دریاچه جانبی، پنج مدل ORELM تعریف شد. سپس با انجام یک تحلیل حساسیت، مدل ORELM برتر و مؤثرترین پارامتر ورودی شناسایی گردید. علاوه بر این، یک عدم قطعیت بر روی مدل‌های ORELM اجرا شد. لازم به ذکر است که بر روی مدل ORELM برتر نیز یک تحلیل حساسیت مشتق نسبی انجام گردید.

مواد و روش‌ها

ماشین آموزش نیرومند

یکی از روش‌هایی که به صورت گسترده برای حل مسائل غیرخطی در علوم مهندسی مورد استفاده قرار می‌گیرد، الگوریتم پس‌خور (BP) است. این الگوریتم یکی از رایج‌ترین الگوریتم‌ها جهت آموزش شبکه‌های عصبی چند لایه است. عمومیت یافتن الگوریتم BP، بخاطر سادگی و کاربردهای موفقیت آمیز آن در حل مسائل غیرخطی پیچیده می‌باشد. علیرغم کاربرد موفقیت آمیز این الگوریتم در یادگیری شبکه عصبی مصنوعی چند لایه، این الگوریتم ممکن است به نقاط مینیمم محلی در فضای پارامتر، همگرا شود. بنابراین زمانی که الگوریتم BP همگرا می‌شود، نمی‌توان مطمئن شد که یک جواب بهینه حاصل شده باشد. از طرفی، سرعت همگرایی الگوریتم BP، خیلی کند است. علاوه بر این، همگرایی الگوریتم BP، به انتخاب مقادیر اولیه وزن‌های شبکه، بردارهای بایاس و پارامترهای موجود در الگوریتم، مانند نرخ یادگیری، وابسته است و گاهی ممکن است برای دستیابی به عملکردی بهتر، به تعداد زیاد تکرار مراحل یادگیری، نیاز باشد. شبکه‌های عصبی مبتنی بر ماشین آموزش نیرومند، بر خلاف الگوریتم BP، نیازی به تنظیم پارامترهای لایه پنهان (وزن و بایاس) ندارد و این پارامترها به طور تصادفی انتخاب

ضریب دبی روزنه‌های جانبی مستطیلی را توسط مدل GMDH پیش‌بینی کردند. آنها با اجرای یک تحلیل حساسیت مدل برتر و پارامتر تأثیرگذار بر روی ضریب دبی را معرفی کردند. خوشبین و همکاران (۲۰۱۶) یک مدل هیبریدی را برای محاسبه ضریب دبی سرریزهای جانبی مستطیلی توسعه دادند. آنها مدل‌های انفیس، الگوریتم ژنتیک (GA) و تجزیه بردار منفرد (SVM) را برای شبیه‌سازی ضریب دبی ترکیب نمودند. عظیمی و همکاران (۲۰۱۷b) ضریب دبی روزنه‌های جانبی مستطیلی توسط یک مدل دینامیک سیالات محاسباتی و یک مدل هیبریدی هوش مصنوعی تخمین زدند. ایشان نشان دادند که مدل هوش مصنوعی دقت بیشتری برای مدل‌سازی ضریب دبی داشت. اخباری و همکاران (۲۰۱۷) با استفاده از یک مدل شبکه عصبی مصنوعی و مدل M5 ضریب دبی سرریزهای مثلثی را شبیه‌سازی کردند. آنها روابطی را برای تخمین ضریب دبی پیشنهاد دادند. همچنین عظیمی و همکاران (۲۰۱۹) ضریب دبی سرریزهای مستطیلی واقع بر مجاری نوزنقه‌ی را توسط مدل ماشین بردار پشتیبان (SVM) پیش‌بینی کردند. آنها با اجرای یک تحلیل حساسیت مدل برتر و پارامتر مؤثر را معرفی کردند و برای تخمین ضریب دبی یک ماتریس پیشنهاد نمودند.

مرور مطالعات گذشته نشان می‌دهد که ضریب دبی سازه‌های انحرافی از قبیل سرریزهای جانبی، روزنه‌های جانبی و دریاچه جانبی از اهمیت بالایی برخوردار است و ضریب دبی مهمترین پارامتر برای ارائه یک طرح بهینه و مناسب است. علاوه بر این، تکنیک‌های متنوع هوش مصنوعی به شکل گسترده‌ای برای شبیه‌سازی ضریب دبی این نوع از سازه‌های انحراف جریان به‌کار گرفته شده‌اند. بنابراین با توجه به مطالب ارائه شده، در این مطالعه برای اولین بار ضریب دبی دریاچه جانبی توسط یک مدل نوین هوش مصنوعی تحت عنوان ماشین آموزش نیرومند خارج از محدوده ORELM شبیه‌سازی شد. هدف اصلی در این مطالعه،

مطالعه با تعریف پارامتر C به عنوان یک پارامتر تنظیم کننده، نسبت بین خطای آموزش و هنجار وزن خروجی، محاسبه می‌شود. در واقع با استفاده از این پارامتر جهت افزایش عملکرد تعمیم پذیری روش ماشین آموزش نیرومند خارج از محدوده نسبت به ماشین آموزش نیرومند، حد وزن‌های خروجی و خطای آموزش به طور همزمان به صورت معادله ۱ ارائه می‌شود:

$$\min_{w_0} C \|T - Hw_0\|_2^2 + \|w_0\|_2^2 \quad [1]$$

در این رابطه، C مقدار ثابت بوده و H ، T و W_0 حد وزن‌های خروجی و خطای آموزش مدل ماشین آموزش نیرومند خارج از محدوده محسوب می‌شوند. در روش ORELM، جهت کاهش خطای آموزش (e)، وزن خروجی در (w₀) مدل ماشین آموزش نیرومند را با هنجار ℓ_2 بررسی می‌شود:

$$\min_{w_0} C \|e\|_0 + \|w_0\|_2^2 \quad \text{subject to } T - Hw_0 = e \quad [2]$$

رابطه ۲، یک مسئله غیرهمگرا است. در روش ORELM برای حل آن از فرم تخفیف استفاده می‌شود. بدین صورت که هنجار ℓ_1 با هنجار ℓ_0 جایگزین می‌شود. در واقع با این کار، نه تنها مشخصه پراکنندگی تغییر نمی‌کند بلکه محدوده کلی همگرایی نیز به حداقل می‌رسد.

مدل فیزیکی

در این مطالعه، برای اعتبارسنجی مدل‌های هوش مصنوعی از داده‌های آزمایشگاهی گزارش شده توسط اوجها و سوبایها (۱۹۹۷) و حسین و همکاران (۲۰۱۱) استفاده شد. مدل‌های آزمایشگاهی اوجها و سوبایها (۱۹۹۷) و حسین و همکاران (۲۰۱۱) جزء معتبرترین مطالعات آزمایشگاهی ضریب دبی روزنه‌ها و دریچه‌های جانبی محسوب می‌شوند که توسط محققان مختلفی جهت اعتبارسنجی مدل‌های هوش مصنوعی استفاده شده‌اند. مدل گزارش شده توسط اوجها و سوبایها (۱۹۹۷) شامل یک کانال مستطیلی بود که دارای طول ۴/۵ متر، عرض ۰/۴ متر، ارتفاع ۰/۵ متر

می‌شوند. هدف در این روش، رسیدن به کمترین خطای آموزش و کوچکترین هنجار وزن خروجی است. این الگوریتم عملکرد کلی خوبی را نتیجه می‌دهد و بسیار سریع اجرا می‌شود و مشکل کمینه محلی ندارد و حداقل مداخله انسانی را نسبت به الگوریتم BP دارد. ماشین آموزش نیرومند که توسط هووانگ و همکاران (۲۰۰۶) ارائه شده است، از معماری شبکه عصبی مصنوعی پیش‌خور تک لایه (SLFFNN) استفاده می‌کند. وزن‌های لایه ورودی به لایه پنهان به صورت تصادفی انتخاب می‌شوند و وزن‌های خروجی از طریق عملیات شبه معکوس بدست می‌آیند. روش ماشین آموزش نیرومند^۱ (ELM) از قابلیت تعمیم پذیری بالاتر و زمان آموزش کمتری نسبت به شبکه عصبی برخوردار است. همچنین، این روش نسبت به سایر روش‌ها از مداخله انسانی کمتری برخوردار است. تمامی پارامترهای شبکه به صورت خودکار تعیین می‌شوند که این امر باعث جلوگیری از مداخله انسانی شده و این روش را در کاربردهای برخط، کارآمدتر می‌کند. روش ELM مزایای زیادی نسبت به همتایان خود دارد از جمله این برتری‌ها می‌توان به استفاده سهل، سرعت بالای آموزش، عدم رخداد اُور فیتینگ، قدرت تعمیم بالاتر و قابلیت استفاده از توابع فعال‌سازی مختلف خطی و غیر خطی اشاره کرد (عظیمی و همکاران ۲۰۱۷a).

ماشین آموزش نیرومند خارج از محدوده^۲

روش ماشین آموزش نیرومند خارج از محدوده اولین بار توسط ژانگ و لئو (۲۰۱۵) به منظور غلبه بر مشکل‌های ماشین آموزش نیرومند در پیش‌بینی مجموعه داده‌هایی که دارای مقادیر خارج از محدوده می‌باشند، ارائه شد. در این روش، برای افزایش توانایی پیش‌بینی مدل از تابع فقدان هنجار ℓ_1 در ترکیب با روش ماشین آموزش نیرومند استفاده می‌شود. در این

¹ Extreme learning machine

² Outlier robust extreme learning machine

مقادیر B ، W و Y_m به طول دریاچه جانبی بدون بعد می شود. بنابراین معادله ۳ به صورت رابطه ۴ نوشته می شود:

$$C_d = f_2\left(\frac{B}{L}, \frac{W}{L}, \frac{Y_m}{L}, Fr\right) \quad [4]$$

علاوه بر این، گروه های بدون بعد معرفی در مطالعه حاضر توسط سایر محققین از روش پی باکینگهام استخراج شده اند و جهت جلوگیری از تکرار مطالب چاپ شده در مطالعات گذشته این موارد ارائه نشده اند (عظیمی و همکاران ۲۰۱۷b).


بنابراین در این مطالعه اثر پارامترهای بدون بعد معادله ۴ بر روی ضریب دبی دریاچه جانبی در نظر گرفته شد. محدوده پارامترهای بدون بعد گزارش شده توسط اوجها و سوبایاها (۱۹۹۷) و حسین و همکاران (۲۰۱۱) شامل حداکثر، حداقل، متوسط، واریانس و انحراف معیار مقادیر آزمایشگاهی برای تولید مدل های ORELM در جدول ۱ مرتب شده است.

جدول ۱- محدوده پارامترهای بدون بعد گزارش شده توسط اوجها و سوبایاها (۱۹۹۷) و حسین و همکاران (۲۰۱۱) برای تولید مدل های ORELM.

	B/L	W/L	Y_m/L	Fr	C_d
Max	11.364	4.545	12.764	1.207	0.442
Min	2	0.1	0.434	0.006	0.238
Ave	5.223	1.230	3.769	0.201	0.599
Var	13.088	1.320	9.639	0.013	0.059
Std.	3.618	1.149	3.105	0.116	0.243

نحوه ترکیب پارامترهای بدون بعد رابطه ۱۱ برای توسعه مدل های ORELM در شکل ۲ نشان داده شده است. لازم به ذکر است که مدل هوش مصنوعی در محیط نرم افزار متلب اجرا گردید. تعداد داده های آزمایشگاهی استفاده شده در این مطالعه مساوی با ۲۸۳ بود. این مقادیر آزمایشگاهی برای آموزش و آزمون این مدل های هوش مصنوعی استفاده شدند. لازم به یادآوری است که ۷۰ درصد مقادیر آزمایشگاهی

بود. دریاچه کشویی مستطیلی جانبی این مدل آزمایشگاهی به فاصله ۲/۵ متری از ورودی کانال اصلی واقع شده بود. عرض دریاچه کشویی جانبی مدل گزارش شده توسط اوجها و سوبایاها (۱۹۹۷) مساوی ۰/۲ متر بود. مدل آزمایشگاهی حسین و همکاران (۲۰۱۱) شامل یک کانال مستطیلی به طول ۹/۱۵ متر، عرض ۰/۵ متر و ارتفاع ۰/۶ متر بود. در این مدل آزمایشگاهی دریاچه مستطیلی جانبی در فاصله ۵ متری از ورودی کانال اصلی واقع شده بود. در مطالعه حسین و همکاران (۲۰۱۱)، مقادیر آزمایشگاهی برای دریاچه های مستطیلی با سه عرض مختلف ۰/۰۴۴ متر، ۰/۰۸۹ و ۰/۱۳۳ متر استفاده شد. در شکل ۱ طرح کلی مدل آزمایشگاهی گزارش شده توسط اوجها و سوبایاها (۱۹۹۷) و حسین و همکاران (۲۰۱۱) به تصویر کشیده شده است.



شکل ۱- طرح کلی مدل آزمایشگاهی گزارش شده توسط اوجها و سوبایاها (۱۹۹۷) و حسین و همکاران (۲۰۱۱).

ضریب دبی دریاچه های جانبی تابعی از طول دریاچه جانبی (L)، ارتفاع دریاچه جانبی (b)، عرض کانال اصلی (B)، ارتفاع کف دریاچه 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) محسوب می شود (حسین و همکاران ۲۰۱۱، عظیمی و همکاران ۲۰۱۷b):

$$C_d = f_1(L, b, B, W, V_1, Y_m, \rho, \mu, g) \quad [3]$$

با توجه به اینکه عدد فرود جریان عبارت است از $Fr = V_1 / (g \cdot Y_m)^{0.5}$ ، علاوه بر این، مقدار چگالی و ویسکوزیته ثابت در نظر گرفته می شود و در مقابل

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (F_i - O_i)^2} \quad [7]$$

$$SI = \frac{RMSE}{\bar{O}} \quad [8]$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |F_i - O_i| \quad [9]$$

$$NSC = 1 - \frac{\sum_{i=1}^n (O_i - F_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad [10]$$

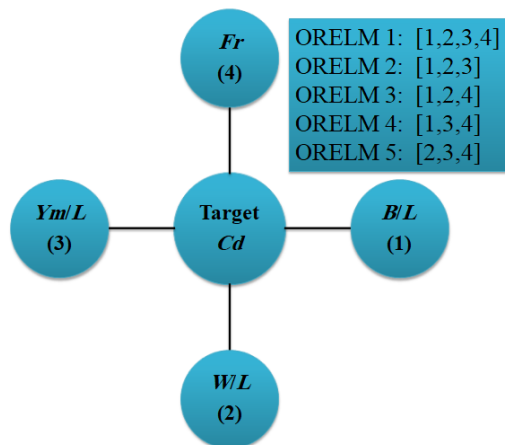
در اینجا، Var واریانس مقادیر شبیه‌سازی شده است. O_i مقادیر مشاهداتی، F_i مقادیر تراز پیش‌بینی شده به وسیله مدل‌های عددی، \bar{O} میانگین مقادیر مشاهداتی و n برابر تعداد مقادیر مشاهداتی است.

نتایج و بحث

تغییرات تعداد نرون‌های لایه مخفی در شرایط آزمون مدل عددی در مقابل شاخص‌های آماری مختلف محاسبه شده در شکل ۳ قابل مشاهده است. با افزایش تعداد نرون‌های لایه مخفی زمان محاسباتی به شکل قابل توجهی افزایش می‌یابد. در وضعیت آزمون، بهینه‌ترین تعداد نرون‌های لایه مخفی برابر با ۱۴ در نظر گرفته شد زیرا زمان محاسباتی و دقت مدل هوش مصنوعی در حد قابل قبولی بود. برای مدلی که تعداد نرون‌های لایه مخفی آن مساوی ۱۴ بود، مقادیر RMSE، R و MAE به ترتیب برابر با ۰/۰۲۹، ۰/۹۲۵ و ۰/۰۱۹ محاسبه شدند. لازم به ذکر است که شاخص‌های آماری NSC، VAF و SI برای این مدل به ترتیب برابر با ۰/۸۵۱، ۸۷/۶۸ درصد و ۰/۰۴۹ تخمین زده شدند.



برای آموزش مدل‌های عددی و ۳۰ درصد باقیمانده برای تست آنها استفاده گردید.



شکل ۲- نحوه ترکیب پارامترهای ورودی برای مدل‌های ORELM

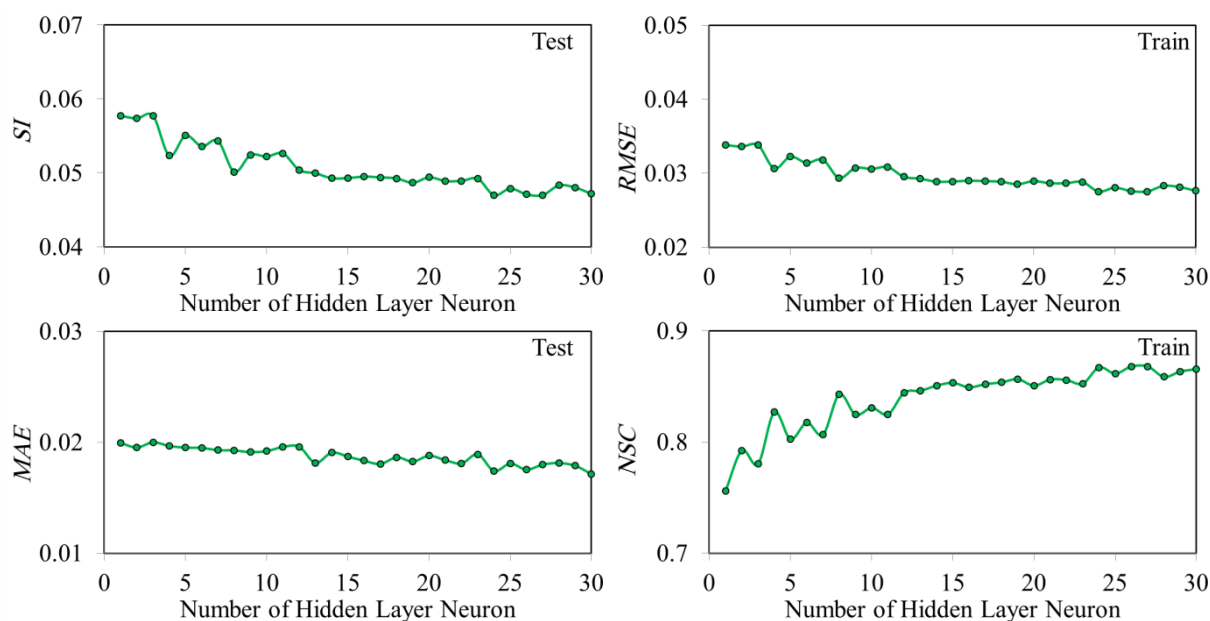
معیارهای بررسی دقت مدل‌های هوش مصنوعی

در این مقاله، برای ارزیابی دقت مدل‌های عددی معرفی شده از شاخص‌های آماری ضریب همبستگی (R)، شاخص عملکرد (VAF)، خطای مربعات میانگین ($RMSE$)، شاخص پراکندگی (SI)، خطای مطلق میانگین (MAE) و ضریب بهره‌وری نش سائکلایف (NSC) به صورت زیر استفاده می‌گردد:

$$R = \frac{\sum_{i=1}^n (F_i - \bar{F})(O_i - \bar{O})}{\sqrt{\sum_{i=1}^n (F_i - \bar{F})^2 \sum_{i=1}^n (O_i - \bar{O})^2}} \quad [5]$$

$$VAF = \left(1 - \frac{\text{var}(F_i - O_i)}{\text{var}(F_i)} \right) \times 100 \quad [6]$$

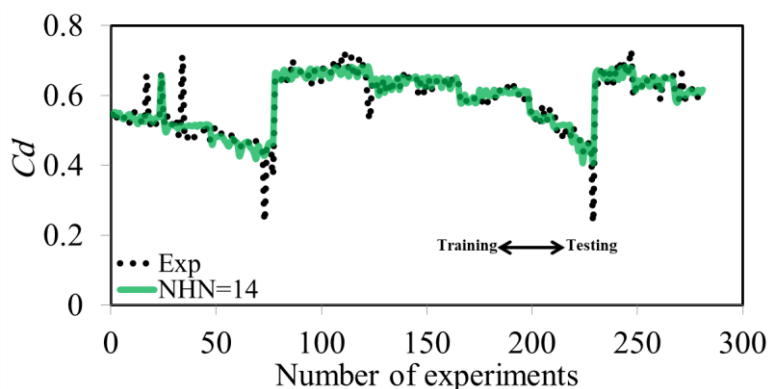




شکل ۳- تغییرات تعداد نرون‌های لایه مخفی مدل ماشین آموزش نیرومند خارج از محدوده در برابر شاخص‌های آماری مختلف در وضعیت آزمون.

مصنوعی مساوی با ۱۴ در نظر گرفته شد. دقت مدل‌سازی در هر دو وضعیت آموزش و آزمون در این شرایط در حد قابل قبولی بود. بنابراین در ادامه شبیه‌سازی ضریب دبی توسط مدل ORELM، تعداد نرون‌های لایه مخفی مساوی با ۱۴ در نظر گرفته شد.

شکل ۴ مقایسه ضریب دبی شبیه‌سازی شده با مقادیر آزمایشگاهی برای تعداد نرون‌های لایه مخفی برابر با ۱۴ در هر دو وضعیت آموزش و آزمون را نشان می‌دهد. با توجه به زمان محاسباتی مناسب و دقت قابل قبول، مدلی که ۱۴ نرون در لایه مخفی خود داشت، تعداد بهینه نرون‌های لایه مخفی برای مدل هوش



شکل ۴- تغییرات ضریب دبی شبیه‌سازی شده با مقادیر آزمایشگاهی برای تعداد نرون‌های لایه مخفی برابر با ۱۴ در هر دو وضعیت آموزش (۱۹۸ مشاهده) و آزمون (۸۳ مشاهده).

مدل ORELM پرداخته می‌شود. در جدول ۲ نیز شاخص‌های آماری مختلف محاسبه شده برای این پنج تابع فعال‌سازی مختلف در هر دو وضعیت آموزش و آزمون نشان داده شده است. برای تابع فعال‌سازی sig،

مدل ORELM دارای پنج تابع فعال‌سازی با عناوین مختلف از قبیل sig، sin، hardlim، tribas و radbas است. در این بخش به بررسی توابع فعال‌سازی مختلف و تاثیر آنها بر روی نتایج مدل‌سازی ضریب دبی توسط

مقادیر R ، MAE و MAE در وضعیت آزمون به ترتیب مساوی با ۰/۹۳۵، ۰/۰۱۹ و ۸۷/۴۶۸ بودند. همچنین، برای تابع فعال‌سازی tribas در شرایط آزمون، مقادیر شاخص‌های SI ، NSC و $RMSE$ به ترتیب مساوی با ۰/۶۲۱، ۰/۲۲۲ و ۰/۳۶۴ بودند. همان‌طور که از جدول ۲ دیده می‌شود، تابع فعال‌سازی sig دارای کمترین مقدار خطا و بیشترین دقت است و در ادامه شبیه‌سازی‌ها از این تابع فعال‌سازی استفاده می‌شود.

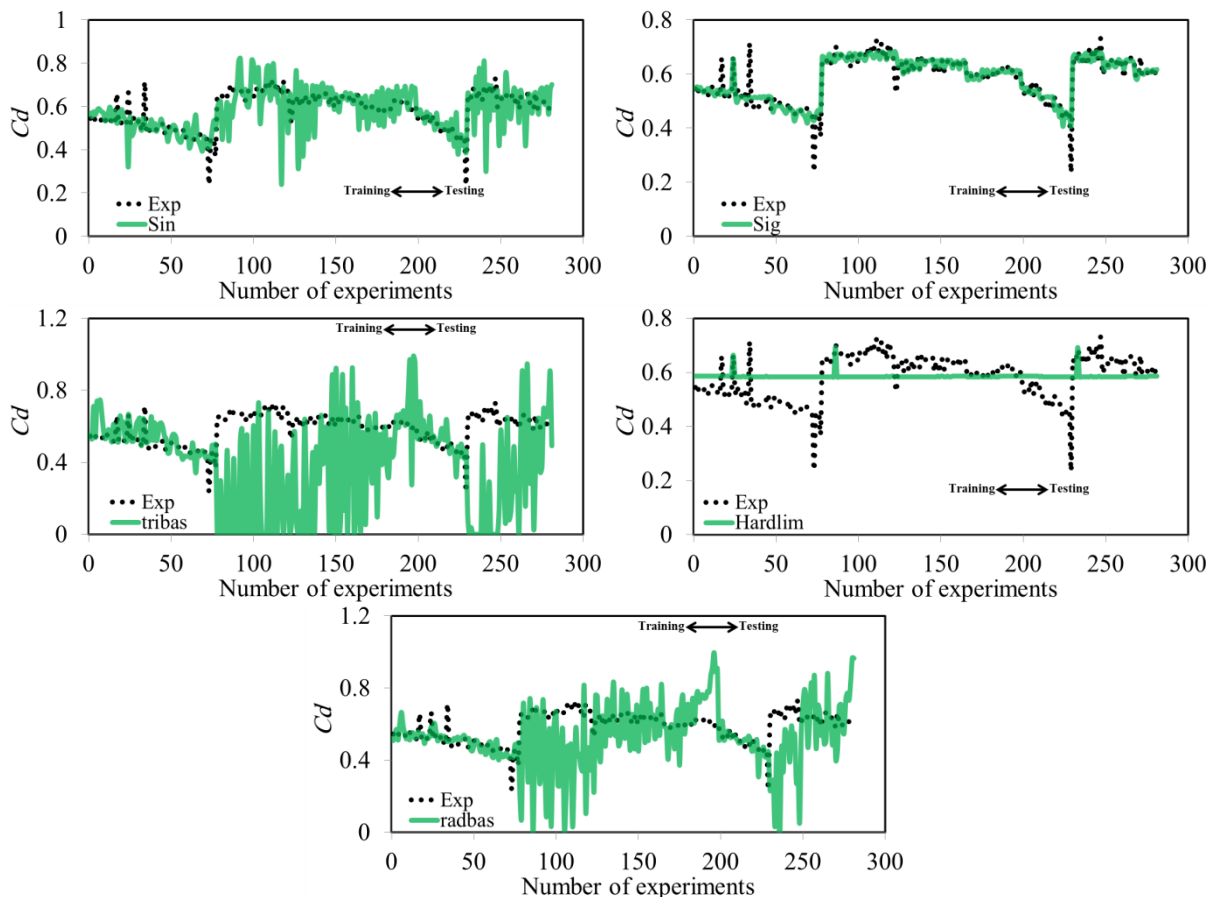
جدول ۲- نتایج شاخص‌های آماری محاسبه شده در وضعیت آزمون برای توابع فعال‌سازی مختلف.

جدول ۲- نتایج شاخص‌های آماری محاسبه شده در وضعیت آزمون برای توابع فعال‌سازی مختلف.

تابع فعال‌سازی	R	MAE	$RMSE$	SI	NSC
Sig	0.935	0.019	0.029	0.049	0.851
Sin	0.367	0.056	0.080	0.137	0.306
Hardlim	0.019	0.066	0.081	0.138	-45.351
Tribas	0.169	0.266	0.364	0.621	-0.222
Radbas	0.002	0.140	0.204	0.347	-0.145

شکل ۵ تغییرات بین ضریب دبی‌های شبیه‌سازی شده توسط توابع فعال‌سازی مختلف در هر دو وضعیت آموزش و آزمون با مقادیر آزمایشگاهی را نشان می‌دهد. بر اساس نتایج شبیه‌سازی‌ها، تابع فعال‌سازی sig در مقایسه با سایر توابع فعال‌سازی از خود عملکرد بهتری را نشان داد. این تابع فعال‌سازی در هر دو وضعیت آموزش و آزمون مقادیر ضریب دبی را با دقت خوبی مدل‌سازی کرد. بنابراین در ادامه مدل‌سازی ضریب دبی توسط مدل ORELM، این تابع فعال‌سازی انتخاب شد.

شکل ۵ تغییرات بین ضریب دبی‌های شبیه‌سازی شده توسط توابع فعال‌سازی مختلف در هر دو وضعیت آموزش و آزمون با مقادیر آزمایشگاهی را نشان می‌دهد. بر اساس نتایج شبیه‌سازی‌ها، تابع فعال‌سازی sig در مقایسه با سایر توابع فعال‌سازی از خود عملکرد



شکل ۵- تغییرات ضریب دبی شبیه سازی شده توسط توابع فعال سازی مختلف در هر دو وضعیت (۱۹۸ مشاهده) و آزمون (۸۳ مشاهده).

تحلیل حساسیت

۰/۹۲۴ بودند. همچنین برای مدل 3 ORELM تاثیر پارامتر Y_m/L برای آن نادیده گرفته شد. لازم به ذکر است که مقادیر شاخص های آماری R ، SI و NSC برای شرایط آزمون مدل 3 ORELM به ترتیب مساوی با ۰/۹۳۶، ۰/۰۴۹ و ۰/۸۵۲ تخمین زده شدند. علاوه بر این، تاثیر پارامتر بدون بعد W/L برای مدل 4 ORELM حذف گردید برای 4 ORELM. مقادیر NSC ، MAE و $RMSE$ در شرایط آزمون به ترتیب برابر با ۰/۸۳۶، ۰/۷۹۴ و ۰/۰۳۱ محاسبه شدند. این در حالی است که برای مدل 5 ORELM تاثیر پارامتر بدون بعد B/L نادیده گرفته شده است. برای 5 ORELM در وضعیت آموزش، مقادیر MAE ، SI و VAF به ترتیب مساوی با ۰/۰۱۹، ۰/۰۵۳ و ۸۵/۵۱۸ تخمین زده شدند.

نتایج شاخص های آماری محاسبه شده برای مدل های ORELM مختلف در هر دو وضعیت آموزش و آزمون در جدول ۳ قابل مشاهده است. مدل 1 ORELM مقادیر ضریب دبی ها را بر حسب B/L ، W/L ، Y_m/L و Fr شبیه سازی کرد. برای این مدل هوش مصنوعی، مقادیر SI ، VAF و NSC در شرایط آموزش به ترتیب مساوی با ۰/۰۵۲، ۸۵/۹۲۳ و ۰/۸۳۶ بودند. در مقابل چهار مدل 2 ORELM تا 5 ORELM مقادیر ضریب دبی را بر حسب سه پارامتر ورودی شبیه سازی کردند. به عنوان مثال، برای مدل 2 ORELM تاثیر عدد فرود برای آن حذف شد. برای 2 ORELM مقادیر MAE ، $RMSE$ و R در وضعیت آزمون به ترتیب مساوی با ۰/۰۳۱، ۰/۰۱۹ و

جدول ۳- نتایج شاخص های آماری محاسبه شده برای مدل های ORELM مختلف در هر دو وضعیت آموزش و آزمون.

وضعیت	مدل	R	VAF	$RMSE$	SI	MAE	NSC
آموزش	ORELM 1	0.927	85.923	0.030	0.052	0.018	0.836
	ORELM 2	0.924	85.321	0.031	0.053	0.019	0.828
	ORELM 3	0.932	86.778	0.029	0.050	0.018	0.848
	ORELM 4	0.912	83.243	0.033	0.057	0.020	0.799
	ORELM 5	0.925	85.518	0.031	0.053	0.019	0.831
آزمون	ORELM 1	0.935	87.468	0.029	0.049	0.019	0.851
	ORELM 2	0.924	85.321	0.031	0.053	0.019	0.828
	ORELM 3	0.936	87.510	0.029	0.049	0.018	0.852
	ORELM 4	0.926	85.794	0.031	0.052	0.021	0.836
	ORELM 5	0.928	86.091	0.030	0.052	0.019	0.829

به عنوان بدترین مدل هوش مصنوعی معرفی می گردد. لازم به ذکر است که با حذف پارامترهای W/L و Fr دقت مدل سازی به شکل قابل ملاحظه ای کاهش یافت. بنابراین این دو پارامتر بدون بعد به عنوان موثرترین پارامترهای ورودی مدل ORELM معرفی می شوند.

شکل ۶ تغییرات ضریب دبی محاسبه شده توسط مدل های ORELM مختلف با مقادیر مشاهده ای در هر دو وضعیت آموزش و آزمون را نشان می دهد. بر اساس تجزیه و تحلیل نتایج شبیه سازی ها، مدل 3 ORELM در هر دو شرایط آموزش و آزمون مقادیر ضریب دبی ها را با دقت بهتری در مقایسه با سایر مدل های تعریف شده شبیه سازی کرد. بنابراین این مدل به عنوان مدل برتر معرفی می شود. در مقابل مدل 4 ORELM نیز

تحلیل عدم قطعیت

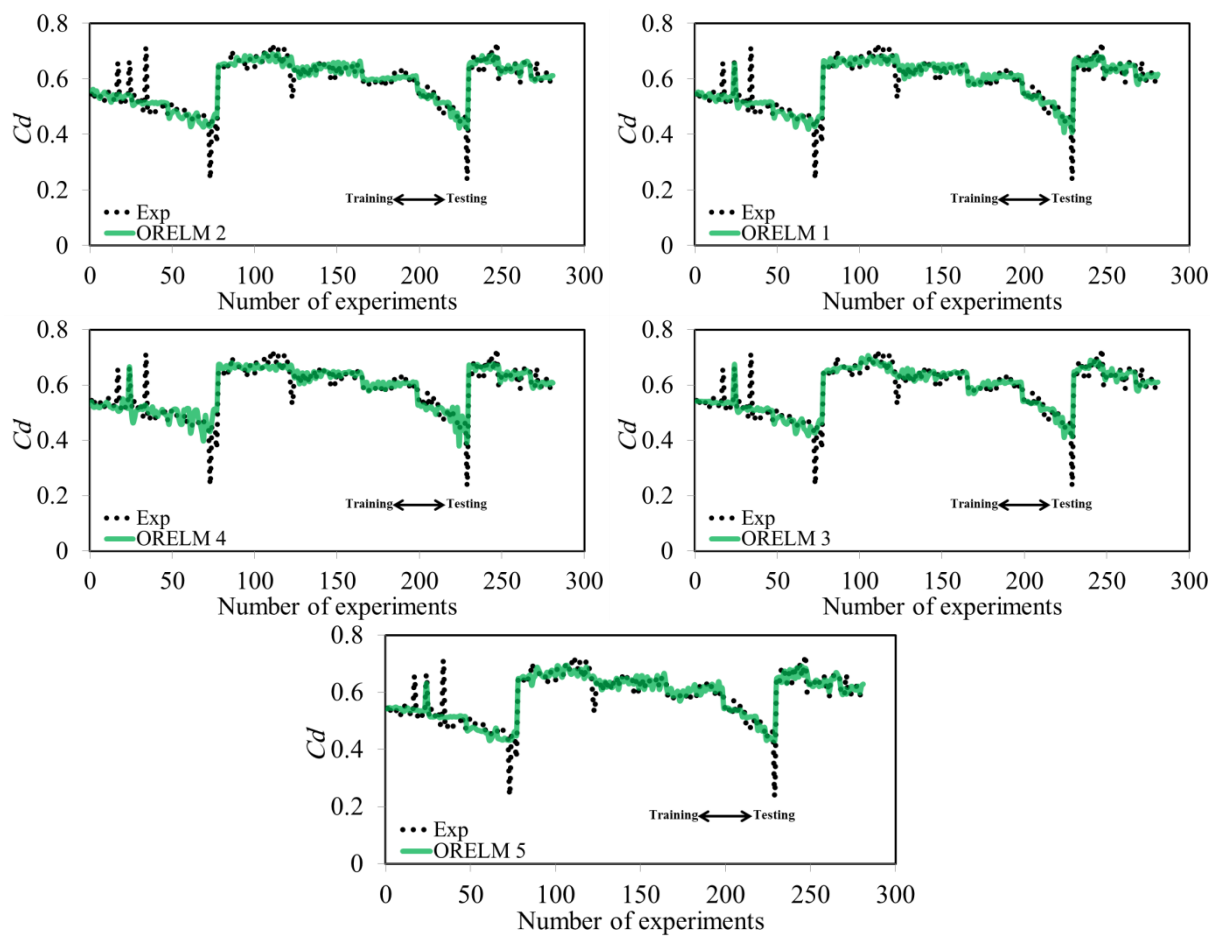
در ادامه با انجام یک تحلیل عدم قطعیت نحوه عملکرد مدل‌های برتر مورد ارزیابی قرار گرفت. به‌طور کلی تحلیل عدم قطعیت یک تحلیل مفید جهت بررسی عملکرد مدل‌های عددی مورد استفاده قرار گرفته است (عظیمی و همکاران ۲۰۱۸، عظیمی و همکاران ۲۰۱۹). نتایج تحلیل عدم قطعیت در جدول ۴ مرتب شده است. در این جدول عرض باند عدم قطعیت با WUB و ۹۵٪ خطای پیش‌بینی شده با PEI ۹۵٪ نشان داده می‌شود. پارامترهای تحلیل عدم قطعیت در محیط نرم افزار مینی‌تب و با استفاده از آزمون T^3 محاسبه شدند.

با توجه به نتایج تحلیل حساسیت اجرا شده، مدل‌های ORELM 1، ORELM 2، ORELM 4 و ORELM 5 دارای عملکردی بیشتر از مقدار واقعی بودند و در مقابل مدل ORELM 3 عملکردی کمتر از مقدار خود نشان داد. لازم به ذکر است که مقادیر انحراف استاندارد مقادیر خطای پیش‌بینی شده برای ORELM 2، ORELM 4 و ORELM 5 به ترتیب مساوی با ۰/۰۳۱، ۰/۰۳۳ و ۰/۰۳۱ بودند. علاوه بر این مقدار WUB برای مدل‌های ORELM 1، ORELM 2 و ORELM 3 به ترتیب مساوی با $\pm 0/004$ ، $\pm 0/003$ و $\pm 0/004$ تخمین زده شدند. لازم به یادآوری است که PEI ۹۵٪ برای مدل ORELM 3 مساوی با ۰/۰۰۳ تا ۰/۰۰۳- بود.

تحلیل حساسیت مشتق نسبی

در این بخش از مطالعه، یک تحلیل حساسیت مشتق نسبی (PDSA) برای مدل ORELM برتر که همان ORELM 3 است، اجرا می‌شود. معمولاً، PDSA برای شناسایی تاثیر پارامترهای ورودی بر روی پارامتر هدف اجرا می‌گردد. به بیان دیگر، PDSA یکی از روش‌ها برای شناسایی نحوه تغییرات پارامتر هدف با توجه به


پارامترهای ورودی است. مثبت بودن PDSA به معنای افزایش تابع هدف (ضریب دبی) است و در مقابل منفی بودن PDSA به معنای کاهش یافتن مقدار تابع هدف است. به عبارت دیگر، در این روش مشتق نسبی هر پارامتر ورودی نسبت به تابع هدف محاسبه می‌شود (عظیمی و همکاران، ۲۰۱۷c). با توجه به نتایج PDSA، تقریباً با افزایش پارامتر B/L مقدار PDSA نیز افزایش یافت و بخشی از نتایج PDSA مثبت و بخش دیگر آن منفی بدست آمد. علاوه بر این، با افزایش پارامتر بدون بعد W/L مقدار PDSA کاهش یافت و تقریباً کلیه نتایج PDSA برای این پارامتر مثبت محاسبه شد. این در حالی است که با افزایش عدد فرود مقدار PDSA نیز یک روند افزایشی داشت. نتایج تحلیل حساسیت مشتق نسبی در شکل ۷ نشان داده شده است.



شکل ۶- مقایسه ضریب دبی محاسبه شده توسط مدل های ORELM مختلف با مقادیر مشاهداتی در هر دو وضعیت آموزش و آزمون.

جدول ۴- نتایج تحلیل عدم قطعیت مدل های ORELM.

مدل	\bar{e}	S_e	WUB	95% PEI
ORELM 1	4.146×10^{-8}	0.030	± 0.004	-0.004 تا 0.004
ORELM 2	7.97×10^{-8}	0.031	± 0.004	-0.004 تا 0.004
ORELM 3	-1.5×10^{-6}	0.029	± 0.003	-0.003 تا 0.003
ORELM 4	9.99×10^{-9}	0.033	± 0.004	-0.004 تا 0.004
ORELM 5	9.7×10^{-7}	0.031	± 0.004	-0.004 تا 0.004



شکل ۷- نتایج PDSA برای مدل برتر (ORELM 3).

نتیجه‌گیری کلی

ضریب دبی مهمترین پارامتر برای طراحی یک دریچه جانبی است که در این مطالعه برای اولین بار ضریب دبی دریچه جانبی واقع بر کانال‌های مستطیلی توسط یک مدل هوش مصنوعی نوین تحت عنوان ماشین آموزش نیرومند خارج از محدوده (ORELM) شبیه-سازی گردید. برای این کار ابتدا پارامترهای بدون بعد تاثیرگذار بر روی ضریب دبی شناسایی شدند و توسط آنها، پنج مدل متمایز ORELM توسعه داده شد. دو سری داده مختلف برای اعتبار سنجی نتایج مدل‌های هوش مصنوعی استفاده گردید. همچنین، ۷۰ درصد مقادیر آزمایشگاهی برای آموزش مدل‌های ORELM و ۳۰ درصد باقیمانده برای آزمون آنها استفاده شد. لازم به ذکر است که بهینه‌ترین تعداد نرون‌های لایه مخفی برای این مدل هوش مصنوعی مساوی با ۱۴ انتخاب گردید. علاوه بر این، تابع فعال‌سازی سیگموئید به‌عنوان تابع فعال‌سازی برتر برای این مطالعه برگزیده شد. سپس با اجرای یک تحلیل حساسیت، مدل برتر ORELM انتخاب گردید. این مدل مقادیر ضریب دبی دریچه جانبی را بر حسب W/L ، B/L و Fr تخمین زد. این مدل در هر دو وضعیت آموزش و آزمون دقت قابل قبولی داشت، به عنوان مثال، برای شرایط آموزش مقادیر RMSE، VAF و SI به ترتیب برابر با ۰/۰۲۹، ۸۶/۷۷۸ و ۰/۰۵۰ تخمین زده شدند. نتایج تحلیل حساسیت نشان داد که

مقادیر بدون بعد Fr و W/L تاثیرگذارترین پارامترهای ورودی برای شبیه‌سازی ضریب دبی دریچه جانبی توسط مدل ORELM بودند. همچنین، نتایج مدل ORELM با مدل ELM نیز مقایسه شد که مدل ORELM در هر دو شرایط آموزش و آزمون عملکرد بهتری از خود به نمایش گذاشت. لازم به ذکر است که یک تحلیل عدم قطعیت نیز برای مدل‌های هوش مصنوعی اجرا گردید که نشان داد مدل ORELM دارای عملکردی کمتر از واقعی بود. علاوه بر این، تحلیل حساسیت مشتق نسبی نشان داد که با افزایش پارامتر W/L مقدار تابع هدف یا همان ضریب دبی نیز افزایش یافت. در مقایسه با مطالعات گذشته، مدل ORELM دارای عملکرد بهتری جهت شبیه‌سازی ضریب دبی سرریزهای جانبی واقع بر کانال‌های دوزنقه‌ای بود. به-عنوان مثال، برای مدل ماشین آموزش نیرومند (ELM) ارائه شده توسط عظیمی و همکاران (۲۰۱۷a) مقادیر ضریب همبستگی و خطا به ترتیب مساوی با ۰/۹۶۲ و ۲/۹۱۶ محاسبه شدند. علاوه بر این، مقادیر R، RMSE و SI برای مدل برنامه‌نویسی بیان ژن (GEP) استفاده شده توسط عظیمی و همکاران (۲۰۱۹) به ترتیب برابر با ۰/۹۶۰، ۰/۰۱۲ و ۰/۰۳۴ تخمین زده شدند. همان‌طور که مشاهده می‌شود، مدل ORELM استفاده شده در مطالعه حاضر، مقادیر ضریب دبی سرریزهای جانبی را با دقت بیشتر و همبستگی بالاتری پیش‌بینی نمود.

منابع مورد استفاده

- Akhbari A, Zaji AH, Azimi H and Vafaeifard M, 2017. Predicting the discharge coefficient of triangular plan form weirs using radian basis function and M5' methods. *Applied Research in Water and Wastewater* 4(1): 281-289.
- Azimi H, Bonakdari H and Ebtehaj I, 2019. Design of radial basis function-based support vector regression in predicting the discharge coefficient of a side weir in a trapezoidal channel. *Applied Water Science* 9: 78. <https://doi.org/10.1007/s13201-019-0961-5>.
- Azimi H, Bonakdari H and Ebtehaj I, 2017a. Sensitivity analysis of the factors affecting the discharge capacity of side weirs in trapezoidal channels using extreme learning machines. *Flow Measurement and Instrumentation* 54: 216-223.
- Azimi H, Shabanlou S, Ebtehaj I, Bonakdari H and Kardar S, 2017b. Combination of computational fluid dynamics, adaptive neuro-fuzzy inference system, and genetic algorithm for predicting discharge coefficient of rectangular side orifices. *Irrigation and Drainage Engineering* 143(7): 040170151-9.
- Azimi H, Bonakdari H, Ebtehaj I and Khoshbin F, 2018. Evolutionary design of Generalized Group Method of Data Handling-type neural network for estimating hydraulic jump roller length. *Acta Mechanica* 229(3): 1197-1214.
- Azimi H, Bonakdari H and Ebtehaj I, 2017c. A highly efficient gene expression programming model for predicting the discharge coefficient in a side weir along a trapezoidal canal. *Irrigation and Drainage* 66(4): 655-666.
- Ebtehaj I, Bonakdari H, Zaji AH, Azimi H and Sharifi A, 2015. Gene expression programming to predict the discharge coefficient in rectangular side weirs. *Applied Soft Computing* 35: 618-628.
- Ebtehaj I, Bonakdari H, Khoshbin F and Azimi H, 2015. Pareto genetic design of group method of data handling type neural network for prediction discharge coefficient in rectangular side orifices. *Flow Measurement and Instrumentation* 41: 67-74.
- Huang GB, Zhu QY and Siew CK, 2006. Extreme learning machine: theory and applications. *Neurocomputing* 70(1-3): 489-501.
- Hussain A, Ahmad Z and Asawa GL, 2011. Flow through sharp-crested rectangular side orifices under free flow condition in open channels. *Agricultural Water Management* 98(10): 1536-1544.
- Khoshbin F, Bonakdari H, Ashraf Talesh SH, Ebtehaj I, Zaji AH and Azimi H, 2016. Adaptive neuro-fuzzy inference system multi-objective optimization using the genetic algorithm/singular value decomposition method for modelling the discharge coefficient in rectangular sharp-crested side weirs. *Engineering Optimization* 48(6): 933-948.
- Ojha CSP and Subbaiah D, 1997. Analysis of flow through lateral slot. *Journal of Irrigation and Drainage Engineering* 123(5): 402-405.
- Zhang K and Luo M, 2015. Outlier-robust extreme learning machine for regression problems. *Neurocomputing* 151: 1519-1527.