

کاربرد مدل‌های هوش مبتنی بر محاسبات نرم در بررسی میزان ضریب تخلیه دریاچه کشویی در حالت جریان آزاد و آستانه متقارن به کمک مدل‌های ANN, KNN, GEP و SVM

حمیدرضا عباسزاده (دانشجوی دکتری)

یوسف حسنزاده * (استاد)

گروه مهندسی عمران، دانشکده مهندسی عمران، دانشگاه تبریز، تبریز، ایران

رسول دانشفراز (استاد)

رضا نوروزی (دکتری)

گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه مراغه، مراغه، ایران

مهندسی عمران شریف، زمستان ۱۴۰۳
دوره ی ۴۰، شماره ی ۴، صص. ۳-۱۲، (پژوهشی)

در پژوهش حاضر میزان ضریب‌دبی دریاچه کشویی با استفاده از روش‌های داده کاوی مبتنی بر مدل‌های ماشین‌بردار پشتیبان (SVM)، برنامه‌ریزی بیان ژن (GEP)، روش شبکه عصبی مصنوعی (ANN) و الگوریتم K نزدیک‌ترین همسایه (KNN) برای نخستین رابطه تئوری ارائه شده برای دریاچه‌های کشویی در حالت آستانه غیرهم‌عرض، مورد ارزیابی قرار گرفت، تا عملکرد آن با استفاده از روش‌های محاسبات نرم سنجیده شود. برای مدل SVM، کرنل تابع پایه شعاعی (RBF) نتایج بهتری در مقایسه با کرنل‌های چند جمله‌ای (Polynomial)، خطی (Linear) و سیگموئید (Sigmoid) دارد. شاخص‌های آماری R، KGE، RMSE و MRE% برای مدل SVM-RBF در مرحله آزمون به ترتیب ۰/۹۶، ۰/۹۰، ۰/۱۸ و ۱/۹۲ است. در مدل KNN فاصله اندازه‌گیری Manhattan دقت بالاتری در پیش‌بینی ضریب‌دبی نسبت به معیارهای Euclidean Squared، Euclidean و Chebychev داشت. روش ANN در مقایسه با مدل‌های SVM، GEP و KNN دقت بیشتری دارد به طوری که برای این مدل MRE%=۱/۱۵ و RMSE=۰/۰۹۸ است.

ha.abbaszadeh@tabrizu.ac.ir
yhassanzadeh@tabrizu.ac.ir
daneshfaraz@maragheh.ac.ir
norouzi@maragheh.ac.ir

واژگان کلیدی: اندازه‌گیری دبی، ضریب‌دبی، سازه کنترل، مدل‌های هوشمند، شاخص‌های آماری.

۱. مقدمه

دریاچه‌ها از انواع سازه‌های هیدرولیکی هستند که در آن‌ها حرکت آب از زیر دریاچه و گاه از روی دریاچه صورت می‌پذیرد. از پرکاربردترین این دریاچه‌ها، دریاچه‌های کشویی هستند که به صورت صفحه‌ای عمودی در مسیر جریان به منظور تنظیم میزان بازشدگی، بالا و پائین حرکت می‌کنند. تعیین میزان دبی عبوری و تخمین ضریب‌دبی یکی از مهم‌ترین مسائل موجود در مهندسی هیدرولیک بوده و کمک شایانی به مهندسان و کاربران به منظور طراحی سازه و آگاهی از وضعیت جریان می‌کند. کنترل میزان سطح آب بالادست دریاچه، تنظیم دبی و همچنین میزان دقت عبوری جریان از زیر دریاچه به ترتیب براساس میزان بازشدگی دریاچه از کف کانال و تخمین ضریب‌دبی دریاچه صورت می‌گیرد. در دهه‌های اخیر با توجه به کمبود منابع آب، لزوم استفاده بهینه از منابع آبی و بهره‌گیری مطلوب از آن بایستی مورد توجه قرار گیرد. جهت جلوگیری از هدر رفت آب بایستی در کنترل

در زمینه وجود آستانه هم‌عرض کانال و ترکیب آن با دریاچه کشویی مطالعات متعددی انجام شده است که می‌توان به بررسی آزمایشگاهی تأثیر استفاده از آستانه‌های چند ضلعی و دایروی در زیر دریاچه کشویی بر میزان ضریب‌دبی در شرایط جریان آزاد اشاره کرد^[۱]، Alhamid^[۲] افزایش میزان ضریب‌دبی در حالت استفاده از آستانه نسبت به حالت بدون آستانه در تمامی مدل‌های آزمایشگاهی را گزارش نمود.^[۱] Negm et al. بررسی آزمایشگاهی دریاچه

دریاچه‌ها از انواع سازه‌های هیدرولیکی هستند که در آن‌ها حرکت آب از زیر دریاچه و گاه از روی دریاچه صورت می‌پذیرد. از پرکاربردترین این دریاچه‌ها، دریاچه‌های کشویی هستند که به صورت صفحه‌ای عمودی در مسیر جریان به منظور تنظیم میزان بازشدگی، بالا و پائین حرکت می‌کنند. تعیین میزان دبی عبوری و تخمین ضریب‌دبی یکی از مهم‌ترین مسائل موجود در مهندسی هیدرولیک بوده و کمک شایانی به مهندسان و کاربران به منظور طراحی سازه و آگاهی از وضعیت جریان می‌کند. کنترل میزان سطح آب بالادست دریاچه، تنظیم دبی و همچنین میزان دقت عبوری جریان از زیر دریاچه به ترتیب براساس میزان بازشدگی دریاچه از کف کانال و تخمین ضریب‌دبی دریاچه صورت می‌گیرد. در دهه‌های اخیر با توجه به کمبود منابع آب، لزوم استفاده بهینه از منابع آبی و بهره‌گیری مطلوب از آن بایستی مورد توجه قرار گیرد. جهت جلوگیری از هدر رفت آب بایستی در کنترل

*نویسنده مسئول

تاریخ دریافت: ۱۴۰۲/۰۴/۲۵، تاریخ اصلاحیه: ۱۴۰۲/۰۸/۱۲، تاریخ پذیرش: ۱۴۰۲/۰۸/۲۳.

استناد به این مقاله:

عباسزاده، حمیدرضا، حسنزاده، یوسف، دانشفراز، رسول، و نوروزی، رضا، ۱۴۰۳. کاربرد مدل‌های هوش مبتنی بر محاسبات نرم در بررسی میزان ضریب تخلیه دریاچه کشویی در حالت جریان آزاد و آستانه متقارن به کمک مدل‌های ANN, KNN, GEP و SVM. مهندسی عمران شریف، ۴۰(۴)، صص. ۳-۱۲.

DOI: 10.24200/J30.2023.62661.3237

متر و ارتفاع ۰/۵۰ متر صورت پذیرفته است. آزمایش‌ها در بازه دبی ۰/۰۰۲۵ الی ۰/۰۱۴۲ مترمکعب برثانیه و عمق بالادست ۰/۰۵ الی ۰/۴۴ متر انجام یافته است. جریان ورودی به فلوم توسط دو پمپ هر یک با دبی اسمی ۰/۰۰۷۵ مترمکعب بر ثانیه تأمین می‌شود. به منظور قرائت دبی ورودی از روماترهای نصب شده روی فلوم با خطای نسبی $\pm 2\%$ استفاده شده است. آستانه‌ها در عرض‌های مختلف ۰/۰۲۵ الی ۰/۳۰ متر (۸ عرض)، ضخامت ۰/۰۵ متر و ارتفاع ۰/۰۳ متر در موقعیت‌های مختلف نسبت به دریچه کشویی در زیر و ماس بر دریچه در بالادست و پائین‌دست آن در بازشدگی‌های مختلف مورد استفاده قرار گرفته بودند (شکل ۱). در مجموع ۳۴۵ داده آزمایشگاهی به منظور بررسی عملکرد مدل‌های GEP, ANN, SVM و KNN در پیش‌بینی ضریب دبی دریچه کشویی در حالت با آستانه در موقعیت‌های مختلف نسبت به دریچه کشویی مورد بررسی قرار گرفت.

دبی عبوری از زیر دریچه در حالت آستانه هم‌عرض و آستانه غیرهم‌عرض کانال به ترتیب مطابق روابط (۱) و (۲) محاسبه می‌گردد.

$$Q = C_d W G \sqrt{2g(H_0 - Z)} \quad (1)$$


$$Q = C_d (A_1 \sqrt{2gH_0} + A_2 \sqrt{2g(H_0 - Z)} + A_3 \sqrt{2gH_0}) \quad (2)$$

در روابط فوق Q دبی، C_d ضریب دبی، W عرض کانال، G میزان بازشدگی، g شتاب گرانش زمین، H عمق بالادست دریچه، Z ارتفاع آستانه، A_1 و A_2 به ترتیب مساحت جریان عبوری از کناره‌های آستانه و بالای آستانه غیرهم‌عرض است.

مهم‌ترین پارامترهای تأثیرگذار بر ضریب دبی دریچه در حالت با آستانه عبارتند از [۱۲]:

$$f_1(C_d, A_{total}, H_0, B, Z, \epsilon, W, X, \rho, g, \mu, \sigma) \quad (3)$$

در معادله (۱)، A_{total} مساحت جریان عبوری، B عرض کانال، ϵ ضخامت آستانه، X فاصله محور دریچه تا محور آستانه، ρ جرم مخصوص آب، μ لزجت



شکل ۱. الف) شماتیک دریچه-آستانه ب) آستانه هم‌عرض کانال ج) آستانه غیرهم‌عرض کانال

کشویی با آستانه را در شرایط جریان فوق بحرانی و زیر بحرانی مورد مطالعه قرار دادند. آن‌ها ضریب دبی را تابعی از نسبت اختلاف عمق بالادست و پائین-دست دریچه به میزان بازشدگی دریچه، نسبت عمق بالادست به میزان بازشدگی، نسبت عمق پایاب به بازشدگی دریچه و پارامترهای هندسی آستانه عنوان کردند. [۴] Salmasi and Norouzi تأثیر شکل‌های مختلف هندسی آستانه هم‌عرض کانال بر ضریب دبی دریچه کشویی را بررسی نمودند. نتایج نشان داد که آستانه ضریب دبی را حداقل ۲۳٪ و حداکثر ۳۱٪ افزایش می‌دهد. آستانه دایره‌ای موثرترین شکل و آستانه مثلثی از جمله بهترین آستانه‌های چندوجهی می‌باشد. [۵] Karami et al. تأثیر پارامترهای آستانه همچون ارتفاع و شکل بر ضریب دبی دریچه‌های کشویی در جریان آزاد را با استفاده از نرم‌افزار DyFLOW- مورد بررسی قرار دادند. نتایج نشان داد که آستانه نیم‌دایره‌ای باعث افزایش ۲۰٪ ضریب دبی می‌شود. [۶] Salmasi and Abraham ضریب دبی دریچه‌های کشویی با آستانه‌های چندوجهی و غیرچندوجهی را بررسی و نتیجه گرفتند که آستانه دایره‌ای بیشترین تأثیر و آستانه‌های دوزنقه‌ای کم‌ترین تأثیر را بر ضریب دبی دارند. [۷] Ghorbani et al. با استفاده از روش O₃H و مدل‌های هوشمند از جمله GBM, RF, DL و GLM به تجزیه و تحلیل ضریب دبی دریچه‌های کشویی با آستانه هم‌عرض کانال پرداختند. نتایج نشان داد که روش یادگیری ماشین O₃H عملکرد خوبی در تخمین ضریب دبی دریچه کشویی دارد. [۸] Daneshfaraz et al. به بررسی آزمایشگاهی و عددی تأثیر کاربرد آستانه هم‌عرض و غیرهم‌عرض بر ضریب دبی دریچه کشویی پرداختند. نتایج تحقیق آن‌ها نشان داد که ضریب دبی مربوط به آستانه در موقعیت ماس بر دریچه در بالادست آن بیشتر از موقعیت ماس در پائین‌دست و موقعیت قرارگیری آستانه در زیر دریچه است. [۹] Daneshfaraz et al. به بررسی آزمایشگاهی تأثیر فاصله آستانه‌های هم‌عرض و غیرهم‌عرض در بالادست دریچه پرداختند. نتایج آن‌ها نشان داد که با افزایش فاصله ضریب دبی کاهش می‌یابد.

در سال‌های اخیر روابط مختلفی برای تخمین ضریب دبی دریچه کشویی در حالت بدون آستانه و برای آستانه هم‌عرض کانال ارائه شده است. بررسی پیشینه تحقیق نشان داد که کاربرد آستانه‌های غیرهم‌عرض در دریچه‌های کشویی موضوع جدیدی بوده و به جز چند تحقیق انجام یافته در یک سال اخیر، هیچ پژوهشی در رابطه با آستانه‌های غیرهم‌عرض انجام نیافته است. لازم به ذکر است که در تحقیقات گذشته برای موضوع مذکور، رابطه تئوری برای تخمین میزان دبی عبوری از دریچه برای اولین بار ارائه شده است. [۱۰] بنابراین با توجه به عدم قطعیت حاکم بر مسئله در این تحقیقات، انجام پژوهش‌های جدید در زمینه مدل‌سازی هوشمند ضریب دبی دریچه-آستانه هم‌عرض کانال در موقعیت‌های مختلف آستانه نسبت به دریچه در عرض‌های مختلف ضروری به نظر می‌رسد. همچنین تاکنون مطالعه‌ای در خصوص استفاده از محاسبات نرم مورد توجه قرار نگرفته است. بدین منظور در پژوهش حاضر با استفاده از مدل‌های هوشمند ماشین بردار پشتیبان (SVM)، شبکه عصبی مصنوعی (ANN)، الگوریتم K نزدیک‌ترین همسایه (KNN) و برنامه‌ریزی بیان ژن (GEP) به پیش‌بینی ضریب دبی دریچه کشویی پرداخته شده است.

۲. مواد و روش‌ها

۲.۱. انتخاب پارامترها

در پژوهش حاضر از داده‌های آزمایشگاهی [۱۱] Daneshfaraz et al. استفاده شده است. [۱۲] تمامی آزمایش‌ها در کانالی به طول ۵ متر، عرض ۰/۳۰

دینامیکی و σ بیانگر کشش سطحی است. با استفاده از تئوری π باکینگهام می‌توان رابطه (۴) را ارائه کرد.

$$f_2 \left(C_d, \frac{A_{total}}{B^2}, \frac{H_0}{B}, \frac{Z}{B}, \frac{\varepsilon}{B}, \frac{W}{B}, \frac{X}{B}, Re, We \right) \quad (4)$$

که در آن Re و We بیانگر عدد رینولدز و عدد وبر است. زمانی که مایع یکسان و دما ثابت باشد، Re و We به یکدیگر وابسته هستند و با بازشدگی درجه تغییر می‌کنند، بنابراین می‌توان از تأثیر عدد وبر و یا عدد رینولدز چشم‌پوشی نمود [۱۰، ۱۲]. همچنین با توجه به متلاطم بودن جریان از تأثیر عدد رینولدز چشم‌پوشی شد. پارامتر عرض کانال مقدار ثابتی به خود گرفته و از اهداف تحقیق [۸، ۳] Daneshfaraz et al. نبوده است. پارامترهای مورد بررسی در رابطه (۵) آورده شده است.

$$C_d = f_3 \left(\frac{A_{total}}{B^2}, \frac{H_0}{B}, \frac{Z}{B}, \frac{\varepsilon}{B}, \frac{X}{B} \right) \quad (5)$$

محدوده پارامترهای مورد استفاده در این پژوهش، در جدول (۱) نشان داده شده است. پارامترهای ورودی به نرم‌افزار Statistica ۱۲، در مدل‌های مختلف به SVM، KNN، GEP و ANN معرفی شدند (جدول ۱).

۲.۲. ماشین بردار پشتیبان

ماشین بردار پشتیبان به‌عنوان یکی از روش‌های یادگیری با نظارت، اولین بار توسط Vapnik [۱۱] برای طبقه‌بندی و پیش‌بینی مورد استفاده قرار گرفت. ماشین بردار پشتیبان یک سیستم یادگیری کارآمد بر مبنای تئوری بهینه‌سازی مقید است که از اصل استقرای کمینه‌سازی خطای ساختاری استفاده کرده و منجر به یک جواب بهینه کلی می‌گردد. در مدل رگرسیون SVM تابعی مرتبط با متغیر وابسته Y که خود تابعی از چند متغیر مستقل X است، برآورد می‌شود. انتخاب کرنل برای SVM به حجم داده‌های آموزشی و ابعاد بردار ویژگی بستگی دارد. به‌عبارت دیگر، باید با توجه به این پارامترها تابع کرنلی را انتخاب نمود که توانایی آموزش برای ورودی‌های مسئله را داشته باشد. در عمل چهار نوع کرنل خطی (Linear)، چندجمله‌ای (Polynomial)، کرنل سیگموئید (Sigmoid) و کرنل تابع پایه شعاعی (RBF) به کار گرفته می‌شوند [۱۲]

$$K(X_i, X_j) = (X_i, X_j) \quad (6)$$

$$K(X_i, X_j) = (1 + (X_i, X_j))^d \quad (7)$$

$$K(X_i, X_j) = \tanh(-a(X_i, X_j) + C) \quad (8)$$

$$K(X_i, X_j) = \exp\left(-\frac{\|(X_i, X_j)\|^2}{\sigma^2}\right) \quad (9)$$

در روابط بالا $K(X_i, X_j)$ تابع کواریانس یا کرنل بوده که در نقاط X_i و X_j محاسبه می‌گردد. d, C, a و σ بیانگر توابع کرنل هستند. d درجه چندجمله‌ای و C عددی صحیح و مثبت است که عامل تعیین جریمه در هنگام رخ دادن خطای آموزش مدل است.

۳.۲. الگوریتم K نزدیک‌ترین همسایه

الگوریتم K نزدیک‌ترین همسایه یا KNN یکی از ساده‌ترین الگوریتم‌های یادگیری ماشین با ناظر است که برای حل مسائل طبقه‌بندی و رگرسیون استفاده می‌شود. این الگوریتم یک روش رایج برای طبقه‌بندی است و بر اساس سنجش فاصله می‌باشد. KNN همچنین به‌عنوان یک مدل مبتنی بر نمونه یا یک یادگیرنده‌ی تنبل شناخته می‌شود؛ زیرا یک مدل داخلی ایجاد نمی‌کند

و از داده‌های آموزش عملکرد متمایز را یاد نمی‌گیرد؛ فقط نمونه‌های آموزشی را حفظ می‌کند که به‌عنوان دانش برای مرحله پیش‌بینی استفاده می‌شود. برای مسائل رگرسیون K نزدیک‌ترین همسایه را پیدا و با محاسبه‌ی میانگین مقدار نزدیک‌ترین همسایه‌ها، مقدار مدنظر را پیش‌بینی می‌کند. برای تعیین فاصله از توابع فاصله همچون اقلیدسی (Euclidean)، اقلیدسی مربع (Euclidean Squared)، منهتن (Manhattan) و چیشو (Chebychev) استفاده می‌شود [۱۳].

۴.۲. شبکه عصبی مصنوعی

یک شبکه عصبی مصنوعی در حالت کلی از لایه‌های ورودی، لایه‌های پنهان و لایه‌های خروجی تشکیل می‌شود. نورون کوچک‌ترین واحد پردازشگر اطلاعات است که اساس عملکرد شبکه‌های عصبی را تشکیل می‌دهد. یک شبکه عصبی مجموعه‌ای از نورون‌هاست که با قرار گرفتن در لایه‌های مختلف، معماری خاصی را بر مبنای ارتباطات بین نورون‌ها در لایه‌های مختلف تشکیل می‌دهد. نورون می‌تواند یک تابع ریاضی غیرخطی باشد، در نتیجه یک شبکه عصبی که از اجتماع این نورون‌ها تشکیل می‌شود، نیز می‌تواند یک سامانه کاملاً پیچیده و غیرخطی باشد. در شبکه عصبی هر نورون به‌طور مستقل عمل می‌کند و رفتار کلی شبکه، برآیند رفتار نورون‌های متعدد است. با استفاده از دانش برنامه‌نویسی رایانه می‌توان ساختار داده‌ای طراحی کرد که همانند یک نورون عمل نماید [۱۴]. سپس با ایجاد شبکه‌ای از این نورون‌های مصنوعی به هم پیوسته، ایجاد یک الگوریتم آموزشی برای شبکه و اعمال این الگوریتم به شبکه آن را آموزش داد. در پژوهش حاضر از شبکه عصبی مصنوعی پرسپترون چند لایه (MLP) استفاده شده است.

۵.۲. برنامه‌ریزی بیان ژن

این روش جز روش‌های الگوریتم گردشی محسوب می‌شود که مبنای تمامی آن‌ها بر اساس نظریه تکامل داروین استوار است. الگوریتم‌های یاد شده اقدام به تعریف یک تابع هدف در قالب معیارها و سپس تابع یاد شده را برای اندازه‌گیری و مقایسه روش‌های مختلف حل، در یک فرآیند گام به گام تصحیح ساختار داده‌ها به کار می‌گیرند و در نهایت، روش حل مناسب را ارائه می‌نمایند. برنامه‌ریزی بیان ژن جدیدترین شیوه از بین روش‌های الگوریتم گردشی است که به دلیل دارا بودن دقت کافی، به‌عنوان مرسوم‌ترین شیوه بوده و از کاربرد

جدول ۱. مدل‌های تعریف شده و محدوده تغییرات پارامترها.

مدل	پارامترهای ورودی	پارامترها	محدوده تغییرات
۱	$\frac{A_{total}}{B^2}, \frac{H_0}{B}$	$\frac{A_{total}}{B^2}$	$0.033 \leq \frac{A_{total}}{B^2} \leq 18$
۲	$\frac{A_{total}}{B^2}, \frac{H_0}{B}, \frac{X}{B}$	$\frac{H_0}{B}$	$0.296 \leq \frac{H_0}{B} \leq 8.6$
۳	$\frac{A_{total}}{B^2}, \frac{H_0}{B}, \frac{Z}{B}$	$\frac{Z}{B}$	$0.1 \leq \frac{Z}{B} \leq 1.2$
۴	$\frac{A_{total}}{B^2}, \frac{H_0}{B}, \frac{\varepsilon}{B}$	$\frac{\varepsilon}{B}$	$0.167 \leq \frac{\varepsilon}{B} \leq 2$
۵	$\frac{A_{total}}{B^2}, \frac{H_0}{B}, \frac{Z}{B}, \frac{\varepsilon}{B}$	$\frac{X}{B}$	$-0.084 \leq \frac{X}{B} \leq 0.084$
۶	$\frac{A_{total}}{B^2}, \frac{H_0}{B}, \frac{Z}{B}, \frac{\varepsilon}{B}, \frac{X}{B}$		

می‌باشد. علت این امر را می‌توان به قرارگیری آستانه اشاره نمود. به طوری که در حالت مماس، کل ضخامت آستانه در پشت دریاچه قرار داشته و بعد از آن حجم بیشتری از آب از زیر دریاچه با الگوی جریان یکنواخت، جریان می‌یابد. در مدل مربوط به حالت زیر آستانه، نصف آستانه در موقعیت بعد از دریاچه قرار دارد که به صورت مانع عمل کرده و باعث افزایش ضریب اصطکاک جریان با آستانه و به تبع آن افزایش بیشتر عمق جریان در بالادست دریاچه نسبت به حالت مماس می‌شود. برای مدل مماسی بعد دریاچه در مقایسه با حالت آستانه زیر دریاچه، ضریب دبی بیشتر و در مقایسه با مدل مماسی بالادست دریاچه کم‌تر است. به طوری که در مدل مماسی بالادست، میزان عمق آب در بالادست دریاچه در مقایسه با مدل زیر دریاچه و پائین‌دست دریاچه کم‌تر بوده و بیشترین میزان آن مربوط به حالت آستانه زیر دریاچه است. بنابراین آستانه‌های غیرمعرض مدل مماسی با توجه به عملکرد مطلوب آن از نظر افزایش میزان راندمان دبی عبوری و همچنین جلوگیری از تجمع رسوبات در پشت دریاچه، می‌تواند مورد توجه و استفاده قرار گیرد. وجود آستانه زیر دریاچه و مماس بر دریاچه کشویی نسبت به بالادست و پائین‌دست دریاچه در مقایسه با حالت بدون آستانه، باعث افزایش ضریب دبی و عملکرد بهتر سیستم از نظر میزان آبگذری دارد و بیشترین مقدار آن مربوط به حالت آستانه مماس بر دریاچه در بالادست (پشت دریاچه) آن است. با توجه به اینکه موقعیت آستانه باعث تغییر شکل خطوط جریان می‌گردد، بنابراین تأثیر به‌سزایی بر ضریب دبی جریان می‌گذارد. به طوری که خطوط جریان در مدل مماسی پشت دریاچه بلافاصله پس از طی مسیر روی آستانه با حالت ملایم‌تری بعد از آستانه به مسیر خود ادامه می‌دهد و لذا افت انرژی کم‌تری را باعث می‌شوند. در حالی که در مدل مماسی بعد از دریاچه و مدل زیر دریاچه، جریان به‌صورت جت آبی از روی آستانه رها گشته و جریان‌های گردابی منجر به افت بیشتر انرژی می‌شود. همچنین افزایش طول تماس جریان با آستانه باعث افزایش اصطکاک و مقاومت جریان خروجی از دریاچه می‌گردد که منجر به افزایش عمق در پشت دریاچه می‌شود. به ازای دبی ثابت، بار آبی بالادست دریاچه کشویی در تمامی موقعیت‌های آستانه کم‌تر از حالت بدون آستانه است. وقتی عمق جریان بالادست دریاچه افزایش می‌یابد، مقدار جریان عبوری از زیر دریاچه دارای فشار بیشتری بوده و باعث ایجاد افت و جریان‌های ناهمگرا و چرخشی بعد از دریاچه می‌شود که این امر منجر به کاهش ضریب دبی می‌گردد. همچنین وجود آستانه باعث می‌گردد تا فشار وارد بر دریاچه به کم‌تر از H برسد. بنابراین کاهش فشار و مکش جریان منجر به افزایش ضریب دبی می‌گردد.

۲.۳. SVM

پارامترهای بی‌بعد مختلف به‌عنوان ورودی مدل‌های مختلف، و ضریب دبی دریاچه کشویی با آستانه به‌عنوان خروجی و ویژگی هدف در نظر گرفته شد و سعی گردید امکان کاربرد روش‌های داده‌کاوی در تخمین ضریب دبی مورد ارزیابی قرار گیرد. برای پیش‌بینی ضریب دبی توسط روش‌های داده‌کاوی در حالت کلی تعداد ۷۰٪ داده‌ها برای مرحله آموزش مدل و ۳۰٪ داده‌ها برای قسمت آزمون مدل انتخاب گردید. در پژوهش حاضر ضریب دبی به پارامترهای مختلفی بستگی دارد. این پارامترها مطابق جدول (۱) در مدل‌های مختلفی بررسی شدند. نتایج شاخص‌های آماری ماشین‌بردار پشتیبان برای این مدل‌ها در جدول (۲) نشان داده شده است. نحوه انتخاب بهترین مدل بدین صورت بود که شاخص‌های آماری R ، $RMSE$ ، $MRE\%$ و KGE مناسبی در مقایسه با نتایج آزمایشگاهی داشته باشد. مطابق جدول (۲)، مدل شماره ۶ در

بیشتری برخوردار است. زمینه اصلی برنامه‌ریزی بیان ژن، همان الگوریتم ژنتیک است، با این تفاوت که در این روش از شاخه‌های مجزا به جای نوارهای بیت استفاده می‌شود. هر شاخه نیز از یک مجموعه پایانه‌ها (متغیرهای مسئله) و مجموع توابع (عملگرهای اصلی) تشکیل می‌شود [۱۵].

۶.۲. شاخص‌های آماری

در پژوهش حاضر برای ارزیابی کارایی روش‌های به‌کاربرده شده برای پیش‌بینی ضریب دبی از شاخص‌های آماری میانگین درصد خطای نسبی ($MRE\%$)، خطای جذر میانگین مربعات ($RMSE$) و شاخص کلینگ گوپتا (KGE) استفاده شده است.

$$MRE\% = \frac{1}{n} \left(\frac{C_{d\text{obs}} - C_{d\text{cal}}}{C_{d\text{obs}}} \times 100 \right) \quad (10)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (C_{d\text{obs}} - C_{d\text{cal}})^2}{n}} \quad (11)$$

$$KGE = \sqrt{(R-1)^2 + (\beta-1)^2 + (\gamma-1)^2}$$

$$\beta = \frac{C_{d\text{cal}}}{C_{d\text{obs}}}, \gamma = \frac{CV_{\text{cal}}}{CV_{\text{obs}}} = \frac{\frac{\sigma_{\text{cal}}}{C_{d\text{cal}}}}{\frac{\sigma_{\text{obs}}}{C_{d\text{obs}}}} \quad (12)$$

$$R = \frac{\left[\sum_{i=1}^n (C_{d\text{obs}i} - \overline{C_{d\text{obs}}}) \times (C_{d\text{cal}i} - \overline{C_{d\text{cal}}}) \right]}{\sum_{i=1}^n (C_{d\text{obs}i} - \overline{C_{d\text{obs}}}) \sum_{i=1}^n (C_{d\text{cal}i} - \overline{C_{d\text{cal}}})}$$

$$0.6 < KGE < 0.7 \text{ (good)}$$

$$0.5 < KGE \leq 0.6 \text{ (satisfactory)}$$

$$0.4 < KGE \leq 0.5 \text{ (acceptable)}$$

$$KGE \leq 0.4 \text{ (unsatisfactory)}$$

در روابط بالا، Obs و Cal به ترتیب بیانگر نتایج مشاهداتی و محاسباتی و n تعداد کل داده‌ها می‌باشند. مقادیر روابط (۱۰) و (۱۱) هرچه به عدد صفر نزدیک باشد، بیانگر دقت بالای حل مدل مورد نظر خواهند بود. در رابطه (۱۲)، R ضریب همبستگی، β نسبت میانگین داده‌های محاسباتی به میانگین داده‌های مشاهداتی و γ بیانگر نسبت انحراف استاندارد مقادیر محاسباتی به انحراف استاندارد مقادیر مشاهداتی می‌باشند. شاخص آماری KGE بر اساس تقسیم‌بندی این شاخص به خیلی خوب، خوب، رضایت بخش، قابل قبول و غیررضایت بخش، می‌تواند بیانگر دقت حل باشد [۱۶].

۳. نتایج و بحث

۳.۱. کاربرد آستانه در دریاچه کشویی

در مدل‌های آستانه در زیر و مماس بر دریاچه در بالادست و پائین‌دست آن با افزایش عرض آستانه، ضریب دبی افزایش می‌یابد. به طوری که آستانه با کم‌ترین عرض، دارای حداقل مقدار ضریب دبی می‌باشد. همچنین مشاهده می‌گردد که با افزایش نسبت عمق جریان بالادست دریاچه به عرض آستانه، ضریب دبی روند افزایشی دارد. با مقایسه ضریب دبی در موقعیت‌های مختلف، ضریب دبی در حالت مماس بر دریاچه در بالادست آن، بیشتر از حالت زیر دریاچه کشویی

بیشتری به پارامتر H_0/B دارد. کمترین میزان حساسیت نیز مربوط به پارامتر X/B است.

مطابق جدول (۳)، از میان کرنل‌های Linear, Polynomial, RBF و Sigmoid، کرنل RBF با توجه به نتایج شاخص‌های آماری آن به‌عنوان کرنل برتر برای مدل ماشین‌بردار پشتیبان انتخاب گردید.

به‌منظور بررسی دقیق‌تر مدل‌های مختلف در پژوهش حاضر، مقادیر ضریب‌دبی آزمایشگاهی و پیش‌بینی شده به‌زای تعداد داده‌های مربوط به مرحله آموزش و آزمون در شکل (۳) نشان داده شده است. مقادیر ضریب‌دبی آزمایشگاهی و پیش‌بینی شده برای کرنل‌های مختلف، در شکل (۳-الف) ارائه شده است. همان‌طور که ملاحظه می‌گردد کرنل RBF دقت بالایی در مقایسه با سایر کرنل‌ها داشته و ضریب‌دبی را با دقت بالایی پیش‌بینی کرده است. با توجه به

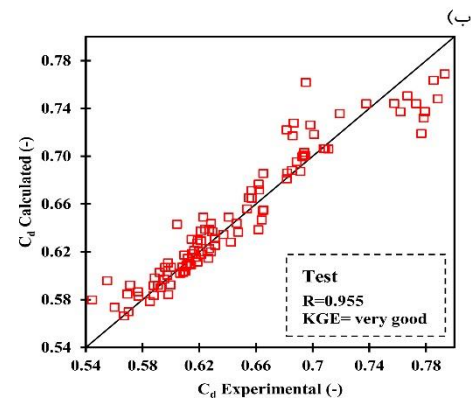
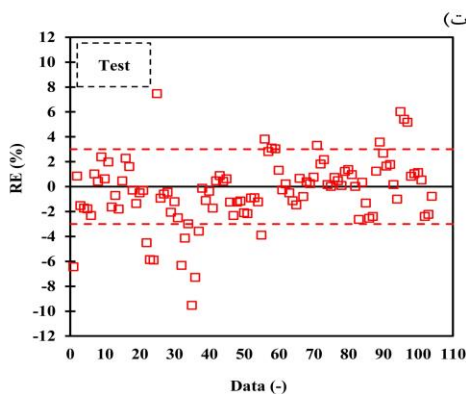
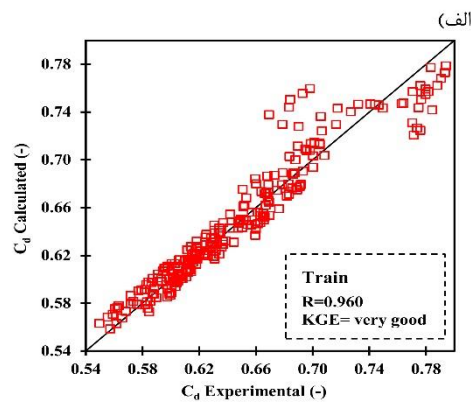
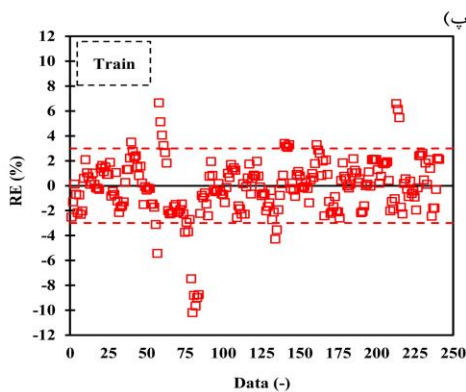
جدول ۳. نتایج شاخص‌های آماری کرنل‌های مختلف در مرحله آزمون برای مدل SVM

شاخص آماری	کرنل			سیگموئید
	خطی	چندجمله‌ای	پایه تابع شعاعی	
R	۰/۸۱	۰/۶۵	۰/۹۶	۰/۳۴
KGE	۰/۷۰	۰/۵۶	۰/۹۰	-۲/۰۷
RMSE	۰/۰۳۶	۰/۰۵	۰/۰۱۸	۰/۲۴
MRE%	۴/۰۶	۵/۴۷	۱/۹۲	۲۲/۱

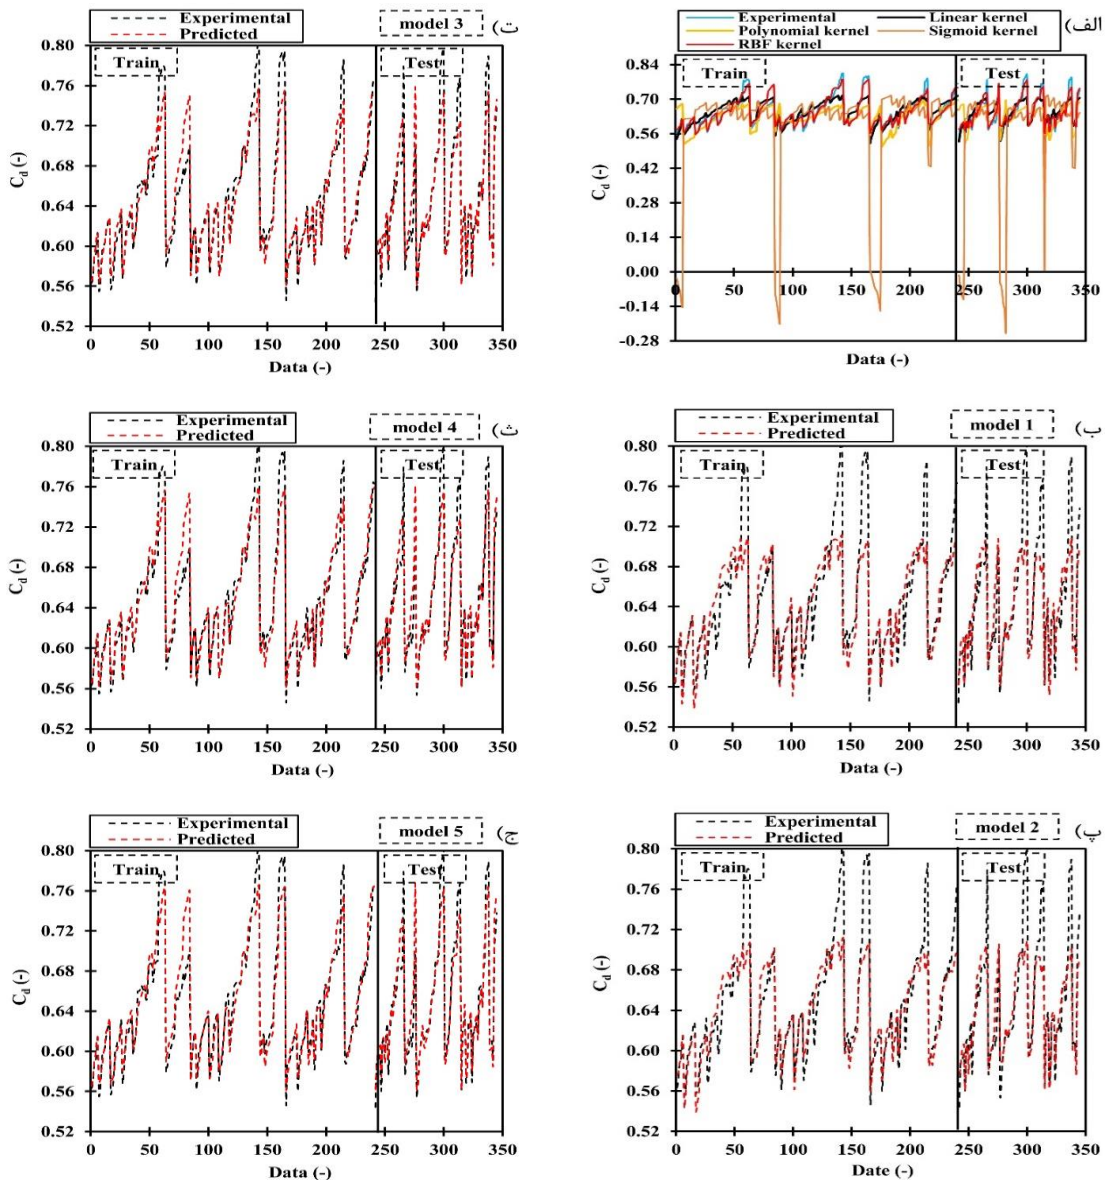
مقایسه با سایر مدل‌ها نتایج مطلوبی دارد، به‌طوری که برای این مدل در مرحله آموزش $R=۰/۹۶۰$ ، $RMSE=۰/۰۱۶۲$ ، $MRE\%=۱/۶۸$ و $KGE=۰/۹۳۹$ است. همچنین برای مرحله آزمون مقادیر این شاخص‌ها به‌ترتیب $۰/۹۵۵$ ، $۰/۰۱۸۲$ ، $۰/۰۱۹۲$ و $۰/۹$ است. مدل شماره ۶ بیانگر مدل برتر در بخش ماشین‌بردار پشتیبان است. در شکل (۲) نمودار داده‌ها مابین مقادیر آزمایشگاهی و پیش‌بینی شده حاصل از مدل SVM برای مدل برتر نشان داده شده است. نتایج حاکی از آن است که روند میزان تغییرات حاصل از نتایج آزمایشگاهی همانند نتایج پیش‌بینی شده است. با توجه به شکل (۲-ب، ت)، ملاحظه می‌گردد که برای مدل برتر، در مرحله آموزش و آزمون دامنه وسیعی از داده‌ها در باند خطای $\pm 3\%$ قرار دارند به‌طوری که در مرحله آموزش و آزمون به‌ترتیب بیش از ۹۰ و ۸۱ درصد داده‌ها در باند خطای $\pm 3\%$ قرار دارند که این موضوع بیانگر دقت بالای حل در زمان انتخاب تمامی پارامترهای موثر ورودی به مدل SVM است. بررسی نتایج نشان داد که ضریب تخلیه حساسیت

جدول ۲. نتایج پیش‌بینی ضریب‌دبی در نمونه‌های مختلف.

نمونه	آموزش				آزمون			
	R (-)	RMSE (-)	KGE (-)	MRE (%)	R (-)	RMSE (-)	KGE (-)	MRE (%)
۱	۰/۸۷	۰/۰۲۹۵	۰/۷۴	۲/۶۸	۰/۸۵	۰/۰۳۲۶	۰/۶۹	۲/۹۵
۲	۰/۸۸	۰/۰۲۹۲	۰/۷۲	۲/۶۳	۰/۸۶	۰/۰۳۲۵	۰/۶۷	۲/۸۷
۳	۰/۹۵	۰/۰۱۸۲	۰/۸۹	۰/۸۷	۰/۹۴	۰/۰۲۰۷	۰/۸۴	۲/۰۲
۴	۰/۹۵	۰/۰۱۸۱	۰/۹۲	۱/۸۳	۰/۹۴	۰/۰۲۰۴	۰/۸۷	۲/۰۷
۵	۰/۹۶	۰/۰۱۷۳	۰/۹۴	۱/۷۶	۰/۹۵	۰/۰۱۸۸	۰/۹۰	۱/۹۹
۶	۰/۹۶	۰/۰۱۶۲	۰/۹۴	۱/۶۸	۰/۹۶	۰/۰۱۸۲	۰/۹۰	۱/۹۲



شکل ۲. ضریب‌دبی آزمایشگاهی در برابر پیش‌بینی شده (الف) مرحله آموزش (ب) مرحله آزمون، پراکندگی درصد خطای نسبی داده‌ها (پ) مرحله آموزش (ت) مرحله آزمون.



شکل ۳. مقادیر آزمایشگاهی و پیش‌بینی شده ضریب‌دبی در مرحله آموزش و آزمون به‌ازای داده‌های مختلف.

جدول ۴. نتایج شاخص‌های آماری مدل‌های مختلف در روش ANN.

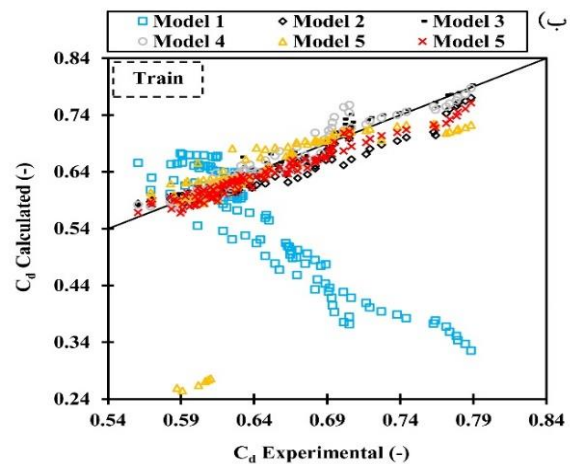
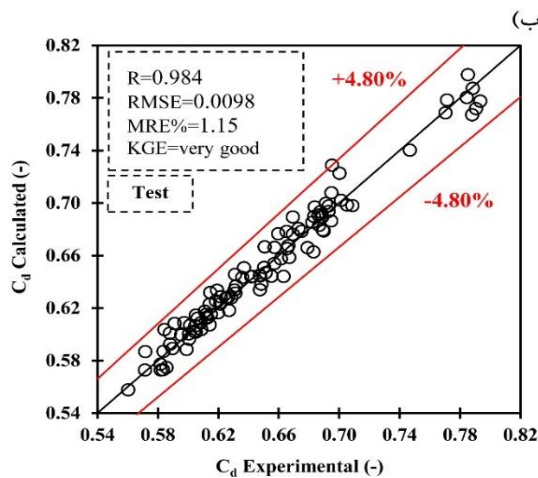
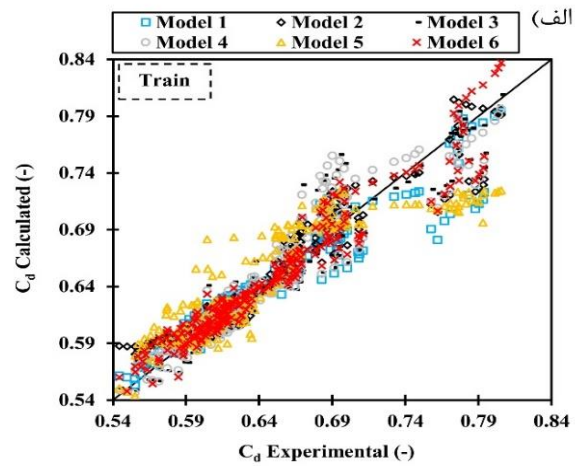
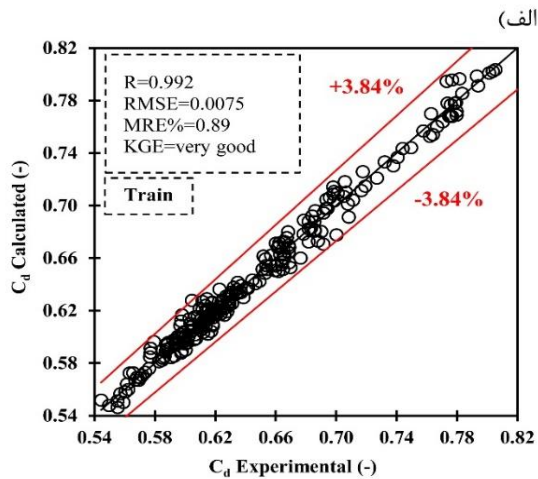
نمونه	آموزش				آزمون			
	R	RMSE	KGE	MRE	R	RMSE	KGE	MRE
	(-)	(-)	(-)	(%)	(-)	(-)	(-)	(%)
۱	۰/۹۷	۰/۰۱۴۰	۰/۹۶	۱/۶۱	۰/۹۵	۰/۰۱۷۲	۰/۹۵	۱/۷۲
۲	۰/۹۷	۰/۰۱۳۸	۰/۹۶	۱/۴۶	۰/۹۶	۰/۰۱۵۱	۰/۹۶	۱/۴۴
۳	۰/۹۸	۰/۰۱۲۵	۰/۹۷	۱/۳۰	۰/۹۵	۰/۰۱۶۸	۰/۹۵	۱/۶۶
۴	۰/۹۸	۰/۰۱۳۳	۰/۹۷	۱/۴۹	۰/۹۵	۰/۰۱۶۸	۰/۹۵	۱/۶۳
۵	۰/۹۸	۰/۰۱۲۹	۰/۹۶	۱/۳۸	۰/۹۵	۰/۰۱۶۷	۰/۹۵	۱/۵۶
۶	۰/۹۹	۰/۰۰۷۵	۰/۹۹	۰/۸۹	۰/۹۸	۰/۰۰۹۸	۰/۹۸	۱/۱۵

حداکثر تعداد لایه‌های مخفی به ترتیب ۳ و ۲۱ انتخاب شد تا عملیات بیشتری به‌منظور پیدا کردن برترین مدل انجام گیرد. مطابق جدول (۴) زمانی که از تمام پارامترهای ابعادی استفاده می‌شود دقت حل در مقایسه با سایر مدل‌ها افزایش می‌یابد. هرچند که نتایج سایر مدل‌ها نیز به‌یکدیگر نزدیک هستند اما مورد شماره ۶ نتایج بهتری را تولید می‌کند. نتایج شاخص‌های R ، $RMSE$ ، $MRE\%$ و KGE برای مورد شماره ۶ در مرحله آموزش به ترتیب $۰/۹۹۲$ ، $۰/۰۰۷۵$ ، $۰/۸۹$ و $۰/۹۹۲$ است این مقادیر برای مرحله آزمون نیز به ترتیب

شکل (۳)، در میان مدل‌ها که مدل شماره ۶ به‌عنوان مدل برتر معرفی گردید، مدل شماره ۵ نیز نتایج نزدیک به نتایج آزمایشگاهی دارد. نتایج شاخص‌های آماری برای این مدل در مرحله آموزش $R=۰/۹۵۵$ ، $RMSE=۰/۰۱۷۳$ ، $MRE\%=۱/۷۶$ و $KGE=۰/۹۴$ است. نتایج این شاخص‌ها برای مرحله آزمون به ترتیب $۰/۹۵۱$ ، $۰/۰۱۸۸$ ، $۰/۰۹۰۱$ و $۰/۰۱۹۹$ است. در مدل‌های شماره ۱ و ۲ این اختلاف بیشتر است. علت این موضوع را می‌توان به عدم استفاده از سایر پارامترهای بی‌بعد همچون X/B ، Z/B و ε/B دانست. هرچند که پارامتر X نقش چندانی نداشته و نتایج مدل‌های ۵ و ۶ به یکدیگر نزدیک هستند. علت این مسئله می‌تواند به تأمین نقش این پارامتر توسط سایر پارامترها گردد. با اینکه موقعیت آستانه تأثیر م ثبتی در افزایش ضریب‌دبی دریچه کشویی دارد و بیشترین مقدار آن مربوط به حالت مماس بر دریچه در بالادست آن است.

۳.۳. ANN

در جدول (۴) نتایج شاخص‌های آماری برای مدل‌های مختلف ورودی (جدول ۱) در روش ANN با استفاده از نوع شبکه MLP آورده شده است. در این روش نیز همانند مدل ماشین‌بردار پشتیبان، ۷۰% داده‌ها برای آموزش و ۳۰% داده‌ها برای آزمون به‌صورت تصادفی توسط نرم‌افزار انتخاب شدند. حداقل و



شکل ۵. پراکندگی داده‌ها در موردهای مختلف در مدل GEP (الف) مرحله آموزش (ب) مرحله آزمون.

شکل ۴. ضریب‌دبی آزمایشگاهی در برابر ضریب‌دبی پیش‌بینی شده (الف) مرحله آموزش (ب) مرحله آزمون.

۰/۹۸۴، ۰/۰۹۸، ۱/۱۵ و ۰/۹۷۶ است. نمودار اسکاتر پلات برای مرحله آموزش و آزمون مدل شماره ۶ در شکل (۴) نشان داده شده است.

۴.۳ GEP

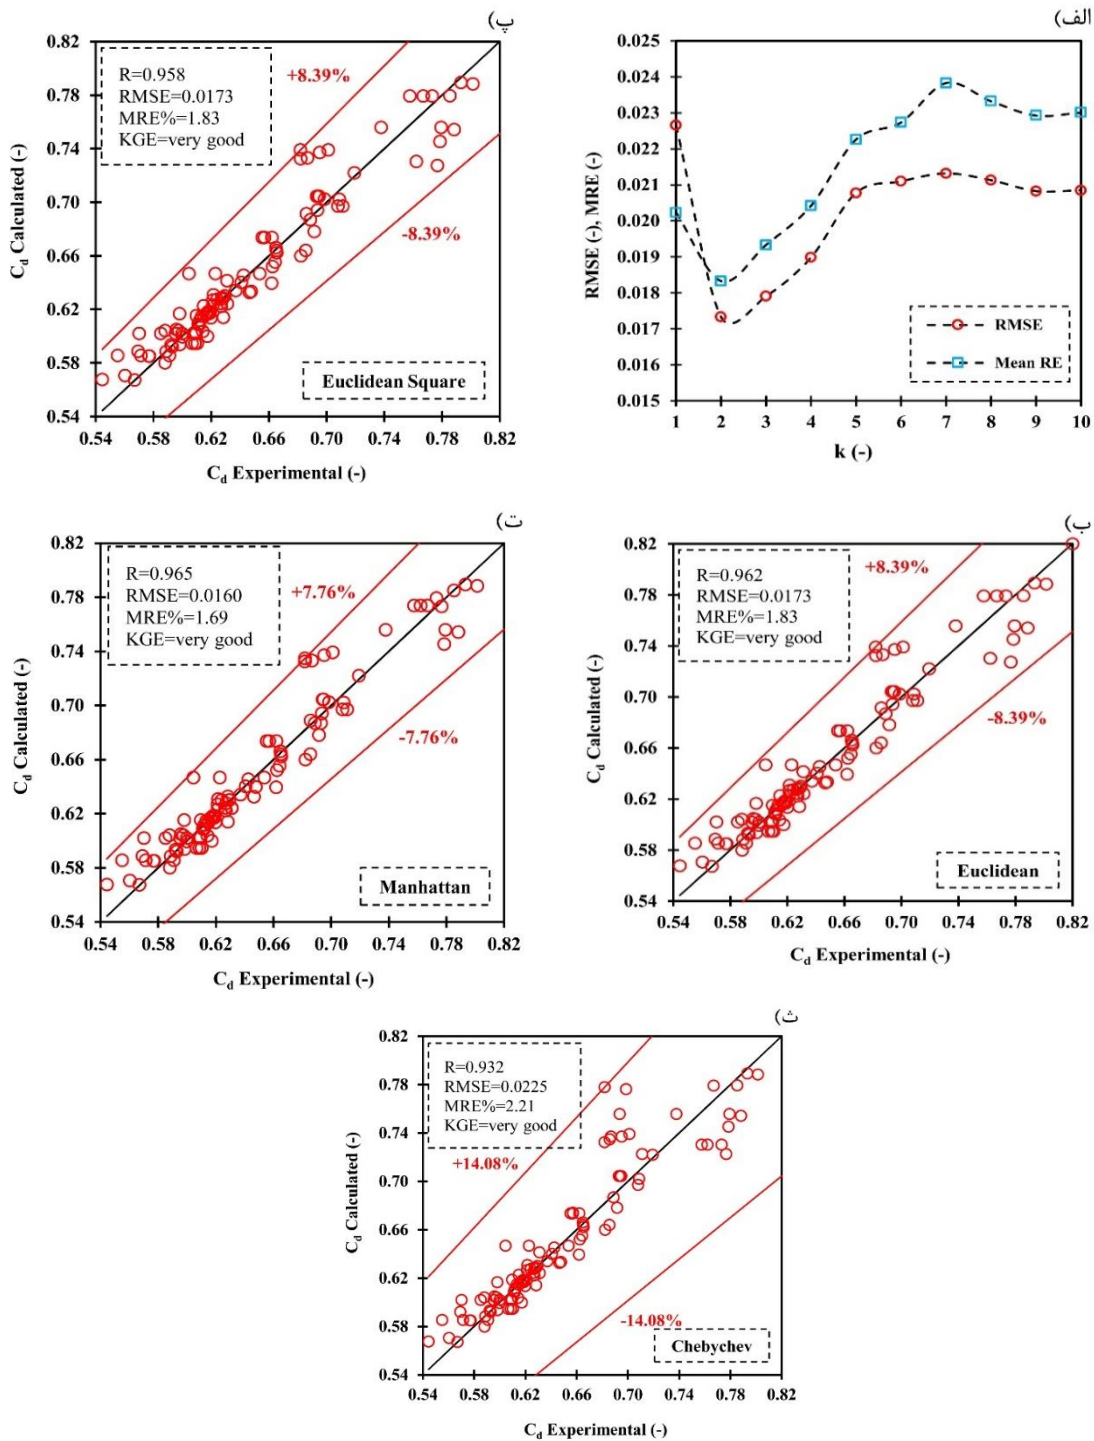
در شکل (۵) نمودار پراکندگی در مرحله آموزش و آزمون برای تمامی موردهای مختلف در مدل GEP آورده شده است. نتایج شاخص‌های آماری R ، $RMSE$ ، KGE و $MRE\%$ برای مرحله آموزش به ترتیب ۰/۹۶۶، ۰/۰۱۵۸، ۰/۰۹۴۲ و ۱/۶۹ است. برای مرحله آزمون نیز به ترتیب برابر با ۰/۹۷۹، ۰/۰۱۸۶، ۰/۱۸۵ و ۲/۲۸ است.

۵.۳ KNN

در شکل (۶-الف)، میزان $RMSE$ و MRE برای مرحله آزمون مدل ۶ در مقادیر مختلف K آورده شده است. میزان K ای درست است که بتواند مرزی را تعیین کند که با کم‌ترین خطا داده‌ها را پیش‌بینی نماید. بررسی ضریب همسایگی نزدیک نشان داد بهترین نتیجه زمانی حاصل می‌گردد که از ضریب ۲ استفاده شود. در K برابر ۲ مقادیر شاخص‌های آماری $RMSE$ و MRE کم‌ترین میزان را به خود اختصاص داده است. در شکل (۶-ب، پ، ت و ث) مقادیر ضریب‌دبی برای معیارهای مختلف فاصله اندازه‌گیری ارائه شده است. همان‌طور که ملاحظه می‌گردد در فاصله منتهن نتایج نزدیک به نتایج آزمایشگاهی بوده و مقادیر شاخص‌های آماری R ، $RMSE$ ، $MRE\%$ و KGE به ترتیب ۰/۹۶۵، ۰/۰۱۶، ۱/۷۰ و ۰/۹۶ است. نتایج در فاصله اقلیدسی

۶.۳ مدل برتر

به منظور انتخاب برترین مدل از میان مدل‌های ANN، KNN، SVM و GEP نتایج برترین‌های هر گروه در شکل (۷) نشان داده شده است. مطابق شکل (۷-الف) مشاهده می‌گردد که برای مدل SVM-RBF مقادیر در بازه خطای نسبی $\pm 9/54\%$ قرار دارند. مقدار $RMSE$ و $MRE\%$ برای این مدل به ترتیب ۰/۰۱۸۲ و ۱/۹۲ است. برای مدل KNN-Manhattan داده‌ها در بازه خطای نسبی $\pm 7/76\%$ قرار دارند. این مدل در مقایسه با مدل SVM-RBF نتایج مطلوبی را ارائه داده است. به طوری که میزان $RMSE$ و $MRE\%$ برای مدل مذکور به ترتیب ۰/۰۱۶۰ و ۱/۷۰ است. برای روش GEP حداکثر



شکل ۶. الف) مقادیر $RMSE$ و $MRE\%$ به ازای K مختلف، ضریب دبی پیش بینی شده در برابر آزمایشگاهی در معیار اندازه گیری (ب) فاصله اقلیدسی، (پ) فاصله اقلیدسی مربع، (ت) فاصله منهتن و (ث) فاصله چیبیشو.

نمودار جعبه ای یک روش استاندارد برای نمایش توزیع داده ها است که براساس شاخص های آماری کوچک ترین مقدار، چارک اول، میانه، چارک سوم و بزرگ ترین مقدار ساخته شده است (شکل ۸). همچنین این نمودار می تواند در مورد وجود داده های دور افتاده یا پرت، اطلاعاتی را دهد و مقدار آن ها را تعیین کند. همچنین نشان دادن تقارن در داده ها از کارهایی این نمودار است. خط عمودی که به موازات جعبه ها امتداد می یابد، تغییرپذیری خارج از چارک های بالا و پائین را نشان می دهد. نمودار جعبه ای که در شکل (۸) برای

مقدار درصد خطای نسبی $6/11\%$ است. نتایج روش ANN-MLP در مقایسه با سه مدل قبلی نتایج بهتری از نظر آماری دارد و به نتایج آزمایشگاهی نزدیک است. برای روش ANN-MLP داده ها در بازه درصد خطای نسبی $\pm 4/80$ قرار گرفته اند. مقادیر شاخص های آماری فوق نیز برای این مدل به ترتیب $0/0098$ و $1/115$ است. مقدار ضریب همبستگی برای مدل های فوق در مرحله آزمون به ترتیب $0/955$ ، $0/965$ و $0/984$ است. مقایسه ضرایب دبی حاصل از مدل های مختلف و نتایج آزمایشگاهی حاکی از هم پوشانی بهتر داده ها در روش ANN با نتایج آزمایشگاهی است (شکل ۷-ب).

جدول ۵. مقایسه نتایج پژوهش حاضر با تحقیق [۲].

Daneshfaraz et al

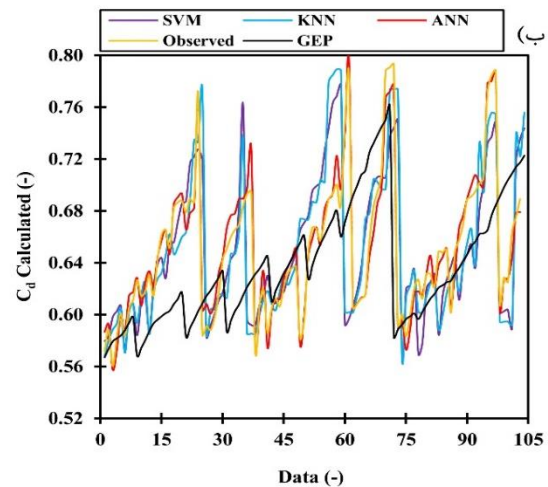
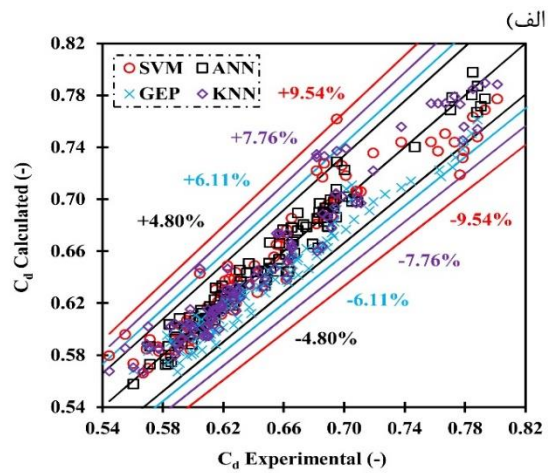
مورد	R	MRE (%)	RMSE
ANN-MLP	۰/۹۸۴	۱/۱۵	۰/۰۰۹۸
Daneshfaraz et al. [2]	۰/۹۸۰	۱/۴۸	۰/۰۱۱۲

در جدول (۵) مقایسه نتایج حاصل از پژوهش حاضر با رابطه تجربی تحقیق [۲] Daneshfaraz et al. نشان داده شده است. مطابق جدول (۵) نتایج شاخص‌های آماری RMSE، MRE% و R در مدل ANN نتایج مطلوبی در مقایسه با رابطه تحقیق [۲] Daneshfaraz et al. دارد.

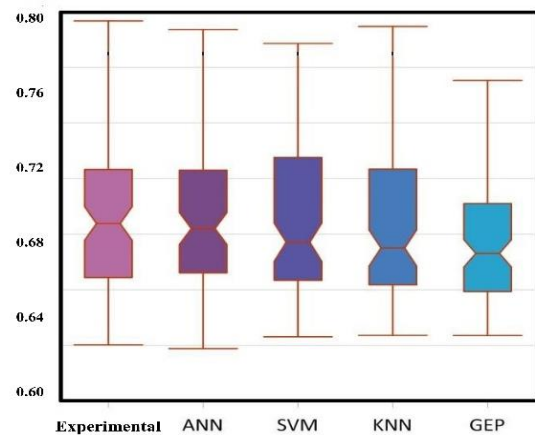
۴. نتیجه‌گیری

در پژوهش حاضر از روش‌های نوین داده‌کاوی ماشین بردار پشتیبان (SVM)، الگوریتم K نزدیک‌ترین همسایه (KNN) برنامه‌ریزی بیان ژن (GEP) و شبکه عصبی مصنوعی (ANN) در پیش‌بینی ضریب‌دبی در پیچه کشویی در حالت با آستانه استفاده شد. بدین منظور از ۳۴۵ داده آزمایشگاهی در قالب ۶ مدل مختلف ورودی براساس آنالیز ابعادی استفاده گردید. برای تمامی مدل‌های مذکور به صورت تصادفی ۷۰٪ داده‌ها برای مرحله آموزش و ۳۰٪ برای مرحله آزمون مورد استفاده قرار گرفتند. نتایج حاصل از شاخص‌های آماری ضریب همبستگی (R)، خطای جذر میانگین مربعات (RMSE)، میانگین درصد خطای نسبی (MRE%) و شاخص کلینگ گوپتا (KGE) نشان داد که در تمامی مدل‌های SVM، KNN، ANN و GEP، مدل با تمامی پارامترهای ورودی به‌عنوان مدل برتر شناخته شد. نتایج بررسی کرنل‌های مختلف نشان داد که کرنل تابع پایه شعاعی (RBF) در مقایسه با سایر کرنل‌های چند جمله‌ای (Polynomial)، خطی (Linear) و سیگموئید (Sigmoid) نتایج مطلوبی در مقایسه با نتایج آزمایشگاهی دارد. در مدل KNN به‌ازای ضرایب همسایگی مختلف، در K برابر با ۲ نتایج شاخص‌های آماری RMSE و MRE کم‌ترین میزان را دارا است. همچنین برای این مدل بررسی معیارهای مختلف فاصله اندازه‌گیری نشان داد که معیار فاصله منهتن (Manhattan) در مقایسه با معیارهای اقلیدسی (Euclidean)، اقلیدسی مربع (Euclidean Squared) و چبیشو (Chebychev) نتایج بهتری را دارد و به‌عنوان معیار برتر در مدل KNN با نتایج شاخص‌های فوق، به‌ترتیب برابر با ۰/۹۶۵، ۰/۱۶۰، ۰/۱۶۹ و ۰/۹۶۳ را به‌خود اختصاص داده است. بررسی نتایج مدل‌ها نشان داد که مدل‌های هوشمند مورد استفاده دقت بالایی در پیش‌بینی ضریب‌دبی در پیچه با آستانه دارند که مبتنی بر پارامترهای مختلف ورودی که شامل مشخصات هندسی آستانه باشد، است. روش ANN در مقایسه با مدل‌های GEP، KNN و SVM نتایج بهتری دارد و به نتایج آزمایشگاهی نزدیک‌تر است.

هیچ گونه تعارض منافع توسط نویسندگان بیان نشده است.



شکل ۷. الف) مقادیر ضریب‌دبی آزمایشگاهی در برابر پیش‌بینی شده (ب) مقایسه مقادیر ضریب‌دبی به‌ازای داده‌های مختلف در مرحله آزمون.



شکل ۸. نمودار جعبه‌ای داده‌های مشاهداتی و محاسباتی برای مرحله آزمون.

مرحله آزمون نشان داده شده است، نشان می‌دهد که مدل ANN دارای عمق انتهای بالاتر و پائین جعبه‌ها تقریباً با مقادیر مشاهده شده، یکسان است.

References - منابع

1. Negm, A.M., Alhamid, A.A. and El-Saiad, A.A., 1998. Submerged flow below sluice gate with a sill. *Proceedings of International Conference on Hydro-Science and Engineering Hydro-Science and Engineering ICHE98, Advances in Hydro-Science and Engineering*, Cottbus/Berlin, G.
2. Daneshfaraz, R. Norouzi, R. Abbaszadeh, H. and Azamathulla, H.M., 2022. Theoretical and experimental analysis of applicability of sill with different widths on the gate discharge coefficients. *Water Supply*, 22 (10), pp.7767-7781. DOI: <https://doi.org/10.2166/ws.2022.354>
3. Alhamid, A.A., 1999. Coefficient of discharge for free flow sluice gates. *Journal of King Saud University - Engineering Sciences*, 11 (1), pp.33-47. DOI: [https://doi.org/10.1016/S1018-3639\(18\)30989-9](https://doi.org/10.1016/S1018-3639(18)30989-9)
4. Salmasi, F. and Norouzi Sarkarabad, R., 2018. Investigation of different geometric shapes of sills on discharge coefficient of vertical sluice gate. *Amirkabir Journal of Civil Engineering*, 52 (1), 2-2 Doi: 10.22060/ceej.2018.14232.5596. DOI: <https://doi.org/10.22060/ceej.2018.14232.5596>
5. Karami, S. Heidari, M.M. and Adib Rad, M.H., 2020. Investigation of free flow under the sluice gate with the sill using flow-3D model. *Iran J Sci Technol Trans Civ Eng*, 44, pp.317-324. DOI: <https://doi.org/10.1007/s40996-019-00310-x>
6. Salmasi, F. and Abraham, J., 2020. Prediction of discharge coefficients for sluice gates equipped with different geometric sills under the gate using multiple non-linear regression (MNL). *Journal of Hydrology*, 597, 125728. DOI: <https://doi.org/10.1016/j.jhydrol.2020.125728>
7. Ghorbani, M.A. Salmasi, F. Saggi, M.K. Bhatia, A.S. Kahya, E. and Norouzi, R., 2020. Deep learning under H₂O framework: A novel approach for quantitative analysis of discharge coefficient in sluice gates. *Journal of Hydroinformatics*, 22 (6), pp.1603-1619. DOI: <https://doi.org/10.2166/hydro.2020.003>
8. Daneshfaraz, R. Norouzi, R. Abbaszadeh, H. Kuriqi, A. and Di Francesco, S., Influence of sill on the hydraulic regime in sluice gates: An experimental and numerical analysis. *Fluids*, 7 (7), 244. DOI: <https://doi.org/10.3390/fluids7070244>
9. Lauria, A. Calomino, F. Alfonsi, G. and D'Ippolito, A., 2020. Discharge Coefficients for Sluice Gates Set in Weirs at Different Upstream Wall Inclinations. *Water*, 12 (1), 245. DOI: <https://doi.org/10.3390/w12010245>
10. Raju, R., 1984. Scale Effects in Analysis of Discharge Characteristics of Weir and Sluice Gates; Kobus: Esslingen am Neckar, Germany.
11. Vapnik. VN., 1995. *The Nature of Statistical Learning Theory*, Springer-Verlag, New York.
12. Jahed Armaghani, D. Asteris, P.G. Askarian, B. Hasanipanah, M. Tarinejad, R. and Huynh, V.V., 2020. Examining hybrid and single SVM models with different kernels to predict rock brittleness. *Sustainability*, 12 (6), 2229. DOI: <https://doi.org/10.3390/su12062229>
13. Su, M.Y., 2011. Real-Time anomaly detection systems for denial-of-service attacks by weighted K-nearest neighbor classifiers. *Expert Systems with Applications*, 38, pp.3492-3498. DOI: <https://doi.org/10.1016/j.eswa.2010.08.137>
14. Al-Bulushi, N.I. King, P.R. Blunt, M.J. and Kraaijeveld, M., 2010. Artificial neural networks workflow and its application in the petroleum industry. *Neural Comput. Appl*, 21, pp.409-421. DOI: <https://doi.org/10.1007/s00521-010-0501-6>
15. Mohammed, A.Y. and Sharifi, A., 2020. Gene Expression Programming (GEP) to predict coefficient of discharge for oblique side weir. *Appl Water Sci*, 10, 145. DOI: <https://doi.org/10.1007/s13201-020-01211-5>
16. Gupta, H.V. Kling, H. Yilmaz, K.K. and Martinez, G.F., 2009. Decomposition of the mean squared error and NSE performance criteria: Implications for improving hydrological modelling. *J. Hydrol*, 377 (1-2), pp.80-91. DOI: <https://doi.org/10.1016/j.jhydrol.2009.08.003>