دانشگاه علوم کشاورزی و منابع طبیعی ساری
پژوهشنامه مدیریت حوزه آبخیز

مدل‌سازی رواناب رودخانه صوفی چای با استفاده از ماشین بردار پشتیبان و شبکه عصبی مصنوعی

فاطمه آخونی پورحسینی[۱] و صابره دربندی[۲]

۱- دانشجوی کارشناسی ارشد مهندسی منابع آب، دانشگاه تبریز، (نویسنده مسوول: fateme.pourhosseini@yahoo.com)
۲- استادیار گروه مهندسی آب، دانشگاه تبریز

تاریخ دریافت: ۹۵/۲/۲ تاریخ پذیرش: ۹۵/۶/۱۴

چکیده

شبیه‌سازی دقیق فرآیند رواناب می‌تواند نقش بسزایی در مدیریت منابع آب و مسائل مربوطه داشته باشد. پیچیدگی ذاتی این فرآیند استفاده از مدل‌های فیزیکی و عددی را مشکل می‌نماید. در سال‌های اخیر کاربرد مدل‌های هوشمند به‌عنوان ابزاری توانمند در علم هیدرولوژی افزایش‌یافته است. هدف این مطالعه کاربرد آزمون گاما برای انتخاب ترکیب بهینه متغیرهای ورودی در مدل‌سازی رودخانه صوفی چای می‌باشد. مدل‌سازی جریان آب رودخانه با استفاده از تعداد نقاط بهینه متغیرهای منتخب با روش‌های شبکه عصبی مصنوعی و ماشین بردار پشتیبان می‌باشد. نتایج آزمون گاما نشان داد که رواناب رودخانه با شش تأخیر زمانی، نتایج بهتری به‌منظور پیش‌بینی ارائه می‌دهد. شبیه‌سازی رواناب با استفاده از دو مدل ماشین بردار پشتیبان و شبکه عصبی مصنوعی نشان داد که بهترین ساختار ورودی برای پیش‌بینی رواناب ماه بعد، تا شش تأخیر خواهد بود. از میان دو مدل با ساختار ورودی یکسان، مدل ماشین بردار پشتیبان کارایی نسبتاً بالایی نسبت به شبکه عصبی مصنوعی داشته است.

واژه‌های کلیدی: آزمون گاما، رواناب، رودخانه صوفی چای، شبکه عصبی مصنوعی، ماشین بردار پشتیبان

مقدمه

آب یکی از عوامل مهم در توسعه پایدار هر منطقه می‌باشد. به نظر می‌رسد با توجه به شرایط اقلیمی، کمیت و کیفیت آب قابل‌دسترس برای توسعه اقتصادی و زیست‌محیطی در اکثر نقاط ایران کافی نمی‌باشد (۱۷). در سال‌های گذشته وقوع سیلاب‌ها و خشکسالی‌ها همواره امنیت زندگی و اموال مردم ساکن در پایین‌دست هر رودخانه‌ای را تهدید و خسارات فراوانی را به بار آورده هست. بنابراین با مدل‌سازی و پیش‌بینی دقیق دبی رودخانه در فصول مختلف، می‌توان اولین گام را در مدیریت علمی منابع آب‌های سطحی منطقه برداشت (۱۷). در فرآیند تشکیل رواناب حوزه متغیرهای متعددی دخالت دارند. اثر متقابل این متغیرها باعث می‌شود که این فرآیند به یک پدیده غیرخطی و پیچیده تبدیل شود. از طرفی برای اینکه بتوان یک مدل مناسب برای پیش‌بینی میزان دبی جریان آب رودخانه ارائه نمود لازم هست تا حد امکان تمامی عوامل مؤثر اندازه‌گیری در مدل دخالت داده شود. در بیشتر مواقع اندازه‌گیری غلط، ثبت اشتباه داده، کمبود دقت و منابع مالی جهت احداث ایستگاه‌های هیدرومتری و نهایتاً کافی نبودن طول سری داده‌ها باعث می‌شود که محقق قادر به تهیه مدل با دقت مناسب نباشد (۱۷). تاکنون مطالعات زیادی برای مدل‌سازی و پیش‌بینی جریان رودخانه با روش‌های مختلف صورت گرفته است. بااین‌حال هنوز مسائل حل‌نشده فراوانی در این زمینه وجود دارد. انتخاب بهترین ترکیب برای دبی جریان یکی از این مسائل می‌باشد (۱۷). یکی از مراحل مهم و پیچیده برای مدل‌سازی غیرخطی، پیش‌پردازش داده‌های ورودی به‌منظور انتخاب ترکیبی مناسب از آن در مدل‌ها می‌باشد که سبب کاهش مراحل سعی و خطا و شناخت مهم‌ترین متغیرهای بر پدیده موردنظر در مدل‌سازی می‌باشد. رمضان و همکاران (۱۳) برای مدل‌سازی تابش روزانه‌ی خورشید در حوزه آبریز برو در جنوب غربی انگلستان از چهار پارامتر هواشناسی شامل تابش‌های برون زمینی خورشیدی، میانگین دمای هوا، میانگین سرعت روزانه باد و عمق بارش روزانه استفاده کردند. آن‌ها برای انتخاب بهترین ورودی به مدل از آزمون گاما استفاده کردند. نتایج تحقیق آن‌ها نشان داد که بهترین ترکیب پارامترهای ورودی به مدل، ترکیبی است که در آن هر چهار پارامتر ذکرشده در ورودی مدل وجود داشته باشد. لفدانی و همکاران (۱۱) جهت پیش‌بینی حجم رسوبات معلق رودخانه دویرج، واقع در استان ایلام از روش آزمون گاما جهت تعیین متغیرهای ورودی به مدل ماشین بردار پشتیبان استفاده نمودند و نتیجه گرفتند که عملکرد مدل GT-SVM در مرحله آزمون بهتر از عملکرد مدل SVM می‌باشد. رمضان و همکاران (۱۴) با استفاده از داده‌های روزانه بارش و رواناب و روش هیبرید موجک رواناب حوزه آبخیز برو را در انگلستان مدل‌سازی نمودند. آن‌ها از داده‌های روزانه بارش و رواناب بازمان تأخیرهای مختلف، ترکیب‌های مختلفی را به‌عنوان متغیرهای ورودی موردبررسی قراردادند و با استفاده از آزمون گاما نتیجه گرفتند سه تأخیر در رواناب و یک تأخیر در بارش بهترین ترکیب ورودی برای مدل‌سازی رواناب رودخانه هست. دیباک و همکاران (۶) قابلیت‌های مدل SVM را در خصوص پیش‌بینی‌های هیدرولوژیکی نشان دادند. آن‌ها با استفاده از این روش درزمینه‌ی دسته‌بندی داده‌های سنجش‌ازدور و مدل‌سازی بارش- رواناب و مقایسه آن با روش‌های شبکه عصبی مصنوعی به نتایج خوبی برای پیش‌بینی دست یافتند. باتسیس و همکاران (۱) بارش-رواناب روزانه در کالیفرنیا را شبیه‌سازی کردند مدل ماشین بردار پشتیبان با سه نوع تابع کرنل با مدل شبکه عصبی مصنوعی مورد مقایسه قرار گرفت، درنتیجه این تحقیق ماشین بردار پشتیبان شبیه‌سازی

[Downloaded from jwmr.sanru.ac.ir on 2026-10-30]
[DOR: 20.1001.1.22516174.1397.9.17.2.4]
[DOI: 10.29252/jwmr.9.17.57]

دقیق‌تری از بارش- رواناب داشت. یون و جون (۲۱) دو مدل شبکه عصبی مصنوعی و ماشین بردار پشتیبان را به‌منظور پیش‌بینی تغییرات سطح آب زیرزمینی بکار گرفتند، به این نتیجه رسیدند که مدل ماشین بردار پشتیبان دارای عملکردی بهتر از شبکه عصبی مصنوعی است. کیسی و مسات (۹) مطالعه‌ای به‌منظور پیش‌بینی جریان ماهانه دو ایستگاه گردلی[1] و ایساکوی[2] در منطقه شرقی دریای سیاه ترکیه با استفاده از مدل موجک- ماشین بردار پشتیبان انجام دادند. نتایج این تحقیق افزایش دقت مدل هیبریدی موجک- ماشین بردار پشتیبان را نسبت به مدل ماشین بردار پشتیبان به همراه داشت. طاهری و همکاران (۲۰) دو روش یادگیری فعال[3] و ماشین بردار پشتیبان را جهت شبیه‌سازی جریانات روزانه رودخانه کارون بکار برده و به نتایج مشابهی برای این دو روش رسیدند و قابلیت بالای ماشین بردار پشتیبان در شبیه‌سازی رواناب را مطرح نمودند. لفدانی و همکاران (۱۰) سه مدل ماشین بردار پشتیبان و سیستم استنتاج فازی- عصبی تطبیقی (ANFIS) و مدل هیدرولوژیکی مفهومی Mike11/NA را در شبیه‌سازی جریان روزانه حوزه اسکندری به کار گرفتند. نتایج نشان داد که هر سه مدل دارای عملکرد مناسب در منطقه مورد مطالعه می‌باشند. درنهایت مدل ماشین بردار پشتیبان با بالاترین ضریب همبستگی و کمترین میانگین مربعات خطا عملکرد بهتری نسبت به دو مدل دیگر داشت. فرج زاده و همکاران (۷) با استفاده از مدل‌های سری زمانی و شبکه عصبی مصنوعی به‌پیش‌بینی جریان ماهانه و بارش حوزه دریاچه ارومیه پرداختند. نتایج حاصل از پیش‌بینی جریان حاکی از دقت خوب هر دو مدل در تخمین جریان ماهانه دارد. البته طبق این تحقیق تفاوت چندانی بین دو مدل مقایسه در تخمین جریان وجود ندارد. نوری و همکاران (۱۲) جریان ماهانه رودخانه صوفی چای را از طریق آنالیز مؤلفه اصلی (PCA) بر مبنای ماشین بردار پشتیبان مدل‌سازی نموده و عملکرد مدل‌های SVM و PCA-SVM را مورد ارزیابی قراردادند. نتایج این تحقیق نشان داد که پیش‌پردازش متغیر ورودی به ماشین بردار پشتیبان با استفاده از آنالیز مؤلفه اصلی، بهبود عملکرد مدل SVM را به همراه خواهد داشت. در مدل PCA SVM به‌جای ۱۸ ورودی تنها از ۵ مؤلفه به‌عنوان ورودی به مدل استفاده شد که این واقعیت مزیت اصلی این مدل به شمار می‌رود. در مطالعه حاضر برای یافتن بهترین ترکیب از متغیرهای ورودی روش آزمون گاما انتخاب شد و با کمک ماشین بردار پشتیبان و شبکه عصبی مصنوعی به پیش‌بینی رواناب رودخانه صوفی چای پرداخته شد.

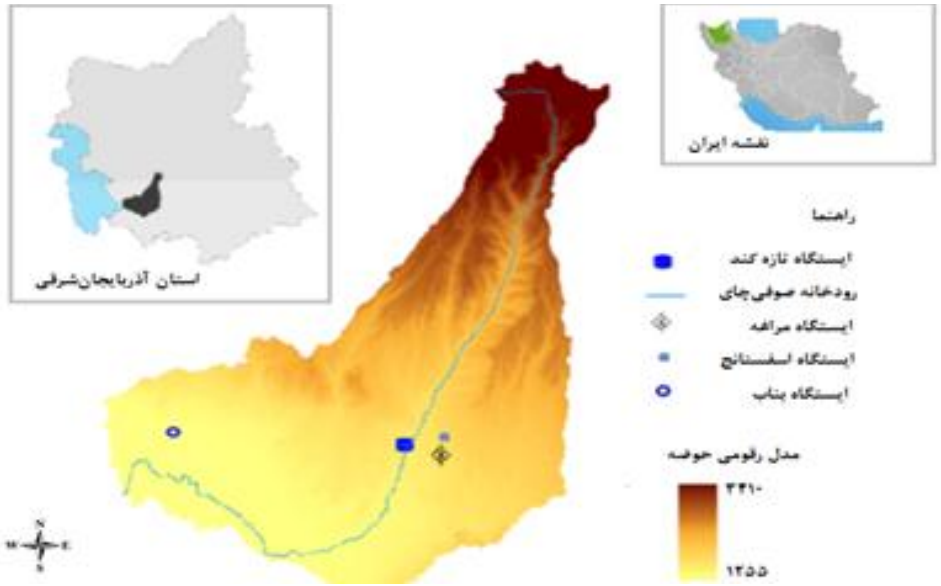
مواد و روش‌ها

منطقه مورد مطالعه و داده‌های مورداستفاده

حوزه صوفی چای از دامنه جنوبی کوهستان سهند سرچشمه گرفته و از شمال به حوزه آبریز لیقوان و کند چای، از شرق به حوزه آبریز مردق چای، از غرب به حوزه آبریز قلعه چای و از جنوب بعد از عبور از محدوده سد علویان به دریاچه ارومیه منتهی می‌شود. رودخانه صوفی چای با طول ۲۰ کیلومتر در داخل حوزه آبریز صوفی چای قرار دارد. یکی از نزدیک‌ترین ایستگاه هیدرومتری به این حوزه، ایستگاه هیدرومتری تازه کند می‌باشد. ایستگاه تازه کند در مختصات جغرافیایی در طول ′۱۶ °۴۶ و در عرض ′۲۹ °۳۷ قرار دارد. مساحت حوزه آبریز تا محل ایستگاه هیدرومتری تازه کند سد علویان در حدود ۲۵۰ کیلومترمربع و شیب متوسط وزنی آن ۷/۳ درصد و زمان تمرکز حوزه به روش کرپیچ ۸/۷۵ ساعت می‌باشد. بر اساس آمار و اطلاعات ایستگاه‌ها، متوسط بارندگی سالانه ۳۳۰ میلی‌متر می‌باشد که حدود ۳۰ درصد بارندگی در زمستان، بیش از ۴۰ درصد آن در بهار،۲ درصد در تابستان و حدود ۲۵ درصد در پاییز می‌باشد. داده‌های مورد استفاده در این تحقیق شامل مقادیر ماهانه رواناب در طول ۴۰ سال (مهر ۱۳۵۲- شهریور ۱۳۹۱) برای ایستگاه هیدرومتری تازه کند می‌باشد. شکل۱موقعیت حوزه آبریز صوفی چای و ایستگاه مذکور را نشان می‌دهد. نمودار تغییرات داده‌های رواناب و بارش ماهانه رودخانه صوفی چای در ایستگاه تازه کند در شکل ۲ و مشخصات آماری ایستگاه باران‌سنجی نیز در جدول ۱ ارائه شده است.

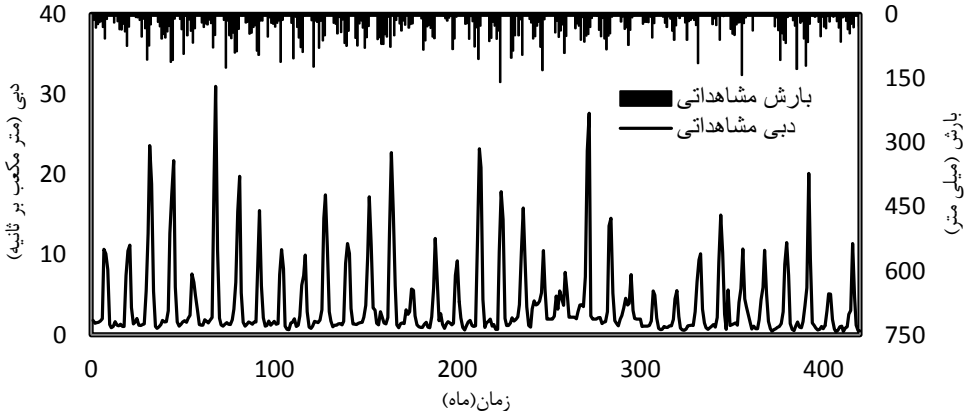
1- Gerdelli 2- Isakoy 3- Active Learning Method

[Downloaded from jwmr.sanru.ac.ir on 2026-10-30]
[DOR: 20.1001.1.22516174.1397.9.17.2.4]
[DOI: 10.29252/jwmr.9.17.57]



شکل ۱- مشخصات جغرافیایی ایستگاه‌های هیدرومتری در حوزه صوفی چای (نوری، ۱۳۸۹)

Figure1. The geographical location and hydrometric stations in sofichy basin



شکل ۲- مقادیر مشاهداتی بارش و رواناب ماهانه ایستگاه تازه کند در طول آماری

Figure 2. The observed values of monthly precipitation and runoff Tazekand station during statistical period

جدول ۱- مشخصات آماری رواناب ماهانه ایستگاه هیدرومتری تازه کند

Table 1. Statistical Profile monthly runoff in Tazekand hydrometric station

پارامتر	کل	آموزش (مترمکعب بر ثانیه)	صحت سنجی (مترمکعب بر ثانیه)
میانگین	۳/۷۸	۴/۰۸	۳/۰۷
حداقل	۰/۳۵	۰/۵۵	۰/۳۵
حداکثر	۳۰/۹۸	۳۰/۹۸	۲۰/۱۳

به‌منظور تخمین رواناب ماه‌های آینده، از اطلاعات رواناب ماه‌های قبل استفاده گردید. با استفاده از ماتریس همبستگی سری زمانی با تأخیر زمانی شش ماه قبل، به‌عنوان ورودی به مدل‌ها معرفی شد (جدول ۲). مقدار رواناب ماه بعد به‌عنوان خروجی مدل‌ها تعیین گردید.همچنین از شش متغیر شامل سری مربوط با تأخیر یک‌روزه Q_{t-1}، دوروزه Q_{t-2}، سه‌روزه Q_{t-3}، چهار روزه Q_{t-4}، پنج روزه Q_{t-5}و شش روزه Q_{t-6} به‌عنوان متغیر ورودی و Q_t به‌عنوان متغیر خروجی به مدل معرفی گردید.

[Downloaded from jwmr.sanru.ac.ir on 2026-10-30]
[DOR: 20.1001.1.22516174.1397.9.17.2.4]
[DOI: 10.29252/jwmr.9.17.57]

جدول ۲- همبستگی متقابل بین پارامترهای ورودی و خروجی

Table 2. Cross-correlation coefficient between input and output parameters

$(m^3/s)Q_t$	$(m^3/s)Q_{t-1}$	$(m^3/s)Q_{t-2}$	$(m^3/s)Q_{t-3}$	$(m^3/s)Q_{t-4}$	$(m^3/s)Q_{t-7}$	$(Q\ m^3/s)_{t-6}$
۱	۰/۶۴	۰/۱۱	-۰/۱۹	-۰/۲۷	-۰/۲۶	-۰/۲۵

آزمون گاما

آزمون گاما یک روش غیرمتغیری است که نتایج آن صرف‌نظر از روش‌های خاص برای مدل‌سازی به کار می‌رود. این روش را به‌عنوان ابزاری مناسب برای یافتن بهترین ترکیب از متغیرهای ورودی به مدل غیرخطی می‌توان در نظر گرفت. درواقع آزمون گاما تخمینی از حداقل میانگین مربعات خطای آن بخش داده‌ها است که با مدل خطی نمی‌توان آن را تعیین کرد. فرض می‌شود مجموعه داده‌های مشاهداتی به‌صورت زیر است (۱۵).

$$\{(x_i - y_i), 1 \le i \le M\}. \quad (۱)$$

که در آن x_i بردار مشاهداتی ورودی، y_i خروجی مشاهداتی و M تعداد کل مشاهدات می‌باشد. از بردار x_i (در فضای mبعدی) برای مدل‌سازی y_i (در فضای R) استفاده می‌شود. بنابراین رابطه‌ی بین ورودی و خروجی به شرح زیر در نظر گرفته می‌شود:

$$y = f(x) + r \quad (۲)$$

که در آن fیک تابع همواره r متغیر تصادفی نشان‌دهنده خطا می‌باشد.فرض شد برای بردار ورودی x_i،مجموعه[k، $N[i)(1 \le k \le p)$ به نام مجموعه نزدیک‌ترین همسایگی هست (۱۸).

مدل ماشین بردار پشتیبان (SVM)[1]

ماشین بردار پشتیبان یک سیستم یادگیری کارآمد بر مبنای تئوری بهینه‌سازی مقید است که از اصل استقرای کمینه‌سازی خطای ساختاری استفاده کرده و منجر به یک جواب بهینه کلی می‌گردد (۳). مشابه سایر مسائل رگرسیونی فرض می‌شود که رابطه میان متغیرهای مستقل و وابسته با تابع جبری مانند $f(x)$ به‌علاوه مقداری اغتشاش (خطای مجاز (ε)) مشخص شود.

$$f(x) = W^T.\emptyset(x) + b \quad (۳)$$

$$y = f(x) + noise \quad (۴)$$

چنانچه W (بردار ضرایب) و b (ثابت) مشخصه‌های تابع رگرسیونی و $\emptyset$ 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.

انواع رایج توابع کرنل قابل‌استفاده در مدل SVM رگرسیونی عبارت‌اند از کرنل خطی،کرنل چندجمله‌ای و کرنل توابع پایه شعاعی (RBF) که میزان کارایی ماشین بردار پشتیبان با توجه به نوع تابع کرنل متفاوت می‌باشد که تابع پایه شعاعی به‌عنوان بهترین انتخاب از بین دیگر توابع کرنل گزارش‌شده است (۸).

جدول ۳- توابع کرنل

Table 3. Kernel functions

توابع کرنل	رابطه ریاضی
تابع کرنل خطی	$K(x_i.x_j) = x_i^T.x_j$
تابع کرنل چندجمله‌ای	$K(x_i.x_j) = (x_i^T.x_j + \tau)^d$
تابع کرنل با پایه شعاعی	$K(x.\ x_i) = exp\left(\frac{-\lvert x_i - . x_j\rvert^2}{2\sigma^2}\right)$

مدل شبکه‌های عصبی مصنوعی (ANNs)[2]

شبکه عصبی مصنوعی در علوم مختلف ازجمله فیزیک، علوم مهندسی، پزشکی و ... گسترش و انواع مختلفی از شبکه‌ها و الگوریتم‌های آموزش توسعه یافتند. حدود ۹۰ درصد شبکه‌هایی که در مسائل مختلف هیدرولوژی کاربرد دارد شبکه‌های پیشرو هستند (۲). معماری معمول این شبکه متشکل از سه لایه ورودی، پنهان و خروجی است. تعداد نرون‌های موجود در لایه ورودی و خروجی، بستگی به نوع مسئله دارد ولی تعداد گره‌های لایه پنهان با سعی و خطا دست می‌آید. در شبکه‌های پیشرو، اتصالات میان گره‌هایی وجود دارد که در لایه‌های متفاو ت قرار دارند.همچنین ورودی‌ها در لایه ورودی شبکه نمایش داده‌شده و عمل تحریک از ورودی به سمت خروجی شبکه شروع می‌شود (۵).

روش کار

به‌منظور تعیین ترکیب بهینه متغیرهای ورودی در مدل‌های ماشین بردار پشتیبان و شبکه عصبی مصنوعی ابتدا با استفاده از آزمون گاما، مقدار گاما برای حالت استفاده از تمام متغیرهای ورودی به دست آمد. سپس یکی از متغیرهای ورودی حذف و مقدار گاما برای ترکیب مفروض محاسبه شد. آنگاه متغیر مذکور دوباره به مدل وارد و متغیر دیگری حذف شد و مقدار گاما برای ترکیب جدید به دست آمد. این کار برای همه متغیرها تکرار و در جدولی ثبت شد.

جدول ۴ نتایج آزمون گاما را در ایستگاه تازه کند نشان می‌دهد. در این جدول ترکیب شماره یک، ترکیبی است که در آن همه متغیرهای ورودی حضور دارد. در ترکیبات دیگر همه متغیرها به‌جز یکی در مدل حاضر هستند. مثلاً در ترکیب

1- Support vector machine

2- Artificial Neural Network

[Downloaded from jwmr.sanru.ac.ir on 2026-10-30]

[DOR: 20.1001.1.22516174.1397.9.17.2.4]

[DOI: 10.29252/jwmr.9.17.57]

شماره دو، همه متغیرها به‌جز متغیر Q_{t-6} حاضر می‌باشد. بعدازاینکه مقدار گاما برای تمام ترکیب‌های جدول ۴ به دست آمد مقدار آماره (Γ) هریک از ترکیبات شماره‌ی ۲ تا ۷ با مقدار آماره گامای مربوطه به ترکیب یک مقایسه شد. ترکیباتی که در آن‌ها مقدار گامای مدل با ترکیبات مفروض بیشتر از مقدار گامای نظیر ترکیب شماره ۱ بود، به‌عنوان مهم‌ترین متغیر در پیش‌بینی رواناب تشخیص داده شدند و از آن‌ها برای مدل‌سازی استفاده گردید (۱۲). به‌طوری‌که از جدول ۴ مشاهده می‌شود شش ترکیب وجود دارد که مقدار گامای آن‌ها از ترکیب شماره ۱ بیشتر می‌باشد. بنابراین متغیرهای غایب این ترکیبات شامل شش متغیر Q_{t-1}، Q_{t-2}، Q_{t-3}، Q_{t-4}، Q_{t-5}، Q_{t-6} به‌عنوان متغیر مؤثر در مدل‌سازی رواناب تشخیص داده شدند. همچنین متغیر Q_{t-1} به‌عنوان مهم‌ترین متغیر در این ترکیب می‌باشد. وقتی این متغیر از ترکیب حذف می‌شود مقدار (Γ) نسبت به ترکیب شماره یک (یعنی زمانی که همه متغیرها حضور دارند) بیشترین مقدار را به خود اختصاص می‌داد.

جدول ۴- نتایج آزمون گاما در مدل‌سازی رواناب ایستگاه هیدرومتری موردمطالعه

Table 4. Gamma test results in modeling runoff in Tazekand hydrometric station

ترکیب	متغیر غایب در مدل	گاما	شیب A	خطای استاندارد	نسبت V	تعداد داده‌ها
۱	–	۰/۰۶۵	۰/۰۶۳	۰/۰۰۷	۰/۲۶۲	۴۲۶
۲	Q_{t-6}	۰/۰۷	۰/۰۶۳	۰/۰۰۹	۰/۲۸۲	۴۲۶
۳	Q_{t-5}	۰/۰۶۹	۰/۰۵۲	۰/۰۰۵	۰/۲۷۷	۴۲۶
۴	Q_{t-4}	۰/۰۶۸	۰/۰۵۹	۰/۰۰۶	۰/۲۷۲	۴۲۶
۵	Q_{t-3}	۰/۰۶۷	۰/۱۳۵	۰/۰۰۸	۰/۲۵۴	۴۲۶
۶	Q_{t-2}	۰/۰۷۰	۰.۱۰۳	۰/۰۰۸	۰/۲۸۰	۴۲۶
۷	Q_{t-1}	۰/۱۳۴	۰.۰۴۲	۰/۰۱۴	۰/۵۳۶	۴۲۶

جهت استفاده از داده‌های رواناب ماهانه ایستگاه تازه کند رودخانه صوفی چای در مدل‌های ماشین بردار پشتیبان و شبکه عصبی مصنوعی ابتدا داده‌ها به‌صورت تصادفی به دو قسمت تقسیم‌بندی شدند. ۷۰ درصد برای آموزش مدل و ۳۰ درصد بقیه برای بخش صحت سنجی استفاده گردید (۱۶). به‌منظور افزایش کارایی مدل، همه داده‌ها ابتدا به شکل نرمال بین دو عدد صفر و ۱ استاندارد شدند سپس آن‌ها به مقادیر اولیه بعد از استفاده در شبیه‌سازی برگشتند.

$$X_n = \frac{X_i - X_{max}}{X_{min} - X_{max}} \quad (۵)$$

در این رابطه X_i مقادیر داده‌های مشاهداتی، X_n داده‌های استانداردشده، X_{max} و X_{min} به ترتیب معرف داده‌های حداکثر و حداقل می‌باشد.

برای مقایسه داده‌های مشاهداتی و پیش‌بینی‌شده از شاخص‌های آماری ضریب تبیین (R^2)، ریشه متوسط مربعات خطا (RMSE) و معیار نش ساتکلیف(E)[1] استفاده گردید.

$$R^2 = \left[\frac{\sum_N^{i=1}(x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_N^{i=1}(x_i - \bar{x})^2 . \sum_N^{i=1}(y_i - \bar{y})^2}}\right]^2 \quad (۶)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^{N}(x_i - y_i)^2}{N}} \quad (۷)$$

$$E = 1 - \frac{\sum_N^{i=1}(x_i - y_i)^2}{\sum_N^{i=1}(x_i - \bar{x})^2} \quad (۸)$$

که در روابط ۶ الی ۸، x_i مقدار دبی مشاهداتی، y_i مقدار دبی پیش‌بینی‌شده و $\bar{x}$ و $\bar{y}$ به ترتیب نشانگر مقادیر میانگین داده‌های متناظر می‌باشند. مدلی بهترین نتیجه را خواهد داشت که برای این سه معیار به ترتیب مقادیری نزدیک به یک، صفر و یک را به همراه داشته باشد.

نتایج و بحث

به‌منظور مدل‌سازی داده‌های رواناب با استفاده از دو مدل SVM و ANN بخشی از داده‌ها جهت آموزش و بخشی دیگر جهت صحت سنجی مورد استفاده قرار گرفت. در جداول ۵ و ۶ مقادیر شاخص‌ه ای آماری محاسبه‌شده مربوط به نتایج بخش آموزش و صحت سنجی در هر دو مدل SVM و ANN ارائه شده است.

1- Nash Sutcliffe

[Downloaded from jwmr.sanru.ac.ir on 2026-10-30]
[DOR: 20.1001.1.22516174.1397.9.17.2.4]
[DOI: 10.29252/jwmr.9.17.57]

جدول ۵- ارزیابی مدل ماشین بردار پشتیبان در شبیه‌سازی رواناب ایستگاه هیدرومتری تازه کند

Table 5. Evaluation of Support Vector Machine to predict runoff in Tazekand hydrometric station

ترکیب	مدل	پارامترهای ورودی	آموزش			صحت سنجی		
			R^2	E	RMSE(m^3/s)	R^2	E	RMSE(m^3/s)
۱	پایه شعاعی	Q_{t-1}	۰/۴۴۹	۰/۴۴۹	۳/۸۰۲	۰/۳۹۴	۰/۳۵۸	۲/۹۹۳
	چندجمله‌ای خطی	Q_{t-1}	۰/۴۴۹	۰/۴۴۹	۳/۸۰۳	۰/۳۸۶	۰/۳۵۷	۲/۹۹۵
		Q_{t-1}	۰/۴۲۲	۰/۴۲۱	۳/۸۹۷	۰/۳۵۷	۰/۳۴۷	۳/۰۲۰
۲	پایه شعاعی	Q_{t-1}, Q_{t-2}	۰/۷۳۹	۰/۷۳۹	۲/۱۸	۰/۵۳۸	۰/۴۲۸	۲/۸۲۵
	چندجمله‌ای خطی	Q_{t-1}, Q_{t-2}	۰/۷۲۹	۰/۷۲۶	۲/۶۸۰	۰/۴۸۲	۰/۳۸۱	۲/۹۴۰
		Q_{t-1}, Q_{t-2}	۰/۵۹۲	۰/۵۹۲	۳/۲۷۰	۰/۴۶۷	۰/۳۱۷	۲/۸۰۶
۳	پایه شعاعی	Q_{t-1},Q_{t-2}, Q_{t-3}	۰/۷۵۶	۰/۷۵۶	۲/۵۳۰	۰/۵۷۹	۰/۴۹۸	۲/۶۴۷
	چندجمله‌ای خطی	Q_{t-1},Q_{t-2}, Q_{t-3}	۰/۷۴۰	۰/۷۳۹	۲/۶۱۷	۰/۵۳۵	۰/۴۶۲	۲/۷۴۱
		Q_{t-1},Q_{t-2}, Q_{t-3}	۰/۵۹۷	۰/۵۹۷	۳/۲۵۱	۰/۴۵۷	۰/۴۲۴	۲/۸۳۷
۴	پایه شعاعی	Q_{t-1},Q_{t-2}, Q_{t-3}, Q_{t-4}	۰/۷۵۹	۰/۷۵۹	۲/۵۱۳	۰/۵۷۵	۰/۴۷۷	۲/۷۰۲
	چندجمله‌ای خطی	Q_{t-1},Q_{t-2}, Q_{t-3}, Q_{t-4}	۰/۷۳۱	۰/۷۳۱	۲/۶۵۷	۰/۵۳۷	۰/۴۳۹	۲/۸۰۷
		Q_{t-1},Q_{t-2}, Q_{t-3}, Q_{t-4}	۰/۶۰۶	۰/۶۰۶	۳/۲۱۴	۰/۴۶۱	۰/۴۱۷	۲/۸۰۲
۵	پایه شعاعی	Q_{t-1},Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}	۰/۷۶۲	۰/۷۶۲	۲/۴۹۷	۰/۵۷۵	۰/۴۹۱	۲/۶۶۶
	چندجمله‌ای خطی	Q_{t-1},Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}	۰/۷۳۶	۰/۷۳۴	۲/۶۴۱	۰/۵۴۷	۰/۴۳۷	۲/۸۰۳
		Q_{t-1},Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}	۰/۶۱۳	۰/۶۱۳	۳/۸۶	۰/۴۷۷	۰/۴۲۹	۲/۸۲۵
۶	پایه شعاعی	Q_{t-1},Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5},Q_{t-6}	۰/۷۷۸	۰/۷۷۷	۲/۴۱۸	۰/۵۸۸	۰/۵۰۳	۲/۶۳۴
	چندجمله‌ای خطی	Q_{t-1},Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5},Q_{t-6}	۰/۷۴۳	۰/۷۴۳	۲/۵۹۵	۰/۵۵۸	۰/۴۴۱	۲/۷۹۴
		Q_{t-1},Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5},Q_{t-6}	۰/۶۱۹	۰/۶۱۹	۳/۱۶۱	۰/۴۸۸	۰/۴۳۳	۲/۸۱۴

جدول ۶- نتایج شبکه عصبی مصنوعی استفاده‌شده در مراحل آموزش و صحت‌سنجی

Table 6. Results artificial neural network used in the training and validation

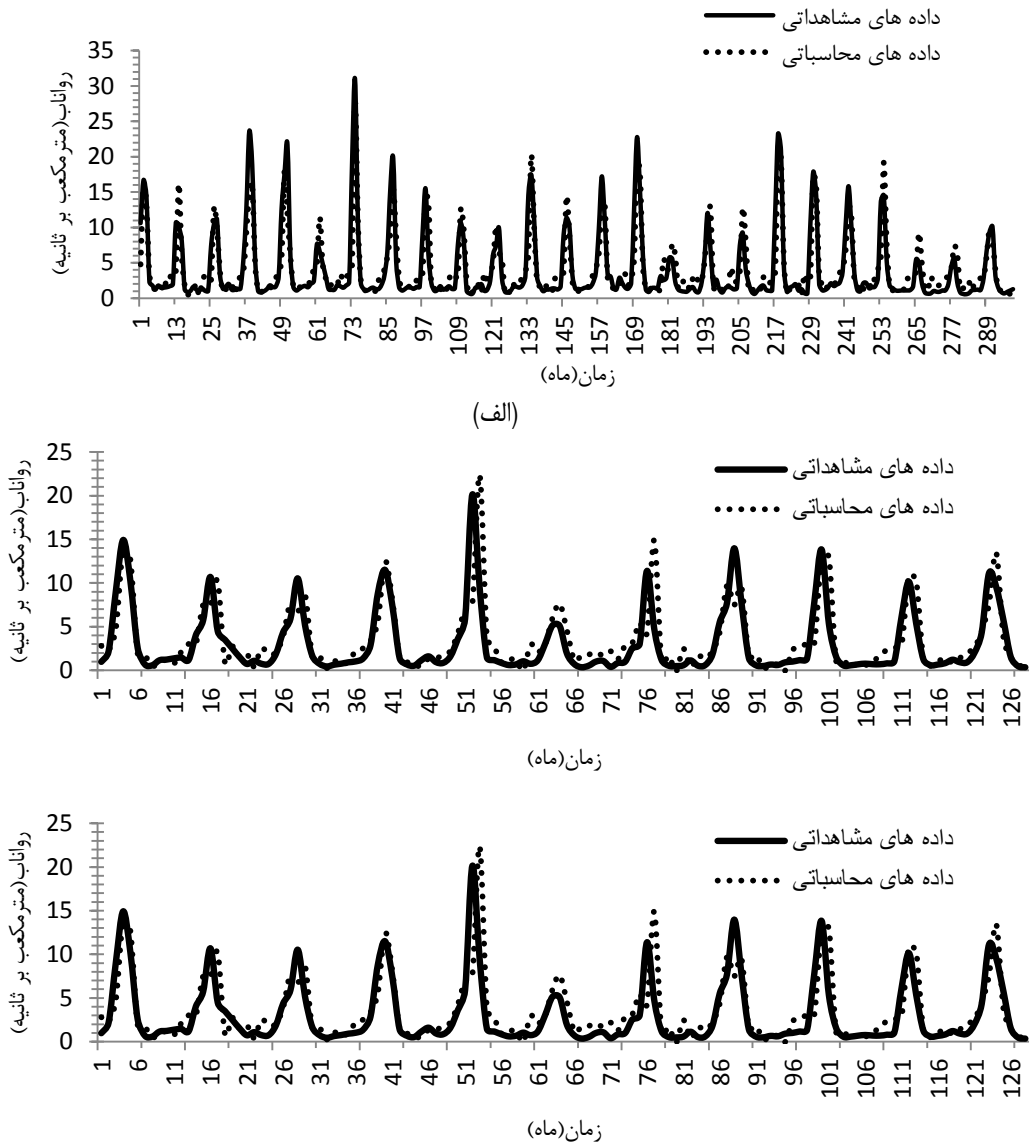
ترکیب	تعداد نرون بهینه	تعداد تکرار (EPOCH)	پارامترهای ورودی	آموزش			صحت سنجی		
				R^2	E	RMSE(m^3/s)	R^2	E	RMSE(m^3/s)
۱	۱۲	۱۳	Q_{t-1}	۰/۵۴۵	۰/۵۳۱	۳/۵۰۷	۰/۳۶۴	۰/۰۹۶	۳/۵۵۲
۲	۱۰	۱۲	Q_{t-1}, Q_{t-2}	۰/۷۵۵	۰/۷۵۴	۳/۵۳۹	۰/۵۱۶	۰/۱۲۷	۳/۹۷۰
۳	۱۳	۱۴	Q_{t-1},Q_{t-2}, Q_{t-3}	۰/۷۱۲	۰/۶۳۴	۳/۰۹۹	۰/۵۷۴	۰/۲۸۶	۴/۲۳۹
۴	۲۰	۲۲	Q_{t-1},Q_{t-2}, Q_{t-3}, Q_{t-4}	۰/۷۱۰	۰/۷۰۹	۲/۸۰۳	۰/۵۳۳	۰/۱۱۶	۳/۵۱۴
۵	۷	۱۰	Q_{t-1},Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5}	۰/۷۲۸	۰/۷۲۸	۲/۷۱۲	۰/۵۴۹	۰/۰۱۶	۳/۷۰۷
۶	۱۷	۲۰	Q_{t-1},Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5},Q_{t-6}	۰/۷۷۴	۰/۷۳۳	۲/۴۷۴	۰/۵۷۹	۰/۲۲۴	۳/۲۹۱

همان‌طور که در جدول ۵ مشاهده می‌شود، میزان R^2 در بخش آموزش ششمین ترکیب مدل ماشین بردار پشتیبان برابر با ۰/۷۷۸ به دست آمده که نسبت به ترکیبات قبلی بزرگ‌تر است. همچنین میزان E و RMSE برابر با ۰/۷۷۷و ۲/۴۱۸ است. در بخش صحت‌سنجی نیز وضعیت به همین ترتیب است. مقدار R^2 در ششمین ترکیب این بخش، بزرگ‌تر از ترکیبات قبلی و برابر با ۰/۵۵۸ است. میزان E و RMSE برابر با ۰/۵۰۳ و۲/۶۳۴ هستند. شاخص‌های آماری یادشده نشان می‌دهند که ترکیب مدنظر نسبت به سایر ترکیبات مدل‌سازی شده با روش‌های دیگر و دیگر توابع کرنل از دقت بیشتری برخوردار است. در شکل ۳، مقادیر مشاهداتی و پیش‌بینی‌شده برای ترکیب ششم نشان داده شده است. اصولا نوع تابع کرنل مناسب باید به روش سعی و خطا تعیین گردد (۱۹)؛ با این حال در اکثر تحقیقات به این موضوع اهمیت داده نشده و تابع کرنل RBF به‌طور پیش‌فرض به‌عنوان تابع کاربردی مدل، مورد استفاده قرار گرفته‌است. با توجه به این

[Downloaded from jwmr.sanru.ac.ir on 2026-10-30]
[DOR: 20.1001.1.22516174.1397.9.17.2.4]
[DOI: 10.29252/jwmr.9.17.57]

که این پیش‌فرض ممکن است در تمام موارد صحیح نباشد، در این تحقیق از روش سعی و خطا استفاده شد. در جدول ۵ ملاحظه می‌گردد که در همه ترکیب‌ها، مدل ماشین بردار پشتیبان با تابع کرنل پایه شعاعی نسبت به مدل با توابع کرنل خطی و چندجمله‌ای، مقادیر شبیه‌سازی شده‌ی بهتری ارائه می‌دهد، بنابراین می‌توان اطمینان داشت که تخمین ارائه شده توسط تابع کرنل RBF نسبت به توابع دیگر دقیق‌تر است.

نتایج حاصل از شبیه‌سازی با شبکه عصبی مصنوعی با مینیمم میزان یادگیری[1] ۰۰۱ /۰ و ماکزیمم میزان یادگیری[2] ۰/۳ و ضریب مومنتوم[3] ۰/۸ نشان می‌دهد ترکیب ششم در جدول ۶ در بخش آموزش میزان R^2 برابر با ۰/۷۷۴ است که نسبت به ترکیبات قبلی بزرگتر می باشد. همچنین میزان E و RMSE برابر با ۰/۷۷۳و ۲/۴۷۴ است. در بخش صحت‌سنجی نیز وضعیت به همین ترتیب است. مقدار R^2 در ششمین ترکیب این بخش، بزرگ‌تر از ترکیبات قبلی و برابر با ۰/۵۷۹ است. میزان E و RMSE برابر با ۰/۲۲۴ و۳/۲۹۱ هستند. شاخص‌های آماری یادشده نشان می‌دهند که ترکیب مدنظر نسبت به سایر ترکیبات مدل‌سازی شده با این روش از دقت بیشتری برخوردار است. در شکل ۴، مقادیر مشاهداتی و پیش‌بینی‌شده برای ترکیب ششم نشان داده شده است.

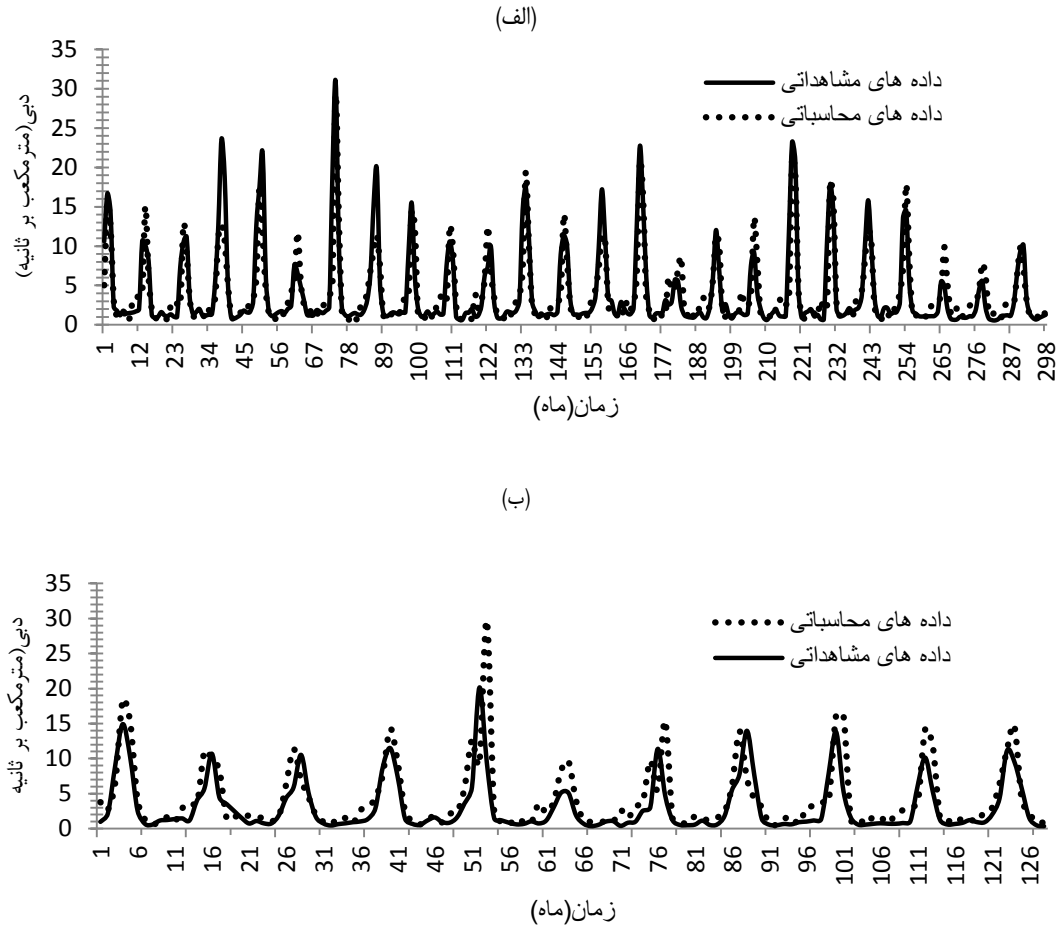


شکل ۳- مقادیر مشاهداتی و پیش‌بینی‌شده میزان رواناب ایستگاه تازه کند رودخانه صوفی چای با بهترین ترکیب ماشین بردار پشتیبان (ترکیب ۶) الف- آموزش ب- صحت سنجی

Figure 3.The observed and predicted values of Tazekand station with the best combination of SVM (compound6) the training and validation

1- Minimum Learning Rate 2- Maximum Learning Rate 3- Momentum Coefficient

[Downloaded from jwmr.sanru.ac.ir on 2026-10-30]
[DOR: 20.1001.1.22516174.1397.9.17.2.4]
[DOI: 10.29252/jwmr.9.17.57]



شکل ۴- مقادیر مشاهداتی و محاسباتی میزان رواناب ایستگاه تازه کند با بهترین ترکیب شبکه عصبی مصنوعی(ترکیب ششم) : الف) آموزش ب) صحت سنجی+++

Figure 4. The observed and predicted values of runoff Tazekand station with the best combination of ANN . (compound6) the training and validation

در این تحقیق، بهترین ترکیب متغیرهای ورودی با روش آزمون گاما برای مدل سازی جریان ماهانه حوزه صوفی چای انجام گرفت. برای اینکار سری‌های مورد استفاده در ورودی مدل، که داده‌های جریان ماهانه با تاخیرهای مختلف بودند، نرمال شدند. سپس از بین شش متغیر ورودی ترکیب بهینه متغیرها با استفاده از آزمون گاما بدست آمد. ترکیب منتخب شامل شش متغیر Q_{t-6} و Q_{t-1},Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5} می‌باشد. نتایج این تحقیق با نتایج رمضان و همکاران (۱۳) مطابقت دارد. ایشان اذعان داشته‌اند با توجه به قابلیت بالای آزمون گاما در کاهش مراحل سعی و خطا در تعیین ورودی‌ها به مدل کمک بسزایی خواهد شد. هدف بعدی، مدل‌سازی جریان رودخانه با استفاده از دو روش ماشین بردار پشتیبان و شبکه عصبی مصنوعی بود. نتایج مدل‌سازی با استفاده از سه معیار R^2 و E وRMSE مورد ارزیابی قرار گرفت. نتایج نشان داد که مدل ماشین بردار پشتیبان با تابع کرنل پایه شعاعی از دقت بیشتری نسبت به مدل شبکه عصبی مصنوعی برخوردار است. نتایج حاصله در مجموع روش ماشین بردار پشتیبان را به عنوان یک روش صحیح و دقیق برای پیش‌بینی جریان رودخانه‌ها پیشنهاد می‌کند. این پیشنهاد با نتایج حاصل از مطالعه چوبی و همکاران (۴) و دو تحقیق انجام شده توسط یو و همکاران (۲۳،۲۲) مطابقت دارد. چوبی و همکاران (۴) با استفاده از دو مدل ماشین بردار پشتیبان و شبکه عصبی مصنوعی به پیش‌بینی جریان ماهانه در رودخانه نارمادا[1] در هند پرداختند. نتایج این تحقیق نشان از برتری ماشین بردار پشتیبان نسبت به شبکه عصبی مصنوعی در پیش‌بینی جریان ماهانه رودخانه مورد نظر داشت. یو و همکاران (۲۳) برای مدل سازی سیلاب رودخانه لن یانگ[2] در تایوان از مدل ماشین بردار پشتیبان استفاده کردند. نتایج حاصل، حاکی از دقت خوب ماشین بردار پشتیبان در تخمین سیلاب بود. با دقت بیشتر به شکل‌های ارائه شده برای هر دو روش می‌توان نتیجه گرفت که عملکرد دو روش ماشین بردار پشتیبان و شبکه عصبی مصنوعی از نظر تحلیلی آماری به هم نزدیک است. از نظر گرافیکی و تخمین دبی‌های کمینه و بیشینه، هر دو مدل در پیش‌بینی دبی بیشینه خطای بیشتری دارند اما در پیش‌بینی دبی متوسط و کمینه عملکرد، مدل ماشین بردار پشتیبان به مراتب بهتر از شبکه عصبی مصنوعی است.

1- Narmada

2- Lan-Yang

[Downloaded from jwmr.sanru.ac.ir on 2026-10-30]
[DOR: 20.1001.1.22516174.1397.9.17.2.4]
[DOI: 10.29252/jwmr.9.17.57]

منابع

1. Botsis, D., P. Latinopoulos and k. Diamantaras. 2011. Rainfall-Runoff Moeling Using Suport Vector Regression and Artificial Neural Networks. CEST 2011-Rhodes, Greece.
2. Coulibaly, P., F. Anetil and B. BoBee. 2000. Daily reservoir inflow forecasting using artificial neural networks with stopped training approach. Journal of Hydrology, 230: 244-257.
3. Cristianini, N. and J. Shawe-Taylor. 2000. An Introduction to Support Vector Machines, Cambridge University Press, New York.
4. Choubey, V., S. Mishra and S.K. Pandy. 2014. Time Series Data Mining in Real Time Surface Runoff Forecasting through Support Vector Machine. International Journal of Computer Applications, 98(3): 23-30.
5. Dawson, C.W., R.J. Abrahart, A.Y. Shamseldin and R.L. Wibly. 2006. Flood estimation at ungauged sites using artifitial neural networks. Journal of Hydrology, 319: 391-409.
6. Dibike, Y.B., S. Velickov, D.P. Solomatine and M.B. Abbott. 2001. Model Induction with Support Vector Machines: Introduction and Application, ASCE. Journal of Computing in Civil Engineering, 15(3): 208-216.
7. Farajzadeh, J., A. Fakheri Fard and S. Lotfi. 2014. Modeling of monthly rainfall and runoff of Urmia lake basin using feed-forward neural network and time series analysis model. Water Resources and Industry, 7(8): 38-48 (In Persian).
8. Jones, A.J. 2004. New tools in non-linear modeling and prediction. Computational Management Science 1: 109-149.
9. Kisi, O. and C. Mesut. 2011. A wavelet-support vector machine conjunction model for monthly stream flow forecasting. Journal of Hydrology, 399: 132-140.
10. Lafadani, E., A. Moghadamnia, A. Ahmadi, M. Jajarmizadeh and M. Ghafari Gosheh. 2013. Stream flow simulation using SVM, ANFIS and NAM models (A Case study). Caspian Journal of Applied Sciences Reaserch, 2(4): 86-93 (In Persian).
11. Lafadani, E., A. Moghadamnia, A. Ahmadi and H. Ebrahimi. 2014. Evaluate the effect of processing the input variables to the model of support vector machine to predict the volume of sediment gamma test. Iranian Journal of Natural Resources, 67(2): 289-303 (In Persian).
12. Noori, R., A. Karbassi and M. Sabahi. 2009. Evaluation of PCA and gamma test techniques on ANN operation for weekly solid waste prediction. Journal of Environmental Management, 91: 767-771 (In Persian).
13. Remesan, R., M.A. Shamim and D. Han. 2008. Model data selection using gamma test for daily solar radiation estimation Hydrological Processes, 22: 4301-4309.
14. Remesan, R., M.A. Shami, D. Han and J. Mathew. 2009. Runoff prediction using an integrated hybrid modeling scheme. Journal of Hydrology, 372: 48-60.
15. Rezaee, E., A. Shahidi, A. Khashee and H. Riyahi Madvar. 2014. Application of Least Squares Support Vector Machine Model for Water Table Simulation (Case Study: Ramhormoz plain). Iranian Journal of lrrigation and Drainage, 4: 510-520 (In Persian).
16. Roozbahani, A., B. Zahraie and M. Tabesh. 2012. Risk Analysis of Drinking water system by aggregation of Fuzzy Fault Tree Analysis with Bayesian networks and Dempster-shafer theory ,10th International Conference on Hydro informatics ,Humborg ,Germany.
17. Sharifi, A., Y. Dinpashoh, A. Fakheri-Fard and A. Moghaddamniya. 2013. Optimum Combination of Variables for Runoff Simulation in Amameh Watershed using Gamma test. Journal of Water and Soil, 23(4): 59-72 (In Persian).
18. Seifi, A. and H. Riahi-Madvar. 2012. Input Variable Selection in expert systems based on hybrid Gamma Test-Least Square Support Vector Machine, ANFIS and ANN models. Provisional chapter. INTECH.
19. Seifi, A. 2010. Developing an Expert System for Predicting Daily Reference Evapotranspiration Using Support Vector Machines (SVM) in Comparison with ANFIS, ANN and Empirical Methods. M. S. in Irrigation and drainage Engineering, Tarbiat Modares University, Tehran.
20. Taheri, H. and M. Ghafouri. 2012. Comparison between active learning method and support vector machine for runoff modeling. Journal hydraulic Hydromech, 1: 16-32 (In Persian).
21. Yoon, H. and S.C. Jun. 2011. A comparative study of artificial neural networks and support vector machines for predicting groundwater levels in a coastalaquifer. Journal of Hydrology, 396: 128-138.
22. Yu, P.S., S.T. Chen and I.F. Chang. 2005. Flood stage forecasting using support vector machines. Geophysical Research Abstracts, 7: 41-76.
23. Yu, P.S., S.T. Chen and I.F. Chang. 2006. Support vector regression for real-time flood stage forecasting. Journal of Hydrology, 328: 704-716.

[Downloaded from jwmr.sanru.ac.ir on 2026-10-30]
[DOR: 20.1001.1.22516174.1397.9.17.2.4]
[DOI: 10.29252/jwmr.9.17.57]

Sofichay River Runoff Modeling using Support Vector Machine and Artificial Neural Network

Fateme Akhoni Pourhosseini[1] and Sabereh Darbandi[2]

1- M.Sc. Student, Department of Engineering, Faculty of Agriculture, University of Tabriz
(Corresponding Author: fateme.pourhosseini@yahoo.com)
2- Assistant Professor, Department of Engineering, Faculty of Agriculture, University of Tabriz
Received: April 21, 2016 Accepted: September 4, 2016

Abstract

Accurate simulation runoff process can have a significant role in water resources management and related issues. The inherent complexity of this process makes difficult the use of physical and numerical models. In recent years, application of intelligent models is increased a powerful tool in hydrological modeling. The aim of this study was the application of the Gamma test to select the optimal combination of input variables for runoff modeling in Sofi Chay. Streamflow modeling was performed based on the optimum number of the selected variables using the artificial neural network (ANN) and Support vector machine (SVM) methods .Gamma test results showed that monthly runoff with six antecedent runoff values provide better results to predict. Runoff simulation using support vector machines and artificial neural network models also showed that the best input structure will be delayed until six to predict of next month runoff. Among to models with the same input structure, support vector machine have relatively high efficiency compared to artificial neural network.

Keywords: Artificial Neural Network, Gamma Test, Runoff, SofiChay River, Support Vector Machine

[Downloaded from jwmr.sanru.ac.ir on 2026-10-30]

[DOR: 20.1001.1.22516174.1397.9.17.2.4]

[DOI: 10.29252/jwmr.9.17.57]