

Evaluation of Support Vector Machine and Adaptive Neuro-Fuzzy Inference System Performance in Prediction of Monthly River Flow (Case Study: Nazlu chai and Sezar Rivers)

FARSHAD AHMADI^{*1}

1. Water Engineering Department, Shahid Chamran University of Ahvaz, Ahvaz, Iran.
(Received: Oct. 31, 2019- Revised: Nov. 29, 2019- Accepted: Dec. 7, 2019)

ABSTRACT

In recent years by growing technology, new methods have been substantially developed to solve nonlinear problems such as river flow forecasting. Among the available various methods, Support Vector Machine (SVM) and Adaptive Neuro-Fuzzy Inference System (ANFIS) models have been recently used by many researchers. In this study, these methods were used to predict the monthly flow of NazluChai and Sezar Rivers during 1956-2016 period. Firstly, the data were prepared in two modes: (a) using flow data and considering the role of memory; (b) influencing the periodic term. Modeling was done by 80% of the data (576 months) for training and the remaining 20% (144 months) for testing. The root mean square error (RMSE), Nash-Sutcliffe (NS) and mean absolute relative error (MARE) metrics were used to evaluate the performance of the proposed models. The results showed that the SVM method with the RBF kernel function had the best performance in predicting monthly flow of the studied rivers. In addition, the periodic term significantly increased the prediction accuracy of the SVM-RBF model. Also, the performance of the ANFIS method was improved by using the periodic term and this model had the least error in estimating the monthly flow of the Saesar and Nazlu chi Rivers in M6 and M7 patterns, respectively. In general, the results of this study showed that the SVM method performs better than the ANFIS model in monthly flow prediction and the selection of appropriate kernel function has a direct effect on its efficiency.

Keywords: Periodic effect, Partial autocorrelation function, Membership function, Kernel function.

ارزیابی عملکرد روش‌های ماشین‌بردار پشتیبان و سیستم استنتاج عصبی فازی تطبیقی در پیش‌بینی جریان ماهانه رودخانه‌ها (مطالعه موردی رودخانه‌های نازلو و سزار)

فرشاد احمدی^{۱*}

۱. گروه هیدرولوژی و منابع آب، دانشکده مهندسی علوم آب، دانشگاه شهید چمران اهواز، اهواز، ایران
(تاریخ دریافت: ۱۳۹۸/۸/۹ - تاریخ بازنگری: ۱۳۹۹/۳/۱۷ - تاریخ تصویب: ۱۳۹۸/۹/۱۶)

چکیده

در سال‌های اخیر با رشد فناوری، روش‌های نوین برای حل مسائل غیرخطی نظیر پیش‌بینی جریان رودخانه‌ها به صورت قابل ملاحظه‌ای توسعه یافته است. از جمله روش‌هایی که اخیراً توسط محققان مختلف در این زمینه مورد استفاده قرار گرفته است مدل‌های ماشین‌بردار پشتیبان (SVM) و سیستم استنتاج عصبی فازی تطبیقی (ANFIS) می‌باشد. در این مطالعه از روش‌های مذکور برای پیش‌بینی جریان ماهانه رودخانه‌های نازلوچای و سزار در دوره آماری ۱۳۳۵-۱۳۹۵ استفاده شد. در ابتدا الگوهای ورودی در دو حالت الف) استفاده از داده‌های جریان و در نظر گرفتن نقش حافظه و ب) تاثیر دادن ترم پریودیک آماده و به مدل‌ها معرفی گردید. مدل‌سازی براساس ۸۰ درصد داده‌های تاریخی ثبت شده صورت گرفت (۵۷۶ ماه) و با ۲۰ (۱۴۴ ماه) درصد بقیه ارزیابی گردید. عملکرد مدل‌های به کار رفته با شاخص‌های آماری مجذور میانگین مربعات خطا (RMSE)، نش-ساتکلیف (NS) و میانگین قدر مطلق خطای نسبی (MARE)، مورد بررسی قرار گرفت. نتایج حاصل نشان داد که روش SVM با تابع کرنل RBF بیش‌ترین دقت را در پیش‌بینی جریان ماهانه هر دو رودخانه داشته و استفاده از ترم پریودیک توانسته است عملکرد آن را به طور قابل ملاحظه‌ای افزایش دهد. همچنین کارایی مدل ANFIS نیز با استفاده از ترم پریودیک بهبود یافته و در محل ایستگاه تپیک در الگوی M7 و برای جریان رودخانه سزار با الگوی M6 کمترین خطا را در پیش‌بینی جریان داشته است. به طور کلی نتایج این مطالعه نشان داد که روش SVM از عملکرد بهتری نسبت به مدل ANFIS در پیش‌بینی جریان برخوردار بوده و انتخاب تابع کرنل مناسب تاثیر مستقیمی بر کارایی آن دارد.

واژه‌های کلیدی: اثر پریودیک، تابع خود همبستگی جزئی، تابع عضویت، تابع کرنل.

مقدمه

یک دهه قبل به این سو، امکان کشف و آشکارسازی بهتر ارتباطات بین متغیرهای مختلف هیدرولوژیکی به‌طور چشم‌گیری افزایش یافته است. ماشین‌بردار پشتیبان (SVM)^۱ و سیستم استنتاج عصبی-فازی تطبیقی (ANFIS)^۲ از جمله روش‌های نوینی هستند که در زمینه پیش‌بینی جریان رودخانه در سال‌های اخیر به‌کار گرفته شده‌اند.

ماشین‌بردار پشتیبان یکی از روش‌های یادگیری تحت نظارت بوده و این قابلیت را دارد که هم برای دسته‌بندی و هم رگرسیون مورد استفاده قرار گیرد. این روش توسط Vapnik (1998) بر پایه تئوری یادگیری آماری آبنا نهاده شده و تا کنون در مطالعات متعدد هیدرولوژی به کار گرفته شده است. Rezaei *et al.* (2014) از مدل ماشین‌بردار پشتیبان در طراحی شبکه پایش سطح آب زیرزمینی استفاده نموده و دقت و عملکرد آن را

پیش‌بینی و تخمین آینده‌ی حوضه‌ها یکی از ارکان مهم مدیریت صحیح طرح‌ها و منابع آبی می‌باشد. بدین منظور محققان بر اساس ساختار حوضه، داده‌های موجود و اهداف مطالعه از روش‌های مختلفی استفاده نموده‌اند. روش‌های پیش‌بینی موجود را می‌توان در سه گروه الف) روش سری‌های زمانی، ب) مدل‌های توزیعی و نیمه‌توزیعی و ج) مدل‌های هوش مصنوعی تقسیم‌بندی نمود. به دلیل محدودیت‌های ساختاری، روش‌های سری‌زمانی از دقت کمتری در پیش‌بینی دراز مدت جریان رودخانه‌ها برخوردار می‌باشد. از طرف دیگر، مدل‌های توزیعی و نیمه‌توزیعی نیز بسیار پیچیده بوده و به اطلاعات وسیع‌تری از حوضه نیاز داشته و در نتیجه هزینه تهیه و تولید آن‌ها همواره قابل توجه است. اما در سال‌های اخیر با توسعه و گسترش روش‌های هوش مصنوعی از

* نویسنده مسئول: F.ahmadi@scu.ac.ir

1 -Support Vector Machine (SVM)
2 -Adaptive Neuro-Fuzzy Inference System (ANFIS)
3 -Supervised Learning
4 -Statistical Learning Theory

و سطح پیچیده و بالایی را برای مدل کردن و تخمین پیشنهاد می‌کند. این روش اساساً قسمت فازی داده‌ها را بر اساس درجه عضویت (که عددی بین ۰ و ۱ می‌تواند باشد) گروه‌بندی نموده و در نهایت تصمیم‌گیری برای فعالیت بعدی با استفاده از یک سری قوانین صورت می‌گیرد. ANFIS در ابتدا توسط Jang (1993) معرفی و در دهه اخیر در هیدرولوژی به‌طور گسترده‌ای مورد استفاده قرار گرفته است. *kia et al.* (2019) با استفاده از روش-های رگرسیون خطی چند متغیره^۳ (MLR) و ANFIS به توسعه مدل مناسب برای پیش‌بینی جریان حوضه آبریز کوهستانی هراز در دوره آماری ۱۳۶۳ تا ۱۳۹۴ پرداختند. بدین منظور ۴۴ ترکیب مختلف از پارامترهای بارندگی، دما، تبخیر، دبی جریان و شاخص بارش پیشین با تأخیر زمانی بین آن‌ها به‌صورت روزانه وارد مدل ANFIS گردید. از بین ترکیبات مختلف ورودی، ساختار بارندگی و دمای متوسط روز جاری، شاخص رطوبتی و دبی یک روز قبل به‌عنوان مدل مناسب انتخاب شد. نتایج حاصل نشان داد که روش ANFIS با تابع عضویت مثلثی شکل درجه دو با معیارهای آماری $RMSE=2.67$ متر مکعب در ثانیه، $R^2=0.98$ و $NS=0.97$ از عملکرد بهتری برخوردار بود. *Khazaei Poul et al.* (2019) در پژوهشی مدل‌های ANFIS، MLR، ANN و KNN^۴ برای پیش-بینی جریان ماهانه رودخانه کلایر^۵ واقع در مرزهای ایلات متحده و کانادا را به کار برده و گزارش نمودند که مدل ANFIS از دقت و عملکرد بهتری نسبت به سایر روش‌ها برخوردار بود. از روش ANFIS در زمینه‌های مختلف علم هیدرولوژی نیز به‌طور گسترده‌ای استفاده شده است که از آن جمله می‌توان به مطالعات *Riahi-Madvar et al.* (2019)، *Dehghani et al.* (2019) و *Zhou et al.* (2019) اشاره نمود.

عنایت به موارد فوق مشاهده می‌شود که مدل‌سازی و پیش‌بینی جریان میان مدت رودخانه‌ها مورد توجه محققان امر بوده و بدین منظور از مدل‌های هوش مصنوعی و به‌ویژه روش‌های SVM و ANFIS استفاده شده است. در اکثر مطالعات انجام شده با استفاده از ماشین‌بردار پشتیبان، تأثیر خاصیت تناوبی داده‌ها و نوع تابع کرنل مورد استفاده چندان مورد بحث و بررسی قرار نگرفته و در پژوهش‌های اندکی همچون *Isazadeh et al.* (2016) به نقش و تعیین تابع کرنل بهینه اهمیت داده شده است. از این رو، هدف از مطالعه حاضر تحلیل تأثیر ترم پریودیک در پیش‌بینی جریان رودخانه‌ها و انتخاب تابع کرنل بهینه بوده و از مدل ANFIS برای ارزیابی عملکرد روش SVM با تابع کرنل منتخب

مورد ارزیابی قرار دادند. نتایج نشان داد که این روش با میانگین خطای مطلق ۰/۳۴ متر و ضریب تبیین ۰/۹۹ به خوبی توانسته است ترکیب بهینه تعداد چاه‌ها را برآورد نماید. *Isazadeh et al.* (2016) با استفاده از مدل SVM و روش‌های سری زمانی به پیش‌بینی جریان رودخانه خرخره‌چای واقع در حوضه آبریز دریاچه ارومیه پرداخته و گزارش نمودند که روش SVM نسبت به مدل $ARMA(p,q)$ از عملکرد بسیار بهتری برخوردار بود. *Zaini et al.* (2019) به‌منظور پیش‌بینی جریان روزانه رودخانه از مدل SVM و الگوریتم بهینه‌سازی ازدحام ذرات^۱ (PSO) بهره برده و بیان داشتند که استفاده از الگوریتم بهینه‌ساز توانسته دقت در مدل‌سازی را افزایش داده و عملکرد SVM را بهبود بخشد. *Wu et al.* (2019) از مدل SVM برای پیش‌بینی سیلاب‌های ناگهانی حوضه‌های آبریز بهره بردند. بدین منظور آن‌ها از داده‌های ۶۹ واقعه بارش و سیلاب در دوره آماری ۱۹۸۴ تا ۲۰۱۲ برای ایجاد الگوهای مختلف ورودی استفاده کرده و نتایج حاصل را به این شرح بیان نمودند: (i) مدل SVM در پیش‌بینی سیلاب‌های یک تا سه ساعته عملکرد بسیار مطلوبی داشته است؛ (ii) استفاده از داده‌های تاخیر یافته جریان نسبت به بارش‌ها در پیش‌بینی سیلاب حوضه‌های مورد مطالعه در عملکرد مدل از تأثیر بسیار بیشتری برخوردار بوده است؛ (iii) تاخیر فاز (اختلاف زمانی) نتایج پیش‌بینی و مشاهداتی به‌طور معنی‌داری در هر دو مدل پیش-بینی دو و سه ساعته وجود داشته و استفاده از پارامتر بارش می‌تواند تا حدود بسیار زیادی اختلاف زمانی پیش‌بینی را کاهش دهد. *Babaei et al.* (2019) در پژوهشی به مقایسه دقت و عملکرد روش شبکه‌های عصبی مصنوعی و ماشین‌بردار پشتیبان در پیش‌بینی جریان ماهانه ورودی به سد زاینده‌رود اصفهان پرداختند. این محققان ۹ الگوی مختلف را با پارامترهای دبی، بارش ایستگاه قلعه شاهرخ و تأثیر تاخیر زمانی توسعه داده و به-عنوان ورودی‌های مدل در نظر گرفتند. مقایسه نتایج نشان داد که مدل SVM از عملکرد بهتری نسبت به شبکه عصبی مصنوعی (ANN)^۲ در پیش‌بینی جریان ماهانه ورودی به سد زاینده‌رود برخوردار بوده است. از روش ماشین‌بردار پشتیبان در زمینه‌های مختلف علم هیدرولوژی نیز به‌طور گسترده‌ای استفاده شده است که از آن جمله می‌توان به مطالعات *Rehana et al.* (2019)، *Pham et al.* (2019) و *Bafitlhile & Li* (2019) اشاره نمود.

ANFIS یک سیستم ترکیبی است که از توانایی تصمیم-گیری منطق فازی با قابلیت حساب‌گری شبکه عصبی بهره برده

4 -K-Nearest Neighbors (KNN)
5 -Clair River

1 -Particle Swarm Optimization (PSO)
2 -Artificial Neural Network (ANN)
3 -Multiple Linear Regression (MLR)

نامیده می‌شود. این رودخانه در پایین دست (در استان خوزستان) رودخانه دز نامیده می‌شود و سد بزرگ دز بر روی آن واقع شده است. شکل (۱-ب) وضعیت شبکه آبراهه‌ها و ایستگاه هیدرومتری منتخب به همراه موقعیت قرارگیری حوضه آبریز سپید دشت سزار را در استان لرستان نشان می‌دهد. همچنین در جدول (۱) مشخصات فیزیوگرافی و هیدرولوژیکی هر یک از حوضه‌های آبریز مورد مطالعه ارائه شده است.

ماشین بردار پشتیبان

ماشین بردار پشتیبان یک طبقه‌بندی کننده دو دویی غیر آماری است که در سال‌های اخیر بسیار مورد توجه قرار گرفته و به اختصار آن را با نام SVM معرفی می‌نمایند (Mantero *et al.*, 2005). SVM داری خواص زیر می‌باشد:

(۱) ایجاد حدکثر تعمیم در طراحی طبقه‌بندی کننده‌ها، (۲) دارا بودن توانایی یافتن جواب بهینه کلی تابع، (۳) تهیه خودکار ساختار و سازوکار بهینه در حل مسائل طبقه‌بندی، (۴) مدل‌سازی توابع غیرخطی با استفاده از کرنل‌های غیرخطی و شیوه حاصل-ضرب داخلی در فضاهای هیلبرت.

ماشین بردار پشتیبان الگوریتمی است که مدل‌های خطی منحصر به فرد را یافته و با استفاده از آن‌ها حداکثر حاشیه ابر صفحه را حاصل می‌کند. حداکثر شدن حاشیه ابر صفحه، حداکثر شدن تفکیک بین طبقات را حاصل نموده و موجبات بهبود دقت در فرآیند مدل‌سازی را فراهم می‌نماید. به نزدیک‌ترین نقاط آموزشی موجود در حاشیه ابر صفحه، بردارهای پشتیبان اطلاق گردیده و از آن‌ها برای مشخص کردن مرز بین طبقات استفاده می‌شود (Shin *et al.*, 2005).

تفاوت اساسی این روش با طبقه‌بندی کننده‌های مرسوم آماری در قابلیت پردازش و طبقه‌بندی داده‌های ابرطیفی بوده و دیگر کاهش تعداد باندها در فرآیندهای مختلف مدل‌سازی نیاز نمی‌باشد. همچنین در این روش با استفاده از یک الگوریتم بهینه-سازی تعداد نمونه‌های مورد نیاز برای تشکیل مرزهای کلاس‌ها به دست آمده و یک مرز تصمیم‌گیری خطی بهینه برای جداسازی کلاس‌ها محاسبه می‌شود. اگر داده‌ها به صورت خطی و جدا از هم باشند، SVM با استفاده از ماشین‌های خطی یک سطح بهینه را با کم‌ترین خطا و حداکثر فاصله میان صفحه و نزدیک‌ترین نقاط آموزشی (بردارهای پشتیبان) تفکیک نموده و آموزش می‌دهد (Shin *et al.*, 2005).

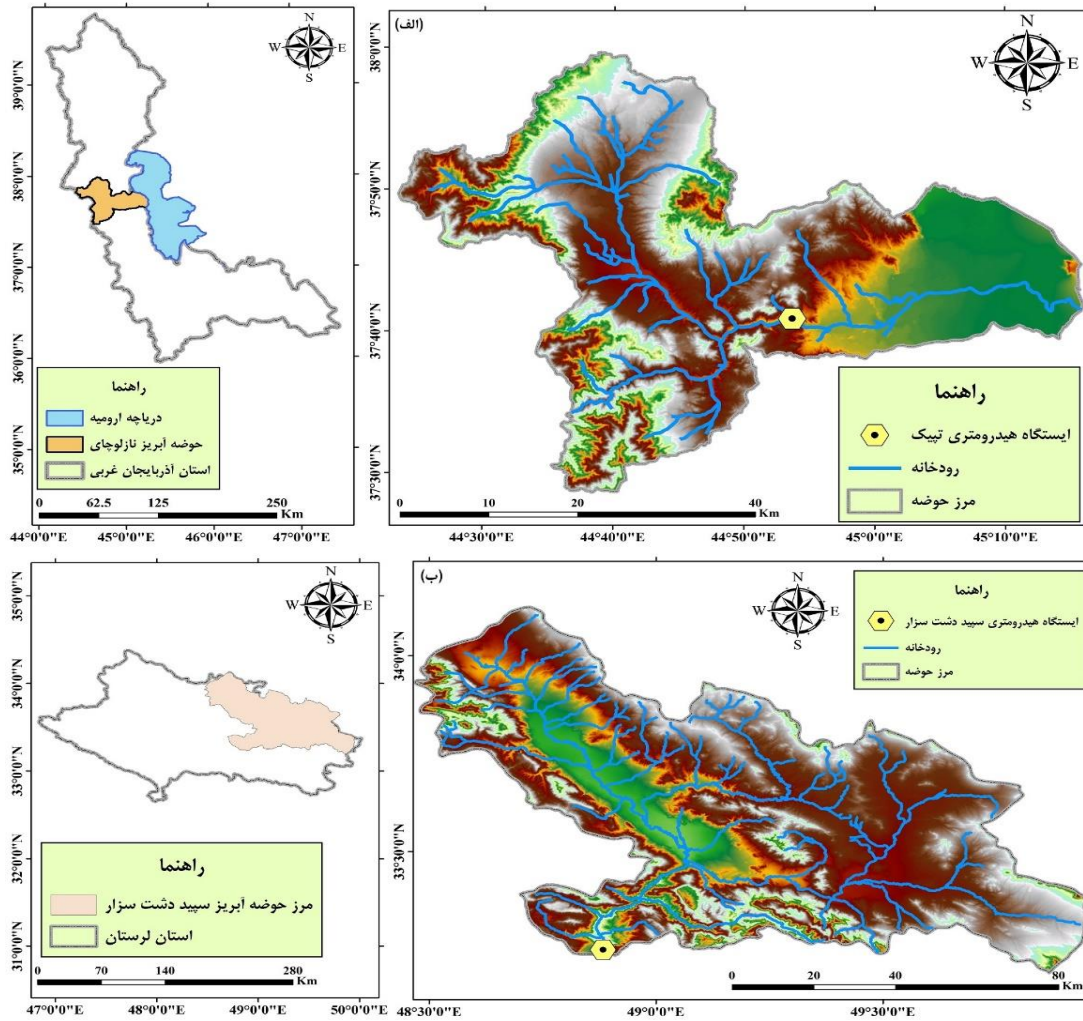
استفاده می‌شود. همچنین در این مطالعه دو حوضه آبریز نازلوچای و سپید دشت سزار در طول و عرض‌های جغرافیایی متفاوت مورد بررسی قرار می‌گیرد تا تاثیر شرایط آب و هوایی نیز در انتخاب تابع کرنل بهینه در مدل SVM سنجیده شود.

مواد و روش‌ها

داده‌ها و منطقه مورد مطالعه

در این پژوهش از اطلاعات ایستگاه‌های آبریز دو حوضه آبریز سپید دشت سزار (از سرچشمه‌های مهم حوضه آبریز دز) و نازلوچای (از رودخانه‌های مهم منتهی به حوضه آبریز دریاچه ارومیه) در مقیاس زمانی ماهانه و در طول دوره آماری ۱۳۳۵ تا ۱۳۹۵ استفاده گردید. رودخانه نازلوچای از آب‌های خطالرأس بلندی‌های مرزی ایران و ترکیه آغاز شده و سرچشمه مهم آن، سروچای است که خود از دو شاخه سرو و برادوست تشکیل شده است. در طول راه رودخانه مارمیشو که آن‌هم از خاک ترکیه جریان دارد، خود را به نازلوچای می‌رساند. پس از طی مسافتی نام رودخانه مارمیشو به آذرین رود تبدیل می‌شود. بخشی از آب رودخانه به مصرف آبیاری باغ‌ها و تاکستان‌ها و کشتزارهای توتون، چغندر قند و غلات و حبوبات دهستان نازلوم می‌رسد. نازلوچای مسیر جاده تبریز به ارومیه را قطع کرده، مازاد آب آن تشکیل دلتایی را داده و در نهایت وارد دریاچه ارومیه می‌گردد. در شکل (۱-الف) وضعیت شبکه آبراهه‌ها و ایستگاه هیدرومتری منتخب به همراه موقعیت قرارگیری این حوضه در استان آذربایجان غربی ارائه شده است.

حوضه آبریز سپید دشت سزار، یکی از زیرحوضه‌های بزرگ رودخانه دز با مساحت ۷۱۷۴ کیلومتر مربع می‌باشد. ایستگاه آبریز این حوضه در شهر سپید دشت و در فاصله حدود ۱۰۰ متری بالادست محل تلاقی دو شاخه زاز و سزار قرار دارد (Mozaian *et al.*, 2015). رودخانه سزار یکی از رودخانه‌های دائمی و پرآب استان لرستان است. این رودخانه که سرشاخه اصلی رود دز در استان خوزستان است از مناطق کوهستانی الیگودرز، ازنا، دورود، و بروجرد سرچشمه می‌گیرد. رودخانه سزار از به هم پیوستن دو رودخانه ماربره (که از به هم پیوستن آب‌های الیگودرز، دورود و ازنا تشکیل می‌شود) و رودخانه تیره (که آب‌های گله‌رود، سراب سفید، کرتول و چند رود دیگر را دریافت می‌کند) در شهر دورود تشکیل می‌شود که از این محل تا ایستگاه تنگ پنج که با رودخانه بختیاری تلاقی می‌کند سزار



شکل ۱- الف) حوضه آبریز نازلوچای و ب) حوضه آبریز سپید دشت سزار به همراه ایستگاه‌های مورد مطالعه

جدول ۱- خصوصیات فیزیوگرافی و هیدرولوژیکی حوضه‌های آبریز مورد مطالعه (۱۳۹۵-۱۳۳۵)

ردیف	پارامتر	حوضه آبریز سپید دشت سزار	حوضه آبریز نازلوچای
۱	میانگین آبدهی در محل ایستگاه هیدرومتری (MCM)	۱۳۰۲/۷۵	۳۷۳/۵۰
۲	مساحت تحت پوشش ایستگاه هیدرومتری (Km ²)	۷۱۴۰/۲	۱۲۶۳/۴۸
۳	مساحت کل حوضه (Km ²)	۷۱۴۷/۵	۱۵۴۴/۲۲
۴	محیط کل حوضه (Km)	۵۳۸/۳۹	۲۶۶/۰۹
۵	طول شاخه اصلی (Km)	۲۰۱/۷۰	۱۱۲/۱۷
۶	حداقل ارتفاع حوضه (m)	۹۷۱/۳۰	۱۲۸۰/۷۰
۷	حداکثر ارتفاع حوضه (m)	۴۰۱۵/۲۵	۳۶۰۳/۴۰
۸	متوسط ارتفاع حوضه (m)	۲۰۹۳/۷۵	۱۹۰۴/۰۰

بیان می‌باشد:

$$Y = \text{sgn}(\sum_{i=1}^N y_i a_i (X \times X_i) + b) \quad (\text{رابطه ۱})$$

که در رابطه فوق Y خروجی رابطه، y_i ارزش طبقه نمونه X_i و a_i و b پارامترهای تعیین کننده ابر صفحه می‌باشند. اگر امکان تفکیک داده‌ها به صورت خطی فراهم نباشد، در این صورت رابطه

اگر نقاط آموزشی را به صورت $[x_i, y_i]$ و بردار ورودی حائر شرط $x_i \in R^n$ باشد، در این صورت ارزش هر طبقه به صورت $y_i \in \{-1, 1\}$ $i = 1, \dots, i$ تعریف می‌گردد. آنگاه قواعد تصمیم‌گیری که تعریف می‌شود توسط یک صفحه بهینه که طبقات تصمیم‌گیری را تفکیک می‌کند، به صورت رابطه (۱) قابل

(۱) به شرح زیر تغییر می‌یابد:

$$Y = \text{sgn}(\sum_{i=1}^N y_i a_i K(X \times X_i) + b) \quad (\text{رابطه ۲})$$

در این رابطه $K(X \times X_i)$ تابع کرنلی است که برای ایجاد ماشین‌های بردار پشتیبان با حالت‌های مختلف از سطوح تصمیم‌گیری غیرخطی در فضای داده‌ها، ضرب‌های داخلی تولید کرده و بدین منظور نیاز به تعریف معادله خط می‌باشد. معادله خط در فضای دوبعدی با استفاده از رابطه (۳)، معادله صفحه از رابطه (۴) و معادله صفحه نمایش از رابطه (۵) محاسبه می‌گردد (Chen et al., 2002).

$$w_1 x_1 + w_2 x_2 + b = 0 \quad (\text{رابطه ۳})$$

$$w_1 x_1 + w_2 x_2 + w_3 x_3 + b = 0 \quad (\text{رابطه ۴})$$

$$(\text{رابطه ۵})$$

$$\sum_{i=1}^n w_i x_i + b = 0 \rightarrow w^T x + b = 0, \quad w = \begin{bmatrix} w_1 \\ \vdots \\ w_i \end{bmatrix} \quad x = \begin{bmatrix} x_1 \\ \vdots \\ x_i \end{bmatrix}$$

در شکل (۲) خط پرنگ ممتد با معادله $w^T x + b = 0$ به‌عنوان خط تفکیک کننده داده‌ها در صفحه بوده و آن‌ها را به دو دسته A و B تقسیم نموده است. این خط فضایی را تشکیل می‌دهد که در آن داده‌های متعلق به دسته A عدد مثبت و داده‌های متعلق به دسته B عدد منفی به خود بگیرند. اما در SVM علاوه بر استفاده از خط جدا کننده از یک حاشیه اطمینان نیز برای دسته‌بندی استفاده می‌شود (شکل ۲). در این حالت هیچ یک از داده‌ها اجازه قرارگیری در ناحیه میانی را ندارند. با فرض اینکه خط با معادله $w^T x + b = 0$ نقطه صفر مرزی است بنابراین برای داده‌ها بسته به موقعیت قرارگیری در کلاس‌های A و B به ترتیب معادلات $w^T x + b > 1$ و $w^T x + b < -1$ برقرار است. ضخامت تفکیک کننده در SVM یک ناحیه را شامل شده و سبب می‌گردد که فرآیند طبقه‌بندی در مقابل وجود ریسک برآزش اشتباه مقاوم‌تر شود (Foroudi Khour et al., 2017).

در مسائلی که داده‌ها به‌طور خطی تفکیک‌پذیر نباشند، می‌توان با نگاشت داده‌ها به یک فضای ویژگی، آن‌ها را به‌صورت خطی جداپذیر نمود. در حالت کلی ابعاد این فضا بی‌نهایت بوده، بنابراین انجام محاسبات در فضای ویژگی می‌تواند پرهزینه باشد. برای غلبه بر این مشکل از توابع کرنل استفاده می‌شود، در نتیجه معادله صفحه تفکیک کننده برای حالت غیرخطی با دخالت تابع کرنل $K(X)$ به‌صورت رابطه زیر می‌باشد (Chen et al., 2002):

$$w^T x + b = 0 \rightarrow w^T K(X) + b = 0 \quad (\text{رابطه ۶})$$


که در رابطه فوق تابع $K(X)$ با انجام نگاشت، داده‌ها را از فضای غیرخطی به یک فضای خطی منتقل می‌نماید. می‌توان این تابع را به‌صورت $K(X_i, X_j)$ نیز تعریف نموده و به‌وسیله آن فضاهای پیچیده‌تری را مورد بررسی قرار داد. به این فرآیند ترنند کرنل اطلاق می‌گردد. در مدل انتخاب تابع کرنل بسیار مهم بوده و در مسایل مختلف با توجه به ماهیت مسئله می‌توان موارد متفاوتی را در نظر گرفت. بنابراین نمی‌توان تابعی را به‌طور قطعی به‌عنوان تابع مناسب برای SVM معرفی کرد. انواع مختلف تابع در جدول (۲) ارائه شده است. تابع کرنل خطی، حالت خاصی از تابع کرنل چندجمله‌ای بوده و در مسایل ساده‌تر کارایی خوبی از خود نشان می‌دهد ولی در مسایل پیچیده تابع کرنل چندجمله‌ای می‌تواند بسیار مفیدتر باشد. در تابع کرنل چندجمله‌ای پارامتر d باید از طرق آزمون و خطا یا از طریق الگوریتم‌های بهینه‌سازی محاسبه شود. تابع کرنل گوسی یا شعاعی (RBF) نوع دیگری از توابع کرنل بوده و معمولاً در مسائلی به کار برده می‌شود که هیچ‌گونه شناختی از نوع و ماهیت داده‌ها در دسترس نباشد. به‌طور کلی در توابع کرنل می‌باید مقادیر بهینه ضرایب c, d, ε و γ برآورد گردد.

جدول ۲- توابع کرنل رایج در ماشین‌های بردار پشتیبان (Hamel, 2009)

نوع تابع	تابع کرنل
خطی	$K(X_i, X_j) = X_i^T \times X_j$
چند جمله ای	$K(X_i, X_j) = (\gamma X_i^T \times X_j + C)^d$
تانژانت هیپربولیک	$K(X_i, X_j) = \tanh(\gamma X_i^T \times X_j + C)$
RBF	$K(X_i, X_j) = -\exp(-\gamma X_i - X_j ^2)$

روش شبکه‌های عصبی - فازی تطبیقی

سیستم استنتاجی عصبی- فازی تطبیقی از جمله روش‌هایی است که در تحلیل پدیده‌های غیرخطی و بررسی رابطه بین ورودی- خروجی در سیستم‌های چند پارامتری، به کار گرفته می‌شود. بخش فازی مدل ANFIS رابطه‌ای بین متغیرهای ورودی و خروجی برقرار نموده که اصطلاحاً تابع عضویت نامیده می‌شود. به‌طور کلی در جعبه ابزار منطق فازی دو نوع سامانه فازی موسوم



شکل ۲- نمایش گرافیکی بردارهای پشتیبان

اگر خروجی هر لایه به صورت Q_i^1 در نظر گرفته شود که در i امین گره از لایه اول باشد، در این صورت مدل ANFIS پنج لایه زیر را شامل می‌گردد:

لایه اول، گره‌های ورودی: هر گره این لایه یک مجموعه فازی است و خروجی هر گره در این لایه درجه عضویت متغیر ورودی در این مجموعه فازی است که با استفاده از تابع عضویت مشخص می‌گردد.

$$Q_i^1 = \mu_{A_i}(x) \quad i = 1,2 \quad (\text{رابطه ۹})$$

$$Q_i^1 = \mu_{B_i}(y) \quad i = 3,4 \quad (\text{رابطه ۱۰})$$

پارامترهای هر گره تعیین کننده شبکه تابع عضویت مجموعه فازی آن گره است. تابع عضویت مجموعه‌های فازی معمولاً توسط توابع زنگوله‌ای شکل به صورت رابطه (۱۱) بیان می‌شود.

$$\mu_{A_i} = \frac{1}{1 + [(x_i - c_i)/a_i]^{2b_i}} \quad (\text{رابطه ۱۱})$$

که در آن X مقدار ورودی به گره i و a_i, b_i, c_i پارامترهای تابع عضویت این مجموعه است. این پارامترها به نام پارامترهای شرط نامیده می‌شوند.

به الف) سامانه استنتاجی ممدنی^۱ و ب) سامانه استنتاجی نوع سوگنو^۲ وجود دارد. تفاوت اصلی آن‌ها در تابع عضویت است. همچنین خروجی در روش ممدانی غیرخطی است ولی در روش سوگنو خطی یا ثابت است.

اگر فرض کنیم یک سامانه استنتاجی-فازی دو ورودی x و y و یک خروجی Z داشته باشد، مدل فازی مرتبه اول سوگنو با دو قانون فازی اگر-آنگاه به صورت زیر بیان می‌شود (Falehi, 2018):


قانون ۱- اگر x برابر A_1 و y برابر B_1 باشد آنگاه:

$$f_1 = p_1x + q_1y + r_1 \quad (\text{رابطه ۷})$$

قانون ۲- اگر x برابر A_2 و y برابر B_2 باشد آنگاه:

$$f_2 = p_2x + q_2y + r_2 \quad (\text{رابطه ۸})$$

در روابط فوق A_1, A_2, B_1, B_2 به ترتیب توابع عضویت برای ورودی‌های x و y بوده که شامل توابع گوسی، مثلثی و غیره بوده و $p_1, q_1, r_1, p_2, q_2, r_2$ نیز پارامترهای خروجی می‌باشند. در شکل (۳) مدل فازی مرتبه اول نوع سوگنو با دو ورودی (x, y) ، یک خروجی f به همراه دو قانون فازی و همچنین مدل ANFIS معادل آن نشان داده شده است.



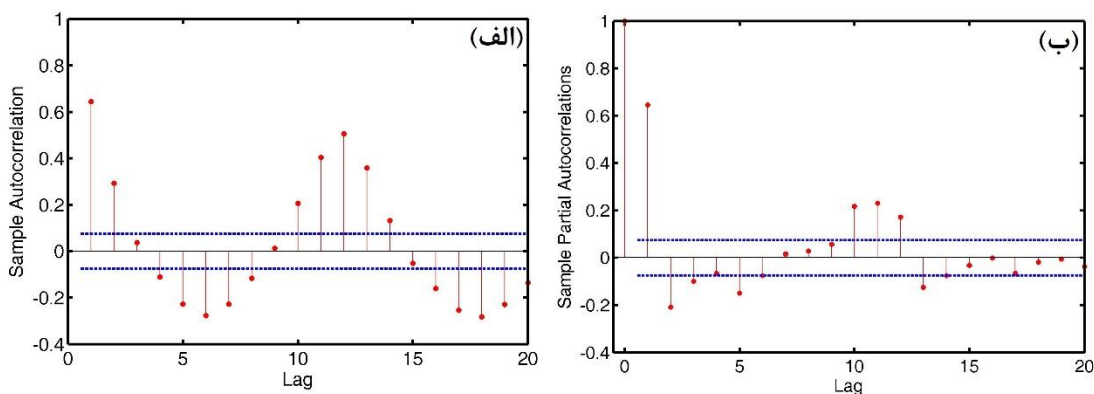
شکل ۳- مدل فازی مرتبه اول نوع سوگنو (a) با دو ورودی (x و y) و یک خروجی f به همراه دو قانون فازی و (b) مدل ANFIS معادل آن (Falehi, 2018)

لایه سوم، گره‌های متوسط: در این لایه نامین گره، نسبت درجه فعالیت قانون نام را به مجموع درجه فعالیت کلیه قوانین به صورت رابطه (۸) نرمال سازی می‌کند که در آن w_i^n درجه فعالیت نرمال شده قانون نام است.

لایه دوم، گره‌های قاعده: هر گره در این لایه درجه فعالیت یک قانون را محاسبه می‌کند و به صورت رابطه زیر نوشته می‌شود که در آن w_i^n درجه فعالیت نرمال شده قانون نام است.

$$Q_i^2 = w_i = \mu_{A_i}(x) \times \mu_{B_i}(y) \quad i = 1,2 \quad (\text{رابطه ۱۲})$$

ANFIS استفاده گردید. بدین منظور نمودارهای خودهمبستگی و خودهمبستگی جزئی سری‌های زمانی جریان در حوضه‌های آبریز مورد مطالعه رسم و مورد بررسی قرار گرفت. با توجه به شکل (۴-۴) الف) مشاهده می‌شود که در ایستگاه سپید دشت سزار خاصیت تناوبی در جریان این رودخانه وجود دارد. در اغلب مطالعات انجام شده بیشتر به رابطه خطی موجود در بین داده‌های ورودی به مدل‌ها تاکید شده و رابطه تناوبی چندان مورد توجه قرار نگرفته است؛ از این رو، در مطالعه حاضر از عبارتهای $\cos[2\pi \cdot i/12]$ و $\sin[2\pi \cdot i/12]$ برای بسط اثر خاصیت پریودیک جریان استفاده شده است (Lohani et al., 2012). شکل (۴-ب) نمودار PACF جریان رودخانه سپید دشت سزار را نشان می‌دهد. با توجه به این شکل می‌توان چنین استنباط کرد که ضرایب خودهمبستگی جزئی تا سه تاخیر زمانی معنی‌دار بوده و تاخیر چهارم در باند اطمینان واقع می‌شود بنابراین برای حصول اطمینان از فرایند مدل‌سازی جریان رودخانه در دو حوضه، تا چهار گام تاخیر زمانی برای ایجاد الگوهای ورودی انتخاب گردید. در جدول (۳) نیز الگوهای مختلف ورودی در دو حالت استاندارد و پریودیک ارائه شده است.



شکل ۴- الف) نمودارهای ACF و ب) نمودارهای PACF سری زمانی جریان رودخانه سپید دشت سزار

جدول ۳- الگوهای مختلف ورودی به مدل‌های مورد استفاده در دو حالت پریودیک و استاندارد

حالت ورودی داده‌ها	ردیف	الگو	آرایش الگوی ورودی
	۱	M1	$Q_t = f(Q_{t-1})$
حالت استاندارد (بدون در نظر گرفتن اثر پریودیک)	۲	M2	$Q_t = f(Q_{t-1}, Q_{t-2})$
	۳	M3	$Q_t = f(Q_{t-1}, Q_{t-2}, Q_{t-3})$
	۴	M4	$Q_t = f(Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4})$
	۵	M5	$Q_t = f(Q_{t-1}, \cos[2\pi \cdot i/12], \sin[2\pi \cdot i/12])$
حالت پریودیک (با در نظر گرفتن ترم‌های تناوبی)	۶	M6	$Q_t = f(Q_{t-1}, Q_{t-2}, \cos[2\pi \cdot i/12], \sin[2\pi \cdot i/12])$
	۷	M7	$Q_t = f(Q_{t-1}, Q_{t-2}, Q_{t-3}, \cos[2\pi \cdot i/12], \sin[2\pi \cdot i/12])$
	۸	M8	$Q_t = f(Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, \cos[2\pi \cdot i/12], \sin[2\pi \cdot i/12])$

$$Q_i^3 = w_i^n \frac{w_i}{w_1 + w_2} \quad i = 1, 2 \quad (\text{رابطه } 13)$$

لایه چهارم، گره‌های نتیجه: در این لایه خروجی هر گره برابر است با:
(رابطه ۱۴)

$$Q_i^4 = w_i^n \times f_i = w_i^n \times (p_i + q_i + r_i) \quad i = 1, 2$$

لایه پنجم، گره‌های خروجی: در این لایه هر گره مقدار خروجی نهایی را به صورت رابطه (۱۵) محاسبه می‌نماید (Falehi, 2018):

$$Q_i^5 = \sum_{i=1}^n w_i^n \times f_i \quad (\text{رابطه } 15)$$

تعیین الگوی ورودی برای مدل‌ها

در فرایند مدل‌سازی انتخاب داده‌های اولیه و تاثیرگذار در پدیده به منظور آموزش ماهیت‌ساز و کار حاکم بر آن بسیار حائز اهمیت بوده و بهبود عملکرد مدل را به همراه خواهد داشت. از طرفی افزایش تعداد ورودی‌ها نه تنها سبب پیچیدگی الگو و افزایش حافظه درگیر خواهد شد، بلکه سبب کاهش دقت نیز می‌گردد. بنابراین در پیش‌بینی جریان رودخانه بایستی سعی نمود موثرترین داده‌های مشاهداتی را به عنوان داده‌های آموزشی انتخاب کرد. در این مطالعه برای پیش‌بینی جریان ماه جاری، از داده‌های جریان ماه‌های قبل به عنوان ورودی مدل‌های SVM و

همچنین قسمت‌های انتهایی خطوط قائم در قسمت فوقانی و تحتانی به ترتیب حداکثر و حداقل بوده و بیانگر مقدار خطا برای الگوهای مختلف ورودی کرنل‌های مدل SVM می‌باشد. با توجه به این شکل مشاهده می‌شود که در رودخانه‌های سپید دشت سزار و نازلو، تابع کرنل خطی ضعیف‌ترین عملکرد را به خود اختصاص داده است. دامنه تغییرات شاخص RMSE با کرنل خطی برای مرحله آموزش، در ایستگاه تپیک بین ۷ تا ۹ متر مکعب در ثانیه متغیر می‌باشد؛ حال آنکه این مقدار در همان ایستگاه برای تابع کرنل RBF بین ۵ تا ۷ متر مکعب در ثانیه به دست آمده است. این شرایط در ایستگاه سپید دشت سزار نیز صادق بوده و بنابراین می‌توان چنین استنباط کرد که تابع کرنل خطی از توانایی لازم برای پیش‌بینی جریان ماهانه رودخانه برخوردار نیست. نتایج مشابهی نیز توسط Isazadeh *et al.* (2016) و Foroudi Khour *et al.* (2017) گزارش شده است. همچنین با توجه به این شکل مشاهده می‌شود که شرایط رودخانه (شامل مساحت تحت پوشش و موقعیت جغرافیایی قرارگیری آن) در عملکرد تابع کرنل تاثیرگذار بوده، به طوری که در حوضه نازلوچای دامنه تغییرات خطای دو تابع کرنل چندجمله‌ای و RBF تقریباً یکسان به دست آمده اما در حوضه سزار تابع کرنل RBF با خطای بسیار کمتری نسبت به سایر توابع جریان رودخانه را برآورد می‌نماید و این امر نشان می‌دهد که از بین توابع کرنل موجود، تابع RBF فارغ از شرایط حوضه از عملکرد بهتری در پیش‌بینی جریان ماهانه رودخانه برخوردار است.

نتایج شاخص‌های آماری حاصل از مدل SVM با تابع کرنل RBF در پیش‌بینی جریان ماهانه رودخانه‌های سزار و نازلو در دو حالت استاندارد و پریودیک در جدول (۴) ارائه شده است. از نتایج این جدول چنین بر می‌آید که دقت مدل‌سازی در تمامی حالات رفته رفته تا سه تاخیر زمانی دبی رو به بهبود بوده و بعد از آن کاهش پیدا می‌کند. همچنین استفاده از ترم پریودیک نیز توانسته است عملکرد مدل SVM را به طور قابل ملاحظه‌ای بهبود بخشیده و در نتیجه بالاترین دقت و کمترین خطا با سه تاخیر زمانی و ترم پریودیک یا همان الگوی M7 حاصل گردد. یافته‌های این پژوهش با نتایج Lohani *et al.* (2012) مطابقت دارد به طوری که نتایج ایشان تاثیر ترم پریودیک را در افزایش دقت مدل‌های هوشمند تایید کرده‌اند. در شکل (۶) نمودارهای پراکندگی و گرافیکی حاصل از مدل SVM-RBF برای الگوی M7 در محل ایستگاه‌های تپیک و سپید دشت سزار ارائه شده است.

ارزیابی مدل‌ها

در این تحقیق، برای ارزیابی مدل‌های موردنظر از معیارهای جذر میانگین مربعات خطا (RMSE)، نش-ساتکلیف (NS) و میانگین قدر مطلق خطای نسبی^۱ (MARE) استفاده می‌شود:

$$RMSE = \left[\frac{\sum_{i=1}^n (O_i - P_i)^2}{n} \right]^{0.5} \quad (\text{رابطه ۱۶})$$

$$NS = 1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (\text{رابطه ۱۷})$$

$$MARE = \frac{\sum_{i=1}^n \left| \frac{O_i - P_i}{O_i} \right|}{n} \quad (\text{رابطه ۱۸})$$

که در روابط فوق O_i مقادیر مشاهداتی، P_i مقادیر پیش‌بینی شده، \bar{O} میانگین جریان مشاهداتی و n تعداد داده‌ها می‌باشد. هر چه مقادیر RMSE و MARE کمتر و مقدار NS به یک نزدیک‌تر باشد، نتایج دقیق‌تر و قابل اعتمادتر خواهند بود.

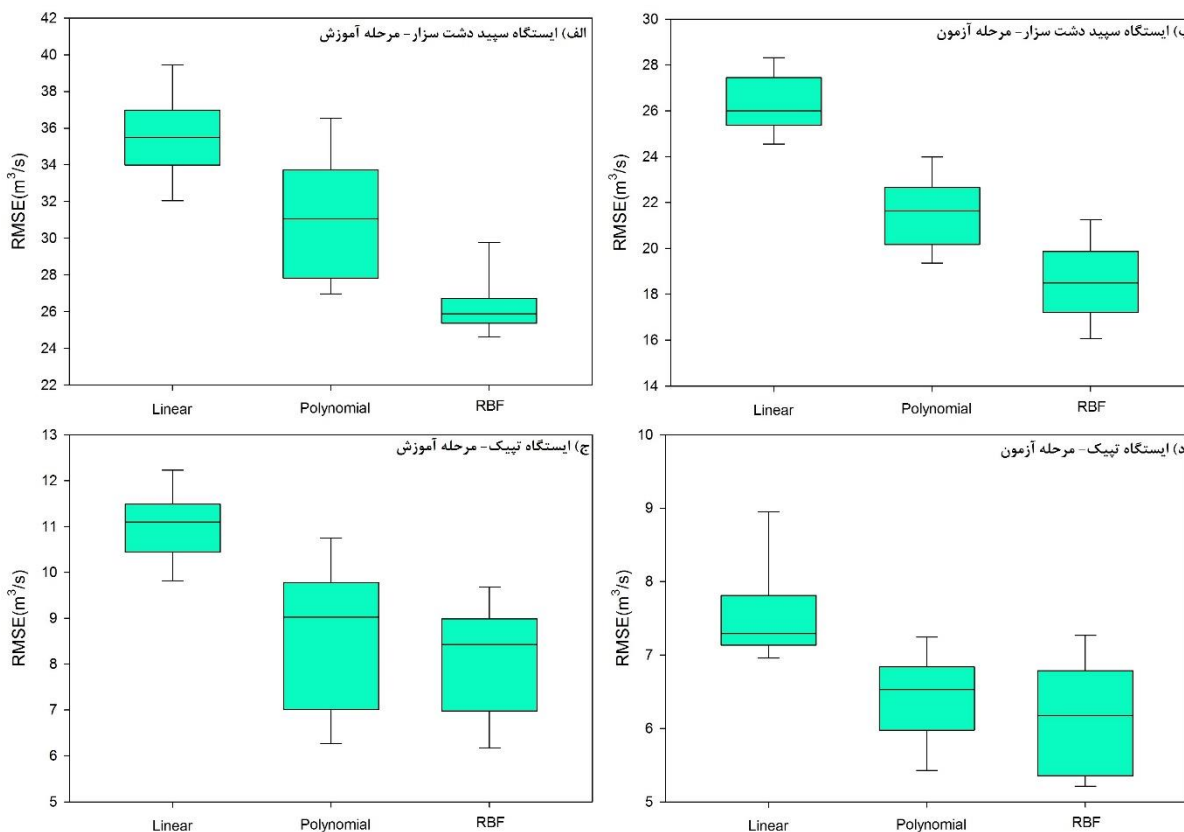
نتایج و بحث

انتخاب تابع کرنل و مدل‌سازی با استفاده از روش SVM

همانگونه که ذکر گردید یکی از اهداف مطالعه حاضر تعیین تابع کرنل مناسب در برآورد جریان ماهانه رودخانه می‌باشد. بدین منظور سه تابع کرنل خطی، چندجمله‌ای و RBF مورد استفاده قرار گرفت. همچنین برای مدل‌سازی جریان ماهانه ۸۰ درصد داده‌ها برای آموزش (از مهر ۱۳۳۵ تا شهریور ۱۳۸۳ به مدت ۵۷۶ ماه) و ۲۰ درصد برای صحت‌سنجی (از مهر ۱۳۸۳ تا شهریور ۱۳۹۵ به مدت ۱۴۴ ماه) در نظر گرفته شد.

هریک از توابع کرنل مورد استفاده داری ضرایبی هستند که می‌باید به صورت بهینه محاسبه شود. در این مطالعه بنا به توصیه Chen and Yu (2007) از الگوریتم اصلاح شده جستجوی شبکه دو مرحله‌ای^۲ به همراه اعتبارسنجی متقاطع^۳ استفاده شد. برای این منظور ابتدا با انتخاب شبکه‌هایی با ابعاد بزرگ محدوده مشخصه‌های ϵ ، d و c به ازای مقدار ثابت γ تعیین شد. سپس با مشخص شدن محدوده مذکور و تقسیم آن به شبکه‌هایی با ابعاد ریزتر مقادیر دقیق ضرایب تعیین گردیده و روند مذکور برای دیگر مقادیر γ تکرار و فرآیند مدل‌سازی تکمیل شد.

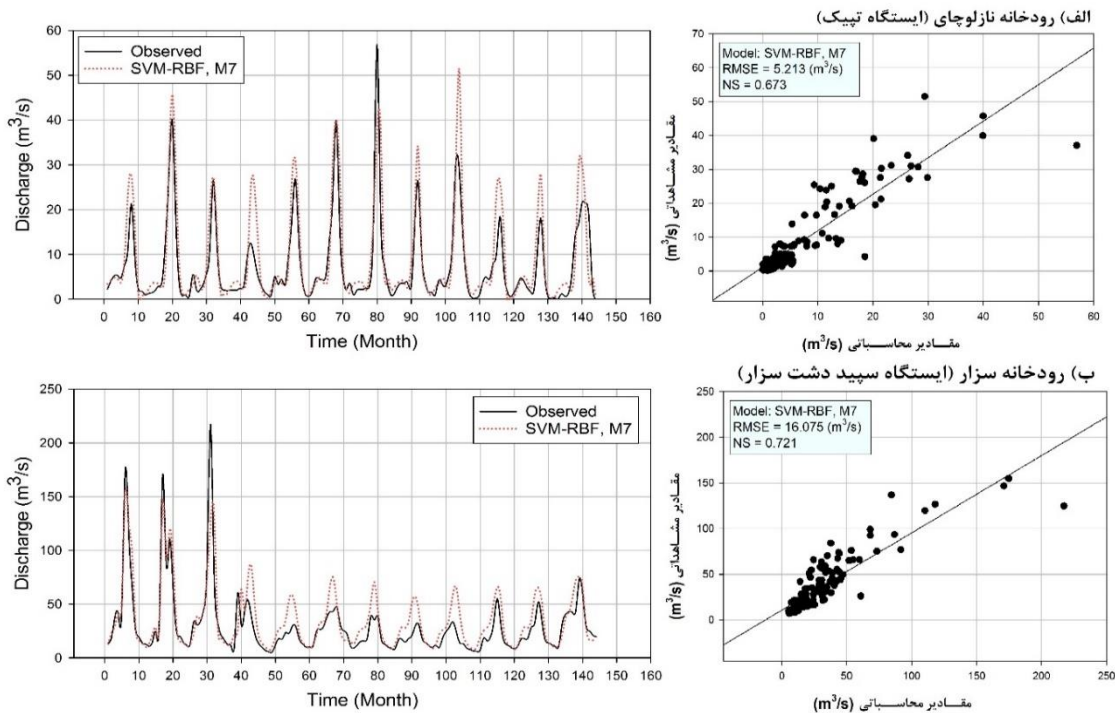
در شکل (۵) نمودار جعبه‌ای شاخص RMSE حاصل از عملکرد کرنل‌های مختلف مدل SVM در برآورد جریان رودخانه برای دو مرحله آموزش و صحت‌سنجی ارائه شده است. در این شکل خط رسم شده در داخل مستطیل‌های میانه RMSE الگوهای مختلف ورودی می‌باشد. عرض مستطیل‌ها در قسمت فوقانی صدک ۷۵ و در قسمت تحتانی صدک ۲۵ را نشان می‌دهد.



شکل ۵- نمودار جعبه‌ای شاخص RMSE برای توابع مختلف کرنل مدل SVM در دو مرحله آموزش و آزمون

جدول ۴- تحلیل‌های آماری نتایج مدل SVM با تابع کرنل RBF برای الگوهای ورودی جریان ماهانه رودخانه‌های مورد مطالعه

مرحله آزمون			مرحله آموزش			الگوی ورودی	رودخانه	تابع کرنل
MARE	NS	RMSE (m³/s)	MARE	NS	RMSE (m³/s)			
۱/۱۱۹	۰/۴۰۱	۷/۲۹۶	۰/۶۰۱	۰/۶۶۳	۹/۶۸۱	M1	نازلو	RBF
۰/۵۷۵	۰/۶۰۲	۰۲۱/۲۵۹	۰/۴۶۵	۰/۵۷۴	۲۹/۷۷۸	M1	سزار	
۰/۸۴۲	۰/۴۸۲	۶/۸۱۲	۰/۵۸۹	۰/۷۷۱	۸/۹۱۵	M2	نازلو	
۰/۴۷۲	۰/۶۷۰	۱۹/۸۹۱	۰/۴۰۲	۰/۶۵۱	۲۶/۳۲۴	M2	سزار	
۰/۷۹۱	۰/۵۳۱	۶/۱۶۳	۰/۵۷۱	۰/۷۹۲	۸/۴۱۵	M3	نازلو	
۰/۴۱۶	۰/۶۹۳	۱۸/۴۳۷	۰/۳۸۹	۰/۶۶۰	۲۵/۵۹۲	M3	سزار	
۰/۸۳۹	۰/۵۹۳	۶/۷۰۳	۰/۶۱۰	۰/۷۳۱	۹/۰۱۲	M4	نازلو	
۰/۴۶۹	۰/۶۷۴	۱۹/۸۰۶	۰/۳۹۱	۰/۶۵۶	۲۵/۹۰۸	M4	سزار	
۰/۷۸۳	۰/۶۱۷	۶/۱۸۷	۰/۵۹۴	۰/۷۸۹	۸/۴۴۱	M5	نازلو	
۰/۴۲۳	۰/۶۸۹	۱۸/۵۵۱	۰/۴۱۶	۰/۶۴۲	۲۶/۸۶۱	M5	سزار	
۰/۷۳۴	۰/۶۴۷	۵/۵۴۹	۰/۵۲۹	۰/۸۰۱	۷/۳۶۵	M6	نازلو	
۰/۴۰۹	۰/۷۱۰	۱۷/۱۳۵	۰/۳۸۴	۰/۶۶۵	۲۵/۲۹۴	M6	سزار	
۰/۶۹۹	۰/۶۷۳	۵/۲۱۳	۰/۴۵۲	۰/۸۶۲	۶/۱۷۰	M7	نازلو	
۰/۳۸۷	۰/۷۲۱	۱۶/۰۷۵	۰/۲۷۴	۰/۶۷۶	۲۴/۶۲۶	M7	سزار	
۰/۷۱۵	۰/۶۵۱	۵/۳۱۰	۰/۵۱۶	۰/۸۲۴	۶/۸۵۲	M8	نازلو	
۰/۴۲۶	۰/۷۰۱	۱۷/۴۲۱	۰/۳۹۲	۰/۶۶۱	۲۵/۸۵۷	M8	سزار	



شکل ۶- نمودارهای پراکندگی و گرافیکی حاصل از مدل SVM برای الگوی M7 در محل ایستگاه الف (تپیک و ب) سپید دشت سزار در مرحله آزمون (دوره آماری ۱۳۸۲ تا ۱۳۹۵)

نتایج مدل سازی ANFIS

در مطالعه حاضر برای مدل سازی جریان ماهانه رودخانه های مورد مطالعه با استفاده از مدل ANFIS، ۸۰ درصد داده ها برای آموزش و ۲۰ درصد برای صحت سنجی در نظر گرفته شد. الگوهای ورودی برای مدل سیستم استنتاج عصبی-فازی تطبیقی نیز به مانند روش ماشین بردار پشتیبان انتخاب شد تا هر دو روش به کار رفته از شرایط یکسانی در اطلاعات دریافتی برخوردار باشند و امکان مقایسه هرچه بهتر دو مدل فراهم گردد.

به منظور مدل سازی جریان ماهانه رودخانه های مورد مطالعه توسط مدل ANFIS از توابع عضویت مختلف نظیر تابع عضویت مثلثی، تابع عضویت گوسی، تابع عضویت ذوزنقه ای و تابع عضویت مستطیلی استفاده و نتایج نهایی تعداد و نوع تابع عضویت بهینه در جدول (۵) ارائه شده است. در این مطالعه تعداد توابع عضویت از طریق آزمون خطا به دست آمده و بر اساس پیشنهاد روسل و کامبل (۱۹۶۹) بین یک تا چهار در نظر گرفته شد.

جدول (۵) مقایسه شاخص های آماری مربوط به نتایج حاصل از کاربرد روش سیستم استنتاج عصبی فازی تطبیقی را در مدل سازی جریان ماهانه رودخانه های مورد مطالعه، برای الگو- های مختلف ورودی نشان می دهد. با توجه به این جداول مشاهده می شود که چنانچه اثر خاصیت تناوبی داده ها در پیش بینی دخالت داده نشود و فقط از توالی دیبی ها استفاده گردد، رفته رفته دقت در مدل سازی افزایش یافته و برای رودخانه نازلوچای از تاخیر چهارم و در رودخانه سزار از تاخیر سوم به بعد عملکرد مدل

ANFIS کاهش می یابد. با در نظر گرفتن اثر ترم پریودیک و استفاده از توالی توام دیبی های ماهانه، عملکرد مدل بسیار بهبود یافته و با توجه به شاخص های RMSE، NS و MARE ارائه شده در جدول (۵) مشاهده می شود که مدل ANFIS برای رودخانه نازلوچای (سزار) با ورودی های دیبی یک تا سه ماه قبل و ترم پریودیک (M7) (دبی تا دو ماه قبل و ترم پریودیک (M6)) بهترین عملکرد را داشته است. در شکل (۷) نمودارهای پراکندگی و گرافیکی حاصل از مدل ANFIS برای الگوی M7 و M6 به ترتیب در محل ایستگاه های تپیک و سپید دشت سزار ارائه شده است.

مقایسه عملکرد مدل های SVM و ANFIS

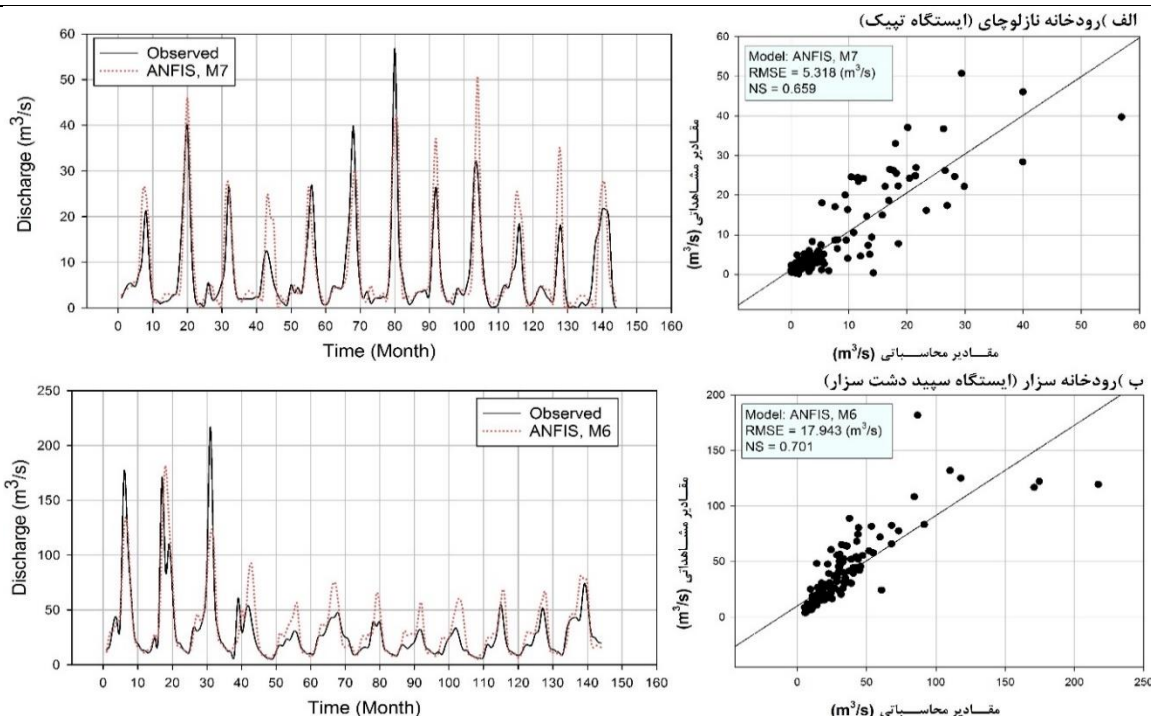
پس از پیش بینی جریان رودخانه های مورد مطالعه در ایستگاه های تپیک و سپید دشت سزار با استفاده از دو مدل SVM و ANFIS بهترین مدل به ازای تأخیرهای مختلف جریان ماهانه برای هر یک از آنها با استفاده از شاخص های آماری RMSE، NS و MARE قابل انجام می باشد. بررسی و مقایسه مقادیر شاخص RMSE در مرحله آزمون برای مدل های مورد استفاده نشان می دهد که تک تک مقادیر پیش بینی شده در هر دو مدل تا حدود زیادی با مقادیر اندازه گیری شده مطابقت دارد. مقدار این شاخص آماری برای الگوهای مختلف ورودی در مدل SVM برای رودخانه سزار بین ۱۶/۰۷ تا ۲۱/۲۶ متر مکعب در ثانیه در حال تغییر می باشد، در حالی که این مقدار برای مدل ANFIS بین ۱۷/۹۴ تا ۲۲/۴۳ متغیر است و بنابراین می توان نتیجه گرفت که مدل SVM در

دست آمده مشاهده می‌شود که هر دو مدل به‌ویژه در تخمین جریان‌های کم تا حدودی دچار بیش‌برآورد شده‌اند، اما این بیش-برآورد باعث ناکارآمدی مدل‌ها نمی‌گردد. با این وجود در مدل ANFIS شاخص MARE از مقادیر متناظر مدل SVM بزرگتر بوده و بر این اساس مدل SVM برای پیش‌بینی جریان ماهانه رودخانه‌های مورد مطالعه پیشنهاد می‌گردد.

مقایسه با مدل ANFIS توانسته است با ورودی‌های مختلف مقادیر مشاهداتی را به‌صورت نظیر به نظیر بهتر برآورد نماید. در رودخانه نازلو نیز مدل SVM نسبت به مدل ANFIS از عملکرد مناسب‌تری برخوردار بود. یکی دیگر از شاخص‌های ارزیابی مهم استفاده شده در این تحقیق، شاخص MARE می‌باشد که مقدار اختلاف برآورد مدل را اندازه‌گیری می‌نماید. با توجه به نتایج به

جدول ۵- تحلیل‌های آماری نتایج مدل ANFIS برای الگوهای ورودی جریان ماهانه رودخانه‌های مورد مطالعه

رودخانه	الگوی ورودی	تابع عضویت	تعداد تابع عضویت	مرحله آموزش			مرحله تست		
				MARE	NS	RMSE (m ³ /s)	MARE	NS	RMSE (m ³ /s)
نازلو	M1	مثلثی	۳	۱/۱۲۰	۰/۴۳۴	۷/۷۵۹	۱/۲۶۴	۰/۶۰۱	۱۰/۵۳۶
سزار	M1	مثلثی	۴	۰/۷۵۳	۰/۶۰۴	۲۱/۲۵۴	۰/۸۷۳	۰/۵۶۱	۳۴/۷۵۸
نازلو	M2	مثلثی	۳-۳	۰/۸۳۸	۰/۵۳۴	۶/۲۲۵	۰/۹۸۱	۰/۷۱۲	۸/۸۹۲۱
سزار	M2	گوسی	۲-۳	۰/۵۷۱	۰/۶۸۵	۱۸/۹۶۷	۰/۴۸۱	۰/۶۶۱	۳۲/۲۲۳
نازلو	M3	مثلثی	۳-۳-۳	۰/۸۹۴	۰/۵۱۴	۶/۸۹۴	۱/۱۳۴	۰/۶۸۵	۹/۴۴۱
سزار	M3	مثلثی	۳-۳-۴	۰/۶۹۹	۰/۶۱۹	۱۹/۴۳۸	۰/۸۰۱	۰/۶۲۴	۳۳/۱۱۴
نازلو	M4	گوسی	۳-۳-۳-۳	۰/۹۱۰	۰/۴۶۵	۷/۲۱۹	۱/۱۸۹	۰/۶۲۳	۹/۹۸۲
سزار	M4	گوسی	۳-۴-۴-۲	۰/۷۸۳	۰/۵۹۲	۲۰/۲۳۹	۰/۹۲۱	۰/۵۷۸	۳۳/۵۴۰
نازلو	M5	گوسی	۴	۰/۸۵۵	۰/۵۹۱	۶/۹۵۹	۰/۶۹۶	۰/۷۶۳	۸/۶۲۱
سزار	M5	گوسی	۴	۰/۶۶۹	۰/۶۲۱	۱۹/۴۱۹	۰/۶۲۸	۰/۵۸۴	۲۷/۵۱۱
نازلو	M6	گوسی	۴-۳	۰/۸۱۴	۰/۶۵۹	۵/۳۱۸	۰/۶۲۴	۰/۸۴۲	۶/۷۵۵
سزار	M6	گوسی	۴-۴	۰/۴۲۹	۰/۷۱۸	۱۷/۹۴۳	۰/۴۶۸	۰/۶۱۳	۲۶/۰۲۸
نازلو	M7	گوسی	۳-۴-۳	۰/۸۲۲	۰/۶۳۳	۵/۷۶۵	۰/۶۴۴	۰/۸۱۱	۷/۲۲۱
سزار	M7	گوسی	۴-۳-۴	۰/۵۶۴	۰/۶۸۸	۱۸/۳۳۶	۰/۵۲۹	۰/۶۰۴	۲۶/۸۳۱
نازلو	M8	گوسی	۳-۲-۲-۴	۰/۸۴۴	۰/۶۲۰	۶/۰۵۴	۰/۶۷۱	۰/۷۹۹	۷/۳۹۴
سزار	M8	گوسی	۳-۴-۴-۳	۰/۵۹۸	۰/۶۵۹	۱۹/۹۸۳	۰/۵۵۷	۰/۵۹۱	۲۷/۱۵۳



شکل ۷- نمودارهای پراکندگی و گرافیکی حاصل از مدل ANFIS برای الگوی M7 در محل ایستگاه الف) تپیک و ب) برای الگوی M6 ایستگاه سپید دشت سزار در مرحله آزمون (دوره آماری ۱۳۸۳ تا ۱۳۹۵)

دخالته اثر تناوبی در داده‌ها به بیشترین دقت در برآورد جریان ماهانه رودخانه‌های مورد مطالعه دست یافته است.

با مقایسه عملکرد دو مدل مشاهده می‌گردد که روش SVM نسبت به مدل ANFIS از دقت بهتری در برآورد جریان برخوردار است اما این به شرطی است که تابع کرنل مناسب انتخاب گردد. با توجه به نتایج به دست آمده مشاهده گردید که در رودخانه نازلوچای عملکرد دو تابع کرنل RBF و چندجمله‌ای نزدیک به یکدیگر بود و این امکان وجود دارد که تابع کرنل مناسب برای پیش‌بینی جریان لزوماً از نوع RBF نباشد و این مسئله می‌باید در کاربرد مدل SVM همواره مورد بررسی قرار گیرد.

یکی دیگر از نتایج مهمی که در این مطالعه حاصل شد، تاثیر مثبت استفاده از ترم پریودیک در برآورد جریان ماهانه بود. ترم پریودیک صرفاً براساس یک رابطه ریاضی ساده محاسبه شده و هیچ‌گونه هزینه‌ای را از نظر جمع‌آوری اطلاعات به کاربران تحمیل نمی‌نماید. حال آنکه در اکثر مطالعات برای بهبود دقت و عملکرد مدل‌های هوشمند از داده‌های هیدرولوژیکی دیگر نظیر بارش، دماهای مینیمم، متوسط و ماکزیمم، تبخیر و غیره بهره برده می‌شود. استفاده از این اطلاعات علاوه بر درگیر کردن حافظه مدل لزوماً باعث بهبود عملکرد آن نشده و هزینه‌های اجرای مدل را از نظر زمانی و تهیه و آماده‌سازی اطلاعات افزایش می‌دهند. از این رو پیشنهاد می‌گردد که در مطالعات آتی نیز تاثیر کاربرد ترم پریودیک با مدل‌ها و پارامترهای مختلف در بهبود نتایج مورد ارزیابی قرار گیرد.

سپاسگزاری

بدین وسیله از حمایت معاونت پژوهش و فناوری دانشگاه شهید چمران اهواز در انجام این تحقیق تشکر و قدردانی می‌گردد.

REFERENCES

- Babaei, M., Moeini, R. & Ehsanzadeh, E. (2019). Artificial Neural Network and Support Vector Machine Models for Inflow Prediction of Dam Reservoir (Case Study: Zayandehroud Dam Reservoir). *Water Resources Management*, 33(6), 2203-2218.
- Bafithhile, T.M. & Li, Z. (2019). Applicability of ϵ -Support Vector Machine and Artificial Neural Network for Flood Forecasting in Humid, Semi-Humid and Semi-Arid Basins in China. *Water*, 11(1), 85-96.
- Chen, Q. Dai, G. & Liu, H. (2002). Volume of fluid model for turbulence numerical simulation of stepped spillway overflow. *Journal of Hydraulic Engineering*, 128(7), 683-688.
- Chen, S.T. & Yu, P.S. (2007). Real-time probabilistic

نتیجه‌گیری

در پژوهش حاضر سعی گردید عملکرد مدل‌های ماشین بردار پشتیبان (SVM) و سیستم استنتاج عصبی فازی تطبیقی (ANFIS) در پیش‌بینی جریان ماهانه دو رودخانه نازلوچای (واقع در استان آذربایجان غربی) و سزار (واقع در استان لرستان) مورد بررسی قرار گرفته و دقت این مدل‌ها در برآورد جریان ماهانه مقایسه شود. نتایج حاصل از پژوهش حاضر به شرح زیر قابل ارائه می‌باشد:

نتایج حاصل نشان داد که تابع کرنل RBF نسبت به توابع چندجمله‌ای و خطی، در پیش‌بینی جریان ماهانه رودخانه سزار با اختلاف قابل توجهی بهترین عملکرد را به خود اختصاص داده است. همچنین در برآورد جریان ماهانه رودخانه نازلو دو تابع کرنل RBF و چند جمله‌ای از نظر عملکرد تقریباً نزدیک به یکدیگر بوده اما به دلیل خطای کمتر، کرنل RBF برای ادامه کار انتخاب گردید.

در حالتی که الگوهای ورودی به مدل SVM براساس توالی دبی‌ها معرفی گردید، دقت در مدل‌سازی جریان ماهانه هر دو رودخانه تا گام سوم زمانی افزایش یافته اما از تاخیر چهارم به بعد از عملکرد مدل کاسته شد. تاثیر ترم پریودیک در فرآیند مدل‌سازی با روش SVM دقت مدل را به طور قابل ملاحظه‌ای بهبود بخشیده به طوری که با ورودی‌های دبی تا سه روز قبل و ترم پریودیک بالاترین دقت در برآورد جریان ماهانه رودخانه‌های مورد مطالعه حاصل شده است.

با توجه به نتایج حاصل مشاهده می‌شود که مدل ANFIS برای رودخانه نازلوچای با الگوی ورودی M7 بهترین عملکرد را داشته اما در محل ایستگاه سپید دشت سزار الگوی M6 مناسب‌ترین نتایج را ارائه داده است. به مانند مدل SVM این روش نیز با

forecasting of flood stages. *Journal of Hydrology*, 340(1-2), 63-77.

Dehghani, M., Seifi, A., & Riahi-Madvar, H. (2019). Novel forecasting models for immediate-short-term to long-term influent flow prediction by combining ANFIS and Grey Wolf optimization. *Journal of Hydrology*.

Falehi, A. D. (2018). MOPSO based TCSC-ANFIS-POD technique: Design, simultaneous scheme, power system oscillations suppression. *Journal of Intelligent & Fuzzy Systems*, 34(1), 23-34.

Foroudi Khowr, A., Saneie, M. & Azhdari Moghaddam, M. (2017). Comparison of Adaptive Neuro Fuzzy Inference System (ANFIS) and Support Vector Machines (SVM) for discharge capacity prediction of a sharp-crested weirs. *Iranian Journal*

- of Irrigation & Drainage, 11(5), 772-784. (In Farsi)
- Isazadeh, M., ahmadzadeh, H. & Ghorbani, M. (2016). Assessment of Kernel Functions Performance in River Flow Estimation using Support Vector Machine. *Journal of Water and Soil Conservation*, 23(3), 69-89.
- Jang, J. S. (1993). ANFIS: adaptive-network-based fuzzy inference system. *IEEE transactions on systems, man, and cybernetics*, 23(3), 665-685. (In Farsi)
- Khazaei Poul, A. K., Shourian, M., & Ebrahimi, H. (2019). A Comparative Study of MLR, KNN, ANN and ANFIS Models with Wavelet Transform in Monthly Stream Flow Prediction. *Water Resources Management*, 1-17.
- Kia, I., Emadi, A., Gholami, M. (2019). Rainfall-Runoff Modeling by Adaptive Neuro-Fuzzy Inference System (ANFIS) and Multi-Variable Linear Regression (MLR). *Irrigation and Water Engineering*, 9(4), 39-51. (In Farsi)
- Lohani, A. K., Kumar, R., & Singh, R. D. (2012). Hydrological time series modeling: A comparison between adaptive neuro-fuzzy, neural network and autoregressive techniques. *Journal of Hydrology*, 442, 23-35.
- Mantero, P., Moser, G., & Serpico, S. B. (2005). Partially supervised classification of remote sensing images through SVM-based probability density estimation. *IEEE Transactions on Geoscience and Remote Sensing*, 43(3), 559-570.
- Mozaiyan, M., Akhoond Ali, A., Massah Bavani³, A., Radmanesh, F., Zohrabi, N. (2015). The Impact of Climate Change on Low Flows (Case Study: Sepid Dasht Sezar). *Irrigation Sciences and Engineering*, 38(2), 1-19. (In Farsi)
- Pham, Q. B., Yang, T. C., Kuo, C. M., Tseng, H. W., & Yu, P. S. (2019). Combing Random Forest and Least Square Support Vector Regression for Improving Extreme Rainfall Downscaling. *Water*, 11(3), 45-59.
- Rehana, S. (2019). River Water Temperature Modelling Under Climate Change Using Support Vector Regression. In *Hydrology in a Changing World* (pp. 171-183). Springer, Cham.
- Rezaei, E., Khashei- Siuki, A., Shahidi, A. (2014). Design of Groundwater Level Monitoring Network, Using the Model of Least Squares Support Vector Machine (LS-SVM). *Iranian Journal of Soil and Water Research*, 45(4), 389-396. (In Farsi)
- Riahi-Madvar, H., Dehghani, M., Seifi, A., Salwana, E., Shamshirband, S., Mosavi, A., & Chau, K. W. (2019). Comparative analysis of soft computing techniques RBF, MLP, and ANFIS with MLR and MNL for predicting grade-control scour hole geometry. *Engineering Applications of Computational Fluid Mechanics*, 13(1), 529-550.
- Shin, K. S., Lee, T. S., & Kim, H. J. (2005). An application of support vector machines in bankruptcy prediction model. *Expert systems with applications*, 28(1), 127-135.
- Vapnik, V.N. (1998). *Statistical Learning Theory*. Wiley, New York.
- Wu, J., Liu, H., Wei, G., Song, T., Zhang, C., & Zhou, H. (2019). Flash Flood Forecasting Using Support Vector Regression Model in a Small Mountainous Catchment. *Water*, 11(7), 13-27.
- Zaini, N., Malek, M. A., Yusoff, M., Mardi, N. H., & Norhisham, S. (2019). Daily River Flow Forecasting with Hybrid Support Vector Machine-Particle Swarm Optimization. In *IOP Conference Series: Earth and Environmental Science* (Vol. 140, No. 1, p. 012035). IOP Publishing.
- Zhou, Y., Guo, S., & Chang, F. J. (2019). Explore an evolutionary recurrent ANFIS for modelling multi-step-ahead flood forecasts. *Journal of hydrology*, 570, 343-355.