

معصومه زینعلی^۱، سهیلا فرزی^۲، محمدرضا گلایی^{۳*}، فریدون رادمش^۴

- ۱- دانش آموخته کارشناسی ارشد مهندسی منابع آب، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه رازی کرمانشاه، ایران، m.zeinalie@gmail.com
- ۲- دانش آموخته کارشناسی ارشد آبیاری و زهکشی، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه رازی، کرمانشاه، ایران، soheilafarzi@yahoo.com
- ۳- دانشجوی دکتری منابع آب، دانشکده مهندسی علوم آب، دانشگاه شهید چمران اهواز، ایران، Hamidgolabi65@gmail.com
- ۴- دانشیار گروه مهندسی آب، دانشکده مهندسی علوم آب، دانشگاه شهید چمران اهواز.

تاریخ دریافت: ۱۳۹۶/۰۹/۲۱

تاریخ پذیرش: ۱۳۹۶/۱۱/۲۰

چکیده

یکی از مهم ترین مسائل در مهندسی منابع آب، پیش‌بینی میزان دبی رودخانه‌ها، به عنوان یکی از منابع اصلی تأمین کننده آب بشر، می‌باشد که از نظر برنامه‌ریزی منابع آب دارای اهمیت است. استفاده از مدل‌های جدید در این زمینه می‌تواند به مدیریت و برنامه‌ریزی صحیح کمک کند. در این مطالعه، به ارزیابی ۳ مدل به نام‌های، شبکه عصبی - فازی (ANFIS)، شبکه بیزین (BN) و ماشین بردار پشتیبان (SVM) پرداخته شده است. داده‌های مورد استفاده برای این پژوهش، داده‌های بارش و جریان روزانه رودخانه گاماسیاب نهاوند در یک دوره ۱۰ ساله (۱۳۸۱-۱۳۹۱) می‌باشد. نتایج نشانگر این بود که مدل شبکه عصبی - فازی (ANFIS) و ماشین بردار پشتیبان (SVM) تقریباً عملکرد یکسانی در مدل‌سازی جریان روزانه رودخانه داشتند و نسبت به مدل شبکه بیزین کارایی بهتری داشتند. علاوه بر این سرعت اجرای مدل SVM نسبت به بقیه مدلها بیشتر بود و در زمان کوتاهی قادر به ارائه نتایج بود.

واژه‌های کلیدی: مدل‌سازی جریان، مدل ANFIS، مدل BN، مدل SVM

مقدمه

سابقه‌ای طولانی هستند. در این بین نبود قطعیت و غیرخطی بودن قوی روابط بین متغیرها، مسأله را پیچیده می‌کند. همچنین مدل‌های فیزیکی و مفهومی هیدرولوژیکی به دلیل نیاز به اطلاعات فراوان، پارامترهای گوناگون و واسنجی وقت‌گیر، کمتر مورد توجه قرار گرفته‌اند. به همین دلیل برآورد صحیح و دقیق جریان رودخانه با استفاده از مدل‌های مختلف یکی از موضوعاتی است که در منابع آب مورد بررسی پژوهشگران می‌باشد. این مسئله به عنوان یکی از چالش‌های مدیریت منابع آب در دهه‌های اخیر مطرح بوده است در این راستا استفاده از مدل‌های جدید در این زمینه می‌تواند به مدیریت و برنامه‌ریزی صحیح کمک کند. فرامدل‌های شبیه ساز شبکه عصبی -

بهره برداری بهینه و مناسب از منابع آب یکی از وظایف مهم مدیران منابع آب می‌باشد. از طرف دیگر عدم تخمین مناسب رواناب حاصل از بارش در حوضه های آبریز، مدیریت بهینه منابع آبی و به ویژه مدیریت بهره برداری از مخازن سدها را دچار مشکل می نماید. در این میان مقوله شبیه‌سازی به عنوان راهکاری مناسب جهت تخمین رواناب، نمود پیدا می‌کند. تاکنون مدل‌ها و روش‌های مختلفی برای تخمین و شبیه‌سازی فرآیند بارش - رواناب ارائه شده است که با استفاده از آن‌ها شدت جریان رودخانه‌ها پیش‌بینی می‌شود. برای پیش‌بینی جریان رودخانه، استفاده از مدل‌های آماری، هیدرولوژیکی و هیدرولوژیکی دارای

M5 بود [۲۴]. احمدی و همکاران به مقایسه روش های برنامه ریزی ژنتیک و ماشین بردار پشتیبان برای پیش بینی جریان روزانه رودخانه باراندوزچای پرداختند. مقایسه نتایج دو مدل نشان داد که گرچه دقت روش برنامه ریزی ژنتیک نسبت به روش ماشین بردار پشتیبان اندکی بیشتر بود، اما روش ماشین بردار پشتیبان به مراتب ساده تر از روش برنامه ریزی ژنتیک می باشد و این روش می تواند به عنوان یک روش کاربردی برای پیش بینی جریان روزانه به کار رود [۱]. Karimi پیش بینی کوتاه مدت و بلند مدت جریان رودخانه فلیوس^۱ در ترکیه را با استفاده از مدل ترکیبی برنامه ریزی بیان ژن-موجک مورد بررسی قرار دادند. نتایج نشان داد که مدل ترکیبی عملکرد بهتری نسبت به مدل GEP دارد. آن ها همچنین از مدل های ANN، ARMA و ANFIS برای مقایسه استفاده کردند. نتایج نشان داد که عملکرد مدل ترکیبی از بقیه مدل ها بهتر بوده است [۱۲]. Singh and et al. به مدل سازی رواناب روزانه حاصل از حوضه کاپگری در شرق هندوستان پرداختند. آنها با استفاده از روش نمونه گیری مجدد تعداد لایه های پنهان و تعداد نرون های بهینه را پیشنهاد دادند و نشان دادند این روش حتی در مرحله آموزش سری های زمانی کوتاه مدت نتایج خوبی را ارائه می دهد [۲۱]. Kalin and Noori از مدل شبکه عصبی مصنوعی و SWAT به منظور پیش بینی روزانه ی جریان رودخانه در ۲۹ حوضه آبریز نزدیک و اطراف آتلانتا در جنوب شرقی ایالات متحده استفاده کردند. با توجه به نتایج بدست آمده از مدل ها و خطای آنها هر دو مدل شبکه عصبی مصنوعی و SWAT عملکرد خوبی برای این هدف داشته اند [۱۷]. قربانی و دهقان، در پژوهشی به بررسی کارایی سه مدل شبکه عصبی بیزین، GEP و SVM را در تخمین رواناب ماهانه رودخانه کاکارضا مقایسه کردند. از میان سه مدل ذکر شده، شبکه عصبی بیزین بهترین

فازی (ANFIS)، شبکه بیزین (BN) و ماشین بردار پشتیبان (SVM) از جدیدترین الگوریتم های فراکاوشی هستند که به دلیل دارا بودن دقت کافی، مورد توجه پژوهشگران قرار گرفته اند. زیرا با استفاده از آنها، عدم قطعیت های موجود را به همراه درک روابط ذاتی میان داده ها که ریاضیات کلاسیک قادر به حل آنها نمی باشد، می توان مدل سازی نمود. در زمینه ی استفاده از مدل های فوق، برای پیش بینی جریان رودخانه می توان به مطالعات زیر اشاره نمود: قربانی و همکاران، عملکرد سه روش برنامه ریزی ژنتیک، شبکه عصبی مصنوعی و نروفازی را در روندیابی سیلاب رودخانه قزل ایرماق ترکیه مورد ارزیابی قرار دادند. نتایج این مطالعه نشان داد که از بین سه روش مذکور مدل برنامه ریزی ژنتیک با دقت بیشتری هیدروگراف خروجی را شبیه سازی کرده است [10]. Nabezadeh and et al، جریان رودخانه را با استفاده از ANFIS و FIS در حوضه آبریز ليقوان چای در استان آذربایجان شرقی و با استفاده از داده های روزانه دبی، به مدت ۶ سال جریان رودخانه را پیش بینی کردند و نتایج پژوهش آنها نشان داد با توجه به معیارهای ارزیابی و اینکه ANFIS دبی های اوج را بخوبی برآورد و پیش بینی می کند عملکرد بهتری نسبت به FIS دارد [3]. Adamowski مدل های ماشین بردار پشتیبان و شبکه عصبی مصنوعی را برای شبیه سازی بارش- رواناب حوضه کوهستانی دهرادان در هندوستان بکار بردند. مدل SVM در پیش بینی رواناب مستقیم، جریان پایه و جریان کل این منطقه عملکرد بهتری داشته است [۶]. Zahiri and Azamathulla برای پیش بینی دبی جریان در مقاطع مرکب از دو روش برنامه ریزی ژنتیک خطی و مدل درختی M5 استفاده کردند. نتایج نشان داد که هر چند هر دو مدل از دقت بالایی برای پیش بینی جریان برخوردار بودند، اما دقت روش برنامه ریزی ژنتیک خطی بالاتر از مدل درختی

1- Hlyos

2- Auto regressive moving average

از محلی به نام کوه سنگ سوراخ سرچشمه می گیرد. حوضه آبریز در این پژوهش به بررسی بخشی از حوضه آبریز رودخانه گاماسیاب از قسمت ابتدا تا نقطه ایستگاه وراینه پرداخته شده است. ایستگاه وراینه در موقعیت جغرافیایی ۴۸ درجه و ۲۴ دقیقه و ۱۵ ثانیه طول شرقی و ۳۴ درجه و ۰۴ دقیقه و ۳۲ ثانیه عرض شمالی قرار دارد. این ایستگاه در سال ۱۳۴۸ تأسیس شده است و دارای ارتفاع ۱۷۹۵ متر از سطح دریا با میانگین بارش سالانه دراز مدت ۵۲۱ میلی متر می باشد. داده های مورد استفاده برای این پژوهش، داده های بارش و جریان روزانه رودخانه گاماسیاب نهبوند در یک دوره ۱۰ ساله (۱۳۸۱-۱۳۹۱) می باشد. ابتدا داده های روزانه از سازمان آب منطقه ای همدان دریافت شد، با توجه به اینکه داده ها به صورت کامل موجود بودند بررسی داده ها فقط از نظر داده های پرت مورد بررسی قرار گرفته و مشکلات موجود برطرف گردید. با فرض وابستگی جریان رودخانه به جریان روزهای قبل، اقدام به تخمین جریان روز بعد با استفاده از داده های بارش و جریان امروز می شود. از بین داده های ورودی ۷۵ درصد (۲۷۳۹ داده) از آنها را برای آموزش مدل و ۲۵ درصد (۹۱۳ داده) باقیمانده برای تست مدل انتخاب می شود. برای مرحله پیش بینی یا شبیه سازی از داده های سال آبی (۱۳۸۰-۱۳۸۱) استفاده شده است (جدول ۱). شکل ۱ موقعیت ایستگاه وراینه را نشان می دهد.


عملکرد را داشته است [۲]. نعیمی کلوزی و همکاران، سه روش شامل مدل درختی، نزدیک ترین همسایگی و رگرسیون خطی چند متغیره را برای برآورد آبدی در حوضه های آبریز بدون آمار استان گلستان بررسی کردند [۴]. لذا هدف از این مطالعه در ابتدا بیان نمودن تفاوت ها و شناسایی این ۳ مدل و سپس مدل سازی جریان رودخانه گاماسیاب با استفاده از فرامدل های شبیه ساز شبکه عصبی - فازی (ANFIS)، شبکه بیزین (BN) و ماشین بردار پشتیبان (SVM) است که در اکثر مطالعات، با توجه به تعداد زیاد مدل های موجود برای شبیه سازی، برتری خود را ثابت کرده اند و مقایسه آنها با یکدیگر برای تشخیص اینکه کدام یک از این فرامدل های شبیه ساز نسبت به بقیه برتری دارد. سوال اساسی این تحقیق این است که آیا فرامدل شبیه ساز برتر در این مطالعه با توجه به دقت در مرحله آموزش و تست می تواند در شرایط کمبود داده و اطلاعات، جایگزین مناسبی برای مدل های مفهومی باشد.

مواد و روش ها

منطقه مورد مطالعه، رودخانه گاماسیاب است که در غرب کشور، در محدوده استان های همدان، کرمانشاه و لرستان واقع شده است. رودخانه گاماسیاب از چشمه های کارستی گاماسیاب در ۲۰ کیلومتری جنوب غربی شهر نهبوند و در فاصله اندکی از جاده ارتباطی نهبوند به نورآباد لرستان، از ارتفاع ۱۸۶۰ متری

جدول ۱- متغیرهای اقلیمی ایستگاه وراینه

مقیاس زمانی	متغیر اقلیمی	واحد اندازه گیری	میانگین	حداقل	حداکثر
Time scale	Climatic Variable	Unit of Measurement	Average	Minimum	Maximum
روزانه Daily	جریان Flow	مترمکعب در ثانیه (m ³ /s)	۳/۷۸	۰/۶۷	۲۲/۸۶
	بارش Precipitation	میلی متر (mm)	۱/۴۳	۰	۹۶



شکل ۱- موقعیت ایستگاه وراینه در شهرستان نهاوند، استان همدان و ایران

دامنه توابع تعلق در تکرارهای مختلف جهت رسیدن به شبکه مناسب بر اساس حداقل خطای موجود عمل می‌کند. در مدل سیستم استنتاج عصبی فازی تطبیقی از روش استنتاجی تاکاگی سوگنو استفاده می‌شود. زمانی عمل شبیه‌سازی به درستی استفاده شده است که تمامی پارامترهای مؤثر در ساختار مدل طوری تعیین گردند که مقدار خطای مدل به حداقل مقدار خود برسد و همچنین مقادیر کارایی، بیشترین مقدار را داشته باشند.

ساختار و الگوریتم

سیستم استنتاج فازی-عصبی تطبیقی قابلیت خوبی در آموزش، ساخت و طبقه‌بندی دارد و همچنین دارای این مزیت است که اجازه استخراج قوانین فازی را از اطلاعات عددی یا دانش متخصص می‌دهد و به طور تطبیقی یک قاعده- بنیاد می‌سازد. علاوه بر این، می‌تواند تبدیل پیچیده هوش بشری به سیستم‌های فازی را تنظیم کند. مشکل اصلی مدل پیش‌بینی سیستم شبکه عصبی- فازی تطبیقی احتیاج نسبتاً زیاد به زمان برای آموزش ساختار و تعیین پارامترها می‌باشد. به منظور ساده‌سازی، فرض می‌شود که سیستم استنتاجی مورد نظر دو ورودی x و y و یک خروجی z دارد. برای یک مدل فازی تاکاگی سوگنو

شبکه عصبی-فازی (ANFIS)

نظریه مجموعه فازی توسط پروفیسور لطفی عسگرزاده مشهور به زاده در سال ۱۹۶۵ پیشنهاد شد و به طور گسترده در بسیاری از زمینه‌ها استفاده می‌شود [۱۱]. این تئوری، ابزاری توانمند و انعطاف‌پذیر برای مدل‌سازی عدم قطعیت‌ها و عدم صراحت‌های موجود در دنیای واقعی و بیان عبارات‌های زبانی برگرفته از تجربه و دانش بشر در قالب روابط ریاضی به شمار می‌آید. پیچیدگی و عدم قطعیت در سیستم‌های هیدرولوژیکی، کمبود اطلاعات در بسیاری از فرآیندهای هیدرولوژیکی، مبهم و غیر صریح بودن این داده‌ها موجب شد تا استفاده از تئوری فازی در زمینه هیدرولوژی و بارش-رواناب که از اصلی‌ترین فرآیندهای هیدرولوژیکی است افزایش یابد [۱۱]. با این وجود، مشکل اصلی منطق فازی این است که روند سینماتیکی برای یک کنترل کننده فازی وجود ندارد. به عبارت دیگر، یک شبکه عصبی این توانایی را دارد که از محیط آموزش ببیند، جفت‌های ورودی و خروجی، ساختارش را خود مرتب کند و با شیوه‌ای، تعامل خود را تطبیق دهد. بدین منظور پروفیسور ژانگ و همکاران در سال ۱۹۹۷ مدل سیستم شبکه عصبی- فازی تطبیقی را ارائه کردند که قابلیت ترکیب توانایی دو روش مذکور را داشت [۱۱]. مدل فازی عصبی تطبیقی براساس تغییر در میزان مقادیر و

قانون به مجموع همه قوه اشتعال قوانین می باشد در نتیجه w_i قوه اشتعال نرمال شده به دست می آید.

(۳)

$$O_{3,i} = \bar{w}_i = \frac{w_i}{\sum_{k=1}^4 w_k}$$

لایه چهارم، گره های نتیجه: تابع گره چهارمین لایه توزیع i امین قانون را به کل خروجی محاسبه می کند و به صورت زیر تعریف می شود:

(۴)

$$o_{4,i} = \bar{w}_i f_i = w_i (p_i x + q_i y + r_i)$$

که \bar{w}_i خروجی i امین گره از لایه قبلی است. $(p_i q_i r_i)$ ضرایب این ترکیب خطی بوده، همچنین مجموعه پارامترهای بخش تالی مدل فازی تاکاگی- سوگنو نیز می باشند.

لایه پنجم، گره های خروجی: این تک گره، خروجی کلی را با جمع کردن همه سیگنال های ورودی محاسبه می کند. بنابراین، در این لایه فرآیند غیرفازی سازی، نتایج هر قانون فازی را به خروجی غیرفازی تغییر شکل می دهد.

$$O_{5,i} = \bar{w}_i f_i = \frac{\sum_{i=1}^4 w_i f_i}{\sum_{i=1}^4 w_i} \quad (5)$$

ویژگی متمایز کننده ANFIS، فراهم کردن الگوریتم یادگیری پیوندی روش شیب پس انتشار و روش حداقل مربعات، به منظور اصلاح پارامترها می باشد. روش شیب پس انتشار جهت تنظیم پارامترهای غیرخطی مقدماتی به کار گرفته می شود، در حالی که روش حداقل مربعات جهت تعیین پارامترهای خطی بخش تالی مورد استفاده قرار می گیرد. روند آموزش دو مرحله دارد: مرحله اول با ثابت فرض کردن پارامترهای بخش مقدماتی، از روش حداقل مربعات، پارامترهای بخش تالی تعیین می گردند. سپس در مرحله دوم، سیگنال های خطا پس انتشار می یابند. روش شیب پس انتشار به این جهت به کار می رود تا پارامترهای مقدماتی از طریق حداقل

درجه اول، می توان یک مجموعه قانون نمونه را با دو قانون اگر-آنگاه فازی به صورت زیر بیان کرد:

$$\text{قانون اول: اگر } x \text{ برابر } A_1 \text{ و } y \text{ برابر } B_1 \text{ باشد آنگاه} \\ = p_1 x + q_1 y + r_1 z_1$$

$$\text{قانون دوم: اگر } x \text{ برابر } A_2 \text{ و } y \text{ برابر } B_2 \text{ باشد آنگاه} \\ = p_1 x + q_2 y + r_2 z_2$$

که p_i, q_i, r_i ($i=1,2$) پارامترهای خطی در بخش تالی مدل فازی تاکاگی- سوگنو درجه اول هستند [۵].

مطابق شکل ۲ ساختار سیستم استنتاج فازی- عصبی تطبیقی شامل پنج لایه می باشد [۱۹].

لایه اول، گره های ورودی: هر گره از این لایه، مقادیر عضویتی که به هر یک از مجموعه های فازی مناسب تعلق دارند، با استفاده از تابع عضویت تولید می کنند.

$$O_{1i} = \mu_{A_i}(x) \quad i = 1 \text{ و } 2 \quad (1)$$

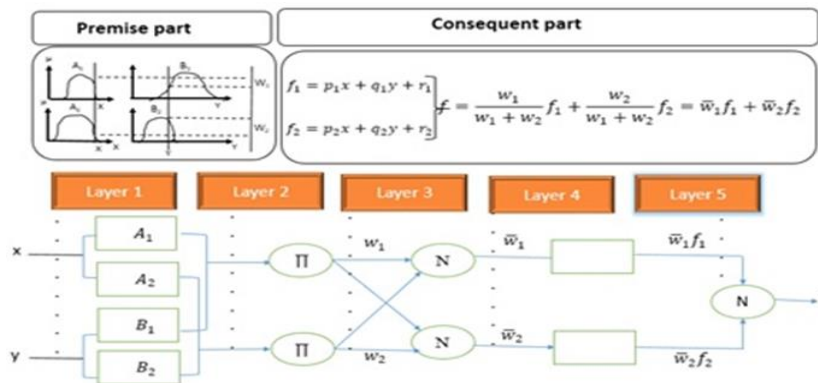
$O_{2i} = \mu_{i-2}(x)$ $i = 3$ و 4
 که x و y ورودی های غیرفازی به گره i ، A_1 و B_1 برچسب های زبانی هستند که به ترتیب با توابع عضویت مناسب μ_{A_i} و μ_{B_i} مشخص می شوند. باید پارامترهای این توابع عضویت که به عنوان پارامترهای مقدماتی در این لایه شناخته می شوند، مشخص شوند. لایه دوم، گره های قاعده: در لایه دوم، عملگر " و " (AND) به کار برده می شود تا خروجی (قوه اشتعال) که نمایانگر بخش مقدم آن قانون است بدست آید. قوه اشتعال به مقدار درجه ای که بخش مقدم یک قانون فازی برآورده شده، گفته می شود و به تابع خروجی آن قانون، شکل می دهد. از این رو، خروجی- های $O_{2,k}$ این لایه، حاصل ضرب درجات مربوط به لایه اول هستند.

$$O_{2,k} = \mu_{A_i}(x) \times \mu_{B_i}(y) \quad (2)$$


لایه سوم، گره های متوسط: هدف اصلی در لایه سوم، تعیین نسبت هر قوه اشتعال به عنوان i امین

مدل سیستم استنتاج عصبی فازی تطبیقی آورده شده است.

کردن تابع هزینه درجه دوم کلی، اصلاح شود. در شکل ۳ ساختاری از عملکرد و ارتباط بین لایه‌ها در



شکل ۲- سیستم ANFIS معادل با سیستم فازی سوگنو با تابع عضویت مثلثی



شکل ۳- ساختار لایه‌ها در مدل سیستم استنتاج فازی عصبی تطبیقی


و کمان‌ها، برای نمایش روابط احتمالی میان متغیرها به‌شمار می‌رود. مک‌کی (۱۹۹۲) دو سطح از استنتاج‌های بیزی را که می‌توان در مدل‌سازی شبکه عصبی بیزین^۲ به کار رود تشریح کرده است. اولین سطح شامل استخراج شبکه وزن‌ها می‌باشد البته با این فرض که ساختار شبکه انتخاب شده صحیح است. سطح دوم شامل مقایسه مدل‌ها و انتخاب مدل است [۱۴]. شبکه عصبی بیزین ابزاری مفید جهت تجزیه و تحلیل عدم قطعیت در مدل‌سازی شبکه‌های عصبی مصنوعی و یکی از روش‌های سیستم پشتیبان تصمیم‌گیری است که از یک شکل هوش مصنوعی استفاده کرده و براساس قانون یادگیری شبکه بیزین

شبکه بیزین (BN)

روش بیزین نخستین بار در اوایل دهه ۱۹۹۰ بوسیله بنتین و بعدها مک‌کی (۱۹۹۲) برای شبکه‌های عصبی مصنوعی به کار برده شد و با سرعت به یک ابزار انتخاب برای کاربردهای هوش مصنوعی تبدیل گشته است [۱۴]. در شبکه‌های بیزین برخلاف شبکه‌های عصبی متداول هدف یافتن یک بردار وزن بهینه نیست بلکه ارائه عدم قطعیت صریح با توجه به مقادیر وزن بوسیله توزیع احتمال ثانویه است [۱۳]. شبکه بیزین^۴ نمایش بامعنی روابط نامشخص مابین پارامترها در یک فرآیند می‌باشد و گرافی جهت‌دار غیرحلقوی از گره‌ها، برای نمایش متغیرهای تصادفی

1-Bayesian Network

2-Bayesian Neural Network



شکل ۴- نمایش گراف چرخه‌ای و مستقیم شبکه بیزین

ماشین بردار پشتیبان (SVM)

ماشین بردار پشتیبان^۲ (SVM) دسته‌بندی کننده‌ای است که جزء شاخه‌ی روش‌های کرنلی^۳ یادگیری ماشین محسوب می‌شود. این نوع سیستم یادگیری هم برای دسته‌بندی و هم برای تخمین و برآورد تابع برازش داده‌ها به کار می‌رود، به طوری که کمترین خطا در دسته‌بندی داده‌ها و یا تابع برازش رخ دهد. ماشین بردار پشتیبان در سال ۱۹۹۲ توسط وپنیک^۴ که یک ریاضیدان روس بود، بر پایه نظریه یادگیری آماری^۵ بنا گردیده است [۸]. هدف ماشین بردار پشتیبان این است که یک تابع $f(x)$ را برای الگوهای آموزشی x طوری تشخیص دهد که ماکزیمم حاشیه را از مقادیر آموزشی y داشته باشد. به عبارتی دیگر، ماشین بردار پشتیبان مدلی است که یک منحنی با ضخامت ϵ را به داده‌ها برازش می‌دهد به طوری که کمترین خطا در داده‌های آزمایشی صورت بگیرد.

در مورد تئوری مدل‌های مطرح شده در این مقاله، تحقیقات زیادی انجام شده است [۷-۲۲]. لذا در این مقاله تنها به شرح خلاصه‌ای از مدل مورد استفاده SVM به نام ϵ SVM پرداخته شده است. در یک مدل رگرسیونی SVM لازم است وابستگی تابعی متغیر وابسته y به مجموعه‌ای از متغیرهای مستقل x

آموزش دیده و با استفاده از اطلاعات مبهم، ناکافی، متضاد و غیرقطعی هم در گذشته و هم در حال حاضر، پارامترها را به صورت عصب به یکدیگر ارتباط می‌دهد که فعالیت سلسله اعصاب یک شبکه و چگونگی پیوند بین آنها مبنای هوشمندی شبکه را نشان می‌دهد. شبکه‌های عصبی بیزین در حل مسائلی که روابط بین متغیرها به درستی مشخص نباشد بسیار مفید هستند.

الگوریتم بیزین

شبکه بیزین یک مدل گرافیکی احتمالاتی است که مجموعه‌ای از متغیرها و احتمالات را نشان می‌دهد. این شبکه، یک گراف مستقیم و غیرچرخه‌ای است که در آن گره‌ها در حکم متغیرهای مسئله هستند. شبکه‌های بیزین محدودیتی در نمایاندن متغیرهای تصادفی ندارند. ساختار یک شبکه بیزین در واقع یک نمایش نموداری از اثرات متقابل متغیرهایی است که باید الگوبندی شوند، علاوه بر اینکه کیفیت، رابطه بین متغیرهای مسئله را نشان می‌دهد، کمیت، ارتباط بین این متغیرها را نیز به نمایش می‌گذارد.

این روش بر مبنای محاسبات احتمالات شرطی (قانون بیز) است. معادله زیر رابطه بیز را نشان می‌دهد.

$$p(a|b) = \frac{p(b|a) * p(a)}{p(b)} \quad (۶)$$

که در آن، $p(a)$ احتمال وقوع پیشامد a ، $p(b)$ احتمال وقوع پیشامد b ، $p(b|a)$ احتمال شرطی پیشامد b است به شرطی که پیشامد a اتفاق افتاده باشد و $p(a|b)$ ، احتمال شرطی پیشامد a است. شکل ۴ نمونه‌ای از گراف شبکه بیزین را به صورت چرخه‌ای و مستقیم نشان می‌دهد.

1- Bayes Theorem
2- Support Vector Machines
3- kernel methods
4- Vpnik
5- Statistical Learning Theory

بنابراین در این تحقیق تابع مذکور که توسط γ در رابطه زیر تعریف شده است، به کار گرفته شد.

$$K(x_i, x) = \exp(-\gamma |x_i - x|^2) \quad (10)$$

با توجه به روابط ۸ تا ۱۰ لازم است برای پیش بینی دبی روزانه، توسط مدل SVM سه پارامتر γ ، ε و C بهینه شوند.

معیارهای ارزیابی مدل‌ها

برای ارزیابی مدل‌ها از سه معیار، ضریب تبیین (R^2)، جذرمیانگین مربعات خطا (RMSE) و پارامتر نش (NASH) استفاده شد. پارامتر آماری نش در سال ۱۹۷۰ توسط نش و ساتکلیف معرفی گردید [۱۵].

در زیر روابط این معیارها ارائه شده است.

(۱۱)

$$RMSE = \sqrt{\frac{\sum (Q_{obs} - Q_{pre})^2}{n}}$$

(۱۲)

$$R^2 = 1 - \frac{\sum_{i=1}^N (Q_{obs} - Q_{pre})^2}{\sum_{i=1}^N (Q_{obs} - \bar{Q})^2}$$

$$NASH = 1 - \frac{\sum_{i=1}^N (Q_{obs} - Q_{pre})^2}{\sum_{i=1}^N (Q_{obs} - \bar{Q})^2} \quad (13)$$

در روابط فوق، n : تعداد داده‌ها، Q_{obs} : داده‌های مشاهداتی، \bar{Q} : میانگین داده‌های مشاهداتی، Q_{pre} : داده‌های محاسباتی، Q_{max} : حداکثر داده‌ها، Q_{min} : حداقل داده‌ها می‌باشد. ضریب R^2 میزان انطباق داده‌هایی که توسط مدل به وجود می‌آید و داده‌های واقعی را نشان می‌دهد. RMSE جذر میانگین مربع خطاهای داده‌های محاسباتی و مشاهداتی را بیان می‌کند. واضح است که هر چه مقدار این عدد کمتر باشد به تبع، آموزش و شبیه‌سازی داده‌ها بهتر صورت گرفته است. همچنین هرچه مقدار پارامتر نش به یک نزدیکتر باشد نشان دهنده تطابق بیشتر مقادیر شبیه سازی شده با مقادیر مشاهداتی است.

تخمین زده شود. فرض بر این است که مانند دیگر مسائل رگرسیونی، رابطه بین متغیرهای وابسته و مستقل توسط یک تابع معین f به علاوه یک مقدار اضافی نویز مشخص می‌شود.

$$y = f(x) + noise \quad (7)$$

بنابراین موضوع اصلی پیدا کردن فرم تابع f است که بتواند بصورت صحیح، موارد جدیدی را که SVM تاکنون تجربه نکرده است پیش بینی کند. این تابع توسط آموزش مدل SVM بر روی یک مجموعه داده به عنوان مجموعه آموزش که شامل فرایندی به منظور بهینه‌سازی دائمی تابع خطا است، قابل دسترسی است. بر مبنای تعریف این تابع خطا، دو نمونه از مدل‌های SVM شناخته شده است که عبارتند از الف) مدل‌های رگرسیون SVM نوع اول که به مدل‌های SVM v- مشهورند. ب) مدل‌های رگرسیون SVM نوع دوم که به مدل‌های ε SVM مشهورند. در این مطالعه مدل SVM ε بدلیل کاربرد گسترده آن در مسائل رگرسیونی استفاده گردید. برای این مدل تابع خطا بصورت زیر تعریف می‌شود.

$$\frac{1}{2} W^T W + C \sum_{i=1}^N \xi_i + C \sum_{i=1}^N \xi_i^0 \quad (8)$$

تابع خطای مذکور لازم است که با توجه به محدودیت‌های زیر کمینه گردد.

$$\begin{aligned} W^T \Phi(x_i) + b - y &\leq \varepsilon + \xi_i^0 \\ y_i - W^T \Phi(x_i) - b &\leq \varepsilon + \xi_i^0 \\ \xi_i, \xi_i^0 &\geq 0 \\ i &= 1, \dots, N \end{aligned} \quad (9)$$

که در این روابط C ثابت گنجایش، W بردار ضرایب، WT ترانهاده بردار ضرایب، ξ_i, ξ_i^0 ضرایب کمبود، b ضریبی ثابت، N الگوی آموزش مدل و Φ تابع کرنل است.

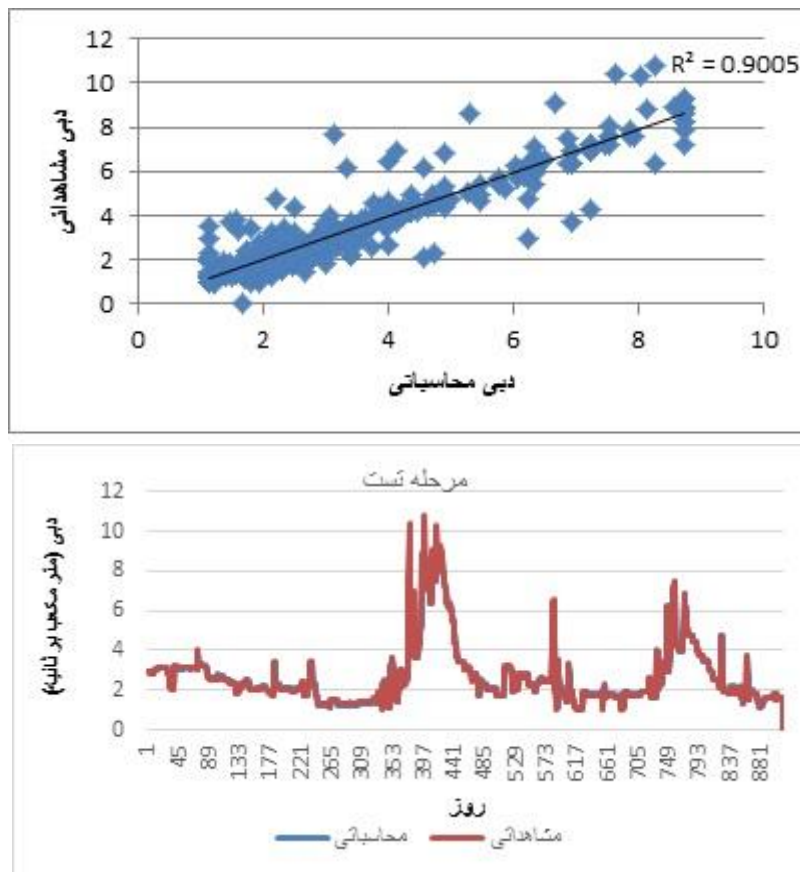
کرنل تابع پایه شعاعی به عنوان بهترین انتخاب از بین دیگر توابع کرنل گزارش شده است [۱۶-۱۸-۹].

بحث و نتایج

نتایج شبکه عصبی- فازی (ANFIS)

برای داشتن مدل سازی مناسب باید تک تک توابع عضویت را یک به یک مورد بررسی قرار داد و با توجه به معیارهای ارزیابی مدل بهترین مدل را انتخاب نمود. با بررسی ترکیب های مختلف مدل عصبی فازی و انتخاب هر یک از انواع توابع عضویت مربوط به پارامتر های ورودی و خروجی مدل در نهایت مدلی با تابع عضویت ورودی نوع دوزنقه ای (Trapmf) و تابع عضویت خروجی نوع constant کمترین مقدار خطای مرحله تست را داشته و انتخاب شد. مقدار خطای

مرحله آموزش و تست به ترتیب برابر ۰/۵۸۴۲ و ۰/۴۹۷۹۱ می باشد. بعد از ذخیره سازی مدل، ضریب تبیین مقادیر مشاهداتی و خروجی مرحله آموزش ۰/۹۲۳۵ می باشد و نشان از عملکرد خوب مدل در مرحله آموزش می باشد. همچنین ضریب تبیین بین این خروجی و داده های مشاهداتی در مرحله تست ۰/۹۰۰۵ می باشد که بازهم نشان از عملکرد خوب مدل دارد. شکل (۵) مقایسه مقادیر مشاهداتی با مقادیر برآوردی برای ساختار برتر فرامدل شبیه ساز عصبی- فازی در مرحله تست را نشان می دهد.



شکل ۵- مقایسه نتایج مدل عصبی فازی با مقادیر مشاهده ای، مرحله تست

شبکه بیزین (BN)

مراحل ساخت و توسعه مدل شبکه بیزین در مطالعه حاضر برای مدل سازی جریان روزانه رودخانه گاماسیاب بصورت زیر انجام شد:

تشکیل چارچوب مدل: که شامل تعریف متغیرها و روابط موجود بین آنها در سیستم است و معمولاً بر اساس یک مدل مفهومی از سیستمی که قرار است مدل سازی و مدیریت شود، شکل می گیرد. بنابراین

این ارتباط بدست آمد. حال با ارتباط ریاضی موجود می‌توان داده مصنوعی تولید کرده و عملکرد مدل را مورد ارزیابی قرار داد. همچنین رابطه ریاضی حاصل از الگوی ورودی بصورت رابطه ۱۴ بدست آمد. مدل بیزین با ضریب تبیین ۰/۹۱۲ و جذر میانگین مربعات ۰/۵۷۲۱ در مرحله آموزش و ضریب تبیین ۰/۸۹۱۲ و جذر میانگین مربعات ۰/۵۳۱۷ در مرحله تست انتخاب شد. شکل (۷) مقایسه مقادیر مشاهداتی با مقادیر برآوردی برای ساختار برتر فرامدل شبیه ساز بیزین در مرحله تست را نشان می‌دهد.


$$Q_2 = -0.00861381 * P_t + 0.961715 * Q_1 + Normal(0.129008, 0.600809)$$

(۱۴)

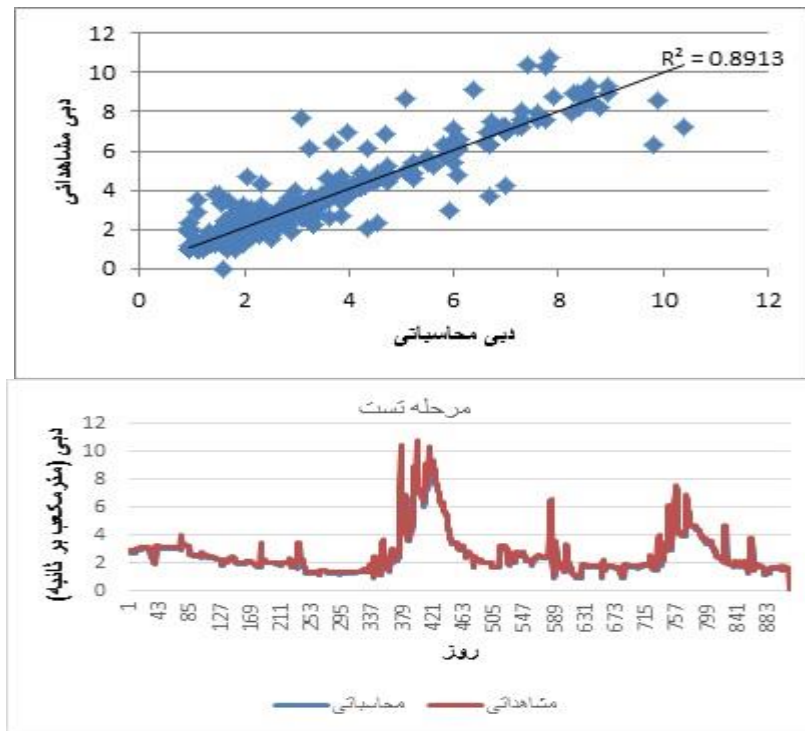
ساخت مدل مفهومی، اولین قدم در ساختن مدل بیزین است. در این مطالعه مدل مفهومی بیزین از طریق الگوهای ورودی ساخته شد (شکل ۶).

تعیین نوع ارتباط بین ورودی‌های مختلف مدل در ساختار مدل مفهومی: در مطالعه حاضر از سری روزانه داده‌های بارش و جریان بعنوان ورودی‌های اصلی استفاده شد. حال در تعریف مفهومی برای مدل بیزین این‌گونه در نظر گرفته شد که، دبی فردا متأثر از دبی روز گذشته و بارش می‌باشد (شکل ۶).

آموزش شبکه و بدست آوردن رابطه بین داده‌ها: پس از تشکیل چارچوب و تعریف مدل، نوبت به آموزش شبکه ساخته شده می‌رسد. در این مرحله با استفاده از ورودی‌های مختلف (بارش و دبی) در مدل سعی در ایجاد ارتباط بین داده‌ها داشته و شکل ریاضی



شکل ۶ - مدل مفهومی ساخته شده برای شبکه بیزین



شکل ۷- مقایسه نتایج مدل شبکه بیزین با مقادیر مشاهده‌ای، مرحله تست

ماشین بردار پشتیبان (SVM)

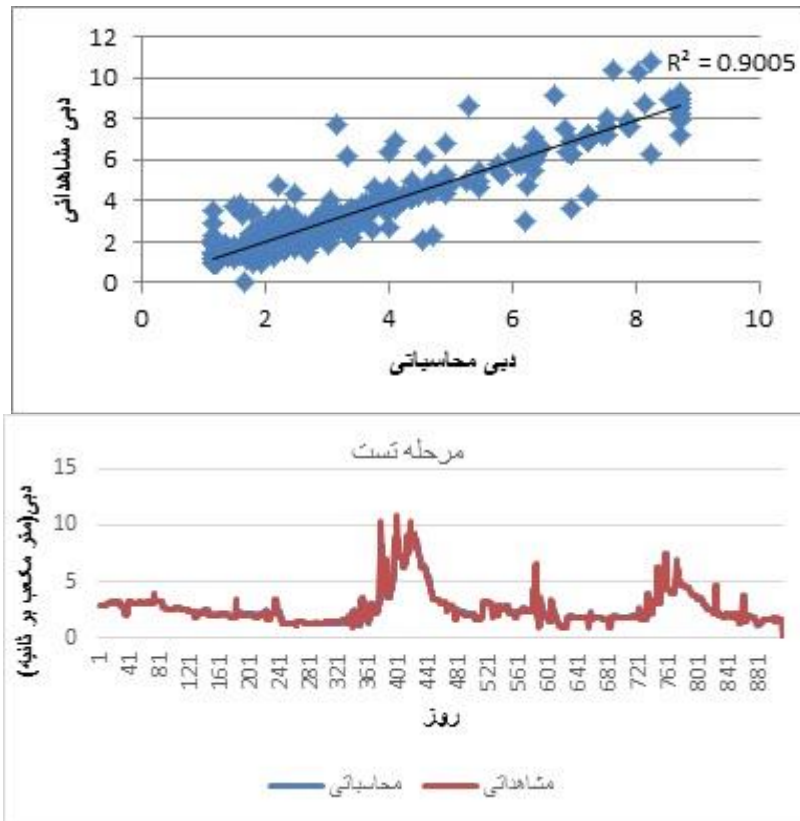
در این مرحله مقادیر بهینه مشخصه‌های مدل SVM شامل ϵ و C تعیین می‌گردد. همچنین در این مطالعه تابع کرنل مورد استفاده، تابع RBF انتخاب شد، زیرا از دقت بیشتری در برآورد جریان روزانه رودخانه گاماسیاب برخوردار بود. در این تابع باید مشخصه γ تعیین گردد. بنابراین در حالت کلی برای مدل سازی و پیش بینی جریان روزانه رودخانه گاماسیاب توسط مدل SVM رگرسیونی، لازم است که مقادیر بهینه سه مشخصه مذکور بدست آید که بدین منظور دو مشخصه ϵ و C توسط الگوریتم بهینه سازی جستجوی شبکه و متغیر γ نیز بصورت آزمون و خطا محاسبه شد و البته قابل ذکر است که الگوریتم بهینه سازی جستجوی شبکه بسیار کند عمل می‌کند و زمان محاسباتی زیادی را بخود اختصاص می‌دهد. برای حل این مشکل در تحقیق مذکور طبق توصیه یو و همکاران (۲۰۰۶) از برنامه اصلاح شده الگوریتم جستجوی شبکه که به نام الگوریتم

جستجوی شبکه دو مرحله‌ای معروف است به همراه اعتبارسنجی مقاطع استفاده شد [۲۵]. برای این منظور ابتدا با انتخاب شبکه‌هایی با ابعاد بزرگ محدوده مشخصه‌های ϵ و C به ازای مقدار ثابت مشخصه γ تعیین شد. سپس با مشخص شدن محدوده مذکور و تقسیم آن به شبکه‌هایی با ابعاد ریزتر مقادیر دقیق دو مشخصه ϵ و C مشخص شدند. روند مذکور برای دیگر مقادیر γ نیز تکرار شد و بدین طریق مدل‌هایی متفاوتی با تغییر در مقدار γ حاصل شدند. حال می‌توان از بین مدل‌های توسعه داده شده مدل با کمترین خطا را تعیین کرده و مشخصه‌های آن را بعنوان مقادیر بهینه ϵ ، C و γ انتخاب نمود.

در تحقیق حاضر از مدل SVM نیز با استفاده از همان الگوی ورودی بقیه مدل‌ها برای مدل سازی جریان رودخانه گاماسیاب استفاده شد. برای الگوی ورودی با تغییر ϵ ، C و γ شبکه‌های مختلفی ساخته و آموزش داده شد و در نهایت ساختاری که دارای کمترین مقدار خطا بود، یعنی $\epsilon=0.1$ و $C=10$ و

۰/۴۹۷۹ در مرحله تست انتخاب شد. شکل (۸) مقایسه مقادیر مشاهداتی با مقادیر برآوردی برای ساختار برتر فرامدل شبیه ساز ماشین بردار پشتیبان (SVM) در مرحله تست را نشان می‌دهد.

۰/۲۱۰ بعنوان مناسب‌ترین الگو انتخاب شد. مدل ماشین بردار پشتیبان (SVM) با ضریب تبیین ۰/۹۲۳۵ و جذر میانگین مربعات ۰/۵۸۴۱ در مرحله آموزش و ضریب تبیین ۰/۹۰۰۵ و جذر میانگین مربعات



شکل ۸- مقایسه نتایج مدل ماشین بردار پشتیبان با مقادیر مشاهده‌ای، مرحله تست.

مشاهده کرد از طرفی با توجه به پارامتر جذر میانگین مربعات خطا، اگرچه در اینجا هم شاهد اختلاف بسیار اندک در مقدار این پارامتر هستیم ولی تقریباً برتری نسبی مدل ANFIS و SVM نسبت به مدل شبکه بیزین را می‌توان مشاهده کرد. بر اساس معیار AIC که هرچه مقادیر آن کمتر باشد مدل عملکرد بهتری دارد، مشاهده می‌شود که در هر ۳ مدل، هم در مرحله آموزش و هم در مرحله تست شاهد اختلاف بسیار اندک در مقدار این پارامتر هستیم و همچنان شاهد برتری نسبی مدل‌های ANFIS و SVM نسبت به مدل شبکه بیزین هستیم و بر اساس معیار NASH که هرچه مقادیر این پارامتر به یک نزدیک‌تر باشد،

مقایسه نتایج مدل‌های استفاده شده

در این قسمت به منظور این که مقایسه‌ی مناسبی بین عملکرد سه مدل صورت گیرد مقایسه کمی صورت گرفته است. برای مقایسه کمی بین سه مدل از چهار معیار ارزیابی به نام‌های ضریب تبیین، جذر میانگین مربعات خطا، مقدار آکائیکه و پارامتر نش استفاده شد. نتایج این بررسی در جدول (۲) ارائه شده است. با توجه به جدول (۲) و مقایسه مدل‌ها مشاهده می‌گردد در مرحله آموزش و با توجه به ضریب تبیین نتایج هر ۳ مدل تقریباً با اختلاف بسیار اندک، نزدیک به هم است و تقریباً برتری نسبی مدل‌های ANFIS و SVM نسبت به مدل شبکه بیزین را می‌توان

SVM بهتر از فرامدل‌های شبیه ساز شبکه بیزین است، طبق جدول ۲ شبکه عصبی- فازی و ماشین بردار پشتیبان در رتبه اول و مدل شبکه بیزین در این مطالعه در رتبه دوم قرار می‌گیرد.

مدل عملکرد بهتری دارد، مشاهده می‌شود که مدل ANFIS و SVM دارای مقدار تقریباً نزدیک به هم هستند و عملکرد بهتری نسبت به مدل BN داشته‌اند. بنابراین می‌توان با مشاهده مقادیر جدول به این نتیجه رسید که برای مدل‌سازی جریان روزانه رودخانه گاماسیاب عملکرد فرا مدل شبیه‌ساز ANFIS و

جدول ۲- مقایسه مدل‌های استفاده شده در این تحقیق

مدل Model	ضریب تبیین R ²		جذرمیانگین مربعات خطا RMSE		مقدار آکائیکه AIC		پارامتر نش NASH	
	آموزش Train	تست Test	آموزش Train	تست Test	آموزش Train	تست Test	آموزش Train	تست Test
	ANFIS	۰/۹۲۳۵	۰/۹۰۰۵	۰/۵۸۴۱	۰/۴۹۷۹	۵۴۷۶/۹۲	۱۸۲۴/۶۰	۰/۹۱۲۵
BN	۰/۹۱۲	۰/۸۹۱۲	۰/۵۷۲۱	۰/۵۳۱۷	۵۵۴۹/۳۲	۱۸۲۴/۷۳	۰/۸۷۴۲	۰/۸۸۶۲
SVM	۰/۹۲۳۵	۰/۹۰۰۵	۰/۵۸۴۱	۰/۴۹۷۹	۵۴۷۶/۹۲	۱۸۲۴/۶۰	۰/۹۱۲۴	۰/۹۰۰۲

عملکرد بهتری نسبت به مدل دیگر دارد و این امر بیانگر آن است که فرا مدل‌های شبیه‌ساز شبکه عصبی - فازی (ANFIS) و ماشین بردار پشتیبان (SVM) توانایی خوبی برای شبیه‌سازی و پیش بینی جریان روزانه رودخانه دارد و این فرامدل‌های برتر شبیه‌ساز، با توجه به دقت برآورد در مرحله آموزش و تست می‌تواند در شرایط کمبود داده و اطلاعات، جایگزین مناسبی برای مدل‌های مفهومی باشد.

نتیجه گیری

در این تحقیق از سه مدل به نام‌های شبکه عصبی - فازی (ANFIS)، شبکه بیزین (BN) و ماشین بردار پشتیبان (SVM) جهت مدل‌سازی جریان روزانه رودخانه گاماسیاب استفاده شد. هدف از این مطالعه نشان دادن تفاوت‌های بین سه مدل و همچنین بررسی توانایی آن‌ها برای مدل‌سازی جریان روزانه رودخانه گاماسیاب بوده است. نتایج بیانگر این بود که فرامدل‌های شبیه‌ساز شبکه عصبی - فازی (ANFIS) و ماشین بردار پشتیبان (SVM)

منابع

- 1- احمدی، ف. رادمنش، ف. و میرعباسی نجف آبادی، ر. ۱۳۹۳. مقایسه روش‌های برنامه ریزی ژنتیک و ماشین بردار پشتیبان در پیش بینی جریان روزانه رودخانه (مطالعه موردی: رودخانه باراندوزچای). مجله آب و خاک. ۲۸ (۶): ۱۱۶۲-۱۱۷۱.
- 2- قربانی، م.ع. دهقانی، ر. ۱۳۹۵. کاربرد شبکه‌های عصبی بیزین، ماشین بردار پشتیبان و برنامه‌ریزی بیان ژنی در تحلیل بارش - رواناب ماهانه (مطالعه موردی: رودخانه کاکارضا). آبیاری و مهندسی. ۳۹ (۲): ۱۳۸-۱۲۵.
- 3- نبی‌زاده، م. مساعدی، ا. موسوی، ح. دهقانی، ا.ا. زاکری نیا، م. و مفتاح هلقی، م. پیش بینی جریان رودخانه با

استفاده از سامانه استنتاج فازی (FIS) و سامانه استنتاج فازی-عصبی تطبیقی (ANFIS). علوم و مهندسی مدیریت آبخیزداری ایران. ۵ (۱۷): ۷-۱۴.

4- نعیمی کلورزی، ز. قربانی، خ. سالاری جزی، م. و دهقانی، ا.ا. ۱۳۹۵. بررسی تأثیر پارامترهای فیزیوگرافی و اقلیمی حوضه در شبیه سازی جریان فصلی رودخانه. مجله اکو هیدرولوژی ایران. ۳ (۴): ۵۴۵-۵۵۵.

5- نورانی، و. صالحی، ک. ۱۳۸۷. مدل سازی بارش- رواناب با استفاده از شبکه عصبی فازی تطبیقی و مقایسه آن با شبکه عصبی و روش استنتاج فازی. مطالعه موردی: (منطقه ليقوان چای در استان آذربایجان شرقی). چهارمین کنگره ملی مهندسی عمران، دانشگاه تهران.

6-Adamowski, J. 2013. Using support vector regression to predict direct runoff, base flow and total flow in a mountainous watershed with limited data in Uttaranchal, India. *Journal of Land Reclamation*. 45(1):71-83.

7-Chen, S. T. and P.S. Yu. 2007. Real-time probabilistic forecasting of flood stages. *J. of Hydrology*, 340 (1-2), 63-77.

8- Cortes, C. and V. Vapnik. 1995. Support-Vector Networks. *Machine Learning*. 20: 273-295.

9-Dibike, Y. B. Velickov, S. Solomatine, D. P. and M.B. Abbott. 2001. Model induction with support vector machines: Introduction and applications. *J. of Computing in Civil Eng.*, 15 (3), 208-216.

10-Ghorbani, M.A. Kisi, O and M.A.A. Alinezhad. 2010. A probe into the chaotic nature of daily stream flow time series by correlation dimension and largest Lyapunov methods. *Applied Mathematical Modelling*. 34(12):4050-4057.

11-Jang, J.S.R. Sun, C. T. and E.Mizutani. 1997. *Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence*. Prentice-Hall International. New Jersey.

12-Karimi, S. Shiri, J. Kisi, O. and A.A.Shiri. 2015. Short-term and long-term streamflow prediction by using 'wavelet-gene expression' programming approach. *ISH Journal of Hydraulic Engineering* 1-15.

13-Kingston, G. B. 2005. Lambert M F and Maier H R. Bayesian training of artificial neural networks used for water resources modeling. *Water Resources Research*. 41(W12409).

14- MacKay, D. J. C. 1992. A Practical Bayesian Framework for Backpropagation Networks " *Neural Computation*. 4: 48-472.

15-Nash, J. E. and J.V. Sutcliffe. 1970. River flow forecasting through conceptual models part I — A discussion of principles. *Journal of Hydrology*. 10 (3), 282-290.

16- Noori, R. Abdoli, M. A. Ameri A. and M. Jalili-Ghazizade. 2008. Prediction of municipal solid waste generation with combination of support vector machine and principal component analysis: A case study of Mashhad. *Environmental Progress and Sustainable Energy*, 28 (2), 249-258.

17-Noori, N. and L.Kalin. 2016. Coupling SWAT and ANN models for enhanced daily streamflow prediction, *J. of Hydrology*. 533: 141-151.

18- Noori, R. Karbassi, A. Farokhnia, A. and M. Dehghani, M. 2009. Predicting the longitudinal dispersion coefficient using support vector machine and adaptive neuro-fuzzy inference system techniques. *Environmental Engineering Science*, 26 (10), 1503-1510.

19-Nourani, V. and M. Komasi. 2013. A geomorphology-based ANFIS model for multi-station modeling of rainfall-runoff process. *Journal of Hydrology*. 490: 41-55.

20-Ross, T. J. 1995. *Fuzzy logic with engineering application*. McGraw Hill Inc., USA.

- 21-Singh, G. Panda, R. K. and M. Lamers. 2015. Modeling of daily runoff from a small agricultural watershed using artificial neural network with resampling techniques, J. of hydroinformatics. vol.17 (1). 56-74.
- 22-Vapnik, V. N. 1998. Statistical learning theory, 1 st Ed., Wiley, New York.
- 23- Yu, P.S. Chen, S.T. and I.F. Chang. 2006. Support vector regression for real-time flood stage forecasting. J. of Hydrology, 328 (3-4), 704-716.
- 24-Zahiri, A. and H.M.Azamathulla. 2014. Comparison between linear genetic programming and M5 tree models to predict flow discharge in compound channels. Neural Comput & Applic, 24:413-420
- .