

جغرافیا و توسعه شماره ۴۹ زمستان ۱۳۹۶

وصول مقاله : ۱۳۹۵/۰۱/۱۸

تأیید نهایی : ۱۳۹۶/۰۶/۰۶

صفحات : ۱۲۹-۱۴۲

مقایسه عملکرد مدل درختی M5 با مدل‌های شبکه عصبی مصنوعی و ماشین بردار پشتیبان در استخراج منحنی تداوم جریان مطالعه موردی: ایستگاه خزانگاه رودخانه ارس

دکتر قربان مهتابی^{۱*}، فاطمه بیات^۲

چکیده

یکی از مهم‌ترین و پرکاربردترین علائم پاسخ هیدرولوژیک حوزه، منحنی تداوم جریان است و در کاربردهای هیدرولوژیکی بی‌شماری برای آنالیز فراوانی جریان‌های کمینه و سیلاب مورد استفاده قرار می‌گیرد. برای نمایش محدوده کامل دبی رودخانه، از جریان‌های حداقل تا حداکثر سیلاب و منحنی تداوم جریان (FDC) استفاده می‌شود؛ بنابراین استخراج دقیق این منحنی‌ها با حداقل خطا حائز اهمیت فراوانی است. در این مطالعه کارایی مدل درختی M5 در استخراج منحنی تداوم جریان در مقایسه با شبکه عصبی مصنوعی و ماشین بردار پشتیبان برای ایستگاه خزانگاه رودخانه ارس واقع در استان آذربایجان شرقی بررسی شد. با توجه به نتایج به دست آمده در مدل درختی M5، ترکیب ۸۰٪ داده‌ها برای آموزش و مابقی برای تست مدل، بهترین عملکرد را در ارائه منحنی تداوم جریان با $R^2=0/992$ ، $RMSE=5/47(m^3/s)$ و $MAE=4/38(m^3/s)$ نشان داد. با بررسی نتایج مدل‌های مختلف شبکه عصبی، بهترین مدل با ۲ نرون برای لایه مخفی با مقادیر $R^2=0/997$ ، $RMSE=3/91(m^3/s)$ و $MAE=3/30(m^3/s)$ به دست آمد. بررسی عملکرد کرنل RBF مدل ماشین بردار پشتیبان نشان داد که این مدل بهترین عملکرد را در شبیه‌سازی منحنی تداوم جریان داشت؛ به طوری که دارای حداقل مقدار مجذور میانگین مربع‌های خطا ($RMSE=2/98(m^3/s)$)، بالاترین ضریب همبستگی ($R^2=0/998$) و کمترین مقدار خطای نسبی ($MAE=2/66(m^3/s)$) بود. مقایسه نتایج بین انواع مدل‌های هوشمند مورد بررسی، بیانگر این است که هر سه مدل در تخمین مقادیر دبی منحنی تداوم جریان عملکرد مناسبی دارند؛ اما مدل درختی M5 به علت سادگی محاسبات و ارائه روابط شده، به لحاظ کاربردی قابلیت بیشتری می‌تواند در استخراج منحنی تداوم داشته باشد. کلیدواژه‌ها: تداوم، دبی جریان، رودخانه ارس، مقدار خطا، مدل‌های هوشمند.

مقدمه

منحنی تداوم جریان^۱ یکی از مهمترین علائم پاسخ هیدرولوژیک حوزه است که در مطالعات مختلف منابع آب جهت آنالیز فراوانی جریان‌های کمینه و بیشینه سیلاب مورد استفاده قرار می‌گیرد. این منحنی از رسم تجمعی دبی رودخانه نسبت به زمان و یا برحسب احتمال وقوع به دست می‌آید و می‌تواند برای مقایسه رژیم‌های جریان حوضه‌های مختلف مورد استفاده قرار گیرد. منحنی تداوم جریان، صدک‌هایی را که یک جریان روزانه یا ماهانه (یا دیگر گام‌های زمانی) از مقداری مشخص تجاوز می‌کند، ارائه می‌دهد. شکل و تفسیر عمومی هر منحنی تداوم جریان، بستگی به مشخصات هیدرومتری و دوره آماری دارد (Smakhtin, 2001: 165).

این منحنی برای تعیین رژیم آبدهی یک رودخانه ابزار توانمندی است و توزیع جریان را بدون توجه به تناوب رخداد آن مشخص می‌کند. بررسی منحنی تداوم جریان و تعیین دبی‌های شاخص (مانند دبی‌نرمال، دبی‌میانه) در برنامه‌ریزی‌های آب رودخانه برای استفاده‌های شرب و یا احداث بندهای انحرافی برای کشاورزی حائز اهمیت است.

بررسی تحقیقات پیشین نشان می‌دهد، مطالعات محدودی در زمینه روش‌های استخراج دقیق منحنی تداوم جریان انجام گرفته است. نخستین مطالعه جامع بر روی منحنی تداوم جریان توسط محقق به نام سارسی انجام گرفت (Searcy, 1959: 17). واگل و فنسی پیشنهاد کردند که منحنی تداوم جریان برای هر سال جداگانه استخراج شود و سپس میانگین هر شاخص جداگانه محاسبه شود. این حالت بیانگر آن است که یک منحنی، کمتر متأثر از نوسانات دوره رکورد است (Vogel and Fennessey, 1994: 501). پاتل در مطالعه‌ای به ارزیابی روش‌های تخمین جریان

کم برای حوضه‌های فاقد آمار با استفاده از مدل‌های رگرسیونی پرداخت. نتایج نشان داد که یک مدل رگرسیونی ساده برای تخمین جریان کم کفایت می‌کند، به طوری که اثر ترتیب شاخص جریان کم مهمترین پارامتر می‌باشد (Patel, 2007: 41). استفاده از منحنی تداوم جریان در مطالعات مختلف منابع آب از قبیل تحلیل سازه‌های انحراف آب رودخانه (Pitman, 1993: 445)، طراحی نیروگاه‌های برق آبی (Warnick, 1984: 59) استحصال و مدیریت منابع آب (Suresh et al, 2003: 25) و ارزیابی توان اکولوژیکی رودخانه (Booker & Dunbar, 2004: 167) گزارش شده است. همچنین در خصوص استفاده از منحنی تداوم جریان در تحقیقات داخل کشور می‌توان به ناحیه‌بندی شاخص‌های جریان کم و تعیین دوره‌های خشکسالی (اسلامیان و همکاران، ۱۳۹۱: ۱)، تحلیل وضعیت جریان‌های رودخانه با استفاده از شاخص خشکسالی هیدرولوژیکی - زیست‌محیطی (اسلامی و شکوهی، ۱۳۹۲: ۱۲۹) و پهنه‌بندی جریان‌های حداقلی و تهیه نقشه پهنه‌بندی خشکسالی هیدرولوژیکی (شماعی‌زاده و سلطانی، ۱۳۹۳: ۲۳۱) اشاره کرد.

با توجه به اهمیت تعیین دبی ورودی مخازن و پیش‌بینی دبی سیل، مدل‌های پیش‌بینی جریان بسیار مورد توجه قرار دارند. برای پیش‌بینی جریان رودخانه، استفاده از مدل‌های آماری، هیدرولیکی و هیدرولوژیکی از سابقه نسبتاً طولانی برخوردار است. در سال‌های اخیر، رویکرد به تئوری‌های مجموعه فازی، شبکه عصبی و سایر مدل‌های هوشمند به عنوان فناوری‌های جدید و ابزاری توانمند در مدل‌سازی و پیش‌بینی فرایندهای هیدرولوژیکی افزایش یافته است. از جمله از روش‌های هوشمند، می‌توان به مدل درخت تصمیم‌گیری^۲، شبکه عصبی مصنوعی^۳، شبکه عصبی بیزین^۴، ماشین بردار

2-Decision Tree Model (M5)
3-Artificial Neural Network
4-Bayesian Neural Network

1-Flow Duration curve

رسوب معلق رودخانه (Cimen, 2008: 656) برآورد جریان ساعتی ورودی به مخزن سد (Lin et al, 2009: 17)، تخمین سطح آبی‌رزمینی (Behzad et al, 2010: 1943) و مدل‌سازی تبخیر و تعرق مرجع (Kisi, 2012: 611) اشاره کرد.

مروری بر تحقیقات گذشته نشان می‌دهد که در زمینه مطالعه عملکرد انواع روش‌های هوشمند در استخراج منحنی تداوم جریان، مطالعه قابل‌ذکری انجام نگرفته است؛ بنابراین هدف این تحقیق بررسی کارایی مدل‌های شبکه عصبی مصنوعی، مدل درختی M5 و ماشین بردار پشتیبان در شبیه‌سازی و پیش‌بینی منحنی تداوم می‌باشد.

مواد و روش‌ها

معرفی ایستگاه مورد مطالعه

در این تحقیق از مقادیر دبی‌های لحظه‌ای جریان ایستگاه خزانگاه رودخانه ارس واقع در استان آذربایجان شرقی از سال ۱۳۸۱ تا ۱۳۸۸ استفاده شد. رودخانه ارس از کوه‌های بینگول منطقه آناتولی ترکیه سرچشمه گرفته و پس از طی مرزهای مشترک ایران، ترکیه و ارمنستان، در منتهی‌الیه شمال استان اردبیل (شهرستان پارس‌آباد) وارد جمهوری آذربایجان شده و به دریای خزر می‌ریزد. طول تقریبی رودخانه ارس ۱۰۷۲ کیلومتر است و سد مخزنی ارس در فاصله ۴۰ کیلومتری شمال‌غربی شهر جلفا قرار دارد. ایستگاه خزانگاه نیز در پایین‌دست سد مخزنی ارس در ارتفاع ۷۴۶ متر از سطح دریا احداث شده و دارای مختصات جغرافیایی ۴۵ درجه و ۲۴ دقیقه طول شرقی و ۳۹ درجه و ۰۵ دقیقه عرض شمالی است. این ایستگاه به لحاظ طول سال آماری و کیفیت داده‌ها نسبت به ایستگاه‌های مجاور، مناسب‌ترین ایستگاه هیدرومتری می‌باشد. در شکل ۱ موقعیت ایستگاه خزانگاه ارائه شده است.

پشتیبان^۱، برنامه‌ریزی بیان ژن^۲، برنامه‌ریزی ژنتیک^۳ اشاره کرد. هر یک از این روش‌ها با توجه به قابلیت‌ها و محدودیت‌های موجود، در انواع زمینه‌های علوم مهندسی آب به کار رفته‌اند. روش‌های مدل درختی M5 بر مبنای رگرسیونی خطی، شبکه عصبی مصنوعی و ماشین بردار پشتیبان در موضوعات مختلف مهندسی آب مورد استفاده محققان قرار گرفته است؛ از جمله تحقیقات انجام یافته با مدل درختی M5 می‌توان به مطالعات پیش‌بینی سیلاب سالانه (Kumar et al, 2002: 224)، مدل کردن رابطه دبی-اشل (Bhattacharya & Solomatine, 2005: 301) پیش‌بینی جریان کم رودخانه (Stravs & Brilly, 2007: 466) برآورد تبخیر-تعرق پتانسیل (Pal & Deswal, 2009: 1437) و تخمین ضریب تشتک تبخیر (Ditthakit & Chinnarasi, 2012: 95) شبیه‌سازی دبی جریان در مقاطع مربع (ظهیری و خلیلی، ۱۳۹۲: ۱۱۳) و پیش‌بینی مقادیر بارش ماهانه (ستاری و همکاران، ۱۳۹۳: ۲۴۷) اشاره کرد.

از کاربردهای شبکه عصبی مصنوعی در مطالعه پدیده‌های هیدرولوژیکی می‌توان به برآورد بار رسوب جریان (Zhou, et al, 2007: 111)، بررسی بارش‌های موسمی درازمدت (Hakurta, 2008: 93)، پیش‌بینی خشکسالی (Sattari et al, 2011: 7)، تخمین دبی روزانه رودخانه (Sattari et al, 2013: 233)، برآورد مقدار تبخیر و تعرق مرجع (عصاری و همکاران، ۱۳۸۸: ۱۰۷؛ صیادی و همکاران، ۱۳۸۸: ۴)، پیش‌بینی جریان رودخانه (زارع‌زاده و مهریزی و بزرگ‌حداد، ۱۳۸۹: ۹۴۲) و برآورد رسوب معلق (شیخعلی‌پور و همکاران، ۱۳۹۴: ۴۱) اشاره کرد. همچنین در زمینه کاربرد ماشین بردار پشتیبان در علوم مهندسی آب می‌توان به مدل‌سازی رواناب (Bray and Han, 2004: 265)، پیش‌بینی بار



شکل ۱: موقعیت ایستگاه خزانگاه در پایین دست سد مخزنی ارس

تهیه و ترسیم: نگارندگان، ۱۳۹۵

– شبکه عصبی مصنوعی

شبکه‌های عصبی مصنوعی^۱ جزو سیستم‌های دینامیکی می‌باشند. با تجزیه و تحلیل داده‌های ورودی و نتایج نظیر آن‌ها و بدون در نظر گرفتن فرایند فیزیکی حاکم بر سیستم، قادر به ایجاد رابطه بین متغیر وابسته و مستقل است. سپس با استفاده از این ارتباط منطقی، کار شبیه‌سازی را برای موارد احتمالی مشابه انجام می‌دهد (کوچک‌زاده و بهمنی، ۱۳۸۴: ۸۰). مدل‌های ANN اغلب توسط توپولوژی شبکه، خواص گره‌ها و قوانین آموزش و یادگیری مشخص می‌شوند. کاربردی‌ترین نوع شبکه‌های عصبی مصنوعی، شبکه‌های پرسپترون چند لایه^۲ با قانون یادگیری پس‌انتشار پیش‌خور^۳ می‌باشد که در این تحقیق نیز از این نوع شبکه استفاده شده است. به‌طور کلی ساختار شبکه‌های عصبی پرسپترون چند لایه (MLP)، از سه لایه ورودی، خروجی و پنهان تشکیل یافته است که برای معماری شبکه در هر لایه تعدادی نرون در نظر گرفته می‌شود. تعداد نرون‌های موجود در لایه‌های ورودی و خروجی با توجه به ماهیت مسأله

مورد بررسی مشخص می‌شود؛ درحالی که تعداد نرون‌های موجود در لایه‌های پنهان و همچنین تعداد این لایه‌ها، با سعی و خطا در جهت کاهش مقدار خطا توسط طراح مشخص می‌شود (Moghaddammia et al, 2009: 91)

– مدل درختی M5

اولین بار مدل درختی توسط کوئینلان بر اساس روش طبقه‌بندی درختی برای ایجاد رابطه بین متغیرهای مستقل و وابسته ارائه شد (Quinlan, 1992: 343). مدل M5 یک مدل درختی برای پیش‌بینی صفات عددی پیوسته است که در آن توابع رگرسیونی خطی ساده و قابل فهم در برگ‌های این درخت ظاهر می‌شوند. این مدل در سال‌های اخیر تحول قابل توجهی در مسائل طبقه‌بندی و پیش‌بینی ایجاد کرده است (Pal & Deswal, 2009: 1439). یک درخت تصمیم معمولاً از چهار بخش ریشه، شاخه، گره‌ها و برگ‌ها تشکیل شده است. این درخت به منظور سادگی در رسم معمولاً از چپ به راست و یا از بالا به پایین کشیده می‌شود؛ به‌طوری‌که ریشه (گره اول) در بالا قرار می‌گیرد. انتهای یک زنجیره را برگ می‌نامند

1-Artificial Neural Networks

2-Multi-Layer Perceptron

3-Feed-Forward Back Propagation

در این تحقیق جهت مدل‌سازی روش مدل درختی M5 از نرم‌افزار WEKA^۱ که در دانشگاه Waikato نیوزلند توسعه داده شده، استفاده شد.

– ماشین بردار پشتیبان

مفهوم اولیه‌ی ماشین‌های بردار پشتیبان (SVM) اولین بار توسط محقق روسی به نام واپنیک در سال ۱۹۹۵ مطرح شد. این مفهوم روش جدیدی را بر مبنای طبقه‌بندی ارائه می‌دهد و یکی از ویژگی‌های آن طراحی دسته‌بندی‌کننده با حداکثر تعمیم است (Borges, 1998: 131). 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 می‌شود. در مدل رگرسیون SVM تابعی مرتبط با متغیر وابسته Y که خود تابعی از چندمتغیر مستقل X است، برآورد می‌شود (Gunn, 1998: 1305). تابع رگرسیونی SVM به فرم زیر است:

$$Y = \text{sign} \left(\sum_{i=1}^N y_i \alpha_i K(X, X_i) + b \right) \quad (3)$$

که در آن Y خروجی معادله، y_i ارزش طبقه نمونه آموزشی X_i ، ضریب لاگرانژ، بردار X نشان‌دهنده داده ورودی، X_i بردار ضرائب، b (ثابت) مشخصه تابع رگرسیونی و $K(X, X_i)$ تابع کرنلی است که برای ایجاد ماشین‌هایی با انواع مختلفی از سطوح تصمیم‌گیری غیرخطی در فضای داده‌ها، ضرب داخلی تولید می‌کند (کاکایی‌فدانی و همکاران، ۱۳۹۲: ۲۹۲). می‌توان توابع کرنل مختلف شامل Linear, Polynomial, Radial Basis Function (RBF) و Exponential را برای ساخت انواع مختلف SVM رگرسیونی به کار برد. البته در مطالعات هیدرولوژی عمدتاً از کرنل تابع پایه شعاعی (RBF) استفاده می‌شود (Lin et al, 2009: 27; Nouri et al, 2011: 188).

و هر گره مربوط به یک خصوصیت معین است و شاخه‌ها به معنای بازه‌ای از مقادیر هستند. عمل انشعاب توسط یکی از متغیرهای پیش‌بینی‌کننده انجام می‌پذیرد و بازه‌های انشعاب طوری انتخاب می‌شوند که مجموع مجذور انحراف از میانگین داده‌های هر گره را حداقل کنند (ستاری و همکاران، ۱۳۹۱: ۲۵۰). معیار انشعاب برای الگوریتم M5 بر اساس عملکرد انحراف استاندارد مقادیر هر کلاس و یا طبقه است که در هر گره به دست آمده است (Quinlan, 1992: 346). فرمول محاسبه کاهش انحراف استاندارد (SDR) به صورت روابط ۱ و ۲ می‌باشد:

$$SDR = Sd(T) - \sum_{i=1}^N \frac{|T_i|}{|T|} Sd(T_i) \quad (1)$$

$$Sd(T) = \sqrt{\frac{1}{N} \left(\sum_{i=1}^N y_i^2 - \frac{1}{N} \left(\sum_{i=1}^N y_i \right)^2 \right)} \quad (2)$$

در این روابط T مجموعه‌ای از نمونه‌هاست (موارد) که به هر گره وارد می‌شود، T_i نشان‌دهنده زیر مجموعه‌ای از نمونه‌هاست که i امین نتیجه آزمون پتانسیلی را دارند؛ S_d بیانگر انحراف معیار؛ y_i مقدار عددی ویژگی هدف نمونه i و N شماره داده‌ها را نشان می‌دهد. فرایند انشعاب در هر گره بارها تکرار می‌شود تا به گره پایانی (برگ) برسد که در برگ، مجموع مجذور انحراف از میانگین داده‌ها حدوداً به صفر می‌رسد. با این کار درخت بزرگی توسعه پیدا خواهد کرد و برای رسیدن به یک درخت بهینه و کارآمد، شاخه‌های اضافی درخت هرس می‌شود. پس از هرس کردن، پروسه صاف کردن برای جبران گسیختگی‌های تند اجتناب‌ناپذیر بین مدل‌های خطی هم‌جوار در برگ‌های درخت هرس شده انجام می‌شود (Bhattacharya & Solomatine 2005: 384).

نتایج و بحث

در این تحقیق عملکرد مدل‌های شبکه عصبی مصنوعی، ماشین بردار پشتیبان و مدل درختی M5 در برآورد منحنی تداوم جریان مورد بررسی قرار گرفت. با توجه به اینکه عمدتاً هدف از استخراج منحنی تداوم جریان، تعیین دبی‌ها با فراوانی وقوع معین است، بنابراین فراوانی تجمعی وقوع دبی‌ها به عنوان پارامتر مستقل و دبی جریان به عنوان پارامتر وابسته در نظر گرفته شد. برای ارزیابی دقت شبیه‌سازی هر کدام از روش‌ها، از آماره‌های مقادیر خطا استفاده شد. این مقادیر بر اساس مقایسه مقادیر بین داده‌های محاسباتی و داده‌های مشاهداتی محاسبه می‌شود. معیارهای ارزیابی مورد استفاده شامل مقادیر ضریب همبستگی (رابطه ۴)، مجذور میانگین مربعات خطا (رابطه ۵) و میانگین خطای مطلق (رابطه ۶) بود:

در این تحقیق عملکرد مدل‌های شبکه عصبی مصنوعی، ماشین بردار پشتیبان و مدل درختی M5 در برآورد منحنی تداوم جریان مورد بررسی قرار گرفت. با توجه به اینکه عمدتاً هدف از استخراج منحنی تداوم جریان، تعیین دبی‌ها با فراوانی وقوع معین است، بنابراین فراوانی تجمعی وقوع دبی‌ها به عنوان پارامتر مستقل و دبی جریان به عنوان پارامتر وابسته در نظر گرفته شد. برای ارزیابی دقت شبیه‌سازی هر کدام از روش‌ها، از آماره‌های مقادیر خطا استفاده شد. این مقادیر بر اساس مقایسه مقادیر بین داده‌های محاسباتی و داده‌های مشاهداتی محاسبه می‌شود. معیارهای ارزیابی مورد استفاده شامل مقادیر ضریب همبستگی (رابطه ۴)، مجذور میانگین مربعات خطا (رابطه ۵) و میانگین خطای مطلق (رابطه ۶) بود:

$$R^2 = \frac{(\sum(xi - \bar{x})(yi - \bar{y}))^2}{\sum(xi - \bar{x})^2 \sum(yi - \bar{y})^2} \quad ۴:$$

$$RMSE = \frac{\sum(yi - xi)^2}{n} \quad ۵:$$

$$MAE = \frac{\sum(yi - xi)}{n} \quad ۶:$$

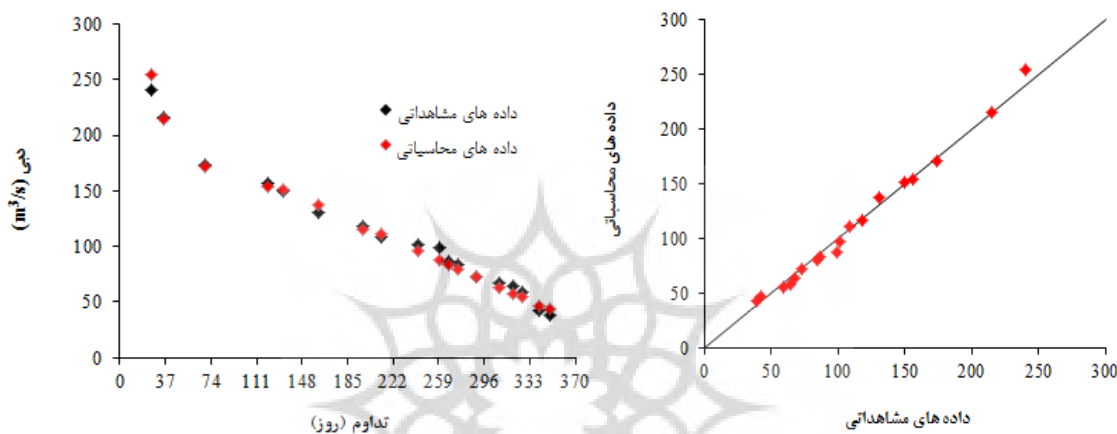
بر اساس نتایج جدول ۱، مدل درختی M5 با سناریوی ۸۰ داده‌ها برای آموزش و مابقی داده‌ها برای ارزیابی مدل، بهترین عملکرد را در شبیه‌سازی منحنی تداوم جریان داشت، به طوری که دارای حداقل مجذور میانگین مربع‌های خطا ($RMSE = ۵/۴۷ m^3/s$) و بالاترین ضریب همبستگی ($R^2 = ۰/۹۹۲$) و کمترین میانگین خطای مطلق ($MAE = ۴/۳۸ m^3/s$) بود. در شکل ۲ مقایسه داده‌های مشاهداتی و محاسباتی توسط مدل درختی M5 و در شکل ۳ پراکنش داده‌های مشاهداتی و محاسباتی نسبت به خط $y=x$ ارائه شده است. همان‌طور که مشاهده می‌شود، مدل درختی M5 عملکرد خوبی در برازش دبی‌های محدوده کم تا بالا (دبی‌های مشخصه رودخانه) دارد.

در روابط بالا، x_i مقادیر داده‌های مشاهداتی، y_i مقادیر داده‌های محاسباتی، \bar{x} میانگین داده‌های مشاهداتی، \bar{y} میانگین داده‌های محاسباتی و n تعداد داده‌ها است. در این تحقیق برای آماده‌سازی و اجرای شبیه‌سازی و تهیه خروجی مدل شبکه عصبی مصنوعی و ماشین بردار پشتیبان از محیط نرم‌افزار MATLAB و Excel استفاده شد.

جدول ۱: نتایج شاخص‌های آماری مدل درختی M5 با سناریوهای مختلف

شاخص آماری	سناریو		
	۷۰ درصد برای آموزش	۷۵ درصد برای آموزش	۸۰ درصد برای آموزش
ضریب همبستگی (R^2)	۰/۶۸	۰/۶۵	۰/۹۹
میانگین خطای مطلق (m^3/s)	۲۰/۶۱	۲۴/۶۹	۴/۳۸
مجذور میانگین مربعات خطا (m^3/s)	۸۱/۱۸	۹۱/۷۸	۵/۴۷

مأخذ: مطالعات میدانی نگارندگان، ۱۳۹۵



شکل ۲: پراکنش داده‌های مشاهده‌ای و محاسباتی
نسبت به خط $y=x$

شکل ۲: مقایسه داده‌های مشاهده‌ای و محاسباتی
توسط مدل M5

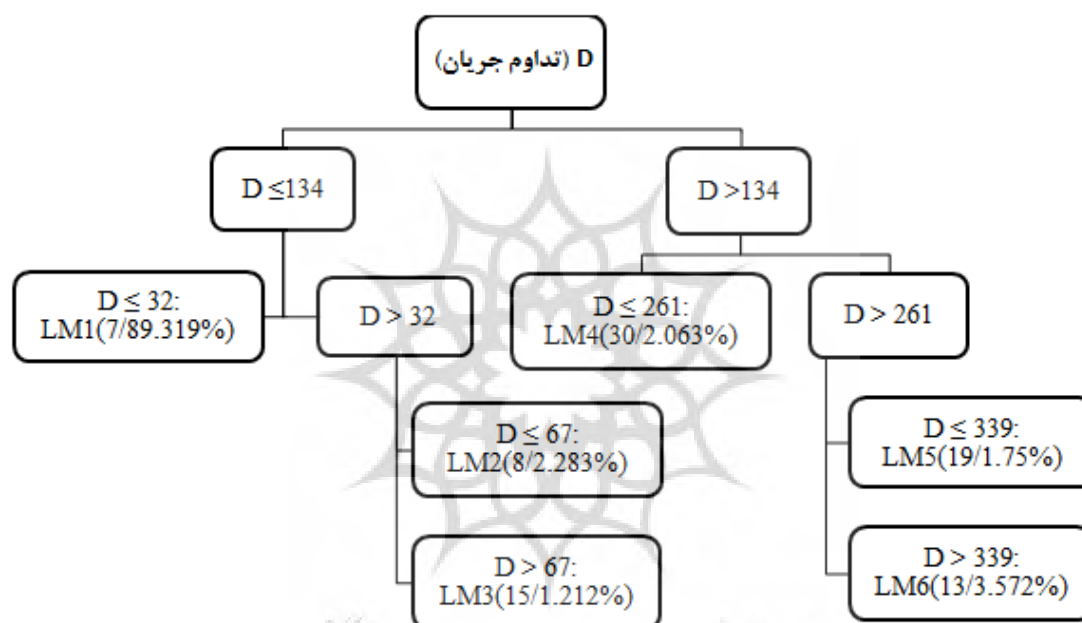
تهیه و ترسیم: نگارندگان، ۱۳۹۵

۲۶۱ روز بیانگر شاخص Q_{70} یا دبی $91 m^3/s$ است که این مقدار آستانه ورود به دوره خشکسالی این رودخانه را نشان می‌دهد (اسلامی و شکوهی، ۱۳۹۲: ۱۲۹). همچنین عدد ۳۳۹ در انتهای مدل درختی نشان‌دهنده آن است که تقریباً در طول یازده ماه از سال، دبی‌های $50 m^3/s$ و بیشتر از آن در رودخانه ارس تداوم داشته است. این مقدار دبی به عنوان شاخص Q_{95} ، حق‌آبه زیست‌محیطی (Shaeri Karimi 549: 2012) یا جریان پایه رودخانه ارس (کازمی و قرمزچشمه، ۱۳۹۵: ۱۳۸) را نشان می‌دهد. در زیرشاخه سمت چپ مدل درختی نیز، تداوم ۳۲ و ۶۷ روز به ترتیب نشان‌دهنده تقریبی شاخص Q_{10} و Q_{20} می‌باشند. در مدل درختی M5، با توجه با ارائه رابطه برای بازه‌های مختلف فراوانی، می‌توان مقادیر دیگر دبی‌های مشخصه رودخانه را محاسبه کرد؛ به عنوان

در شکل ۴ ساختار بهترین مدل درختی M5 برای تعیین دبی رودخانه به ازای تداوم جریان مورد نظر و در جدول ۲ روابط خطی بهترین مدل درختی M5 برای محاسبه دبی ارائه شده است (Q دبی جریان بر حسب m^3/s و D تداوم جریان بر حسب روز است). بر اساس نتایج مدل درختی، رودخانه ارس دارای ۶ رژیم تداوم جریان یا تغییرات دبی رودخانه‌ای است. مطابق شکل ۴، تداوم ۱۳۴ روز به عنوان ریشه توسعه مدل درختی قرار دارد. این بدین معنی است که در ۱۳۴ روز از سال معادل ۴/۵ ماه از سال، دبی‌های $140 m^3/s$ و بیشتر از آن تداوم داشته است. این مقدار دبی (Q_{27}) که برابر با ۷۵ درصد دبی نرمال رودخانه (دبی مشخصه ۶ ماه) است، تقریباً آستانه ترسالی جریان رودخانه را نشان می‌دهد (اسلامی و شکوهی، ۱۳۹۲: ۱۲۹). در زیرشاخه سمت راست مدل درختی، تداوم

سالانه رودخانه استفاده می‌شود (مهروی، ۱۳۹۲: ۱۴۲). روش درختی این امکان را فراهم می‌سازد تا برای شرایط و بازه‌های متفاوتی از متغیرهای مستقل، قوانین مجزا تولید کرده و به ازای هر قانون یک رابطه خطی برای محاسبه پارامتر هدف ارائه می‌کند (ستاری و همکاران، ۱۳۹۲: ۱۰۷).

مثال دبی نرمال در حالت کم‌آبی (مقداری که در ۲۷۴ روز از سال دبی رودخانه مساوی یا بالاتر از آن باشد)، با استفاده از مدل خطی شماره پنج (جدول ۲) برابر با ۸۱/۵۶ (m^3/s) به دست می‌آید. همچنین دبی مشخصه ماکزیمم (مقدار دبی که ۱۱ روز در سال دبی از آن بیشتر باشد) برابر با ۳۳۰/۵۳ (m^3/s) به دست می‌آید که این مقدار به عنوان دبی طغیان معمولی



شکل ۴: ساختار بهترین مدل درختی M5 برای تعیین دبی جریان به ازای تداوم مورد نظر

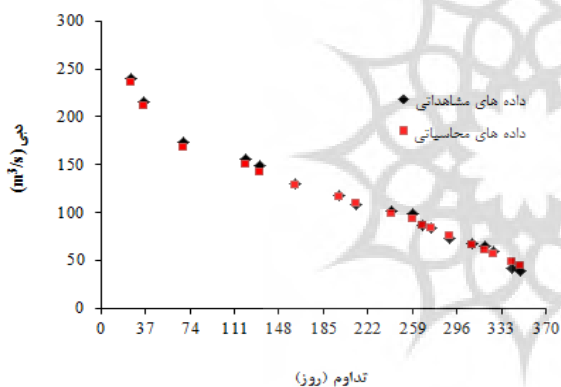
تهیه و ترسیم: نگارندگان، ۱۳۹۵

جدول ۲: روابط خطی بهترین مدل درختی M5 برای محاسبه دبی رودخانه برحسب تداوم جریان

شماره مدل خطی	رابطه ارائه شده
LM num:1	$Q = (-4.7390 \times D) + 382.4847$
LM num:2	$Q = (-1.0311 \times D) + 272.6697$
LM num:3	$Q = (-0.9275 \times D) + 263.8931$
LM num:4	$Q = (-0.4347 \times D) + 204.5758$
LM num:5	$Q = (-0.4900 \times D) + 215.8217$
LM num:6	$Q = (-0.3857 \times D) + 175.7024$

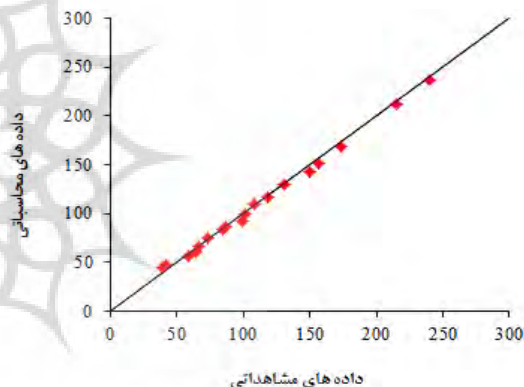
مأخذ: مطالعات میدانی نگارندگان، ۱۳۹۵

جهت پیش‌بینی مقادیر دبی مورد استفاده قرار گرفت. بهترین سناریوی شبکه عصبی مصنوعی به صورت ۲ نرون برای لایه مخفی با مقدار R^2 و RMSE و MAE به ترتیب برابر با ۰/۹۹۷ و $3/91 (m^3/s)$ و $3/30$ انتخاب شد. در شکل ۵ مقایسه داده‌های مشاهداتی و محاسباتی منحنی تداوم جریان توسط مدل شبکه عصبی و در شکل ۶ پراکنش داده‌های مشاهداتی و محاسباتی نسبت به خط $y=x$ ارائه شده است. همانطور که مشاهده می‌شود، مدل شبکه عصبی محدوده دبی‌های بالا را اندکی کمتر از مقدار واقعی پیش‌بینی کرده است.



شکل ۶: پراکنش داده‌های مشاهداتی و محاسباتی نسبت به خط $y=x$

در مدل شبکه عصبی مصنوعی نیز ابتدا داده‌ها به وسیله نرم‌افزار Kutools for Excel تصادفی شدند. در مدل عصبی مصنوعی مشابه مدل درختی، ۸۰ درصد از داده‌ها برای آموزش شبکه اختصاص داده شد و مابقی داده‌ها برای آزمون عملکرد شبکه آموزش دیده به کار برده شد. نوع شبکه عصبی مورد استفاده Feed-forward back prop انتخاب شد و لایه ورودی شبکه عصبی از یک نرون فراوانی تجمعی روزها و لایه خروجی آن نیز از یک نرون دبی جریان تشکیل شد. در هر مرحله تعداد نرون‌های لایه مخفی افزایش یافت و نتایج حاصل مدل شبکه عصبی مصنوعی مورد ارزیابی گرفت و برترین سناریوی حاصل از این ارزیابی




شکل ۵: مقایسه داده‌های مشاهداتی و محاسباتی توسط مدل شبکه عصبی مصنوعی


تهیه و ترسیم: نگارندگان، ۱۳۹۵

در ماشین بردار پشتیبان همانند مدل‌های قبلی، داده‌ها توسط نرم‌افزار Kutools for Excel تصادفی شدند. ۸۰ درصد از داده‌ها برای آموزش شبکه اختصاص داده شد و مابقی داده‌ها برای آزمون عملکرد شبکه آموزش دیده به کار رفت. در عمده نتایج تحقیقات قبلی با استفاده از مدل ماشین بردار، کرنل RBF در مقایسه با کرنل‌های دیگر این مدل، عملکرد خوبی در پیش‌بینی انواع پدیده‌های هیدرولیکی و هیدرولوژیکی داشته است (Lin et al, 2009: 27; Nouri et al, 2011: 188)؛ بنابراین در این بررسی صرفاً از کرنل

در ماشین بردار پشتیبان همانند مدل‌های قبلی، داده‌ها توسط نرم‌افزار Kutools for Excel تصادفی شدند. ۸۰ درصد از داده‌ها برای آموزش شبکه اختصاص داده شد و مابقی داده‌ها برای آزمون عملکرد شبکه آموزش دیده به کار رفت. در عمده نتایج تحقیقات قبلی با استفاده از مدل ماشین بردار، کرنل RBF در مقایسه با کرنل‌های دیگر این مدل، عملکرد خوبی در پیش‌بینی انواع پدیده‌های هیدرولیکی و هیدرولوژیکی داشته است (Lin et al, 2009: 27; Nouri et al, 2011: 188)؛ بنابراین در این بررسی صرفاً از کرنل



شکل ۸: پراکنش داده‌های مشاهده‌ای و محاسباتی
نسبت به خط $y=x$



شکل ۷: مقایسه داده‌های مشاهده‌ای و محاسباتی
به وسیله مدل ماشین بردار پشتیبان

تهیه و ترسیم: نگارندگان، ۱۳۹۵

آمد. همچنین با کمک روابط منحنی تداوم جریان و استخراج حدود آستانه $Q_{۹۵}$ تا $Q_۷$ ، خشکسالی هیدرولوژیکی حوزه رودخانه تحلیل می‌شود (کریمی و همکاران، ۱۳۹۴: ۵۹ و ۵۵: Bayazidi et al, 2010). روابط مدل M5 در منطقه‌ای کردن منحنی تداوم جریان حوزه‌های بدون آمار (شهنواز و همکاران، ۱۳۹۴: ۲۷؛ زارع‌چاهوکی و همکاران، ۱۳۹۲: ۲۵۱) و صحت‌سنجی مدل هیدرولوژیکی بارش- رواناب (یوسفی و همکاران، ۱۳۹۵: ۱۰۱) نیز قابل استفاده است. با استفاده از روابط مدل M5 و تهیه منحنی سنج‌ رسوب می‌توان متوسط رسوب معلق رودخانه را نیز محاسبه کرد (سپهوند و همکاران، ۱۳۹۱: ۴۱). شایان ذکر است امامی‌فر و رحیمی در برآورد تابش رسیده به سطح زمین (امامی‌فر و رحیمی‌خوب، ۱۳۹۰: ۸)، ظهیری و قربانی در شبیه‌سازی دبی جریان در مقاطع مرکب (ظهیری و قربانی، ۱۳۹۲: ۱۲۸)، ستاری و همکاران در تخمین دبی روزانه رودخانه (Sattari et al, 2013: 233) و اونیاری و ایلونگا در پیش‌بینی دبی رودخانه (Onyari & Ilunga, 2013: 11) بر قابلیت و مزایای بالای مدل درختی M5 تأکید کرده‌اند.

خلاصه نتایج به‌دست آمده از سه مدل مورد بررسی در جدول ۳ ارائه شده است. با بررسی نتایج کلی مدل‌های مورد بررسی می‌توان به این نتیجه رسید که هر سه مدل درختی M5، ماشین بردار پشتیبان و شبکه عصبی مصنوعی عملکرد خوبی در پیش‌بینی دبی‌های منحنی تداوم دارند. مدل ماشین بردار پشتیبان و شبکه عصبی مصنوعی در فرایند شبیه‌سازی و پیش‌بینی، روابطی را ارائه نمی‌دهند؛ اما از جنبه کاربردی، مدل درختی M5 ضمن توانایی قابل قبول در تخمین دبی‌های منحنی تداوم جریان، دارای مزیت سادگی محاسبه‌ها و معادله‌های ارائه شده است (Sattari et al, 2013: 233). به‌عنوان مثال با استخراج $Q_{۹۵}$ الی $Q_۷$ از منحنی تداوم جریان (به ترتیب دبی‌ای که بزرگتر یا برابر ۳۲۹ یا ۳۴۷ روز از سال باشد)، می‌توان حق‌آبه زیست محیطی (Alcazar & Palau, 2010: 48; Shaeri Karimi et al, 2012: 549) یا جریان پایه رودخانه (کازمی و قرمزچشمه، ۱۳۹۵: ۱۳۸) را در حوزه‌های آبخیز دارای آمار و هم بدون آمار تخمین زد. بر این اساس در رودخانه ارس مقدار حق‌آبه زیست‌محیطی برابر $۵۰ \text{ m}^3/\text{s}$ به‌دست

جدول ۳: خلاصه نتایج به دست آمده از سه مدل هوشمند

مدل هوشمند	نوع مدل، تابع یا کرنل	MAE (m ³ /s)	RMSE (m ³ /s)	R ²
درخت تصمیم‌گیری	M5	۳/۸۴	۵/۴۷	۰/۹۹۲
شبکه عصبی مصنوعی	Feed-forward back prop	۳/۳۰	۳/۹۱	۰/۹۹۷
ماشین بردار پشتیبان	RBF	۲/۶۶	۲/۹۸	۰/۹۹۸

مأخذ: مطالعات میدانی نگارندگان، ۱۳۹۵

نتیجه

منابع

- اسلامی، علیرضا؛ علیرضا شکوهی (۱۳۹۲). تحلیل وضعیت جریان رودخانه با اس از شاخص خشکسالی هیدرولوژیکی زیست‌محیطی، نشریه مهندسی و مدیریت آبخیز. شماره ۵ (۲). صفحات ۱۳۳-۱۲۵.
- اسلامیان، سیدسعید؛ محسن قاسمی؛ سمیه سلطانی گردفرامری (۱۳۹۱). محاسبه و ناحیه‌بندی شاخص‌های جریان کم و تعیین دوره‌های خشکسالی هیدرولوژیک (مطالعه موردی: حوضه آبخیز کرخه)، مجله علوم و فنون کشاورزی و منابع طبیعی. شماره ۱۶ (۵۹). صفحات ۱۴-۱.
- امامی‌فر، سعید؛ علی رحیمی‌خوب (۱۳۹۰). ارزیابی مدل درختی M5 و مدل تجربی آنگستروم در برآورد تابش رسیده به سطح زمین، نخستین کنفرانس ملی هواشناسی و مدیریت آب کشاورزی. تهران. ۱ و ۲ آذر. صفحات ۱۰-۱.
- ستاری، محمدتقی؛ فرناز نهرین؛ وحید عظیمی (۱۳۹۲). پیش‌بینی تبخیر- تعرق مرجع روزانه با استفاده از مدل شبکه عصبی مصنوعی و مدل درختی (مطالعه موردی: ایستگاه بناب)، نشریه آبیاری و زهکشی ایران. شماره ۷ (۱). صفحات ۱۱۳-۱۰۴.
- ستاری، محمدتقی؛ علی رضازاده جودی؛ فرناز نهرین (۱۳۹۳). پیش‌بینی مقادیر بارش ماهانه با استفاده از شبکه‌های عصبی مصنوعی و مدل درختی M5 (مطالعه موردی: ایستگاه اهر)، مجله پژوهش‌های جغرافیای طبیعی. شماره ۴۶ (۲). صفحات ۲۶۰-۲۴۷.

ترسیم منحنی تداوم جریان یکی از روش‌هایی است که حاوی بیشترین اطلاعات ارزنده برای نمایش محدوده کامل دبی رودخانه از جریان‌های کمینه تا بیشینه سیلاب است. در این تحقیق، عملکرد سه مدل شبکه عصبی مصنوعی (پرسپترون چند لایه)، ماشین بردار پشتیبان و مدل درختی M5 در استخراج منحنی تداوم و پیش‌بینی مقادیر دبی آب رودخانه ارس مورد بررسی قرار گرفت. در این تحقیق داده‌های دبی لحظه‌ای ایستگاه خزانگاه رودخانه ارس واقع در استان آذربایجان شرقی استفاده شد. بررسی نتایج نشان داد در مدل درختی M5، ترکیب ۸۰ درصد داده‌ها برای آموزش و مابقی برای تست، بهترین عملکرد را در برآورد مقادیر دبی منحنی تداوم دارد ($R^2=0/992$ و $RMSE=5/47 (m^3/s)$ و $MAE=3/84 (m^3/s)$). در مدل شبکه عصبی مصنوعی، در بهترین شبکه آموزش دیده (با ۲ لایه پنهان)، مقدار $R^2=0/997$ ، $RMSE=3/91 (m^3/s)$ و $MAE=3/30 (m^3/s)$ به دست آمد. بررسی عملکرد ماشین بردار پشتیبان با کرنل RBF نشان داد این مدل دارای بالاترین ضریب همبستگی ($R^2=0/998$)، کمترین مجذور میانگین مربع‌های خطا ($RMSE=2/98 m^3/s$) و میانگین خطای مطلق ($MAE=2/66$) بود.

- سپهوند، علیرضا؛ نجمیه عزارخوانی؛ مجید طائی سمیرمی؛ شمس‌اله عسگری (۱۳۹۱). مقایسه روابط تجربی رواناب-رسوب حاصل از منحنی‌های سنجۀ رسوب و شبکۀ عصبی مصنوعی (مطالعه موردی: حوزه آبخیز گدارخوش، استان ایلام)، فصلنامه پژوهش‌های فرسایش طبیعی. شماره ۷. صفحات ۲۹-۴۳.
- شمعی‌زاده، مریم؛ سعید سلطانی (۱۳۹۳). تحلیل فراوانی منطقه‌ای کم در حوضۀ آبخیز کارون شمالی، مجله علوم و فنون کشاورزی و منابع طبیعی علوم آب و خاک. شماره ۱۸ (۷۰). صفحات ۲۴۲-۲۳۱.
- شهناز، یاسر؛ سید فرهاد موسوی؛ آرش ملکیان؛ جعفر دستورانی؛ مسعود سمیعی (۱۳۹۴). تحلیل منطقه‌ای منحنی تداوم جریان برای زیرحوضه‌های فاقد آمار (مطالعه موردی: حوضۀ آبخیز دریاچه نمک)، مجله پژوهش آب ایران. شماره ۹ (۳). صفحات ۳۵-۲۷.
- شیخعلی‌پور، زینب؛ فرزاد حسن‌پور؛ وحید عظیمی (۱۳۹۴). مقایسه روش‌های هوش مصنوعی در برآورد بار معلق رسوب (مطالعه موردی: رودخانه سیستان)، مجله پژوهش‌های حفاظت آب و خاک. شماره ۲۲ (۲). صفحات ۶۰-۴۱.
- صیادی، حبیب؛ ابوالفتح اولادغفاری؛ احد فعالیان؛ سید علی اشرف‌الدین صدرالدینی (۱۳۸۸). مقایسه عملکرد شبکه‌های عصبی RBF و MLP در برآورد تبخیر و تعرق گیاه مرجع، مجله دانش آب و خاک. شماره ۱۹ (۱). صفحات ۱۲-۱.
- ظهیری، عبدالرضا؛ خلیل قربانی (۱۳۹۲). شبیه‌سازی دبی جریان در مقاطع مرکب به کمک مدل درخت تصمیم M5، مجله پژوهش‌های حفاظت آب و خاک. شماره ۲۰ (۳). صفحات ۱۳۲-۱۱۳.
- عساری، مصطفی؛ مهدی کوچک‌زاده؛ مهدی شهابی‌فر؛ کامیار بیات (۱۳۸۸). تخمین تبخیر-تعرق گیاه مرجع درون گل‌خانه با استفاده از شبکه‌های عصبی مصنوعی، مجله پژوهش‌های حفاظت آب و خاک. شماره ۱۶ (۱). صفحات ۱۲۱-۱۰۷.
- کاظمی، رحیم؛ باقر قرمزچشمه (۱۳۹۵). بررسی روش‌های مختلف استخراج جریان پایه با استفاده از شاخص منحنی تداوم جریان (مطالعه موردی: ناحیه خزری)، نشریه پژوهش‌های حفاظت آب و خاک. شماره ۲۳ (۲). صفحات ۱۴۵-۱۳۱.
- کاکایی لعدانی، الهام؛ علیرضا مقدم نیا؛ آزاده احمدی؛ حیدر ابراهیمی (۱۳۹۲). ارزیابی تأثیر پیش پردازش متغیرهای ورودی به مدل ماشین بردار پشتیبان به روش آزمون گاما به منظور پیش‌بینی حجم رسوب معلق، مجله منابع طبیعی ایران. شماره ۶۷ (۲). صفحات ۳۰۳-۲۸۹.
- کریمی، مهشید؛ کاکا شاهدهی؛ مطلب بایزیدی (۱۳۹۴). تحلیل خشکسالی هیدرولوژیکی با روش حد آستانه ثابت (مطالعه موردی: حوزه آبخیز کرخه)، پژوهشنامه مدیریت حوزه آبخیز. شماره ۱۱. صفحات ۷۲-۵۹.
- کوچک‌زاده، مهدی؛ عارف بهمنی (۱۳۸۴). ارزیابی عملکرد شبکه‌های عصبی مصنوعی در کاهش پارامترهای مورد نیاز جهت برآورد تبخیر و تعرق مرجع، مجله علوم کشاورزی. شماره ۱۱ (۴). صفحات ۹۷-۷۸.
- زارع‌زاده‌مه‌ریزی، محبوبه؛ امید بزرگ‌حداد (۱۳۸۹). شبیه‌سازی و پیش‌بینی آبدی با استفاده از الگوریتم ترکیبی ANN-GA، آب و خاک (علوم و صنایع کشاورزی). شماره ۲۴ (۵). صفحات ۹۵۴-۹۴۲.
- زارع‌چاکوکی، اصغر؛ علی سلاجقه؛ محمد مهدوی؛ شهرام خایقی؛ سعید اسدی (۱۳۹۲). مدل منطقه‌ای منحنی تداوم جریان حوزه‌های آبخیز بدون آمار مناطق خشک (مطالعه موردی: ایران مرکزی)، نشریه مرتع و آبخیزداری. شماره ۶۶ (۲). صفحات ۲۶۵-۲۵۱.
- مهدوی، محمد (۱۳۹۲). هیدرولوژی کاربردی، انتشارات دانشگاه تهران، جلد دوم، تهران.
- یوسفی مبرهن، ابراهیم؛ فرحمند کامبخش؛ نفیسه فهیم؛ عماد فهیم (۱۳۹۵). کارایی روش منحنی تداوم جریان در صحت‌سنجی مدل هیدرولوژیکی (مطالعه موردی: حوزه آبخیز زولاچای)، نشریه دانش آب و خاک. شماره ۲۶ (۲/۱). صفحات ۱۱۳-۱۰۱.

- Kisi, O (2012). Least squares support vector machine for modeling daily reference evapotranspiration. *Journal of Irrigation Science*, Vol 31(4), PP: 611-619.
- Kumar, M., Raghuwanshi, N.S., Singh, R., Wallender, W.W., Pruitt, W.O (2002). Estimating evapotranspiration using artificial neural network. *Journal of Irrigation and Drainage Engineering*, Vol 128, PP:224- 233.
- Lin, G.F., Chen, G.R, Huang, P.Y., Chou, Y.C (2009). Support vector machine-based models for hourly reservoir inflow forecasting during typhoon-warning periods. *Journal of Hydrology*, Vol 372, PP: 17-29.
- Moghaddamnia, A., Ghafari Gousheh, M., Piri J., Amin S., Han, D (2009). Evaporation estimation using artificial neural networks and adaptive neurofuzzy inference system techniques. *Advances in Water Resources*, Vol 32, PP: 88-97.
- Nouri, R., Karbassi, A.R., Moghaddamnia, A., Han, D., Zokaei-Ashtiani, M.H. Farokhnia, A. Ghafari Gousheh, M (2011). Assessment of input variables determination on the SVM model performance using PCA, Gamma test, and forward selection techniques for monthly stream flow prediction. *Journal of Hydrology*, Vol 401, PP: 177-189.
- Pal, M., Deswal, S (2009). M5 model tree based modeling of reference evapotranspiration. *Hydrological Process*, (23): 1437-1443.
- Patel, J.A (2007). Evaluation of low flow estimation techniques for ungagged catchments. *Water & Environment Journal*, Vol 21, PP:41-46.
- Pitman, W.V (1993). Simulation of runoff river schemes using monthly data. In *Proceedings of the Sixth South African Hydrology Symposium*, Pietermaritzburg, South Africa, PP: 445-452.
- Quinlan.J. R (1992). Learning with continuous classes. In *proceedings AI*, 92 (Adams & Sterling, Eds), Singapore: World Scientific, PP: 343-348.
- Onyari, E.K., Ilunga F. M (2013). Application of MLP Neural Network and M5P Model Tree in Predicting Streamflow: A Case Study of Luvuvhu Catchment, South Africa. *International Journal of Innovation, Management & Technology*, Vo 14 (1), PP:11-15.
- Alcazar, J., Palau, A (2010). Mediterranean watershed based on a regional classification. *Journal of Hydrology*, Vol 388, PP: 41-51.
- Bayazidi, M., Saghafian, B., Sedghi, H., Kaveh. F (2010). Analysis of hydrological drought in Karoon river basin by daily discharge data. *Watershed Management Researches Journal*, Vol 86, PP: 52-63.
- Behzad, M., Asghari, K., Coppola, E (2010). Comparative study of SVMs and ANNs in aquifer water level prediction. *Journal of Computing in Civil Engineering*, Vol 24(408), PP: 1943-5487.
- Bhattacharya, B., Solomatine, D.P (2005). Neural networks and M5 model trees in modeling water level-discharge relationship *Neurocomputing. European Symposium on Artificial Neural Networks*, Vol 63, PP:381-396.
- Booker, D.J., Dunbar, M.J (2004). Application of physical habitat simulation (PHABSIM) modeling to modified urban river channels. *River Research Application*, Vol 20, PP:167-183.
- Bray, M., Han, D (2004). Identification of support vector machines for runoff modeling. *Journal of Hydroinformatics*, Vol 6(4), PP:265-280.
- Burges, Ch.J.C (1998). A Tutorial on SVM for Pattern Recognition. *Data Mining and Knowledge Discovery*, Vol 2, PP: 121-167.
- Çimen, M (2008). Estimation of daily suspended sediment using support vector machines. *Hydrological Sciences Journal*, Vol 53(3), PP: 656-666.
- Dittthakit, P., Chinnarasri, C.H (2012). Estimation of pan coefficient using M5 model tree. *American journal of environmental sciences*, Vol 8(2), PP: 95-103.
- Gunn S.R (1998). SVM for Classification and Regression". *Faculty of Engineering, School of Science & Mathematics*, Springer. PP:1305-1314.
- Hakurta, P. G (2008). Long lead monsoon rainfall prediction for meteorological sub-divisions of India using deterministic artificial neural network model. *Meteorology and Atmospheric Physic*, Vol 101, PP: 93-108.

- Stravs, L., and Brilly, M (2007). Development of a Low Flow Forecasting Model Using the M5 Machine Learning Method, Journal of Hydrological Sciences, Vol 52(3), PP: 466-477.
- Suresh, Chalise, S. R., Kansakar, G., Rees, K., Croker, M., Zaidman, (2003). Management of Water Resources and Low Flow Estimation for the Himalayan Basins of Nepal. Journal of Hydrology, Vol 282, PP: 25-35.
- Vogel, R. M., Fennessey, N. M (1994). Flow-duration curves, I: New interpretation and confidence intervals. Journal of Water Resource & Planning Management, Vol 120, PP: 485-504.
- Warnick, C. C. (1984). Hydropower Engineering. Prentice-Hall, Inc., Englewood Cliffs, New Jersey. PP: 59-73.
- Zhou, Y., Lu, X. X., Huang, Y. and Zhu, Y. M (2007). Suspended sediment flux modeling with artificial neural network: An example of the Longchuanjiang River in the upper Yangtze catchment China. Geomorphology, Vol 84, PP: 111-125.
- Sattari, M. T., Yurekli, K., Unlukara, A (2011). Drought Prediction by Using Artificial Neural Networks Approach in Karaman Province. Research Journal of Agriculture Sciences, Vol 4(1), PP: 7-13.
- Sattari, M. T., Pal, M. Apaydin, H. Ozturk, F (2013). M5 Model Tree Application in Daily River Flow Forecasting in Sohu Stream, Turkey. Water Resources, Vol 40(3), PP: 233-242.
- Searcy, J. K (1959). Flow-Duration Curves, US Geological Survey Water Supply, Paper 1542-A, P. 33.
- Shaeri Karimi, S., Yasi, M., Eslamian, S. (2012). Uses of hydrological methods for assessment of environmental flow in a river reach. International Journal of Environmental Science and Technology, Vol 9, PP: 549-558.
- Smakhtin, V. U (2001). Low - flow hydrology: a review. Journal of hydrology, Vol 240, PP: 147-186.