

ارزیابی دقت مدل‌های داده محور تصادفی و قطعی در مدل‌سازی و پیش‌بینی مقادیر دبی رودخانه (مطالعه موردی: رودخانه‌های غرب و جنوب غرب دریاچه ارومیه)

فاطمه روحانی نیا^۱، مجید منتصری^۲، بهزاد حصاری^{۳*}، جلال شیری^۴

۱- دانشجوی دکترای مهندسی منابع آب، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه ارومیه، ارومیه، ایران.

۲- استاد گروه مهندسی آب، دانشکده کشاورزی، دانشگاه ارومیه، ارومیه، ایران.

۳- دانشیار گروه مهندسی آب، دانشکده کشاورزی و پژوهشکده مطالعات دریاچه ارومیه، دانشگاه ارومیه، ارومیه، ایران.

۴- دانشیار گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران.

* نویسنده مسئول: b.hessari@urmia.ac.ir

تاریخ پذیرش مقاله: ۱۴۰۳/۱۱/۲۸

تاریخ دریافت مقاله: ۱۴۰۳/۰۹/۰۷

چکیده

شبیه‌سازی و پیش‌بینی جریان رودخانه جهت آگاهی از آورد رودخانه در دوره زمانی مختلف، از جمله مسائل مهم و کاربردی در مدیریت منابع آب می‌باشد. لذا در پژوهش حاضر به ارزیابی و تعیین مدل مناسب پیش‌بینی جریان در ۷ ایستگاه آب‌سنجی بر روی رودخانه‌های غرب و جنوب غرب دریاچه ارومیه پرداخته شده است. مدل‌های مورد استفاده جهت دستیابی به هدف مطروحه شامل الگوهای مختلف مدل استوکاستیک ARIMA و مدل‌های مبتنی بر هوش مصنوعی شامل ELM، ANN و SVM بود. نتایج حاصل از به‌کارگیری مدل‌های ذکر شده نشان داد که الگوهای برازش ARIMA(1,0,0) و ARIMA(2,0,1) دارای عملکرد بهتر در مدل‌سازی جریان در رودخانه‌های مورد مطالعه بوده، به طوری که میانگین ضریب نش-ساتکلیف دو مدل ARIMA(1,0,0) و ARIMA(2,0,1) به ترتیب برابر ۰/۶۷ و ۰/۶۸ حاصل شد. در حالی که میانگین این ضریب برای مدل‌های داده محور ANN، SVM و ELM برای رودخانه‌های منطقه به ترتیب برابر ۰/۳۸، ۰/۴۷ و ۰/۲۱ برآورد گردید. ضمناً آماره ضریب همبستگی پیرسون نیز برای مدل‌های استوکاستیک (۰/۸۳) به طور معنی‌داری بالاتر از مدل‌های برتر داده‌محور حاصل (۰/۶۱) شد. بنابراین استفاده از مدل‌های استوکاستیک نسبت به مدل‌های هوش مصنوعی جهت مدل‌سازی و به‌کارگیری آن‌ها در پیش‌بینی جریان رودخانه‌ای برای آینده در منطقه مطالعاتی دارای اولویت بالاتری است.

واژه‌های کلیدی: پیش‌بینی، حوضه آبریز دریاچه ارومیه، سری زمانی، مدل‌های استوکاستیک، مدل‌های هوش مصنوعی.

مقدمه

آتی پدیده‌های هواشناسی و هیدرولوژی در قالب دو مفهوم پیش‌بینی کوتاه‌مدت^۱ و بلندمدت^۲ انجام می‌پذیرد. پیش‌بینی کوتاه‌مدت در مطالعات هیدرولوژی به معنای تخمین رخداد‌های هواشناسی و هیدرولوژیکی برای چند دوره زمانی آینده بلافاصله بعد از دوره آماری مشاهداتی یا تاریخی است. هرچه بازه زمانی برای پیش‌بینی دورتر یا بافاصله زمانی بیشتر از انتها دوره تاریخی باشد، به دلیل افزایش تصاعدی وزن مؤلفه رفتار تصادفی در رخداد، پیش‌بینی نامطمئن‌تر و دارای عدم

از آنجائی که منابع آبی قابل‌دسترس به‌مرور کاهش می‌یابند، اهمیت مدیریت و برنامه‌ریزی آب بیش‌ازپیش مشخص می‌گردد. با توجه به گسترش شهرها و روند صنعتی شدن، تغییر الگوی کشت و رشد کشاورزی، تقاضای آب نیز افزایش پیدا کرده است. لذا مقوله پیش‌بینی پارامترهایی از قبیل جریان و بارش را می‌توان یکی از اساسی‌ترین کارها در این زمینه تلقی کرد. برآورد و تعیین رخداد‌های مورد انتظار

² rediction

¹forecasting

روش سنتی رگرسیون، استفاده از تکنیک‌های داده محور یادگیری ماشین نظیر شبکه‌های عصبی^۴ (NNs) (Noori and Kalin, 2016)؛ دلناز و همکاران، ۱۳۹۶؛ سراوانی و همکاران، ۱۴۰۲؛ صالح آبادی و عمادی، ۱۴۰۲)، ماشین‌های برداری پشتیبان^۵ (SVM) (Adnan et al., 2019)، منطق فازی^۶ (Alvisi and Franchi, 2011) و تبدیل موجک^۷ (WT) (Fang et al., 2019)، برای مدل‌سازی و پیش‌بینی جریان سطحی مورد توجه زیاد محققین قرار گرفته است.

(Niu and Feng, 2021) در پژوهشی توانایی پنج روش هوش مصنوعی برای پیش‌بینی جریان روزانه ورودی به دو مخزن بزرگ برق‌آبی در چین را مورد بررسی قرارداد. در این مطالعه، چهار شاخص آماری به‌عنوان معیارهای ارزیابی برای مقایسه عملکرد این مدل‌ها استفاده شدند. نتایج حاصل مطالعه در دو مخزن عظیم برق‌آبی نشان داد که پنج روش هوش مصنوعی می‌توانند به نتایج پیش‌بینی رضایت‌بخشی دست یابند در حالی که روش‌های SVM، GPR، ELM دارای عملکرد بهتری نسبت به ANN و ANFIS نشان دادند. (2020) Farfan et al.، به پیش‌بینی دبی جریان با استفاده از دو مدل فیزیک پایه WEAP و GR2M و دو مدل مبتنی بر شبکه عصبی مصنوعی در حوضه آبخیز Andean اکوادور پرداختند. نتایج این مطالعه نشان داد که ترکیب این روش‌ها قادر است عملکرد منفرد مدل‌های مذکور را بهبود بخشد و نتایج خوبی را در مراحل واسنجی و اعتبارسنجی ارائه دهد. (2019) Tayyab et al.، به تلفیق مدل‌های شبکه مصنوعی و تبدیل موجک گسسته برای فرآیند بارش-رواناب در حوضه آبخیز رودخانه Jinsha پرداخته و نشان دادند که RBFNN در تلفیق با تبدیل موجک گسسته از قابلیت پیش‌بینی بهتری نسبت به سایر مدل‌های توسعه داده‌شده برخوردار است. مجددی ریزه‌ئی و همکاران (۱۳۹۹) به بررسی کارایی مدل‌های ترکیبی نسبت فراوانی ماشین بردار پشتیبان به منظور شناسایی مناطق مستعد سیل‌خیزی در منطقه کلات پرداختند. نتایج حاصل از این پژوهش نشان داد که مدل FR-SVM دقت بالا و عملکرد بهتری نسبت به مدل SVR دارد و این نتایج را می‌توان در مناطق مستعد سیل و خطرپذیر استفاده نمود. احمدی

قطعیت بیشتر می‌شود. درحالی‌که پیش‌بینی بلندمدت (prediction) یک ارزیابی و تخمین شرایط یا رفتار محتمل مورد انتظار پدیده هواشناسی و هیدرولوژی در آینده است، بدون اینکه به بازه زمانی خاص در آینده ارتباط داشته باشد (Chu et al., 2021). از آنجاکه بارش و جریان وابستگی غیرخطی شدیدی به عوامل جوی و فعالیت‌های انسانی داشته، تغییرات وسیع و فوق‌العاده‌ای در فضای مکانی و زمانی دارد که پیش‌بینی کوتاه و بلندمدت آن را بسیار پیچیده و دشوار می‌کند (Xiao et al., 2019). مدل‌های پیش‌بینی بارش و جریان براساس ماهیت ورودی و عدم قطعیت، مشخصات مکانی و روند پردازش در سه کلاس کلی؛ مدل‌های ریاضی (داده محور) قطعی (مانند رگرسیون، هوش مصنوعی و ...)، مدل‌های ریاضی (داده محور) تصادفی (مانند خود همبسته) و مدل‌های فیزیکی (فرآیند محور) (مانند بارش-رواناب) قرار می‌گیرند (Feng et al., 2020).

مدل‌های ریاضی یا داده‌محور قطعی تلاش می‌کنند روابط بین ورودی‌ها و خروجی‌ها را براساس داده‌های مشاهداتی هیدرولوژیکی بدون در نظر گرفتن عدم قطعیت هیدرولوژیکی و بدون فرض درک فرآیند داخلی، تولید کنند. این مدل‌ها اغلب به راحتی توسعه می‌یابند و می‌توانند برآوردهای قابل‌اطمینان را زمانی که مدل‌ها را با داده‌های قوی و دقیق آموزش داده شوند، ارائه دهند (Wagena et al., 2020). این مدل‌ها می‌توانند جایگزین بسیار خوبی برای مدل‌های فرآیند محور^۳ باشند که درک ارتباط بین اجزا فرآیند پیچیده و مشکل است (Abrahart et al., 2004). در این مدل‌ها به تشریح فرآیند پدیده هیدرولوژیکی پرداخته نمی‌شود و برای تعیین شاخص‌ها و ایجاد ساختار مدل به داده‌های مشاهداتی ورودی و خروجی نیاز دارند و نیاز به تعریف فیزیکی از روابط خود نیستند (Liong et al., 2000). مدل‌های ریاضی یا داده محور قطعی مانند روش رگرسیون می‌توانند خروجی‌های مناسبی را در بازه داده‌های تجربی به دست آورند. در حقیقت این مدل‌ها در میانگینی بسیار مناسب هستند ولی در برون‌یابی ناتوان هستند و معمولاً نتیجه مطلوبی از عملکرد این مدل‌ها حاصل نمی‌شود (Stelling, 2000). در دهه‌های اخیر، علاوه بر

^۶Fuzzy logic^۷Wavelet transfer^۳Process-based models^۴Neural networks^۵Support vector machine

استوکاستیکی و هوش مصنوعی مختلف، گامی مهم در جهت یافتن ابزارهای مؤثرتر برای مدیریت و پیش‌بینی منابع آب این منطقه است. بر همین اساس هدف از این پژوهش ارزیابی دقت روش‌های استوکاستیک و مدل‌های مبتنی بر هوش مصنوعی در پیش‌بینی و برآورد جریان در ۷ ایستگاه آب‌سنجی رودخانه‌های واقع در غرب و جنوب غربی دریاچه ارومیه می‌باشد.

مواد و روش‌ها منطقه مورد مطالعه

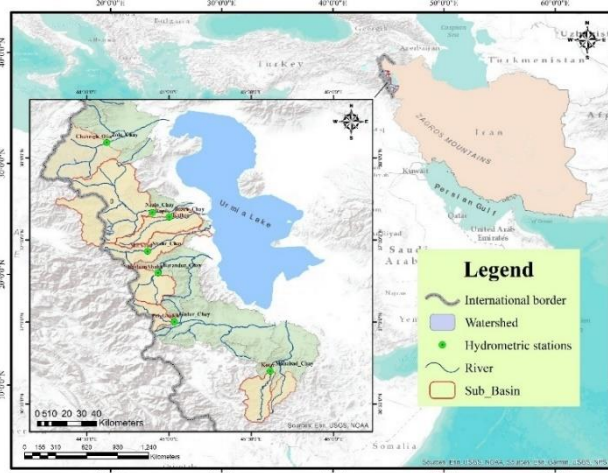
در این مطالعه از داده‌های جریان ماهیانه ۷ رودخانه زولا، نازلو، روضه، شهر، باراندوز، گادار و مه‌آباد در ایستگاه‌های آب‌سنجی چهریق علیا، تپیک، کلهور، میرآباد، هاشم‌آباد، پی قلعه و کوتر استفاده شد. اطلاعات و موقعیت جغرافیایی رودخانه‌های مذکور و ایستگاه‌های آب‌سنجی منتخب در جدول ۱ و نقشه شکل ۱ ارائه شده است. لازم به ذکر است که محل ایستگاه میرآباد شهرچای از سال ۱۳۸۴ به محل جدید در بالادست رودخانه (برده سور) انتقال یافته و داده‌های میرآباد برای سال‌های ۱۳۸۴ به بعد از ایستگاه برده سور تکمیل شده است. ضمناً در این مطالعه، داده‌های جریان رودخانه‌های مذکور در طی سال‌های آماری ۱۳۷۱ الی ۱۴۰۰ به کار گرفته شده است.

(۱۳۹۹) به ارزیابی عملکرد مدل‌های ماشین بردار پشتیبان (SVR) و سامانه استنتاج عصبی-فازی تطبیقی (ANFIS) به منظور پیش‌بینی جریان ماهانه رودخانه‌های نازلو و سزار پرداخت، نتایج بیانگر عملکرد بهتر مدل SVR نسبت به مدل ANFIS در پیش‌بینی جریان ماهانه بوده و می‌توان با استفاده از تابع کرنل مناسب برای هر کدام از این مدل‌ها عملکرد بهتری ایجاد نمود. احمدپور و همکاران (۱۳۹۹) در پژوهشی عملکرد مدل‌های سری زمانی خطی باکس جنکینز و مدل مفهومی IHACRES، مدل شبکه عصبی پرسپترون چندلایه و مدل هیبریدی ARMA-ANN را به منظور شبیه‌سازی و پیش‌بینی جریان روزانه حوضه مارون مورد بررسی و مقایسه قرار داده و نشان دادند که مدل ARMA-ANN بیشترین مقادیری عددی ضریب تعیین ۰/۸۶ و ضریب نش-ساتکلیف ۰/۸۱ داشته و دارای عملکرد بهتری می‌باشد. با توجه به آنچه ذکر گردید می‌توان گفت مدیریت منابع آب، به‌ویژه در مناطق حساس و پرچالش نظیر حوضه‌های آبریز غرب و جنوب غرب دریاچه ارومیه که پیش‌بینی جریان رودخانه‌ها نقش مهمی در برنامه‌ریزی منابع آب، کنترل سیلاب، تخصیص بهینه آب و مدیریت پایدار اکوسیستم‌های آبی این حوضه‌های آبریز دارد، نیازمند شبیه‌سازی و پیش‌بینی دقیق جریان رودخانه‌ها می‌باشد و با توجه به تغییرات اقلیمی و نوسانات هیدرولوژیکی، شناسایی مدل‌های پیش‌بینی دقیق و مناسب، از ضرورت‌های اصلی در این حوضه‌های آبریز می‌باشد. لذا بررسی مدل‌های

جدول ۱- مشخصات ایستگاه‌های مورد مطالعه در استان آذربایجان غربی.

Table 1- Characteristics of the Study Stations in West Azerbaijan Province.

Elevation(m)	Latitude	Langitude	River	Station	No
1533	38.60	44.60	Zola-Chay	Chahriigh_Olia	1
1715	37.66	44.90	Nazlo-Chay	Tapik	2
1285	37.65	44.83	RozeH_Chay	Kalhor	3
1525	37.43	44.87	Shahr_Chay	MirAbad	4
1464	37.28	44.90	Barandoz_Chay	HashemAbad	5
1500	37.00	45.03	Gadar_Chay	Pei-Ghaleh	6
1400	36.70	45.61	Mahabad_Chay	Kotar	7



شکل ۱- موقعیت جغرافیایی محدوده مورد مطالعه.

Figure 1- Geographical location of the study area.

روش انجام پژوهش

ضرایب α_1 و α_2 و ... نیز ضرایب ثابتی از مدل رگرسیونی را نشان می‌دهند (Salas et al., 1988). MA نیز از این واقعیت استخراج می‌شود که X_t با استفاده از وزن‌های β_1 و β_2 و ... و β_q برای متغیرهای ε_t و ε_{t-1} و ... و ε_{t-q} به دست می‌آید. اگر زمان به عنوان یک واحد اضافه شود و این وزن‌ها برای متغیرهای ε_t و ε_{t+1} استفاده شود، X_{t+1} را می‌توان به دست آورد.

$$X_t = \beta_0 \varepsilon_t + \beta_1 \varepsilon_{t-1} + \dots + \beta_q \varepsilon_{t-q} \quad (2)$$

این مدل همچنین نشان می‌دهد که یک فرآیند میانگین متحرک مرتبه q توسط $MA(q)$ نمایش داده می‌شود. ضرایب β_1 و β_2 و ... و β_q ضرایب ثابت میانگین متحرک و ε_t و ε_{t-1} و ... و ε_{t-q} باقیمانده‌های یک گام قبل، دو گام قبل و ... q گام قبل است (Nirumand and Bozorgnia, 2010).

به این ترتیب مدل ARMA که از ترکیب دو مدل رگرسیون و میانگین متحرک به دست آمده است با درجه خودهمبسته p و میانگین متحرک q به صورت $ARMA(p, q)$ نشان داده می‌شود و معادله آن به صورت زیر است (Salas et al., 1988):

$$X_t = \alpha_1 X_{t-1} + \alpha_2 X_{t-2} + \dots + \alpha_p X_{t-p} \quad (3)$$

$$+ \varepsilon_t + \beta_1 \varepsilon_{t-1} + \dots + \beta_q \varepsilon_{t-q}$$

مدل ARIMA نیز با افزودن درجه تفاضل d به ARMA ایجاد می‌شود که به صورت $ARIMA(p, d, q)$ نشان داده می‌شود و معادله آن به صورت زیر است (Salas et al., 1988):

$$(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)(1 - B)^d X_t \quad (4)$$

$$= (1 + \theta_1 B + \theta_2 B^2 + \dots + \theta_q B^q) \varepsilon_t$$

در این مطالعه ۸ الگوی مختلف مدل استوکاستیک ARIMA (p,d,q) با ترکیب مرتبه‌های مختلف یعنی $p=1,2$ ، $q=0,1$ و $d=0,1$ و سه مدل هوش مصنوعی جهت برازش سری زمانی جریان ماهیانه تاریخی در ۷ رودخانه مورد مطالعه استفاده و نتایج آن باهم مقایسه شده است. ذیلاً مشخصات و ساختمان تئوریک مدل‌های مورد استفاده به طور خلاصه ارائه شده است.

مدل‌ها داده محور تصادفی ARMA و ARIMA

اساس این مدل‌ها بر پایه زنجیره مارکوف در زنجیره زمانی بنا شده است. اگر هر داده ثبت شده سری زمانی t با زمان قبل و یا زمان بعد از خود مرتبط باشد. مدل سری زمانی که باکس-جنکینز نیز نامیده می‌شود، معمولاً برای اندازه‌گیری داده‌های مرتب شده بر اساس زمان استفاده می‌شود و فرآیندی است که در آن رویدادها در زمان‌های جداگانه و در فواصل زمانی ثابت رخ می‌دهند و هر یک از آن‌ها مستقل از مقادیر دیگر هستند (Salas et al., 1988). در پژوهش حاضر از مدل‌های سری زمانی ARMA و ARIMA برای مدل‌سازی استفاده شد. این مدل دو مدل پایه خودهمبسته و میانگین متحرک را ترکیب می‌کند که در معادلات زیر به آن‌ها اشاره شده است.

$$X_t = \alpha_1 X_{t-1} + \alpha_2 X_{t-2} + \dots + \alpha_p X_{t-p} \quad (1)$$

که در معادله بالا که مربوطه به قسمت P-type اتورگرسیون می‌باشد $AR(p)$ را معرفی می‌کند؛ و پارامترهای X_{t-1} و X_{t-2} و ... و X_{t-p} داده‌های مدل‌سازی شده از مراحل قبل نظیر یک گام قبل، دو گام قبل و ... تا p گام قبل‌تر را نشان می‌دهند.

آموزش استخراج می‌شود. دو مدل اصلی SVM شامل SVM- ϵ (نوع اول) و SVM- ϵ (نوع دوم) هستند. در این پژوهش، از SVM- ϵ به دلیل کاربرد گسترده آن در مسائل رگرسیونی استفاده شده است. برای این مدل، تابع خطا به صورت زیر تعریف می‌شود:

$$SVM-\epsilon = \frac{1}{2} W^T W + C \sum_{i=1}^N \xi_i + C \sum_{i=1}^N \xi_i^* \quad (6)$$

تابع خطای فوق لازم است با توجه به محدودیت‌های زیر کمینه گردد:

$$W^T \phi(x_i) + b - y_i \leq \epsilon + \xi_i^* \quad (7)$$

$$y_i - W^T \phi(x_i) - b \leq \epsilon + \xi_i \quad (8)$$

$$\xi_i \text{ و } \xi_i^* \geq 0 \quad (9)$$

که در آن C ثابت گنجایش، W بردار ضرایب، W^T ترانهاده بردار ضرایب، ξ_i و ξ_i^* ضرایب کمبود، b ضریب ثابت، N الگوی آموزش مدل و ϕ تابع کرنل است. اطلاعات کمی در مورد انتخاب تابع غیرخطی مناسب ϕ در دسترس می‌باشد. در این پژوهش برای تنظیم بهتر این مدل، نخست از جستجوی شبکه‌ای (Grid Search) برای انتخاب بهترین هایپرپارامترها استفاده شد. همچنین جهت برآورد بهتر و دقیق‌تر این مدل از ۳ پارامتر (C , Epsilon, Kernel) استفاده شده است که دامنه انتخابی برای هر پارامتر به صورت ذیل می‌باشد:

C : (0.1, 1, 10, 100)

مقدار پایین C منجر به مدل نرم‌تر می‌شود که می‌تواند اختلالات بیشتری را تحمل کند، در حالی که مقادیر بالاتر سبب تطبیق بهتر داده‌ها می‌شود.

Epsilon: (0.01, 0.1, 0.2, 0.5)

این پارامتر برای مدل‌های رگرسیون SVM تعریف شده و تعیین می‌کند که تا چه حد خطا در پیش‌بینی‌ها قابل قبول بوده بدون اینکه تأثیری در بهینه‌سازی مدل داشته باشد. مقادیر پایین‌تر epsilon باعث می‌شود که مدل دقیق‌تر داده‌های آموزشی را پردازش و پیش‌بینی کند.

Kernel: (linear, rbf, poly)

که این سه تابع به ترتیب برای داده‌های خطی، داده‌ها با پیچیدگی مناسب و داده‌های خیلی پیچیده به کار می‌روند.

شبکه عصبی یادگیری ماشین حداکثر (ELM)

شبکه عصبی ELM یک رویکرد بسیار ساده‌ای برای حل این مسئله ارائه کرده است و به همین دلیل سرعت یادگیری

مدل‌ها داده محور قطعی (شبکه عصبی مصنوعی، ماشین بردار پشتیبان، یادگیری ماشین حداکثر)

در دهه‌های اخیر، مدل‌های داده‌محور مبتنی بر اصول فیزیکی مانند (شبکه‌های عصبی، ماشین‌های برداری پشتیبان، منطق فازی و رگرسیون) برای تحلیل پدیده‌های طبیعی با حافظه کوتاه‌مدت و بلندمدت توسعه یافته‌اند (Ni et al., 1988). مدل‌های فرآیندمحور نیز با استفاده از شاخص‌های حاصل از مشاهدات، به واسطه مدل کمک کرده و عدم قطعیت در پیش‌بینی‌های هیدرولوژیکی را از طریق سناریوهای مختلف مدنظر قرار می‌دهند (Kottegoda, 1980).

مدل شبکه عصبی مصنوعی ANN

مدل‌های شبکه عصبی مصنوعی (ANN) با شبیه‌سازی عملکرد مغز از نورون‌های متصل به هم تشکیل شده که خروجی هر لایه به عنوان ورودی لایه بعدی عمل می‌کند. وزن‌های اتصال بین نورون‌ها انتقال اطلاعات را مشابه سیناپس‌های مغزی شبیه‌سازی کرده و از طریق تنظیم این وزن‌ها، فرآیند یادگیری در شبکه صورت می‌گیرد. در این پژوهش از یک شبکه عصبی چندلایه پرسپترون (MLP) که در کتابخانه scikit-learn قرار داشته و برای پیش‌بینی به کار می‌رود استفاده شده است. همچنین تعداد لایه‌های مخفی و تعداد نورون‌های موجود در هر لایه به ترتیب برابر با (۱۰۰)، (۱۰۰) و (۱۰۰) و (۵۰، ۵۰ و ۵۰) تنظیم گردید.

مدل ماشین بردار پشتیبان (SVM)

ماشین‌بردار پشتیبان (SVM) یک مدل یادگیری با ناظر است که با استفاده از داده‌های برجسب‌دار، یک هایپرپلین بهینه برای طبقه‌بندی داده‌های جدید ایجاد می‌کند. در مدل رگرسیونی SVM، هدف تخمین وابستگی متغیر وابسته y به مجموعه‌ای از متغیرهای مستقل x است (Hamel, 2011). فرض بر این است که مانند دیگر مسائل رگرسیونی، رابطه بین متغیرهای وابسته و مستقل توسط یک تابع معین f به علاوه مقدار اضافی نویز (Noise) مشخص شود:

$$y = f(x) + Noise \quad (5)$$

هدف اصلی ماشین بردار پشتیبان (SVM) یافتن تابع f است که بتواند به درستی داده‌های جدید را پیش‌بینی کند. این تابع از طریق فرآیند بهینه‌سازی تابع خطا روی یک مجموعه

استفاده می‌شود. در این حالت، کرنل ELM به صورت زیر تعریف می‌شود:

$$\Omega_{ELM} = HH^T: \Omega_{ELM_{ij}} = h(x_i) \cdot h(x_j) = K(x_i, x_j) \quad (14)$$

$$f(x) = h(x)H^T \left(\frac{1}{C} + HH^T \right)^{-1} = \left[\frac{K(x, x_1)}{k(x, x_N)} \right]^T \left(\frac{1}{C} + \Omega_{ELM} \right)^{-1} T \quad (15)$$

که نماد T نشان‌دهنده ترانزاده یک بردار، $k(x_i, x_j)$ بیان‌کننده ارتباط بین دو متغیر x_i و x_j برحسب تابعی از K است. پارامتر I ماتریس تشخیص از ابعاد مناسب است (نوشیار و قاسمی مرزبالی، ۱۳۹۸).

ارزیابی دقت مدل

برای ارزیابی عملکرد مدل‌ها از چهار آماره یا معیار: نش-ساتکلیف (NSE)^۸، میانگین مربعات خطا (MSE)، ریشه میانگین مربعات خطا (RMSE)^۹ و ضریب تعیین (R^۲)^{۱۰} به‌عنوان معیارهای ارزیابی مدل استفاده شده است. مقدار بهینه ضریب نش-ساتکلیف و ضریب تعیین برابر با یک و برای ریشه میانگین خطای تبدیل‌شده عدد صفر می‌باشد (غضنفری مقدم و همکاران، ۱۳۹۷).

$$NSE = 1 - \frac{\sum(Q_E - Q_0)^2}{\sum(Q_0 - \bar{Q}_0)^2} \quad (16)$$

$$RMSE = \sqrt{\frac{\sum(Q_E - Q_0)^2}{n}} \quad (17)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (Q_0 - Q_E)^2 \quad (18)$$

$$R^2 = \left(\frac{\sum(Q_E - Q_E^-)(Q_0 - Q_0^-)}{\sqrt{\sum(Q_E - Q_E^-)^2 \sum(Q_0 - Q_0^-)^2}} \right)^2 \quad (19)$$

که در این روابط Q_0 و \bar{Q}_0 : مقدار مشاهداتی یا تاریخی و میانگین آن‌ها، روابط Q_E و \bar{Q}_E : مقدار برآوردی و میانگین آن‌ها و n تعداد داده‌ها است (Wagener et al., 2009).

نتایج و بحث

نتایج مطالعه در دو بخش اصلی مدل‌های استوکاستیک و هوش مصنوعی تنظیم‌شده است. برای به‌کارگیری مدل‌های استوکاستیک و تعیین مرتبه مناسب پارامترهای مدل استوکاستیک ARIMA(p,d,q) در رودخانه‌های مورد مطالعه، خودهمبستگی با تأخیر یک تا سیزده سری‌زمانی جریان ماهیانه در قالب نمودار ACF محاسبه و تعیین شد. نتایج نشان

بسیار بالایی دارد و سرعت یادگیری آن در مقایسه با MLP شاید حدود ۱۰۰۰ برابر و حتی بیشتر باشد.

روش ELM

ماشین یادگیری شدید (ELM) یک روش یادگیری است که باهدف یکپارچه‌سازی روش‌های مختلف ماشین پشتیبان بردار (SVM) توسعه‌یافته و در ابتدا برای شبکه‌های تعمیم‌یافته پیش‌خور با تک لایه مخفی (SLFN) معرفی شد، سپس به نسخه‌های تعمیم‌یافته SFLN گسترش یافت. تابع خروجی SLFN-های تعمیم‌یافته به صورت زیر است:

$$f(x) = h(x)\beta = \sum_{i=1}^L \beta_i h_i(a_i, b_i, x) \quad (10)$$

که در آن $h(x)_i$ در واقع فضای d بعدی ورودی (x) را به فضای L بعدی نگاشت می‌کند و a_i و b_i به ترتیب پارامترهای تولیدی تصادفی برای i امین گره‌اند. بین لایه نهان و لایه خروجی وزن β_i وجود دارد. برای یک مسئله دسته‌بندی دودسته‌ای تابع تصمیم‌گیر برای این مدل به صورت زیر است:

$$f(x) = \text{sign}(h(x)\beta) \quad (11)$$

بر اساس تئوری بارلت برای شبکه‌های SLFN، تابع هدف ELM به‌گونه‌ای فرموله شده که هم خطای آموزش و هم نرم وزن‌های خروجی را به حداقل برساند.

$$\text{Minimize: } \|H\beta - T\|^2 + \|\beta\| \quad (12)$$

که در آن T ماتریس هدف $[t_1, t_2, \dots, t_N]^T$ ، نماد $\|\cdot\|$ نشان‌دهنده نرم استاندارد و H ماتریس لایه پنهان است که به صورت زیر تعریف می‌شوند:

$$H = \begin{bmatrix} G(a_1, b_1, x_1) & \dots & G(a_L, b_L, x_L) \\ \vdots & \ddots & \vdots \\ G(a_1, b_1, x_N) & \dots & G(a_L, b_L, x_N) \end{bmatrix} \quad (13)$$

که در آن $G(a_i, b_i, x_i)$ نشان‌دهنده ارتباط بین i امین متغیر و ضرایب وزنی آن است. همان‌طور که مشاهده می‌شود حداقل کردن $\|H\beta - T\|^2$ معادل حداکثر کردن فاصله حاشیه دودسته در دسته‌بندی دودسته‌ای یعنی حداکثر کردن $\|H\beta - T\|^{-1}$ است. به‌منظور بهبود و توسعه مدل یادگیری و دور ماندن از نگاشت که گاهی برای طراح مشخص نیست، از مدل مبتنی بر کرنل


¹⁰Coefficient of determination

⁸Nash-Sutcliffe model efficiency coefficient

⁹Box-Cox Transformed Root Mean Squared Error

مطالعاتی نشان می‌دهد. براین اساس، مرتبه p ، d و q به ترتیب برابر $p=1,2$ ، $d=0,1$ و $q=0,1$ به عنوان محدوده مناسب و مطلوب پارامترهای فوق انتخاب شد. نهایتاً ۸ الگوی مختلف مدل سازی $ARIMA(p,d,q)$ با ترکیب مرتبه‌های انتخابی مذکور یعنی $ARIMA(1,0,0)$ ، $ARIMA(1,1,0)$ ، $ARIMA(1,1,1)$ ، $ARIMA(1,0,1)$ ، $ARIMA(2,0,0)$ ، $ARIMA(2,1,0)$ ، $ARIMA(2,0,1)$ و $ARIMA(2,1,1)$ جهت برازش سری زمانی جریان ماهیانه تاریخی یا مشاهداتی استفاده شده است.

داد که از میان خودهمبستگی‌های کوتاه مدت چندماهه، تنها خودهمبستگی یک‌ماهه همراه با خودهمبستگی‌های ۱۱ تا ۱۳ ماهه بلندمدت یا فصلی در تمام ایستگاه‌ها معنی دار بوده است. همچنین برای حدود ۳۰ درصد رودخانه‌ها، خودهمبستگی‌های ۶ و ۷ ماهه بارش نیز در سطح ۵ درصد معنی دار است. شکل ۲ نمودار تغییرات مقادیر خودهمبستگی با تأخیرهای مختلف به همراه باند محدوده مجاز در سطح معنی دار ۰/۵ را برای سری زمانی جریان ماهیانه در ۴ رودخانه را به عنوان نمونه از منطقه



شکل ۲- خودهمبستگی سری زمانی ماهیانه جریان با تأخیر یک تا سیزده در ۴ ایستگاه آبخیز منطقه مطالعاتی.

Figure 2- Autocorrelation of the monthly streamflow time series with lags from one to thirteen at four hydrometric stations in the study area.

در این پژوهش، به منظور توسعه و ارزیابی عملکرد مدل‌های استوکاستیک و هوش مصنوعی در مدل سازی داده‌های جریان، سری زمانی ماهیانه آن‌ها در یک دوره آماری ۳۰ ساله (۱۴۰۰-۱۳۷۱ معادل ۲۰۲۰-۱۹۹۱) استفاده شد. بدین منظور ۷۰

جریان رودخانه‌های مورد مطالعه در دوره آزمون یا اعتبارسنجی را ارائه می‌دهند. به طوری که متوسط مقادیر ضریب همبستگی و نش-ساتکلیف برای ۷ رودخانه به ترتیب برابر ۰/۸۳ و ۰/۶۸ است. ضمناً از میان چهار الگوی برتر مذکور، الگوی ARIMA (2,0,1) با داشتن حداکثر متوسط مقادیر ضریب همبستگی و نش-ساتکلیف یعنی ۰/۸۴ و ۰/۷ بالاترین عملکرد را دارد. این امر بیانگر اثر تنظیمات دقیق‌تر مدل استوکاستیک در بهبود دقت پیش‌بینی آن است. شکل ۳ مقایسه سری نزولی و زمانی جریان ماهیانه تاریخی و برآوردی از مدل استوکاستیک برتر در رودخانه‌های نازلو و تپیک را نشان می‌دهد. شکل مذکور بیانگر عملکرد مطلوب هر چهار الگوی برتر در پیش‌بینی جریان رودخانه‌ای در منطقه مطالعاتی است. همچنین شکل ۴ مقایسه نمودار جعبه‌ای داده‌های جریان ماهیانه تاریخی و برآوردی چهار مدل استوکاستیک برتر در دو ایستگاه میرآباد و چهریق به ترتیب با حداکثر و حداقل مقادیر آماره‌های R و NSE یا رتبه عملکرد در منطقه مطالعاتی (جدول ۲) را نشان می‌دهد. نتایج مقایسه توزیع مقادیر تاریخی و برآوردی در شکل ۴، بیانگر عملکرد مطلوب مدل‌های استوکاستیک منتخب در حفظ یا دوباره تولید میانگین، حداکثر (سیلاب) و حداقل (کم‌آبی) جریان رودخانه‌ای در منطقه مطالعاتی بوده و همچنین اثر خودهمبستگی با تأخیر ۲ در بهبود عملکرد مدل استوکاستیک را نشان می‌دهد.

درصد داده‌های ابتدای سری زمانی جریان ماهیانه به‌عنوان داده ورودی برای آموزش یا واسنجی مدل و ۳۰ درصد دیگر داده‌های انتهایی سری زمانی برای آزمون یا اعتبارسنجی مدل‌های توسعه داده‌شده در نظر گرفته شد. نتایج پژوهش در این مقاله، به دلیل اهمیت عملکرد مدل‌ها مورد استفاده در دوره آزمون یا اعتبارسنجی، صرفاً متمرکز بر این دوره بوده است. مدل‌سازی و پیش‌بینی داده‌های جریان در منطقه مطالعاتی در ۷ ایستگاه آب‌سنجی رودخانه‌های منتخب منطقه یعنی چهریق-زولاچای، تپیک-نازلوچای، کلهور-روضه‌چای، میرآباد-شهرچای، هاشم‌آباد-باراندوزچای، پی‌قلعه-گادارچای و کوتر-مهابادچای انجام پذیرفت که نتایج آن در بخش‌های زیر ارائه شده است.

مدل استوکاستیک

برای ارزیابی عملکرد الگوهای ۸ گانه مدل استوکاستیک ARIMA(p,d,q)، از سه آماره یا معیار R^2 ، RMSE و NSE استفاده شده و نتایج آن در جدول ۲ آمده است. نتایج مذکور نشان می‌دهد که از میان ۸ الگوی مختلف مدل‌سازی جهت برازش با سری زمانی ماهیانه جریان در رودخانه‌های مورد مطالعه، چهار الگوی ARMA(1,0,0) و ARIMA(1,0,1)، ARMA(2,0,0) و ARIMA(2,0,1) بر اساس مقادیر معیارهای آماری مذکور دارای عملکرد بهتری نسبت به سایر الگوها بوده و هر چهار الگو فوق پیش‌بینی مطلوب از مقادیر

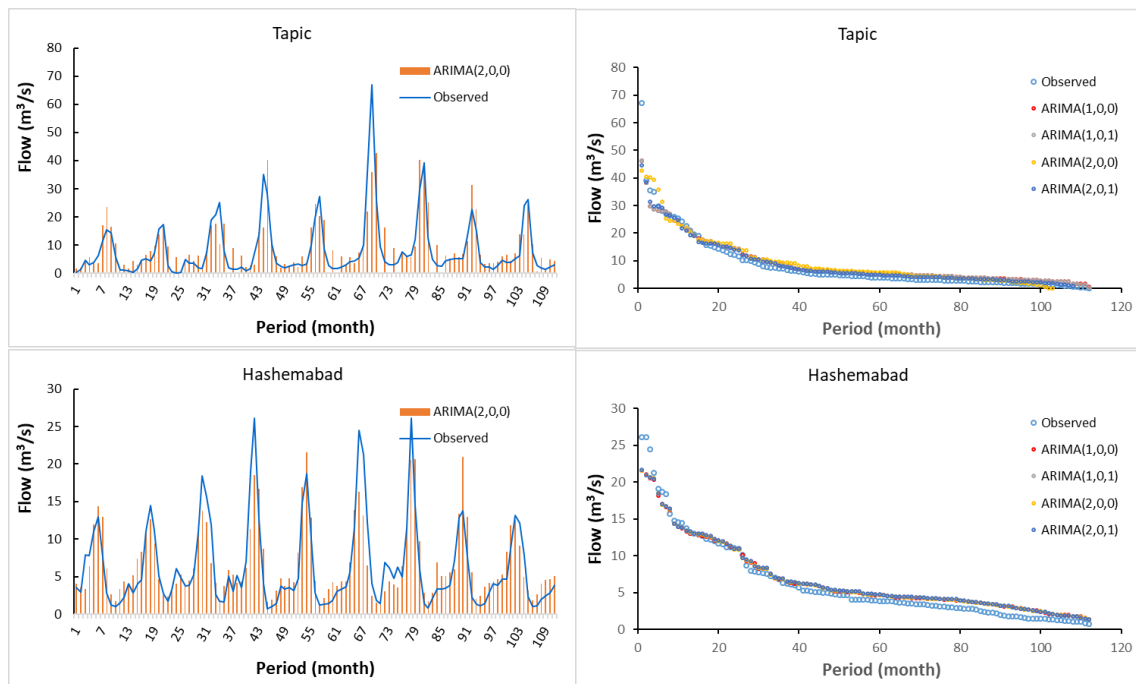
جدول ۲- مقادیر سه آماره یا معیار ارزیابی ضریب همبستگی پیرسون (R)، ریشه میانگین مربعات خطا (RMSE) و ضریب نش-

ساتکلیف (NSE) سری زمانی جریان ماهیانه تاریخی و برآوردی برای ۸ الگوی منتخب مدل استوکاستیک ARIMA.


Table 2- Values of three statistical evaluation metrics—Pearson correlation coefficient (R), root mean square error (RMSE), and Nash-Sutcliffe efficiency coefficient (NSE)—for the historical and estimated monthly streamflow time series of eight selected ARIMA stochastic model patterns.

ARIMA(2, 1,1)	ARIMA(2, 0,1)	ARIMA(2, 1,0)	ARIMA(2, 0,0)	ARIMA(1, 1,1)	ARIMA(1, 0,1)	ARIMA(1, 1,0)	ARIMA(1, 0,0)	
R								
0.141	0.775	0.141	0.825	0.173	0.592	0.141	0.678	Chahrih
0.265	0.825	0.300	0.800	0.300	0.812	0.316	0.812	Tapik
0.000	0.860	0.000	0.866	0.000	0.854	0.100	0.831	Kalhor
4.123	0.883	0.500	0.860	0.806	0.889	0.762	0.894	MirAbabd
0.837	0.872	0.678	0.872	0.837	0.872	0.566	0.866	HashemAb
0.141	0.787	0.141	0.781	0.775	0.775	0.141	0.787	ad
0.566	0.877	0.574	0.877	0.686	0.872	0.574	0.877	Pei-Ghaleh Kotar
RMSE								
7.20	1.71	6.88	1.59	8.23	2.23	7.30	2.01	Chahrih
17.45	5.80	15.82	6.37	15.75	6.00	14.87	6.01	Tapik
2.09	0.52	1.94	0.51	2.91	0.53	1.98	0.60	Kalhor
9.44	2.43	7.72	2.67	3.30	2.44	3.83	2.33	MirAbabd
3.22	2.81	5.02	2.80	3.21	2.81	6.40	2.84	HashemAb
19.74	5.51	19.70	5.54	5.84	5.57	20.59	5.49	ad

5.82	2.38	5.71	2.40	4.51	2.50	5.72	2.38	Pei-Ghaleh Kotar
NSE								
0.141	0.775	0.141	0.825	0.173	0.592	0.141	0.678	Chahrigh
0.265	0.825	0.300	0.800	0.300	0.812	0.316	0.812	Tapik
0.000	0.860	0.000	0.866	0.000	0.854	0.100	0.831	Kalhor
4.123	0.883	0.500	0.860	0.806	0.889	0.762	0.894	MirAbabd
0.837	0.872	0.678	0.872	0.837	0.872	0.566	0.866	HashemAb
0.141	0.787	0.141	0.781	0.775	0.775	0.141	0.787	ad
0.566	0.877	0.574	0.877	0.686	0.872	0.574	0.877	Pei-Ghaleh Kotar



شکل ۳- مقایسه سری نزولی و سری زمانی جریان ماهیانه تاریخی و برآوردی از مدل‌های استوکاستیک برتر در دو ایستگاه آب‌سنجی.
Figure 3- Comparison of the declining series and the historical and estimated monthly streamflow time series from the best stochastic models at two hydrometric stations.



شکل ۴- مقایسه نمودار جعبه داده‌های جریان ماهیانه تاریخی و برآوردی از مدل‌های استوکاستیک برتر در ایستگاه میرآباد رودخانه شهرچای و ایستگاه چهریق رودخانه زولا.
Figure 4- Comparison of box plots of historical and estimated monthly streamflow data from the best stochastic models at Mirabad station on the Shahrchay River and Cherigh station on the Zola River.

و نتایج آن در جدول ۳ آمده است. نتایج جدول ۳ نشان می‌دهد که اولاً از میان ۳ مدل هوش مصنوعی مذکور جهت برآزش با سری زمانی ماهیانه جریان در رودخانه‌های منطقه، عملکرد مدل ELM کاملاً نامطلوب بوده و مدل‌های SVM و ANN به‌طور موردی دارای عملکرد بهتری نسبت به هم داشته

مدل هوش مصنوعی

در این پژوهش سه مدل هوش مصنوعی، ANN، ELM و SVM جهت مدل‌سازی و پیش‌بینی داده‌های جریان رودخانه‌های مورد مطالعه بکار گرفته شد. برای ارزیابی عملکرد سه مدل مذکور، از سه آماره R^2 ، RMSE و NSE استفاده شده

نمودارهای فوق نشان از عملکرد ضعیف‌تر مدل برتر SVM و ANN هوش مصنوعی نسبت به مدل‌های استوکاستیک در پیش‌بینی جریان ماهیانه رودخانه‌های منطقه بوده، به طوری که تطبیق سری نزولی جریان برآوردی از سه مدل هوش مصنوعی با سری نزولی جریان تاریخی دارای انحراف بسیار قابل توجهی خصوصاً در ایستگاه پی‌قلعه بوده است. همچنین جهت درک بهتر و ارزیابی کامل‌تری از عملکرد مدل‌ها، نمودار جعبه‌ای داده‌های جریان ماهیانه تاریخی و برآوردی سه مدل هوش مصنوعی در چهار رودخانه زولا (چهریق)، نازلو (تپیک)، گدار (پی‌قلعه) و مهاباد (کوتر) با مقادیر مختلف از آماره یا معیارهای R و NSE در شکل ۶ ارائه شده است. نتایج فوق (شکل ۶) نشان از عملکرد نامطلوب یا ضعیف مدل‌های سه‌گانه هوش مصنوعی در حفظ یا دوباره تولید توزیع احتمال، میانگین، حداکثر (سیلاب) جریان رودخانه‌ای در منطقه مطالعاتی بوده است. همچنین نمودارهای شکل ۶، تأکیدی بر صحت تفسیر و تشریح نتایج در بالا است.

است. به طوری که مثلاً عملکرد مدل SVM در دو ایستگاه چهریق رودخانه زولا و تپیک رودخانه نازلو و مدل ANN در دو ایستگاه میرآباد رودخانه شهرچای و هاشم‌آباد رودخانه باراندوز دارای عملکرد بهتری نسبت به مدل دیگر بوده و از طرف دیگر هر دو مدل در سایر رودخانه‌ها دارای عملکرد قابل قبولی نبوده است (جدول ۳ و شکل ۶). دوماً مقایسه نتایج مدل‌های هوش مصنوعی و استوکاستیک بیانگر عملکرد بهتر مدل‌های استوکاستیک برتر نسبت به مدل‌های برتر هوش مصنوعی است. به طوری که متوسط مقادیر ضریب همبستگی و نش-ساتکلیف مدل‌های برتر هوش مصنوعی برای ۷ رودخانه به ترتیب برابر ۰/۶۱ و ۰/۳۲ بوده که به طور قابل توجهی کمتر از مقادیر آن‌ها برای مدل‌های استوکاستیک (۰/۸۳ و ۰/۶۸) است.

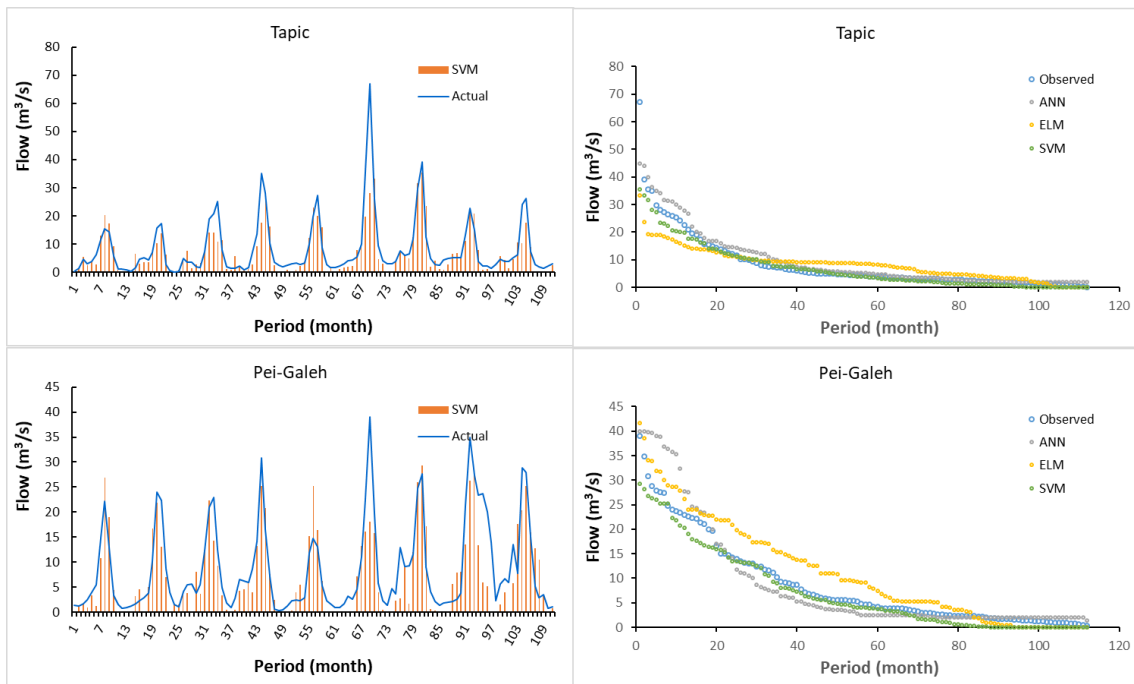
شکل ۵ مقایسه سری نزولی و زمانی جریان ماهیانه تاریخی و برآوردی از مدل SVM در ایستگاه تپیک رودخانه نازلو و ایستگاه پی‌قلعه رودخانه گدار را با حداکثر مقادیر آماره یا معیارهای R و NSE در منطقه مطالعاتی را نشان می‌دهد.

جدول ۳- مقادیر سه آماره یا معیار ارزیابی ضریب همبستگی پیرسون (R)، ریشه میانگین مربعات خطا (RMSE) و ضریب نش-

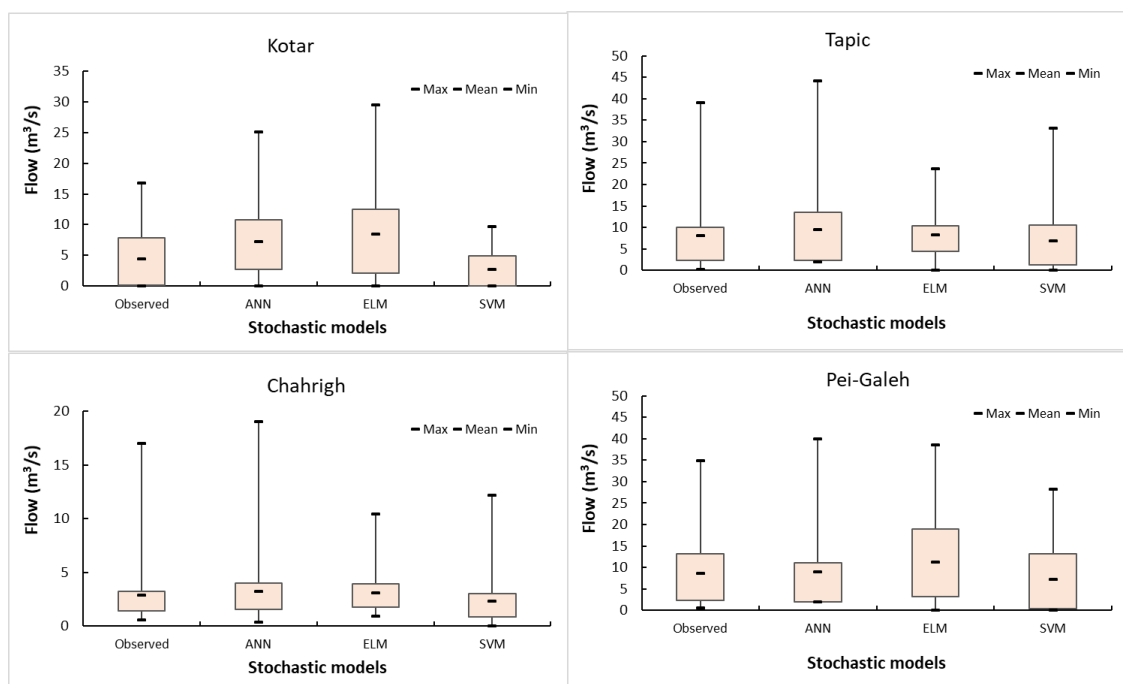
ساتکلیف (NSE) سری زمانی جریان ماهیانه تاریخی و برآوردی برای ۸ الگوی منتخب مدل استوکاستیک ARIMA.

Table 3- Values of three statistical evaluation metrics—Pearson correlation coefficient (R), root mean square error (RMSE), and Nash-Sutcliffe efficiency coefficient (NSE)—for the historical and estimated monthly streamflow time series of eight selected ARIMA stochastic model patterns.

	ANN			ELM			SVM		
	R	RMSE	NSE	R	RMSE	NSE	R	RMSE	NSE
Chahrich	0.55	2.00	0.453	0.23	2.52	0.132	0.56	1.90	0.506
Tapik	0.64	6.62	0.569	0.26	8.67	0.260	0.72	5.56	0.698
Kalhor	0.48	0.85	0.287	0.03	1.23	-0.493	0.64	0.61	0.633
MirAbad	0.69	3.74	0.456	0.23	5.13	-0.035	0.68	5.05	0.010
HashemAbad	0.59	4.43	0.375	0.09	7.21	-0.669	0.62	6.98	-0.55
Pei-Ghaleh	0.29	6.71	0.419	0.39	8.76	0.050	0.70	5.12	0.662
Kotar	0.20	6.97	-0.792	0.07	9.27	-2.170	0.38	4.47	0.263



شکل ۵- مقایسه سری نزولی و سری زمانی جریان ماهیانه تاریخی و برآوردی از مدل هوش مصنوعی SVM در دو رودخانه منطقه.
 Figure 5- Comparison of the declining series and the historical and estimated monthly streamflow time series from the SVM artificial intelligence model in two rivers of the region.



شکل ۶- مقایسه نمودار جعبه‌ای جریان ماهیانه تاریخی و برآوردی مدل‌های هوش مصنوعی در ۴ رودخانه منطقه (مهاباد، نازلو، زولا و گادار).
 Figure 6- Comparison of box plots of historical and estimated monthly streamflow from artificial intelligence models in four rivers of the region (Mahabad, Nazlou, Zola, and Gadar).

براساس نتایج حاصل از مدل‌های هوش مصنوعی، توضیحات تکمیلی زیر در توجیه و درک بهتر نتایج مفید به نظر می‌رسد:
 الف: مدل ELM، یک مدل شبکه عصبی با یادگیری بسیار سریع و با یک لایه پنهان بوده و نیازی به تنظیم دقیق وزن‌ها در لایه‌های مخفی ندارد. همچنین وزن‌های لایه ورودی به صورت تصادفی و بدون تنظیم مقادیر می‌شوند. در این مطالعه برای پیاده‌سازی مدل ELM از بسته نرم‌افزاری hpelm با جستجوی شبکه‌ای برای تعیین بهترین تنظیمات استفاده

نسبت به مدل‌های برتر هوش مصنوعی بوده که کاملاً مشابه نتایج مطالعات پیشین از جمله فتح‌آبادی (۲۰۰۹)، حجابی و همکاران (۱۳۹۲)، پاپچرالامپوس و همکاران (۲۰۱۹)، زین‌الدین و همکاران (۲۰۲۰) و شاهین و همکاران (۲۰۲۴) می‌باشد

نتایج مدل‌های هوش مصنوعی ضرورت تأکید و نیاز بیشتر برای تنظیمات و بهینه‌سازی پارامترهای مدل‌های هوش مصنوعی برای هر شرایط خاص و حاکم بر مقادیر جریان در رودخانه مورد مطالعه را نشان داد.

با توجه به ساختمان مدل‌های استوکاستیک و عملکرد قابل‌اعتماد آن‌ها در مدل‌سازی و پیش‌بینی جریان در این پژوهش، به‌کارگیری آن‌ها در پیش‌بینی جریان‌های آینده رودخانه مطمئن‌تر از مدل‌های هوش مصنوعی به نظر می‌رسد.

سپاسگزاری

این مقاله مستخرج از رساله دکتری گروه مهندسی آب دانشگاه ارومیه بوده و بدین‌وسیله از حامیان طرح خصوصاً شرکت سهامی آب منطقه‌ای آذربایجان غربی در به اشتراک‌گذاری داده‌های طرح قدردانی می‌گردد.

منابع و مأخذ

احمدپور، ع.، میرهاشمی، س. ح.، حقیقت‌جو، پ.، ۱۳۹۹. ارزیابی مدل‌های کلاسیک و مدل مفهومی IHACRES و مدل هیبریدی ARMA-ANN در شبیه‌سازی جریان روزانه بارون، فصلنامه تحقیقات آب‌و‌خاک ایران، ۵۱(۳): ۷۲۷-۷۳۶

حجابی، س.، بذرافشان، ج.، قهرمان، ن.، ۱۳۹۲. مقایسه مهارت مدل‌های استوکاستیک و شبکه‌های عصبی مصنوعی در مدل‌سازی و پیش‌بینی مقادیر و طبقات شاخص بارندگی استاندارد شده، فصلنامه پژوهش‌های جغرافیای طبیعی، ۴۵(۲)، ۱-۲۲.

دلناز، ع.، رخشنده رو، غ.، نیکو، م. ر.، ۱۳۹۶. کاربرد مدل GRNN در قیاس با مدل‌های ANN و RBF در تخمین پارامترهای آبخوان محبوس، فصلنامه ژئوهیدرولوژی، ۲(۱): ۱۱۷-۱۰۲.

سراوانی، ز.، محمدرضاپور، ا.، سیاسر، ه.، ۱۴۰۲. پیش‌بینی پارامترهای کیفی آب‌های زیرزمینی استان گلستان با مدل‌های هوش مصنوعی، فصلنامه ژئوهیدرولوژی، ۸(۲): ۱۵-۲۸.

شد. با این وجود عملکرد مدل ELM در شبیه‌سازی و پیش‌بینی جریان رودخانه در منطقه مطالعاتی نسبت به دو مدل دیگر ANN و SVM کاملاً ضعیف و نامطمئن است.

ب: مدل SVM دارای حساسیت بالا نسبت به داده‌ها و پارامترهای ورودی مدل بوده و این امر می‌تواند دلیل اصلی نوسانات و رفتار متفاوت مدل مذکور در مدل‌سازی و پیش‌بینی جریان در رودخانه‌های مختلف منطقه باشد.

ج: نتایج مدل‌های هوش مصنوعی نشان از تأکید و نیاز بیشتر برای تنظیمات و بهینه‌سازی پارامترهای مدل‌های هوش مصنوعی برای هر شرایط خاص و حاکم بر مقادیر جریان در رودخانه مورد مطالعه است.

نتیجه‌گیری

در این مطالعه، عملکرد ۸ الگوی مختلف مدل استوکاستیک ARIMA و سه مدل هوش مصنوعی ANN، ELM و SVM در مدل‌سازی و پیش‌بینی جریان ۷ رودخانه در غرب و جنوب-غربی دریاچه ارومیه مورد ارزیابی قرار گرفت. بدین‌منظور سری زمانی ماهیانه جریان رودخانه‌های مورد مطالعه در دوره آماری ۱۳۷۱-۱۴۰۰ (۲۰۲۰-۱۹۹۱) مورد استفاده قرار گرفت و ۷۰ درصد آن (۱۳۷۱-۱۳۹۰) برای آموزش مدل‌ها و ۳۰ درصد باقیمانده آن (۱۳۹۱-۱۴۰۰) برای آزمون یا صحت‌سنجی مدل‌ها در نظر گرفته شد. به دلیل اهمیت ویژه عملکرد مدل‌ها جهت پیش‌بینی جریان رودخانه در دوره آزمون و محدودیت صفحات مقاله، نتایج مطالعه صرفاً محدود به ارائه نتایج دوره آزمون شد. نتایج حاصل و تفسیر آن‌ها در بندهای زیر قابل خلاصه است:

بر اساس نمودار ACF تنها خودهمبستگی یک‌ماهه و فصلی (۱۱-۱۳) در سری زمانی جریان ماهیانه در تمام رودخانه‌های منطقه مطالعاتی معنی‌دار بوده، لذا بر مبنای آن ۸ الگوی مناسب مدل استوکاستیک $ARIMA(p,d,q)$ مشخص شد.

- چهار الگو $ARIMA(1,0,0)$ ، $ARIMA(1,0,1)$ ، $ARIMA(2,0,0)$ و $ARIMA(2,0,1)$ پیش‌بینی مطلوب از مقادیر جریان در دوره آزمون را همه رودخانه‌ها نشان داد، به طوری که متوسط مقادیر ضریب همبستگی و نش-ساتکلیف برای ۷ رودخانه منطقه به ترتیب برابر $0/68$ و $0/83$ بود.

- مقایسه نتایج مدل‌های استوکاستیک و سه مدل هوش بیانگر عملکرد بهتر معنی‌دار چهار الگوی برتر مدل استوکاستیک

- Fathabadi, A., Gholami, H., Salajeghe, A., Azaivand, H., Khosravi, H., 2009. Drought forecasting using neural network and stochastic models. *American Eurasian Network for Scientific Information*, 3(2): 137-146.
- Feng, B.F., Xu, Y.S., Zhang, T., Zhang, X., 2022. Hydrological time series prediction by extreme learning machine and sparrow search algorithm. *Water Supply*, 22(3): 3143-3157.
- Feng, D., Fang, K. and Shen, C., 2020. Enhancing streamflow forecast and extracting insights using long-short term memory networks with data integration at continental scales. *Water Resources Research*, 56(9), p.e2019WR026793.
- Hamel, L.H., 2011. Knowledge discovery with support vector machines, John Wiley & sons Publication, (3), 257.
- Kottegoda, N.T., 1980. Stochastic water resources technology. Springer: 384.
- Liong, S.Y., Khu, S.T., Babovic, V., Havnoe, K., Chan, W.T. and Phoon, K.K., 2000. Construction of non-linear models in water resources with evolutionary computation.
- Ni, L., Wang, D., Singh, V.P., Wu, J., Wang, Y., Tao, Y. and Zhang, J., 2020. Streamflow and rainfall forecasting by two long short-term memory-based models. *Journal of Hydrology*, 583: 124296.
- Niu, W.J., Feng, Z.K., 2021. Evaluating the performances of several artificial intelligence methods in forecasting daily streamflow time series for sustainable water resources management. *Sustainable Cities and Society*, 64: 102562.
- Nirumand H.A., Bozorgnia A.Gh., 2010. Introduction to time series analysis. Ferdousi University Publications, Mashhad.
- Noori, N., Kalin, L., 2016. Coupling swat and ann models for enhanced daily streamflow prediction. *Journal of Hydrology*, 533: 141-151.
- Papacharalampous, G., Tyralis, H., Koutsoyiannis, D., 2019. Comparison of stochastic and machine learning methods for multi-step ahead forecasting of hydrological processes. *Stochastic environmental research and risk assessment*, 33(2): 481-514.
- Shahin, M., Chen, F.F., Maghanaki, M., Firouzranjbar, S., Hosseinzadeh, A., 2024. Evaluating the fidelity of statistical forecasting and predictive intelligence by utilizing a stochastic dataset. *The International Journal of Advanced Manufacturing Technology*, 1-31.
- Salas J.D, Delleur W, Yevjevich V, Lane W.L., 1988. Applied modeling of hydrologic time series. Water Resources Publications, Littleton. 458.
- صالح آبادی، آ.، عمادی، س.ر.، ۱۴۰۲. توسعه شبکه‌های عصبی در پیش‌بینی جزر و مد دریای خزر بر اساس الگوریتم لوبنبرگ مارکوارت، مجله هیدروژئولوژی، ۸(۱)، ۶۱-۷۷.
- غضنفری مقدم، م. ص.، فرهمندراد، م.، بارانی، غ.، پوررضابیلندی، م.، ۱۳۹۷. واسنجی چند هدفه مدل هیدرولوژیکی مفهومی مبتنی بر هیدروگراف واحد لحظه ای ژئومورفولوژیکی (مطالعه موردی: زیر حوضه قره سو)، فصلنامه پژوهش‌های حفاظت آب‌و خاک، دوره ۲۵، شماره ۳، صص ۱۶۱-۱۷۵.
- مجددی ریزه‌ئی، ح.، حبیب‌نژادروشن، م.، شاهدی، ک.، پردهان، ب.، ۱۳۹۹. کارایی مدل ترکیبی نسبت فراوانی- ماشین بردار پشتیبان در شناسایی مناطق مستعد سیل آبخیز کلات. اکو هیدرولوژی، ۷(۱)، ۷۷-۹۵.
- نوشیار، م.، قاسمی مرزبالی، ع.، ۱۳۹۸. پیش‌بینی روزانه قیمت برق با روش مبتنی بر ماشین یادگیری شدید، سیستم پیش‌پردازش‌کننده و الگوریتم بهبود یافته کلونی جستجوی ویروس، مجله هوش محاسباتی در مهندسی برق، ۱۰(۲)، ۶۷-۱۰۱.
- Abrahart, R., Kneale, P.E., See, L.M., 2004. Neural networks for hydrological modeling. CRC Press.
- Adnan, R.M., Liang, Z., Heddarn, S., Zounemat-Kermani, M., Kisi, O., Li, B., 2019. Least square support vector machine and multivariate adaptive regression splines for streamflow prediction in mountainous basin using hydro-meteorological data as inputs. *Journal of Hydrology*, 124371.
- Alvisi, S., Franchini, M., 2011. Fuzzy neural networks for water level and discharge forecasting with uncertainty. *Environmental Modelling & Software*, 26: 523-37.
- Anandan, P., Sabeenian, R.S., 2018. Fabric defect detection using discrete curvelet transform. *Procedia computer science*, 133: 1056-1065.
- Chu, H., Wei, J., Wu, W., Jiang, Y., Chu, Q., Meng, X., 2021. A classification-based deep belief networks model framework for daily streamflow forecasting. *Journal of Hydrology*, 595: 125967.
- Farfán, J.F., Andino, P., Ortiz-Rodríguez, D., Vivanco-Gutiérrez, G., 2020. A hybrid neural network-based technique to improve the flow forecasting of physical and data-driven models: Methodology and case studies in Andean watersheds. *Journal of Hydrology: Regional Studies*, 27, 100652.

Stelling, G.S., 2000. A numerical method for inundation simulations. In Proc. 4th International Conference on Hydro-Science and Engineering, Seoul, Korea. 1: 872-892.

Tayyab, M., Zhou, J., Dong, X., Ahmad, I., Sun, N., 2019. Rainfall-runoff modeling at Jinsha River basin by integrated neural network with discrete wavelet transform. *Meteorology Atmospheric Physics*, 131(1): 115-125.

Wagena, M.B., Goering, D., Collick, A.S., Bock, E., Fuka, D.R., Buda, A., Easton, Z.M., 2020. Comparison of short-term streamflow forecasting using stochastic time series, neural networks, process-based, and Bayesian models. *Environmental Modelling & Software*, 126: 104669.

Wagener, T., Van Werkhoven, K., Reed, P., Tang, Y., 2009. Multiobjective sensitivity analysis to understand the information content in streamflow observations for distributed watershed modeling. *Water resources research*, 45(2): 1-5

Xiao, Z., Liang, Z., Li, B., Hou, B., Hu, Y., Wang, J., 2019. New flood early warning and forecasting method based on similarity theory. *Journal of Hydrologic Engineering*, 24: 04019023.

Zeynoddin, M., Bonakdari, H., Ebtehaj, I., Azari, A., Gharabaghi, B., 2020. A generalized linear stochastic model for lake level prediction. *Science of The Total Environment*, 723: 138015.