

## بهره‌گیری از روش‌های رگرسیون بردار پشتیبان و شبکه عصبی مصنوعی در مدل‌سازی بارش رواناب (مطالعه موردی: حوضه آبریز سد صفارود)

نازنین نجیب زاده<sup>۱</sup>، کورش قادری<sup>۲\*</sup>، محمد مهدی احمدی<sup>۳</sup>

تاریخ دریافت: ۱۳۹۸/۲/۳۰ تاریخ پذیرش: ۱۳۹۸/۴/۲۱

### چکیده

مدل‌سازی بارش رواناب در اکثر پروژه‌های مدیریت و برنامه‌ریزی منابع آب و کنترل سیلاب امری ضروری و پیچیده می‌باشد. در این تحقیق مدل‌هایی برای شبیه‌سازی فرآیند بارش رواناب در زیر حوضه سد صفارود واقع در حوضه آبریز هلیل رود با استفاده از روش‌های شبکه عصبی مصنوعی پرسپترون چند لایه (MLP)، شبکه عصبی تابع شعاع مدار (RBF)، رگرسیون ماشین بردار پشتیبان با توابع کرنل خطی (SVR Linear) و پایه شعاعی (SVR RBF) در محیط نرم‌افزاری IBM SPSS Modeler توسعه داده شده‌است. بدین منظور از داده‌های هیدرومتری ایستگاه هنجان و داده‌های بارش ایستگاه‌های هنجان، رابر، چشمه عروس و میدان واقع در منطقه مورد مطالعه طی دوره آماری ۱۳۹۴-۱۳۸۵ در مقیاس روزانه استفاده شد. ۷۰ درصد داده‌ها به عنوان داده‌های آموزش و ۳۰ درصد آنها به عنوان داده‌های آزمون مورد استفاده قرار گرفت. پس از محاسبه ضرایب همبستگی جزئی متغیرهای بارش و دبی، شش الگوی مختلف جهت مدل‌سازی رواناب روزانه ایستگاه هنجان تعیین شد. مقادیر شاخص‌های آماری متوسط قدر مطلق خطا (MAE)، جذر میانگین مربعات خطا (RMSE) و ضریب همبستگی (r) در بهترین الگو مرحله آزمون به ترتیب برابر ۰/۰۳۲، ۰/۰۲۲۹، ۰/۹۶۷ برای مدل SVR Linear 5 ایستگاه هنجان بدست آمدند. نتایج حاکی از عملکرد مناسب روش‌های MLP و SVR Linear در مدل‌سازی بارش رواناب در محدوده مورد مطالعه می‌باشد.

**واژه‌های کلیدی:** بارش رواناب، رگرسیون بردار پشتیبان، سد صفارود، شبکه عصبی مصنوعی

### مقدمه

آوردن خصوصیات حوضه و شرایط مرزی بسیار مشکل است. ۲. رویکرد داده‌محور که شامل تجزیه و تحلیل سری زمانی مجموعه داده‌های ورودی و خروجی هستند (Solomatine and Ostfeld, 2008).

در طی سال‌های اخیر پیش‌بینی فرآیندهای هیدرولوژیکی به منظور بهره‌برداری پایدار از منابع آب با استفاده از روش‌های داده‌محور مورد توجه دست‌اندرکاران بخش آب قرار گرفته است (عبداله‌پور آزاد و ستاری، ۱۳۹۴). اگرچه مدل‌سازی با رویکردهای داده‌محور ممکن است توانائی کافی برای تفسیر فرآیندهای فیزیکی درون حوضه را نداشته باشند اما به‌طور صحیح و دقیقی می‌توانند رواناب خروجی حوضه را تخمین بزنند (Solomatine and Ostfeld, 2008). شبکه‌های عصبی مصنوعی (ANN) و ماشین بردار پشتیبان (SVM) از مهم‌ترین روش‌های داده‌محور می‌باشند که کاربردهای زیادی در مدل‌سازی فرآیندهای هیدرولوژی داشته‌اند (سیدیان و همکاران، ۱۳۹۳). سلگی و رادمنش (۱۳۹۴) به تخمین جریان ماهانه حوضه رودخانه شور در یک دوره ۲۶ ساله (۶۴ تا ۸۹) با استفاده از ANN پرداختند. نتایج دقت بالای ANN را در برآورد به همراه داشت.

رواناب ناشی از بارندگی و ذوب برف از منابع عمده آبی هستند که جهت رفع کمبود آب برای مصارف کشاورزی صنعتی و آشامیدنی حائز اهمیت می‌باشند. لذا برآورد حجم رواناب حاصل از بارندگی جهت به‌کارگیری روش‌های جمع‌آوری و مهار آب‌های سطحی به منظور تأمین آب، روز به روز اهمیت بیشتری پیدا می‌کند. محاسبه رواناب ناشی از بارش نزولات جوی با رویکردهای مختلفی امکان پذیر است. به‌طور کلی دو رویکرد عمده برای مدل‌سازی فرآیند بارش رواناب وجود دارد. ۱. رویکرد دانش‌محور که به عنوان رویکردهای مدل‌سازی مبتنی بر خصوصیات و قوانین فیزیک حاکم بر حوضه شناخته می‌شوند. در اکثر مناطق به ویژه کشورهای در حال توسعه بدست

۱ - دانشجوی کارشناسی ارشد مهندسی منابع آب، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه شهید باهنر کرمان  
۲ - دانشیار گروه مهندسی آب، دانشکده کشاورزی، دانشگاه شهید باهنر کرمان  
۳ - دانشیار گروه مهندسی آب، دانشکده کشاورزی، دانشگاه شهید باهنر کرمان  
(\* - نویسنده مسئول: (Email: kouroshqaderi@uk.ac.ir)

متحرک (ARMA)<sup>۱</sup> را با استفاده از داده‌های مشاهداتی بلندمدت دبی ماهانه روی دو رودخانه مورد ارزیابی قرار دادند (Wang et al., 2009). آنها دریافتند که بهترین عملکرد مربوط به ANFIS و SVM می‌باشد. بوتسیس و همکاران به مقایسه بین مدل SVR و شبکه عصبی چند لایه پیشخور (MFNN)<sup>۲</sup> در پیش‌بینی بارش رواناب پرداختند (Botsis et al., 2011). آنها ذکر کردند که روش SVR بهتر از MFNN بارش رواناب را شبیه‌سازی می‌کند. قربانی و همکاران با استفاده از مدل‌های SVM، MLP و RBF جریان ماهانه رودخانه‌های حوضه دریاچه ارومیه را پیش‌بینی نمودند (Ghorbani et al., 2016). نتایج حاکی از برتری مدل‌های MLP و RBF نسبت به SVM بوده است. چانکلان و همکاران با استفاده از ترکیب دو روش ANN و SVR به مدل‌سازی بارش رواناب پرداختند (Chanklan et al., 2018). نتایج نشان داد که روش ترکیبی ANN و SVR عملکرد بهتری نسبت به سایر روش‌های نامبرده دارد.

بنابراین هدف از انجام این تحقیق مدل‌سازی رواناب ناشی از بارندگی در زیر حوضه سد صفارود با بهره‌گیری از روش‌های رگرسیون بردار پشتیبان با کرنل پایه شعاعی (SVR RBF) و رگرسیون بردار پشتیبان با کرنل خطی (SVR Linear) و شبکه عصبی مصنوعی پرسپترون چند لایه (MLP) و شبکه عصبی تابع شعاع مدار (RBF) در محیط نرم‌افزار IBM SPSS (Clementine) Modeler طی دوره آماری ۱۳۹۴-۱۳۸۵ در مقیاس روزانه می‌باشد.

## مواد و روش‌ها

### منطقه مورد مطالعه

حوضه آبریز سد صفارود در جنوب شرقی ایران، در استان کرمان و در شهرستان رابر با وسعت ۵۰۲/۹ کیلومتر مربع در ناحیه‌ای بین عرض جغرافیایی ۲۹ درجه و ۲۷ دقیقه تا ۲۸ درجه و ۵۴ دقیقه شمالی و طول جغرافیایی ۵۶ درجه و ۴۵ دقیقه تا ۵۷ درجه و ۱۶ دقیقه شرقی واقع شده است. حوضه مطالعاتی از رودخانه‌های اصلی رابر و رودر تشکیل شده است. شکل (۱) موقعیت جغرافیایی حوضه سد صفارود را نشان می‌دهد.

در این مطالعه به مدل‌سازی بارش رواناب حوضه سد صفارود طی بازه زمانی مهر ۱۳۸۵ تا شهریور ۱۳۹۴ در مقیاس روزانه پرداخته شده است. جدول (۱) موقعیت جغرافیایی ایستگاه‌های باران‌سنجی و هیدرومتری مورد مطالعه را نشان می‌دهد. باتوجه به این که آمار بارندگی کلیه ایستگاه‌ها در منطقه مورد مطالعه حوضه سد صفارود کامل بود، عملیات پیش‌پردازش داده‌ها با استفاده از روش ضریب

دهقانی و وفاه‌خواه (۱۳۹۵) جریان روزانه حوضه آبریز کسلیان را با استفاده از روش‌های ANN و سیستم عصبی فازی تطبیقی (ANFIS)<sup>۱</sup> شبیه‌سازی کردند. نتایج آنها نشان داد که ANFIS توانایی بهتری نسبت به مدل ANN برای مدل‌سازی بارش رواناب دارد. بدرزاده و همکاران قابلیت چهار روش مختلف شامل ANN، ANFIS، شبکه عصبی موجک (WNF) و ترکیب ANFIS با آنالیز موجک (WNF) را برای پیش‌بینی رواناب بررسی نمودند (Badrzadeh et al., 2015). نتایج مطالعه آنها نشان داد عملکرد این روش‌ها قابل قبول می‌باشد. با این حال مدل‌های ترکیبی مبتنی بر موجک در مدل‌سازی به طور قابل توجهی عملکرد بهتری نسبت به مدل‌های ANFIS و ANN دارد.

از اولین کاربردهای روش SVM در مسائل آب می‌توان به دیبیک و همکاران برای شبیه‌سازی بارش رواناب اشاره کرد (Dibike et al., 2001). سیدیان و همکاران (۱۳۹۳) با استفاده از روش آماری سری زمانی در قالب الگوی اتورگرسیون (AR) و داده‌محور در قالب SVM جریان رودخانه در حوضه آبخیز گرگانرود را شبیه‌سازی کردند. نتایج حاکی از این بود که روش SVM در هر دو مقیاس هفتگی و ماهانه دقت بیشتری نسبت به سری زمانی داشت. قربانی و ازانی (۱۳۹۴) به بررسی فرآیند بارش رواناب روزانه حوضه آبریز بالیخ لوجای با استفاده از SVM، ANN، هیبرید موجک-ماشین بردار پشتیبان (WSVM)<sup>۲</sup> و هیبرید موجک-شبکه عصبی (WANN)<sup>۳</sup> پرداخته‌اند. همه روش‌ها دارای دقت قابل قبولی بودند. معتمدینا و همکاران (۱۳۹۶) فرآیند بارش رواناب حوضه آبخیز امامه را با استفاده از روش‌های شبکه عصبی پرسپترون چند لایه (MLP)<sup>۴</sup>، تابع پایه شعاعی (RBF)<sup>۵</sup> و ANFIS شبیه‌سازی نمودند. نتایج نشان داد از بین روش‌های استفاده شده، روش ANFIS عملکرد بسیار مناسبی داشته است. ستاری و رضازاده جودی (۱۳۹۷) به مدل‌سازی رواناب ماهانه با استفاده از داده‌های بارش، دما و رواناب ماهانه حوضه آبریز ناورود پرداختند. آنها دریافتند که روش رگرسیون بردار پشتیبان (SVR)<sup>۶</sup> با بهره‌گیری از تابع کرنل شعاعی نسبت به روش نزدیکترین همسایگی از دقت بالاتری در برآورد مقادیر جریان سیلابی برخوردار است.

وانگ و همکاران روش‌های ANN، ANFIS، SVM، برنامه‌ریزی ژنتیک (GP)<sup>۷</sup> و مدل‌های خطی خود همبسته میانگین

- 1- Adaptive Neuro-Fuzzy Inference System
- 2- Wavelet- Support Vector Machine
- 3- Wavelet-Neural Networks
- 4- Multi- Layer Perceptron
- 5- Radial Basis Functions
- 6- Support Vector Regression
- 7- Genetic Programming

- 8- Auto Regressive Moving Average Processes
- 9- Multilayer Feed-forward Neural Network

می‌یابد که حداکثر حاشیه ابر صفحه را حاصل می‌کنند. به نزدیک‌ترین نقاط آموزشی به حداکثر حاشیه ابر صفحه، بردارهای پشتیبان گفته می‌شود و تنها از این بردارها (نقاط) برای مشخص کردن مرز بین طبقات استفاده می‌شود. شکل (۲) فرآیند روش SVM را نشان می‌دهد.

روش SVR مدل رگرسیونی SVM می‌باشد. در SVR تابعی مرتبط با متغیر وابسته  $y$  که خود تابعی از چند متغیر  $x$  مستقل است، برآورد می‌شود. مشابه سایر مسائل رگرسیونی فرض می‌شود رابطه میان متغیرهای مستقل و وابسته با تابع جبری مانند  $f(x)$  به علاوه مقداری اغتشاش (خطای مجاز یا  $\epsilon$ ) مشخص شود:

$$f(x) = W^T \cdot \phi(x) + b \quad (2)$$

$$y = f(x) + \text{noise} \quad (3)$$

چنانچه  $W$  بردار ضرایب و  $b$  ثابت مشخصه‌های تابع رگرسیونی و  $\phi$  نیز تابع کرنل باشد، آنگاه هدف پیدا کردن فرم تابعی برای  $f(x)$  است. این مهم با آموزش مدل SVM توسط مجموعه‌ای از نمونه‌ها (مجموعه آموزش) محقق می‌شود. برای محاسبه  $W$  و  $b$  لازم است تابع خطا معادله (۴) در مدل SVM با در نظر گرفتن شرایط مندرج (قیود) در معادله (۵) بهینه شود.

$$W^T \cdot \phi(X_i) + b - y_i \leq \epsilon + \epsilon_i^*, \frac{1}{2} W^T \cdot W + C \sum_{i=1}^N \epsilon_i \quad (4)$$

$$+ C \sum_{i=1}^N \epsilon_i^* \quad (5)$$

$$y_i - W^T \cdot \phi(X_i) - b \leq \epsilon + \epsilon_i, \epsilon_i, \epsilon_i^* \geq 0 \quad (5)$$

$i=1,2,3,\dots,N$

هرست برای سنجش کفایت داده‌ها، روش جرم مضاعف برای آزمون همگنی و روش ران تست جهت آزمون تصادفی مورد بررسی قرار گرفت. تعداد کل نمونه‌ها طی دوره آماربرداری معادل ۳۲۸۷ داده است. ۷۰ درصد داده‌ها (۲۳۰۱ داده) به عنوان داده‌های آموزش و ۳۰ درصد آنها (۹۸۶ داده) به عنوان داده‌های آزمون در نظر گرفته شد. در جدول (۲) پارامترهای آماری مربوط به داده‌های اندازه‌گیری شده در بازه روزانه ارائه شده است. در تحقیق حاضر برای مدل‌سازی بارش رواناب نرم‌افزار IBM SPSS Modeler (Clementine) مورد استفاده قرار گرفت. به منظور استانداردسازی داده‌های ورودی به مدل از رابطه زیر استفاده شده است.

$$x_n = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

که  $x_n$  داده استاندارد شده،  $x$  داده‌های هر سری و  $x_{\min}$  و  $x_{\max}$  به ترتیب بیشترین و کمترین مقدار در هر سری می‌باشد.

### روش SVM

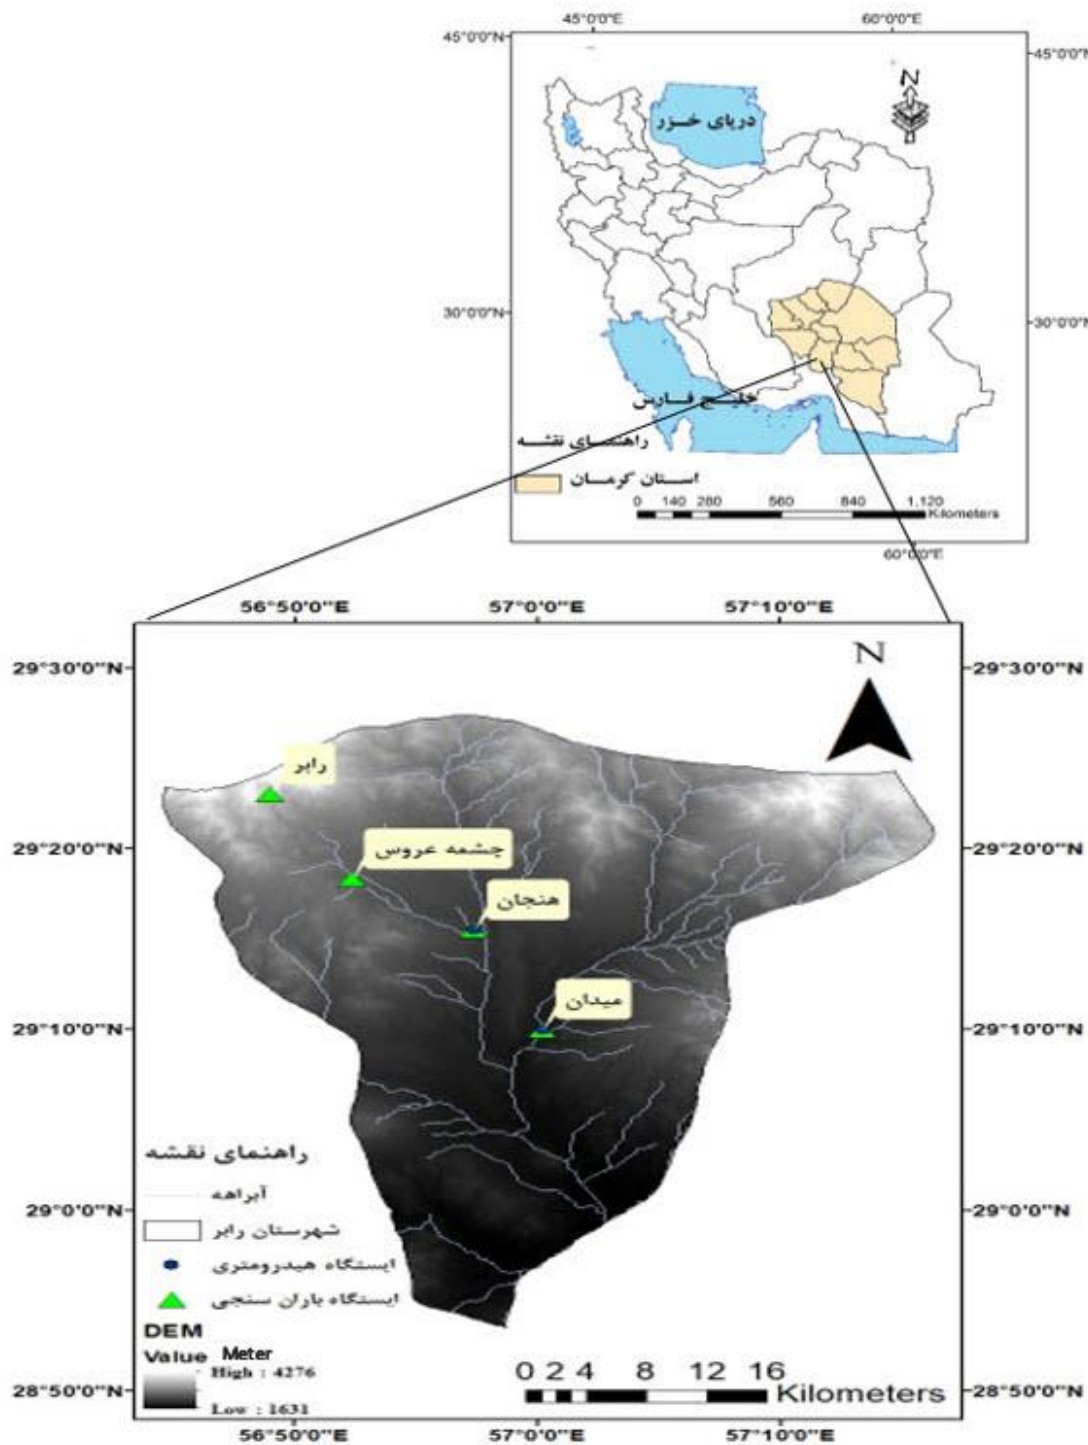
هدف ماشین‌های بردار پشتیبان، یافتن یک تابع پیوسته با مقدار حقیقی است که بتواند به ازای مقادیر ورودی، پیش‌بینی دقیقی از مقدار خروجی داشته باشد (نیک‌بخت شهبازی و همکاران، ۱۳۹۱). به طور کلی SVM نوعی سیستم یادگیری کارآمد بر مبنای تئوری بهینه‌سازی مقید است که توسط وینیک ارائه شده است (نیک‌پور و همکاران، ۱۳۹۶). SVM روشی است که هم برای گروه‌بندی و هم برای تخمین و برآورد تابع برازش داده‌ها در مسائل رگرسیونی به کار می‌رود به طوری که کمترین خطا در گروه‌بندی داده‌ها یا تابع برازش رخ دهد. SVM الگوریتمی است که نوع خاصی از مدل‌های خطی را

جدول ۱- موقعیت جغرافیایی ایستگاه‌های منطقه مورد مطالعه

نام ایستگاه	طول جغرافیایی شرقی	عرض جغرافیایی شمالی	ارتفاع	نوع ایستگاه
هنجان	۵۶° ۵۷' ۳۸"	۲۹° ۱۴' ۱۹"	۲۱۳۷	هیدرومتری - باران‌سنجی
چشمه عروس	۵۶° ۵۲' ۳۵"	۲۹° ۱۸' ۴۷"	۲۴۶۰	باران‌سنجی
میدان	۵۷° ۰۰' ۲۲"	۲۹° ۰۹' ۵۴"	۱۹۱۵	باران‌سنجی
رابر	۵۶° ۵۵' ۳۶"	۲۹° ۱۷' ۲۸"	۲۷۳۰	باران‌سنجی

جدول ۲- شاخص‌های آماری داده‌های بارش و دبی روزانه در ایستگاه‌های منطقه مورد مطالعه

ایستگاه‌ها	رابر باران‌سنجی (mm)	میدان باران‌سنجی (mm)	چشمه عروس باران‌سنجی (mm)	هنجان باران‌سنجی (mm)	هنجان هیدرومتری (m <sup>3</sup> /s)
کمینه	۰	۰	۰	۰	۰
بیشینه	۶۱	۶۱	۶۵	۷۰	۱۱/۱۵
انحراف معیار	۳/۷۸	۳/۲۰	۳/۵۳	۳/۶۴	۰/۹۴
واریانس	۱۴/۲۶	۱۰/۲۵	۱۲/۴۵	۱۳/۳۰	۰/۸۸
دامنه تغییرات	۶۱	۶۱	۶۵	۷۰	۱۱/۱۵



شکل ۱- موقعیت جغرافیایی منطقه مورد مطالعه

$$f(x) = \sum_{i=1}^N \bar{\alpha}_i \phi(x_i)^T \cdot \phi(x) + b \quad (6)$$

که در رابطه (۶) میانگین ضرایب لاگرانژ می‌باشد. محاسبه  $\phi(x)$  در فضای مشخصه آن ممکن است بسیار پیچیده باشد. برای

که  $C$ : عددی صحیح و مثبت است، که عامل تعیین جرمه در هنگام رخ دادن خطای آموزش مدل است.  $\phi$ : تابع کرنل،  $N$ : تعداد نمونه‌ها و دو مشخصه  $\epsilon_i^*$  و  $\epsilon_i$ : متغیرهای کمبود هستند. در نهایت تابع بردار پشتیبان رگرسیونی را می‌توان به شکل زیر بازنویسی کرد:

شده در SVM شامل کرنل‌های خطی (Linear) و پایه شعاعی (RBF) می‌باشند (Chen and Yu., 2007). کرنل گوسی به عنوان تابع RBF شناخته می‌شود. کرنل‌های Linear و RBF به ترتیب از طریق روابط (۸) و (۹) محاسبه می‌گردند.


$$k(u, v) = u \cdot v \quad (8)$$

$$(u, v) = \exp\left(-\frac{\|u-v\|^2}{2\sigma^2}\right), \frac{1}{2\sigma^2} = \gamma \quad (9)$$

حل این مشکل روند معمول در مدل SVR انتخاب یک تابع کرنل به صورت رابطه زیر است.

$$K(X_j, X) = \phi(X_j)^T \sqrt{b^2 - 4ac} \quad (7)$$

بنابراین برای حل مسأله باید مقادیر  $C$ ،  $\epsilon$  و پارامترهای مربوط به تابع کرنل انتخابی مشخص باشند که دقت در تعیین آنها در کاهش خطای مسأله تأثیرگذار است (Dibike et al., 2001). انتخاب تابع کرنل بر اساس آزمون، اطلاع از مسائل طبقه‌بندی و رگرسیون و همچنین ملاحظات نظری است. توابع کرنل شناخته



شکل ۲- فرآیند مدل SVM (سیدیان و همکاران، ۱۳۹۳)

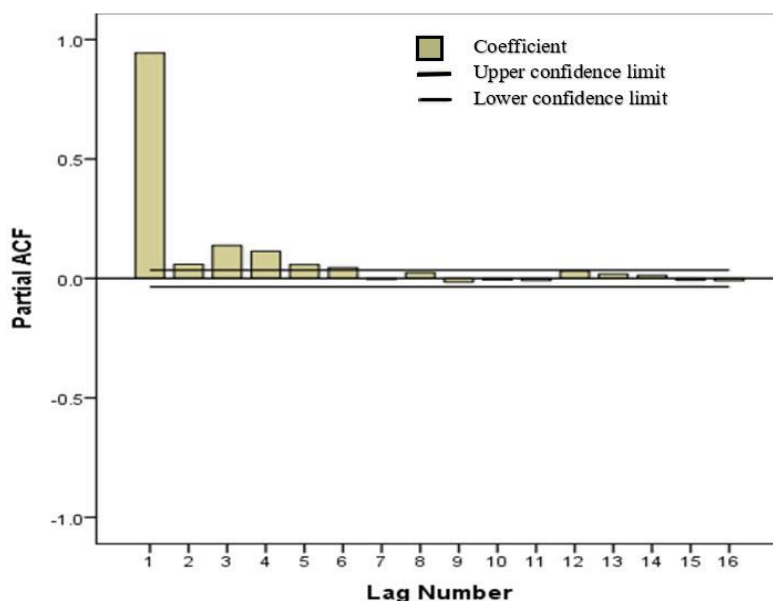
شبکه عصبی تابع شعاع مدار (RBF) استفاده شد. در شبکه‌های عصبی MLP و RBF، غالباً توجه بر بهبود ساختار شبکه عصبی است، به نحوی که خطای تخمین و میزان اشتباه‌های ANN کمینه شود (احمدی و همکاران، ۱۳۹۴).

#### انتخاب الگوی مناسب

به منظور انتخاب ترکیب مناسب از متغیرهای ورودی مدل‌ها، از نمودار خود همبستگی جزئی<sup>۱</sup> متغیر دبی استفاده شد. نمودار خود همبستگی جزئی ایستگاه هنجان در شکل ۳ ارائه شده است. همانطور که از شکل ۳ مشخص است برای ایستگاه هنجان بعد از شش تأخیر سایر مقادیر خود همبستگی در حدود استانداردشان قرار گرفته‌اند. با توجه به نمودار خود همبستگی جزئی الگوهای مختلفی برای مدل‌سازی بارش رواناب روزانه ایستگاه هنجان مطابق با جدول ۳ استفاده شد.

#### روش ANN

یک ANN شامل مجموعه‌ای از واحدهای ورودی/خروجی متصل به یکدیگر است که بر روی هر اتصال نیز، وزنی قرار گرفته است. ANN به کمک فرآیند یادگیری و با استفاده از نورون به ساخت روابط ذاتی بین داده‌ها، نگاشتی میان فضای ورودی (لایه ورودی) و فضای مطلوب (لایه خروجی) ارائه می‌دهد (نیک‌پور و همکاران، ۱۳۹۶). در مدل‌سازی ANN پارامترهای مؤثر شامل تعداد تکرار در مرحله آموزش، تعداد لایه‌های شبکه و تعداد نورون‌های لایه میانی است. از مزایای ANN به تحمل بالای آنها در مواجهه با داده‌های نویز و قابلیت دسته‌بندی الگوهایی که آموزش دیده نشده‌اند می‌توان اشاره کرد. ANN به واسطه قابلیت ضعیف تفسیرپذیری مورد انتقاد قرار می‌گیرند. باتوجه به نوع کاربرد گسترده ANN در زمینه پردازش اطلاعات، شناسایی الگو، تخمین توابع و غیره انواع مختلفی از ANN ابداع شده و مورد استفاده قرار می‌گیرند که در این تحقیق از شبکه عصبی مصنوعی پرسپترون چند لایه (MLP) و



شکل ۳- نمودار خود همبستگی جزئی ایستگاه هنجان

جدول ۳- الگوهای مختلف ورودی برای مدل‌سازی بارش رواناب ایستگاه هنجان

الگو	ساختار
الگو ۱	$Q(t)=f \{R(\text{Henjan}), R(\text{cheshme aros}), R(\text{meydan}), R(\text{rabor}), Q(t-1)\}$
الگو ۲	$Q(t)=f \{R(\text{Henjan}), R(\text{cheshme aros}), R(\text{meydan}), R(\text{rabor}), Q(t-1), Q(t-2)\}$
الگو ۳	$Q(t)=f \{R(\text{Henjan}), R(\text{cheshme aros}), R(\text{meydan}), R(\text{rabor}), Q(t-1), Q(t-2), Q(t-3)\}$
الگو ۴	$Q(t)=f \{R(\text{Henjan}), R(\text{cheshme aros}), R(\text{meydan}), R(\text{rabor}), Q(t-1), Q(t-2), Q(t-3), Q(t-4)\}$
الگو ۵	$Q(t)=f \{R(\text{Henjan}), R(\text{cheshme aros}), R(\text{meydan}), R(\text{rabor}), Q(t-1), Q(t-2), Q(t-3), Q(t-4), Q(t-5)\}$
الگو ۶	$Q(t)=f \{R(\text{Henjan}), R(\text{cheshme aros}), R(\text{meydan}), R(\text{rabor}), Q(t-1), Q(t-2), Q(t-3), Q(t-4), Q(t-5), Q(t-6)\}$

### نتایج و بحث

#### دوره آموزش (واسنجی)

در این تحقیق از روش‌های SVR، MLP، RBF برای مدل‌سازی بارش رواناب استفاده شد. ۷۰ درصد داده‌ها (۲۳۰۱) برای دوره آموزش انتخاب شده‌اند. در جدول ۴ ساختار روش‌های ANN برای مدل‌سازی بارش رواناب برای دوره‌های آموزش و آزمون آورده شده که به طور مثال در مدل MLP 1 در دوره آموزش ANN دارای سه لایه است که تعداد نرون‌ها در لایه‌های ۱، ۲ و ۳ به ترتیب ۵، ۲ و ۱ می‌باشد (جدول ۴). در روش SVR توابع کرنل RBF و Linear به عنوان یکی از بهترین توابع کرنل گزارش شده است. مقادیر پارامترهای  $\gamma$ ،  $c$  و  $\epsilon$  به صورت پیش‌فرض برای روش SVR به ترتیب برابر ۰/۱، ۱۰ و ۰/۱ در نظر گرفته شده است. در این تحقیق به منظور ارزیابی مدل‌ها از معیارهای  $r$ ، RMSE و MAE استفاده شد. با توجه به مقادیر شاخص‌های آماری جدول ۵ مشاهده می‌شود که هر دو روش SVR و ANN با دقت بالا و قابل قبولی قادر به

#### معیارهای ارزیابی مدل

برای ارزیابی نتایج بدست آمده از چندین معیار آماری استفاده شده است. این معیارهای آماری شامل متوسط قدر مطلق خطا (MAE)، جذر میانگین مربعات خطا (RMSE) و ضریب همبستگی ( $r$ ) می‌باشند.

$$MAE = \frac{1}{n} \sum_{i=1}^n |Q_{obs} - Q_{sim}| \quad (10)$$

$$RMSE = \left[ \frac{\sum (Q_{sim} - Q_{obs})^2}{n} \right]^{\frac{1}{2}} \quad (11)$$

$$r = \frac{\sum (Q_{obs} - \bar{Q}_{obs})(Q_{sim} - \bar{Q}_{sim})}{\sqrt{\sum (Q_{obs} - \bar{Q}_{obs})^2 \sum (Q_{sim} - \bar{Q}_{sim})^2}} \quad (12)$$

که در این روابط،  $Q_{obs}$  دبی روزانه ثبت شده،  $Q_{sim}$  دبی روزانه شبیه‌سازی شده،  $\bar{Q}_{obs}$  میانگین دبی روزانه ثبت شده،  $\bar{Q}_{sim}$  میانگین دبی روزانه شبیه‌سازی شده و  $n$  تعداد داده‌ها می‌باشند. MAE و RMSE شاخص‌هایی برای بیان دقت نسبی مدل‌سازی هستند که مقادیر MAE و RMSE نزدیک به صفر مقادیر قابل قبولی هستند. مقدار  $r$  بین منفی یک تا یک است.

مدل‌سازی بارش رواناب می‌باشند. بنابراین این دو روش قابل استفاده برای دوره آزمون می‌باشند. مقادیر بالای  $r$  و پایین RMSE و MAE در روش SVR حاکی از آموزش بهتر این روش نسبت به روش ANN است. به عنوان مثال، نمودارهای پراکنش مقادیر مشاهداتی و محاسباتی برای بهترین مدل‌ها در مرحله آموزش طی سال‌های ۸۵ تا ۹۴ در شکل ۴ و ۶ آورده شده‌است. باتوجه به نتایج ارائه‌شده در شکل ۴، توانایی بالای روش SVR Linear 5 در مدل‌سازی بارش رواناب در دوره آموزش مشخص می‌شود.

### دوره آزمون (صحت‌سنجی)



به منظور مدل‌سازی بارش رواناب با استفاده از روش‌های نام برده در دوره آزمون از ۳۰ درصد داده استفاده شد. با توجه به شاخص‌های آماری مربوط به بارش رواناب دوره آزمون در جدول ۵ برای مدل اول (یعنی استفاده از داده‌های رواناب یک روز قبل و بارش ایستگاه‌ها برای تخمین بارش رواناب هر روز)، مقادیر  $r$ ، RMSE و MAE در روش SVR Linear 5 به ترتیب ۰/۹۱، ۰/۳۲۶ و ۰/۰۱ و در روش MLP به ترتیب ۰/۸۹۸، ۰/۳۴۳ و ۰/۰۰۰۹ ارائه شده‌اند. روند مشابه در مدل‌های دیگر نیز مشاهده شد. بر همین اساس روش SVR Linear 5 و MLP 6 نتایج قابل قبولی در مدل‌سازی بارش رواناب ارائه کرده‌اند و از دقت بالایی نسبت به سایر روش‌ها برخوردار بودند. به طوری که نتایج روش‌های SVR Linear 5، SVR RBF، RBF1، 3 و MLP 6 در مرحله آزمون مقادیر  $r$  به ترتیب برابر با ۰/۹۶۷، ۰/۹۱۴، ۰/۷۸۸ و ۰/۹۶۳ بوده که نسبت به سایر روش‌ها برتری داشته‌است. با مقایسه مقادیر شاخص‌های آماری مدل‌های مختلف در روش SVR Linear 5 مدل SVR نسبت به سایر مدل‌ها با دقت بیشتری قادر به مدل‌سازی بارش رواناب بود ( $r=0/967$ ).

### نتیجه‌گیری

در پژوهش حاضر از روش‌های MLP، RBF، SVR Linear و SVR RBF به منظور مدل‌سازی بارش رواناب ایستگاه هنجان واقع در زیرحوضه آبریز سد صفارود استفاده شد. عملیات پیش‌پردازش داده‌ها با استفاده از روش‌های ضریب هرست، جرم مضاعف و آزمون ران انجام شد. شش الگو مختلف جهت مدل‌سازی رواناب ساخته شد. به منظور ارزیابی مدل‌ها از مقادیر  $r$ ، RMSE و MAE استفاده شد. بهترین مدل‌های پیشنهادی برای مدل‌سازی بارش رواناب در مرحله آزمون در ایستگاه هنجان به ترتیب مدل SVR Linear 5 با مقادیر ارزیابی  $r=0/959$ ،  $RMSE=0/337$  و  $MAE=0/052$  و همچنین مدل MLP 6 با مقادیر ارزیابی  $r=0/963$ ،  $RMSE=0/167$  و  $MAE=0/004$  می‌باشند. با بررسی روش‌های ANN مشخص شد MLP عملکرد بهتری نسبت به RBF داشته‌است که با نتایج قربانی و همکاران (۲۰۱۶) مطابقت دارد.



جدول ۴- ساختار روش‌های ANN مدل‌سازی بارش رواناب ساخته شده برای ایستگاه هنجان

مدل	نوع داده	نسبت	تعداد لایه	ساختار	تابع انتقال لایه پنهان	تابع انتقال خروجی
MLP 1				۱-۲-۵		
MLP 2				۱-۵-۶		
MLP 3	نرمال (۰-۱)	۷۰ به ۳۰	۳	۱-۴-۷	Hyperbolic tangent	
MLP 4				۱-۷-۸		
MLP 5				۱-۷-۹		
MLP 6				۱-۶-۱۰		
RBF 1				۱-۱۰-۵		
RBF 2				۱-۷-۶		
RBF 3	نرمال (۰-۱)	۷۰ به ۳۰	۳	۱-۱۰-۷	Radial Basis Function	
RBF 4				۱-۱۰-۸		
RBF 5				۱-۱۰-۹		
RBF 6				۱-۷-۱۰		





جدول ۵- شاخص‌های آماری دو روش ANN و SVR برای مدل‌سازی بارش رواناب در ایستگاه هنجان

آزمون			آموزش			الگو	روش
r	RMSE	MAE	r	RMSE	MAE		
۰/۸۹۸	۰/۳۴۳	۰/۰۰۱	۰/۸۷۴	۰/۴۸۷	۰/۰۳	۱	شبکه عصبی MLP
۰/۸۸۵	۰/۳۶۶	۰/۰۰۶	۰/۸۷۴	۰/۴۹۲	۰/۰۳۵	۲	
۰/۸۸۲	۰/۳۷۱	۰/۰۱۳	۰/۸۷۵	۰/۴۹۱	۰/۰۳۴	۳	
۰/۸۹	۰/۳۶۳	۰/۰۱۲	۰/۸۷۷	۰/۴۷۷	۰/۰۲۱	۴	
۰/۸۸۵	۰/۳۶۶	۰/۰۰۲	۰/۸۸۴	۰/۴۷۱	۰/۰۲۲	۵	
۰/۹۶۳	۰/۳۱۶	۰/۰۰۶	۰/۹۵۷	۰/۳۱۶	۰/۰۲۵	۶	
۰/۷۸۸	۰/۴۸۵	۰/۰۲۶	۰/۷۹۹	۰/۶۰۳	۰/۰۴۵	۱	شبکه عصبی RBF
۰/۷۶۱	۰/۵۱	۰/۰۰۸	۰/۷۸۵	۰/۶۲۷	۰/۰۵	۲	
۰/۷۲۸	۰/۵۴۱	۰/۰۲۳	۰/۷۸۲	۰/۶۲۸	۰/۰۴۸	۳	
۰/۷۸۵	۰/۴۸۷	۰/۰۲۱	۰/۸۱۹	۰/۵۷۶	۰/۰۴۳	۴	
۰/۷۰۱	۰/۵۶۲	۰/۰۳۷	۰/۷۲۳	۰/۶۸۸	۰/۰۵۹	۵	
۰/۷۲۹	۰/۵۴	۰/۰۳۲	۰/۶۹۶	۰/۷۱۸	۰/۰۶۵	۶	
۰/۹۱۲	۰/۳۲۶	۰/۰۱	۰/۸۸۶	۰/۴۶۸	۰/۰۳۲	۱	SVR Linear
۰/۹۱۲	۰/۳۳	۰/۰۲۳	۰/۸۸۸	۰/۴۶۸	۰/۰۴۶	۲	
۰/۹۱۴	۰/۳۲۹	۰/۰۳	۰/۸۸۹	۰/۴۶۹	۰/۰۵۳	۳	
۰/۹۱۵	۰/۳۲۵	۰/۰۲۶	۰/۸۹	۰/۴۶۵	۰/۰۴۸	۴	
۰/۹۶۷	۰/۲۲۹	۰/۰۳۲	۰/۹۶۲	۰/۳۲۳	۰/۰۵۰	۵	
۰/۹۱۴	۰/۳۲۲	۰/۰۰۷	۰/۸۹	۰/۴۵۷	۰/۰۲۷	۶	
۰/۹۱۴	۰/۳۳۱	۰/۰۳۷	۰/۸۹۱	۰/۴۶۱	۰/۱۶	۱	SVR RBF
۰/۹۱۳	۰/۳۳۴	۰/۰۲۱	۰/۸۹۲	۰/۴۶۴	۰/۰۰۳	۲	
۰/۹۱۴	۰/۳۳۱	۰/۰۲۴	۰/۸۹۳	۰/۴۶۱	۰/۱	۳	
۰/۹۱۲	۰/۳۳۲	۰/۰۱۹	۰/۸۹۴	۰/۴۶	۰/۰۰۴	۴	
۰/۹۱۲	۰/۳۳۵	۰/۰۱۲	۰/۸۹۵	۰/۴۶۱	۰/۰۱	۵	
۰/۹۱۱	۰/۳۳۷	۰/۰۱۴	۰/۸۹۶	۰/۴۵۹	۰/۰۰۸	۶	





شکل ۴- مدل SVR Linear 5 ایستگاه هنجان در حالت آموزش الف: نمودار مقایسه دبی مشاهده‌ای و دبی محاسباتی ب: نمودار پراکنش





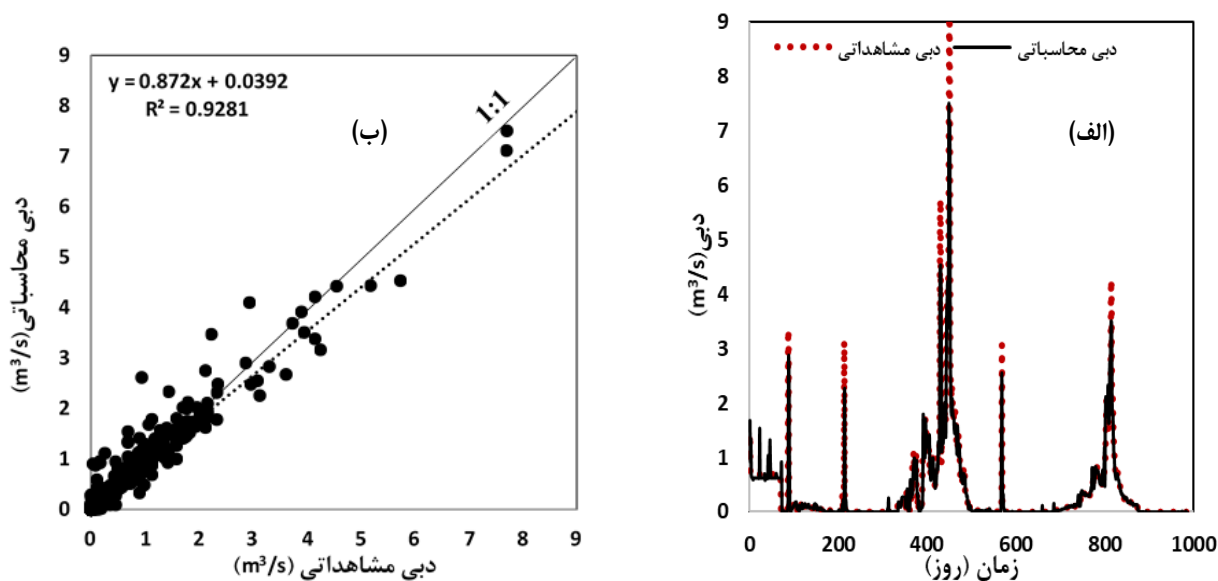
شکل ۵- مدل SVR Linear 5 ایستگاه هنجان در حالت آموزش الف: نمودار مقایسه دبی مشاهده‌ای و دبی محاسباتی ب: نمودار پراکنش



شکل ۶- مدل MLP 6 ایستگاه هنجان در حالت آموزش الف: نمودار مقایسه دبی مشاهده‌ای و دبی محاسباتی ب: نمودار پراکنش

مربعیات خطا (RMSE) و متوسط قدر مطلق خطا (MAE) در حد هزارم اعشار بود. با این حال، روش SVR عملکرد نسبتاً بهتری نسبت به روش ANN داشت.

در نهایت نتایج، توانایی مطلوب هر دو روش SVR و ANN را در برآورد بارش رواناب نشان می‌دهد. بنابراین می‌توان هر دو روش را برای مدل‌سازی بارش رواناب مورد استفاده قرار داد. به طور کلی در هر دو روش اختلاف مقادیر ضرایب همبستگی (r)، ریشه میانگین



شکل ۷- مدل MLP 6 ایستگاه هنجان الف: نمودار مقایسه دبی مشاهده‌ای و دبی محاسباتی ب: نمودار پراکنش

## منابع

تطبیقی (ANFIS). نشریه پژوهش‌های حفاظت آب و خاک. (۲۲): ۲۸۷-۲۹۷.

قربانی، م.، ازانی، ع. ۱۳۹۴. مدل‌سازی بارش رواناب با استفاده از مدل‌های هوشمند هیبریدی. تحقیقات منابع آب ایران. ۱۱(۲): ۱۴۶-۱۵۰.

غلامعلی، غ.، وفاخواه، م. ۱۳۹۲. شبیه‌سازی فرایند بارش رواناب با استفاده از شبکه عصبی مصنوعی و سیستم فازی عصبی تطبیقی (مطالعه موردی حوزه آبخیز حاجی قوشان). مدیریت حوزه آبخیز. ۴(۸): ۱۳۶-۱۲۰.

معمدنی، م.، نوح‌گر، ا.، ملکیان، آ.، صابری، م.، کریمی، کمال. ۱۳۹۶. پیش‌بینی رواناب با استفاده از مدل‌های هوشمند. اکوهیدرولوژی. ۴(۴): ۹۶۸-۹۵۵.

نیک بخت شهبازی، ع.، زهرایی، ب.، ناصری، م. ۱۳۹۱. پیش‌بینی فصلی خشکسالی هواشناسی با استفاده از ماشین‌های بردار پشتیبان. آب و فاضلاب. ۲(۲۳): ۸۵-۷۳.

نیک پور، م.ر.، ثانی‌خانی، ه.، محمودی بابلان، س.، محمدی، ع. ۱۳۹۶. کاربرد مدل‌های ANN، Ls-SVM، WNN و GEP در شبیه‌سازی بارش- رواناب رودخانه خیاوچای. اکوهیدرولوژی. ۴(۲): ۶۳۹-۶۲۷.

Badrzadeh, H., Sarukkalige, R., & Jayawardena, A. W. 2015. Hourly runoff forecasting for flood risk management: Application of various computational

احمدی، ف.، رادمش، ف.، میرعباسی نجف‌آبادی، ر. ۱۳۹۴. مقایسه عملکرد روش‌های ماشین بردار پشتیبان و شبکه‌های بیزین در پیش‌بینی جریان روزانه رودخانه (مطالعه موردی: رودخانه باراندوزچای). نشریه پژوهش‌های حفاظت آب و خاک. ۶(۲۲): ۱۷۱-۱۸۶.

دهقانی، ن.، وفاه‌خواه، م. ۱۳۹۵. مدل‌سازی بارش رواناب با استفاده از شبکه عصبی مصنوعی و شبکه فازی عصبی تطبیقی در حوزه آبریز کسلیان. مدیریت حوزه آبخیز. ۷(۱۳): ۱۳۷-۱۲۸.

ستاری، م. ت.، رضازاده جودی، ع. ۱۳۹۷. مدل‌سازی رواناب ماهانه با استفاده از روش‌های داده‌کاوی براساس الگوریتم‌های انتخاب ویژگی. حفاظت منابع آب و خاک. ۷(۴): ۵۳-۳۹.

سلگی، ا.، رادمش، ف. ۱۳۹۴. مدل‌سازی هوشمند سری زمانی جریان ماهانه حوضه رودخانه شور قروه با شبکه عصبی مصنوعی. حفاظت آب و خاک. ۲۲(۱): ۳۱۸-۳۰۹.

سیدیان، س.م.، سلیمانی، م.، کاشانی، م. ۱۳۹۳. پیش‌بینی دبی جریان رودخانه با استفاده از داده‌کاوی و سری زمانی. اکوهیدرولوژی. ۱(۳): ۱۶۷-۱۷۹.

عبداله‌پور آزاد، م.ر.، ستاری، م.ت. ۱۳۹۴. پیش‌بینی جریان روزانه رودخانه اهرچای با استفاده از روش‌های شبکه‌های عصبی مصنوعی (ANN) و مقایسه آن با سیستم استنتاج فازی-عصبی

- 208-216.
- Erasto, P. 2001. Support Vector Machines-Backgrounds and Practice. Licentiate Thesis, University of Helsinki, Rolf Nevanlinna Institute, Faculty of Science.
- Ghorbani, M.A., Ahmadzadeh, H., Isazadeh, M. and Terzi, O. 2016. A comparative study of artificial neural network (MLP, RBF) and support vector machine models for river flow prediction. *Environmental Earth Sciences*, 75(6): 1-14.
- Solomatine, D.P., and Ostfeld, A. 2008. Data-driven modeling: some past experience and new approaches. *Journal of Hydroinformatics*, 10: 3-22.
- Wang, W. C., Chau, K. W., Cheng, C. T., & Qiu, L. 2009. A comparison of performance of several artificial intelligence methods for forecasting monthly discharge time series. *Journal of hydrology*, 374(3), 294-306.
- Yu, P.S., Chen, S.T., and Chang, I.F. (2006). Support vector regression for real-time flood stage forecasting. *Journal of Hydrology* 328, 704-716.
- intelligence models. *Journal of Hydrology*, 529, 1633-1643.
- Botsis, D., Latinopoulos, P., and Diamantaras, K. 2011. Rainfall- Runoff modeling using support vector regression and artificial neural networks, J. Rhodes, Greece.
- Chanklan, R., Kaoungku, N., Suksut, K., Kerdprasop, K., & Kerdprasop, N. 2018. Runoff Prediction with a Combined Artificial Neural Network and Support Vector Regression. *International Journal of Machine Learning and Computing*, 8(1):39-43.
- Chen, S.T., Yu, P.S. 2007. Pruning of support vector networks on flood forecasting. *Journal of Hydrology*, 347: 67– 78.
- Chuan Wang.W. Wing Chau. K. 2009. A comparison of performance of several artificial intelligence methods for forecasting monthly discharge time series. *Journal of Hydrology*.374: 294-306.
- Dibike, Y.B., Velickov, S., Solomatine, D.P., and Abbott, M.B. 2001. Model induction with support vector machines: introduction and applications. *Journal of Computing in Civil Engineering* 15(3),

## Rainfall-Runoff modelling using Support Vector Regression and Artificial Neural Network models (Case study: SafaRoud Dam Watershed)

N. Najibzade<sup>1</sup>, K. Qaderi<sup>2\*</sup>, M. M. Ahmadi<sup>3</sup>

Received: May.20, 2019

Accepted: Jul.12, 2019

### Abstract

Rainfall-runoff modeling is an important and complex aspect in most water resource management and planning projects. In this study, Perespetron multi-layered artificial neural network (MLP), Radial basis function Neural Network (RBF), and support vector machine regression with linear kernel functions (SVR linear) were used to develop some models in SPSS to simulate Rainfall-runoff process in subarea of Safaroud dam, located in Halil Rood watershed. For this purpose, hydrometric data of Hanjan station and rainfall data of Hanjan, Rabor, Cheshme Aroos, and Meidan stations, located in the studied area, were used. 70% of the data were used as training data and 30% were used as test data. After calculating the partial correlation coefficients of the rainfall and discharge, six different patterns were used to model the daily rainfall of Hanjan station. In the best pattern of the test level, for SVR Linear 5 model, Mean Absolute Error (MAE), Root Mean Squared Error (RMSE) and correlation coefficient ( $r$ ) were equal to 0.032, 0.229, and 0.967, respectively. The results proved the efficient performance of MLP and SVR Linear in Rainfall-runoff modeling in the studied area.

**Keywords:** Rainfall-runoff, Support vector regression, Safaroud Dam, Artificial neural network

---

1- M. Sc. Student in Water Resources Engineering, Department of Water Engineering, Faculty of Agriculture, Shahid Bahonar University of Kerman

2- Associate Professor, Department of Water Engineering, Faculty of Agriculture, Shahid Bahonar University of Kerman

3- Associate Professor, Department of Water Engineering, Faculty of Agriculture, Shahid Bahonar University of Kerman

(\* - Corresponding Author Email: kourosqaderi@uk.ac.ir)