



بررسی اثرات متغیرهای اقلیمی در تخمین جریان رودخانه با استفاده از روش‌های منفرد و هیبریدی-موجکی محاسبات نرم

رضا سبحانی^۱، سروین زمان‌زاد قویدل^۲، هادی ثانی‌خانی^{۳*}، مجید منتصری^۴

تاریخ ارسال: ۱۳۹۷/۱۱/۲۷

تاریخ پذیرش: ۱۳۹۸/۰۳/۲۸

مقاله پژوهشی

چکیده

تغییرات اقلیمی و تاثیر آن در وضعیت منابع آبی می‌تواند از جنبه‌های مختلف زندگی و حیات بشر در روی زمین را به مخاطره بیندازد. در این مطالعه، با استفاده از روش‌های منفرد و هیبریدی-موجکی شبکه عصبی مصنوعی، سامانه استنتاجی فازی عصبی (دسته‌بندی تفریقی) و برنامه‌ریزی بیان ژن به مدل‌سازی پارامتر جریان پرداخته شده است. بدین منظور از داده‌های اقلیمی ماهانه با طول دوره آماری ۲۱ ساله (۱۳۷۵-۱۳۹۵) جریان، دما و بارش ایستگاه تپیک واقع در رودخانه نازلوچای ارومیه استان آذربایجان غربی استفاده شده است. در این مطالعه تاثیر پارامترهای جریان تاخیری، بارش، دما و اثر فصلی (ضریب ماهانه) در مدل‌ها بررسی شده است. نتایج حاکی از عملکرد برتر مدل‌های هیبریدی-موجکی نسبت به مدل‌های منفرد محاسبات نرم و تاثیر مثبت اعمال اثر فصلی در مدل‌سازی جریان رودخانه‌ای می‌باشد. همچنین تبدیل موجک با آنالیز داده‌ها و تفکیک نویزها توانایی ارتقاء بخشیدن به عملکرد مدل‌های هیبریدی نسبت به مدل‌های منفرد را امکان‌پذیر می‌نماید. در مدل بهینه هیبریدی موجکی برنامه‌ریزی بیان ژن، مقادیر شاخص‌های ارزیابی ضریب همبستگی و ریشه میانگین مربعات خطا به ترتیب برابر ۰/۹۷۸ (حداکثر) و ۲/۳۲۶ (m^3/s) (حداقل) به دست آمده است.

واژه‌های کلیدی: برنامه‌ریزی بیان ژن، فازی-عصبی، شبکه عصبی مصنوعی، جریان رودخانه، نازلوچای.

^۱ دانشجوی دکتری سازه‌های آبی، گروه مهندسی آب، دانشگاه علوم کشاورزی و منابع طبیعی ساری. شماره تماس: ۰۹۱۴۷۲۲۰۰۳۰،

Email: rezasobhani.sn@gmail.com

^۲ پژوهشگر پسادکتری، گروه مهندسی آبیاری و آبادانی، دانشگاه تهران. شماره تماس: ۰۹۱۴۱۰۶۶۴۰۹. Email: snzghavidel@ut.ac.ir

^۳ استادیار گروه علوم و مهندسی آب، دانشگاه کردستان. شماره تماس: ۰۹۱۲۵۵۵۰۶۰۰. Email: h.sanikhani@uok.ac.ir

^۴ استاد گروه مهندسی آب، دانشگاه ارومیه. شماره تماس: ۰۹۱۴۳۴۱۴۷۷۹. Email: m.montaseri@urmia.ac.ir

مقدمه

مدیریت موفق منابع آب نیازمند رویکردهای جهت-دار جامع و سیستماتیک می باشد تا بتواند با وجود روند تشدید مشکلات مربوط به آب و افزایش رو به رشد تقاضای آن نیاز مصرف کنندگان را برطرف سازد. در این راستا بهره گیری از شیوه های نوین مدل سازی منابع آب از اهمیت ویژه ای برخوردار است. میزان آورد رودخانه از مهم ترین عوامل تاثیرگذار در مدیریت و بهره برداری از منابع آب کشور می باشد. از طرفی پیشرفت هایی که در زمینه روش های پردازش اطلاعات صورت پذیرفته روش های داده-محور را نسبت به روش های رفتار-محور و روش های فیزیکی افزایش داده است (Sanikhani and Kisi., 2012). در سال های اخیر مطالعات گسترده ای در زمینه به کارگیری محاسبات نرم در پیش بینی پارامترهای اقلیمی از جمله جریان، دما، بارش و تبخیر-تعرق ماهیانه و ... توسط محققین در داخل و خارج از کشور انجام گرفته است، که به طور خلاصه به نمونه هایی از این مطالعات اشاره می گردد.

Traore and Guven (2012) از مدل برنامه ریزی بیان ژن جهت تخمین تبخیر و تعرق در کشور ساحلی بورکینافاسو^۱ استفاده نمودند. آن ها از داده های هواشناسی در نواحی مختلف کشور مذکور استفاده کردند و جهت مدل سازی، ترکیبات ورودی مختلف داده های هواشناسی را بکار بردند. نتایج به دست آمده حاکی از دقت بالای روش برنامه ریزی در فرآیند مدل-سازی تبخیر و تعرق بود. (Shafaei and Kisi (2015) با استفاده از مدل های محاسبات نرم و ترکیب این مدل-ها با تئوری موجک به پیش بینی تراز سطح آب دریاچه وان^۲ ترکیه پرداختند. نتایج حاکی از آن بود که مدل-های ترکیبی در مقایسه با مدل های منفرد نتایج بهتری از خود نشان دادند. (Kisi et al. (2013) برای مدل-سازی بارش-رواناب یکی از حوضه های آبریز کشور ترکیه از روش های محاسبات نرم، شبکه های عصبی

مصنوعی، سامانه استنتاجی عصبی-فازی تطبیقی و برنامه ریزی ژنتیک استفاده کردند. نتایج، برتری برنامه-ریزی ژنتیک را نسبت به سایر روش ها نشان داد. (Sanikhani et al. (2018) با استفاده از اطلاعات آب و هوایی از جمله حداقل و حداکثر درجه حرارت پرتوهای هوا و فرا زمین، مدل های مختلف هوش مصنوعی را برای مدل سازی تبخیر-تعرق مرجع مورد بررسی قرار دادند. ایشان در این مطالعه از داده های ماهانه در ایستگاه های آنتالیا و اسپارتا که در منطقه مدیترانه در ترکیه واقع شده بودند، استفاده کردند. در ایستگاه آنتالیا، عملکرد مدل های برنامه ریزی بیان ژن و شبکه های عصبی رگرسیونی بهتر از سایر مدل ها و در ایستگاه اسپارتا عملکرد مدل های شبکه های عصبی مبتنی بر شعاع و سیستم های فازی عصبی با دسته بندی تفریقی بهتر از مدل های دیگر گزارش گردید. Kisi and Cimen (2012) از ترکیب روش ماشین بردار پشتیبان با روش موجک جهت پیش بینی بارش روزانه دو ایستگاه هیدرومتری ایزمیر^۳ و افیون^۴ ترکیه استفاده کرد. نتایج حاکی از آن بود که عملکرد ترکیبی روش WSVM بهتر از روش منفرد SVM می باشد. محمدرضاپور (۱۳۹۶) به پیش بینی تبخیر-تعرق پتانسیل ماهانه با استفاده از مدل های ماشین بردار پشتیبان، برنامه ریزی ژنتیک و سیستم استنتاج عصبی-فازی پرداخت. نتایج مطالعات ایشان نشان داد که در همه ایستگاه ها مدل ماشین بردار پشتیبان در مرتبه اول و سپس مدل برنامه ریزی بیان ژن و در آخر مدل نروفازی برای تخمین مقادیر تبخیر-تعرق پتانسیل ماهانه بهترین عملکرد را داشتند. محمدی (۱۳۹۶) از مدل های شبکه عصبی مصنوعی و منحنی سنج رسوب در شبیه سازی میزان رسوب معلق در حوزه آبخیز شاهرود استفاده کردند. نتایج مطالعات ایشان نشان داد که در مدل های شبکه عصبی مصنوعی، مدل MLP در

³ Izmir

⁴ Afyon

¹ Burkina Faso

² Van

منطقه مورد مطالعه و داده‌ها

زیر حوضه نازلوچای در قسمت غربی دریاچه ارومیه با وسعتی برابر ۵۱۰۰ کیلومتر مربع واقع شده است. در این مطالعه از داده‌های جریان، دما و بارش ماهیانه در طول دوره مطالعاتی ۲۱ ساله ۱۳۷۵ تا ۱۳۹۵ (۲۱ سال * ۱۲ ماه = ۲۵۲ ماه) ایستگاه هیدرومتری تپیک واقع در رودخانه نازلوچای استفاده گردید. داده‌های مذکور از سازمان آب منطقه‌ای استان آذربایجان غربی اخذ گردید. موقعیت جغرافیایی حوضه آبریز مورد مطالعه در شکل ۱ نشان داده شده است. ایستگاه هیدرومتری تپیک دارای مشخصات ارتفاع از سطح دریا ۱۴۵۰ متر، طول و عرض جغرافیایی به ترتیب (E) 54' و 44° (N) 41' 37° می‌باشد. مشخصات داده‌های جریان، دما و بارش ماهیانه در جدول ۱ آورده شده است. بر اساس اطلاعات جدول شماره ۱ ضریب تغییرات پارامترهای جریان، دما و بارش به ترتیب برابر ۱/۳۸، ۰/۷۶ و ۱/۱۷ می‌باشد.

مقایسه با شبکه‌های RBF از دقت بیشتری در شبیه‌سازی میزان رسوب معلق برخوردارند. همچنین از دیگر مطالعات انجام شده در زمینه مدل‌سازی پارامترهای اقلیمی می‌توان به مطالعات (Goldal and Tongal 2010)، در زمینه کیفیت آب به مطالعه Goldal et al. (2016)، Barzegar (2016)، Montasari et al. (2018) و در زمینه تخمین جریان رودخانه به مطالعات Zhang et al. (2018) نیز اشاره نمود. در این مطالعه با به کارگیری مدل‌های منفرد و هیبریدی- موجکی شبکه عصبی مصنوعی، سامانه استنتاجی فازی عصبی تطبیقی و برنامه‌ریزی بیان ژن به مدل‌سازی میزان جریان در رودخانه نازلوچای که جز مهم‌ترین رودخانه‌های تامین‌کننده مصارف مختلف آب شرب و کشاورزی این منطقه می‌باشد، پرداخته می‌شود. این مطالعه جز اولین مطالعات انجام گرفته در زمینه بررسی اعمال اثر فصلی در مقیاس ماهیانه با ترکیبات ورودی مختلف شامل پارامترهای اقلیمی جهت مدل‌سازی جریان رودخانه مذکور می‌باشد.



شکل (۱): موقعیت جغرافیایی ایستگاه مورد مطالعه

جدول (۱): مشخصات آماری پارامترهای جریان، دما و بارش در ایستگاه تپیک

پارامترها	واحد	میانگین	حداقل	حداکثر	انحراف معیار	ضریب تغییرات
جریان	m ³ /s	۱۱/۰۶	۰/۰۱	۸۷/۹۷	۱۵/۲۶	۱/۳۸
دما	°C	۱۱/۱۳	-۶/۰۰	۲۶/۱۰	۸/۴۷	۰/۷۶
بارش	mm	۲۴/۲۸	۰/۰۰	۱۵۱/۵۰	۲۸/۴۶	۱/۱۷

مواد و روش‌ها

آنالیز موجک

تبدیل موجک اولین بار در سال ۱۹۸۰ به عنوان یک ابزار آنالیز سیگنال‌ها معرفی شد. تبدیل موجک عملگری است که یک تابع را به مجموعه‌ای از تبدیل موجک مادر^۱ اصلاح شده تبدیل می‌کند که این تبدیل موجک‌های اصلاح شده همان تبدیل موجک دختر^۲ هستند (Shafaei and Kisi., 2015). دو نوع تبدیل موجک وجود دارد: ۱- تبدیل موجکی پیوسته (CWT) ۲- تبدیل موجکی گسسته (DWT).^۴ تبدیل موجکی پیوسته با رابطه زیر بیان می‌شود:

(۱)

$$CWT_s^\psi(s, \tau) = \frac{1}{\sqrt{|s|}} \int s(t) \psi_{s, \tau}^*(t) dt$$

در رابطه فوق s بیانگر مقیاس^۵ (مقادیر مثبت)، τ نشان‌دهنده انتقال^۶ و $*$ نشان‌دهنده مزدوج مختلط^۷ می‌باشد که s و τ می‌تواند مقادیر پیوسته یا گسسته را برای در تبدیل موجکی پیوسته یا گسسته به خود اختصاص دهد. $\psi(t)$ تابع موجک مادر نامیده می‌شود. از انواع موجک‌های مادر می‌توان به دابچیز^۸، هار^۹، سیملت^{۱۰} و ... اشاره کرد. سطح تجزیه از دیگر عوامل مهم و تاثیرگذار در روند تجزیه داده‌ها می‌باشد که معمولاً بر اساس رابطه زیر تعیین می‌گردد. که در آن n ، سطح تجزیه و n_i طول سری می‌باشد.

(۲)

$$n = \lceil \log n_i \rceil$$

نتایج تجزیه موجک را می‌توان در قالب رابطه زیر بیان نمود:

(۳)

$$S = \sum_{i=1}^n d_n + a_n$$

که در این رابطه S سیگنال واقعی، d جزئیات، a تقریب و n تعداد مراحل تجزیه می‌باشد. در این مطالعه از موجک مادر دابچیز نوع چهارم (db4) جهت تجزیه و آنالیز داده‌های ماهانه جریان، دما و بارش استفاده گردید.

شبکه عصبی مصنوعی

شبکه‌های عصبی مصنوعی از ابزارهای محاسباتی هستند که عملکرد مشابه با فرآیندهای بیولوژیک مغز دارند. نمای شماتیک یک مدل شبکه عصبی مصنوعی در شکل ۲ نشان داده شده است. در این مطالعه الگوریتم آموزشی لونیبرگ-مارگارت جهت آموزش مدل و تعداد نرون متغیر (۱ تا ۲۰ نرون) و نوع تابع محرک متغیر در یک لایه پنهان و یک خروجی مدل‌ها جهت استخراج بهترین مدل با کدنویسی در محیط متلب به کار گرفته شده است. علاوه بر سریع بودن عملکرد الگوریتم لونیبرگ-مارگارت، این الگوریتم همانند روش‌های شبه‌نیوتن، جهت رسیدن به سرعت آموزشی مرتبه دوم با ماتریس ژاکوبین و بدون محاسبه ماتریس هسین طراحی شده است. ماتریس ژاکوبین می‌تواند از طریق روش انتشار برگشتی استاندارد محاسبه گردد که پیچیدگی کم‌تری از محاسبه ماتریس هسین دارد.

⁶ Translation

⁷ Complex Conjugate

⁸ Daubechies

⁹ Haar

¹⁰ Symlet


¹ Mother Wavelet

² Daughter Wavelet

³ Continues Wavelet Transform

⁴ Discrete Wavelet Transform

⁵ Scale



شکل (۲): نمای شماتیک یک مدل شبکه عصبی مصنوعی با چهار پارامتر ورودی

(مطابق شکل ۳)، مدل فازی مرتبه اول سوگنو با دو قانون فازی اگر-آنگاه به صورت زیر بیان می‌شود:
قانون ۱: اگر Q_{t-1} در حالت LOW و Q_{t-2} در حالت HIGH باشد آنگاه:


$$Q_t = p_1 Q_{t-1} + q_1 Q_{t-2} + r_1 \quad (۴)$$

قانون ۲: اگر Q_{t-1} در حالت LOW و Q_{t-2} در حالت MEDIUM باشد آنگاه:

$$Q_t = p_2 Q_{t-1} + q_2 Q_{t-2} + r_2 \quad (۵)$$

سامانه استنتاجی فازی عصبی تطبیقی

سامانه استنتاجی فازی-عصبی تطبیقی ANFIS برای اولین بار توسط ژانگ (Jang., 1993) معرفی شد. در این مطالعه روش دسته‌بندی تفریقی با شعاع دسته متغیر برای تعیین بهترین مدل‌ها با کدنویسی در محیط نرم افزاری متلب به کار گرفته شده است. همچنین در این مطالعه اگر فرض شود یک سامانه استنتاج فازی دارای دو ورودی Q_{t-1} و Q_{t-2} و یک خروجی Q_t باشد



شکل (۳): نمای شماتیک مدل عصبی-فازی تطبیقی

مطالعه جهت مدل‌سازی جریان رودخانه نازلوچای با استفاده از داده‌های جریان تاخیری و سایر پارامترهای اقلیمی بارش و دما از عملگرهای $+, -, \times, \div, \sqrt[3]{}, \sqrt{\cdot}, \ln, e^x, x^2, x^3, \sin x, \cos x, \arctan x$ عملگرهای ریاضی پیش فرض مدل GeneXpro می‌باشد، استفاده به عمل آمد. به طور خلاصه پارامترهای استفاده شده در هر بار اجرای مدل که اغلب مقادیر پیش‌فرض نرم‌افزار می‌باشند، در جدول ۲ ارائه شده است.


برنامه‌ریزی بیان ژن

روش برنامه‌ریزی ژنتیک جزو روش‌های الگوریتم گردشی محسوب می‌شود که مبنای آنها بر اساس نظریه تکمیل داروین است روش برنامه‌ریزی ژنتیک جدیدترین شیوه از بین روش‌های الگوریتم تکاملی می‌باشد که به دلیل دارا بودن دقت کافی از کاربرد بیشتری برخوردار است. فرآیند گام به گام حل یک مسأله با استفاده از برنامه‌ریزی ژنتیک متشکل از ۵ مرحله تشکیل یافته است (Alvisi et al., 2005). در این

جدول (۲): مقادیر پارامترهای به‌کارگرفته شده در برنامه‌ریزی بیان ژن

مقدار	مشخصات	مقدار	مشخصات	مقدار	مشخصات
۰/۳	نرخ ترکیب تک نقطه‌ای	۰/۱	نرخ برگشت	۳۰	تعداد کروموزوم‌ها
۰/۳	نرخ ترکیب دو نقطه‌ای	۰/۱	نرخ ترانهش ژنی	۸	طول هر راس
۰/۱	نرخ ترکیب ژنی	۰/۰۴	نرخ جهش	۳	تعداد ژن‌ها

بیان ژن در نظر گرفته می‌شود. دلیل انتخاب موجک دابچیز نوع چهار شباهت زیاد روند موجک مذکور با روند داده‌های اصلی جریان، دما و بارش می‌باشد (Barzegar et al., 2016). شکل ۵ روند موجک دابچیز نوع چهارم (db4) را نشان می‌دهد.



شکل (۵): نمای مدل‌های هیبریدی-موجکی (db4)

که در آنها، O_i مقادیر مشاهداتی، E_i مقادیر برآوردی مدل، $Cov(O_i, E_i)$ ، $Var(O_i, E_i)$: به ترتیب کوواریانس و واریانس بین داده‌های جریان مشاهداتی (واقعی) و برآوردی می‌باشند. در این مطالعه، تجزیه پارامترهای اقلیمی جریان، دما و بارش با استفاده از تبدیل موجک بر اساس موجک مادر دابچیز نوع چهارم در سطح دو مورد تجزیه قرار گرفت. پس از تجزیه داده‌ها، روش‌های منفرد و هیبریدی-موجکی شبکه عصبی مصنوعی، سامانه استنتاجی فازی عصبی تطبیقی و برنامه‌ریزی بیان ژن به ازای داده‌های ایستگاه هیدرومتری تپیک با دوره آماری ۲۱ ساله، جهت مدل‌سازی جریان رودخانه نازلوچای استفاده شده است.

نتایج و بحث

مدل‌های منفرد

در روش منفرد، مدل‌سازی با به کارگیری مستقیم داده‌های اصلی انجام گرفت. جهت مدل‌سازی و تخمین میزان جریان در رودخانه نازلوچای داده‌های جریان با تاخیرهای زمانی مختلف، داده‌های اقلیمی دما و بارش ماهانه به کار گرفته شد. بر این اساس ۱۰ مدل که هر کدام از پارامترها دارای همبستگی پیرسون معنی‌دار در سطح ۹۵٪ با پارامتر جریان رودخانه‌ای دارد، به ترتیب در جدول شماره ۳ پیشنهاد شده است. مدل‌های ۱ تا ۳ به ترتیب شامل پارامتر جریان با تاخیرهای زمانی در گام‌های ۱ تا ۳ ماهه می‌باشد. مدل شماره ۵ علاوه بر

در مرحله بعد، برای ایجاد مدل‌های هیبریدی-موجکی همانطور که در شکل ۵ نشان داده شده است، داده‌های آنالیز شده حاصل از تئوری موجک به عنوان پارامترهای ورودی مدل‌های شبکه عصبی مصنوعی، سامانه استنتاجی فازی عصبی تطبیقی و برنامه‌ریزی

پارامترها و شاخص‌های ارزیابی

جریان در رودخانه همبستگی بالایی با جریان‌های تاخیری زمانی مختلف و پارامترهای اقلیمی مختلف از جمله دما و بارش دارد. در این مطالعه با در نظر گرفتن ضرایب ۱ تا ۱۲ به ترتیب برای ماه‌های آبی مهر تا شهریور، اثر فصلی زمانی بر مدل‌های منفرد و هیبریدی-موجک شبکه عصبی مصنوعی، سامانه استنتاجی فازی عصبی تطبیقی و برنامه‌ریزی بیان ژن جهت مدل‌سازی جریان رودخانه نازلوچای در ایستگاه هیدرومتری تپیک با استفاده از پارامترهای ورودی مختلف اقلیمی اعمال گردید. همچنین جهت ارزیابی نتایج مدل‌ها از دو شاخص ارزیابی مهم ضریب همبستگی (R)، ریشه میانگین مربعات خطا ($RMSE$) و روش‌های گرافیکی از جمله نمودارهای پراکنندگی و تیلور استفاده شده است. در این مطالعه داده‌های جریان ماهیانه ۱۷ ساله به عنوان داده‌های دوره آموزش و ۴ ساله به عنوان داده‌های دوره آزمون به کار گرفته شده است.

(۶)

$$R = \frac{Cov(O_i, E_i)}{\sqrt{Var(O_i) \cdot Var(E_i)}} \quad (7)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (O_i - E_i)^2}$$



پارامتر جریان در گام‌های زمانی (ماهانه) قبل، تاثیر پارامتر بارش که جز پارامترهای مهم در مدل‌سازی و تخمین میزان جریان می‌باشد را در مدل‌سازی بررسی می‌کند. مدل شماره ۷ علاوه بر پارامتر جریان در گام-های زمانی قبل، به چگونگی تاثیر پارامتر اقلیمی دمای ماهانه در مدل‌سازی جریان می‌پردازد. نهایتاً مدل شماره ۹ ترکیب همزمان عوامل اقلیمی مختلف تاثیرگذار از جمله پارامتر جریان در گام‌های زمانی مختلف، بارش و دما را شامل می‌شود. در مدل‌های شماره ۴، ۶، ۸ و ۱۰ تاثیر عامل فصلی ماهانه که به ترتیب برای ماه مهر تا ماه شهریور اعداد ۱ تا ۱۲ در نظر گرفته شده، در مدل‌سازی جریان اعمال می‌گردد. نتایج و مشخصات آماری معیارهای ارزیابی مدل‌های منفرد برای سه روش مورد مطالعه در جدول ۳ آورده شده است. نتایج نشان می‌دهد که روش برنامه‌ریزی بیان ژن نسبت به دو روش شبکه عصبی مصنوعی و سامانه استنتاجی فازی عصبی تطبیقی در تمام مدل‌ها دارای عملکرد بالاتری می‌باشد.

جدول (۳): مشخصات معیارهای ارزیابی مدل‌ها با ورودی‌های مختلف برای روش‌های منفرد شبکه عصبی مصنوعی، سامانه استنتاجی فازی عصبی تطبیقی و برنامه‌ریزی بیان ژن در دوره آزمون

شماره مدل	مدل	روش	R	RMSE(m ³ /s)
۱	Q _{t-1}	GEP	۰/۶۸۳	۸/۷۳۰
		ANFIS-SC	۰/۶۱۸	۹/۱۳۰
		ANN	۰/۵۷۸	۱۰/۳۲۵
۲	Q _{t-1} , Q _{t-2}	GEP	۰/۷۱۰	۸/۴۶۳
		ANFIS-SC	۰/۶۸۸	۸/۷۸۰
		ANN	۰/۶۵۷	۹/۰۸۶
۳	Q _{t-1} , Q _{t-2} , Q _{t-3}	GEP	۰/۷۸۲	۷/۲۱۸
		ANFIS-SC	۰/۷۴۷	۷/۶۱۲
		ANN	۰/۷۳۲	۷/۷۰۸
۴	Periodic Number, Q _{t-1} , Q _{t-2} , Q _{t-3}	GEP	۰/۸۶۰	۶/۳۵۰
		ANFIS-SC	۰/۸۱۲	۷/۴۷۶
		ANN	۰/۷۹۷	۷/۶۰۱
۵	P, Q _{t-1} , Q _{t-2} , Q _{t-3}	GEP	۰/۸۵۸	۶/۳۲۹
		ANFIS-SC	۰/۷۹۲	۷/۴۸۸
		ANN	۰/۷۵۵	۸/۰۱۲
۶	Periodic Number, P, Q _{t-1} , Q _{t-2} , Q _{t-3}	GEP	۰/۹۰۶	۴/۸۵۳
		ANFIS-SC	۰/۸۳۵	۷/۱۸۷
		ANN	۰/۷۸۹	۷/۸۷۵
۷	T, Q _{t-1} , Q _{t-2} , Q _{t-3}	GEP	۰/۸۴۵	۶/۸۳۵
		ANFIS-SC	۰/۷۸۵	۷/۵۱۴
		ANN	۰/۷۷۶	۷/۶۷۸
۸	Periodic Number, T, Q _{t-1} , Q _{t-2} , Q _{t-3}	GEP	۰/۹۰۰	۴/۹۰۲
		ANFIS-SC	۰/۸۱۵	۷/۳۰۸
		ANN	۰/۷۸۱	۷/۵۴۳
۹	P, T, Q _{t-1} , Q _{t-2} , Q _{t-3}	GEP	۰/۸۷۲	۵/۷۸۱
		ANFIS-SC	۰/۸۲۲	۷/۴۱۱
		ANN	۰/۸۰۷	۷/۴۵۴
۱۰	Periodic Number, P, T, Q _{t-1} , Q _{t-2} , Q _{t-3}	GEP	۰/۹۲۸	۴/۴۴۵
		ANFIS-SC	۰/۸۶۳	۶/۸۷۸
		ANN	۰/۸۴۴	۷/۱۲۶

۰/۳۱، ۰/۲۷، ۰/۴۲، ۰/۳۲، ۰/۳۵، ۰/۲۶ و ۰/۳۱ بهترین تخمین را انجام داده است.

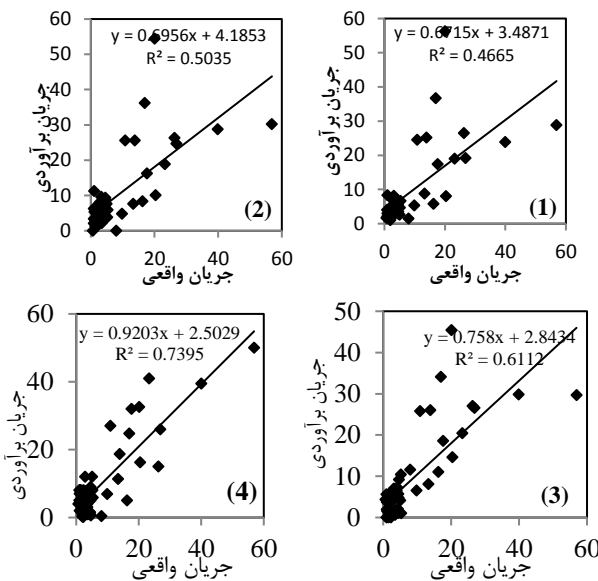
همچنین بر اساس مقایسه نتایج مدل‌های ۵ تا ۸ تاثیر مثبت پارامتر بارش ماهانه نسبت به دمای ماهانه در مدل‌سازی میزان جریان بیشتر می‌باشد. به طوریکه مقادیر ضریب همبستگی و ریشه میانگین مربعات خطا در مدل‌های شماره ۵ و ۷ در روش برنامه‌ریزی بیان ژن به ترتیب ۶/۳۲۹، ۶/۸۳۵ و ۰/۸۵۸، ۰/۸۴۵ (m³/s) می‌باشد. در میان مدل‌های منفرد بدون اعمال اثر

کل ۶ نمودار مقادیر واقعی و برآوردی جریان با روش منفرد برنامه‌ریزی بیان ژن در دوره آزمون را برای مدل‌های ۱ تا ۴ نشان می‌دهد. در این نمودارها معادله رگرسیونی $y=ax+b$ برازش داده شده است. در مدل‌های شبکه عصبی مصنوعی به ترتیب در مدل‌های ۱ تا ۱۰ تعداد نرون ۳، ۳، ۲، ۲، ۳، ۴، ۳، ۵، ۲ و ۲ در مدل‌های دسته‌بندی تفریقی، شعاع دسته ۰/۳۰، ۰/۴۷، ۰/۳۲،


جریان، بارش و دما (مدل‌های ۳ تا ۱۰) بر اساس روش منفرد برنامه‌ریزی بیان ژن در دوره آزمون را نشان می‌دهد. بر اساس نتایج مدل شماره ۱۰ به عنوان مدل بهینه در میان سایر مدل‌های پیشنهادی معرفی می‌گردد.

فصلی، مدل شماره ۹ که شامل جریان‌های تاخیری در گام‌های زمانی ۱ تا ۳ ماهه، بارش و دمای ماهیانه می‌باشد، دارای بالاترین عملکرد بوده و مقادیر ضریب همبستگی و ریشه میانگین مربعات خطا به ترتیب ۰/۸۷۲ و ۵/۷۸۱ (m^3/s) به دست آمده است.


اشکال ۷ تا ۱۰ نمودارهای مقادیر واقعی و برآوردی جریان بدون اثر فصلی و با اثر فصلی در تاخیرهای زمانی




شکل (۶): مقادیر واقعی و برآوردی جریان با روش منفرد برنامه‌ریزی بیان ژن در دوره آزمون



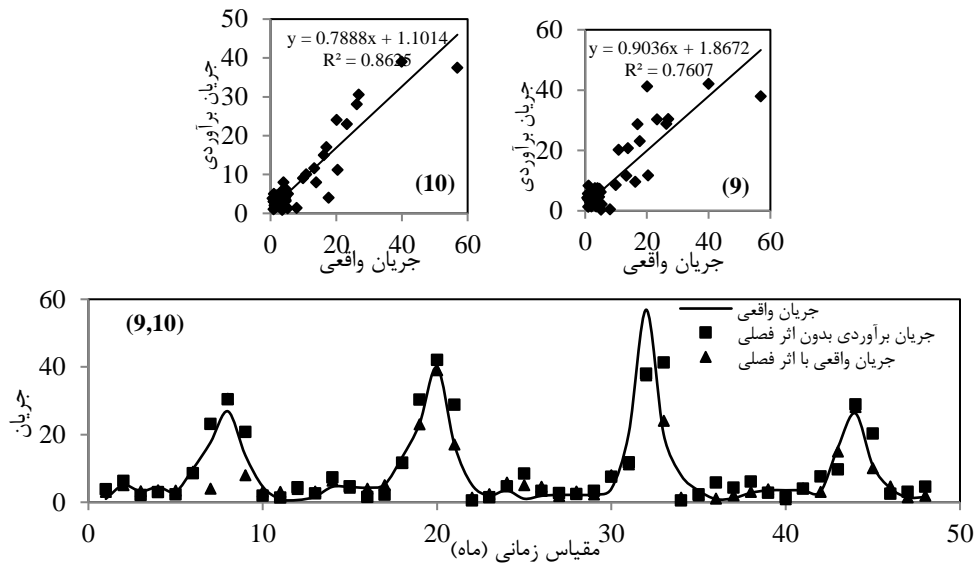
شکل (۷): مقادیر واقعی و برآوردی جریان با و بدون اثر فصلی و با اثر فصلی با روش منفرد برنامه‌ریزی بیان ژن در دوره آزمون



شکل (۸): مقادیر واقعی و برآوردی جریان با و بدون اثر فصلی با روش منفرد برنامه‌ریزی بیان ژن در دوره آزمون




شکل (۹): مقادیر واقعی و برآوردی جریان با و بدون اثر فصلی با روش منفرد برنامه‌ریزی بیان ژن در دوره آزمون



شکل (۱۰): مقادیر واقعی و برآوردی جریان با و بدون اثر فصلی جریان، بارش و دما با روش منفرد برنامه‌ریزی بیان ژن در دوره آزمون

ژن به مقدار ۵۴/۸ درصد برای معیار ارزیابی RMSE افزایش داده است که می‌توان گفت این مقدار بهبود عملکرد قابل توجه و چشمگیر می‌باشد.

نمودار تغییرات R و RMSE برای مدل‌های منفرد در شکل ۱۱ نشان داده شده است. اثر فصلی (ضرایب ۱ تا ۱۲ ماهانه) در بهبود عملکرد مدل‌ها تاثیرگذار بوده و درصد بهبود عملکرد را در مدل بهینه برنامه‌ریزی بیان



شکل (۱۱): تغییرات R و RMSE برای ترکیبات ورودی مختلف روش‌های منفرد (مدل‌های شماره ۱ تا ۱۰)

بر اساس مجموع مدل‌سازی هر یک از زیرسری‌های تولیدی در سطح دوم تبدیل موجک انجام گرفت. مشخصات مدل‌سازی زیرسری‌های اصلی و فرعی با سه روش شبکه عصبی مصنوعی، سامانه استنتاجی فازی عصبی تطبیقی و برنامه‌ریزی بیان ژن در جدول ۴ آورده شده است. به عنوان نمونه مقدار ریشه میانگین مربعات خطا برای زیر سری‌های فرعی D1 و D2 به ترتیب مقادیر ۲/۸۳۶ و ۲/۴۴۴ (m³/s) در مدل برنامه‌ریزی

مدل‌های هیبریدی-موجک

پس از آنالیز داده‌های اصلی و سری داده‌های تولیدی توسط تبدیل موجک، با استفاده از روش‌های هیبریدی-موجکی محاسبات نرم شامل سه روش هیبرید موجک شبکه عصبی مصنوعی، سامانه استنتاجی فازی عصبی تطبیقی و برنامه‌ریزی بیان ژن مدل‌سازی جریان رودخانه نازلوچای در ایستگاه هیدرومتری تپیک انجام گرفت. در این روش مدل‌سازی

فرعی D2 (حذف زیرسری فرعی D1) بررسی گردید. از میان این سه ترکیب، ترکیب سوم (مدل شماره ۱۳) به ترتیب با مقادیر حداکثر ضریب همبستگی و حداقل ریشه میانگین مربعات خطای ۰/۹۷۸ و ۲/۳۲۶ (m^3/s) در مدل هیبریدی موجک برنامه‌ریزی بیان ژن به عنوان بهترین مدل هیبریدی معرفی گردید. بر این اساس نتایج نشان می‌دهد که تبدیل موجک با آنالیز داده‌ها و تفکیک نویزها توانایی ارتقاء بخشیدن به مدل‌های هیبریدی نسبت به مدل‌های منفرد را امکان‌پذیر می‌نماید.

بیان ژن به دست آمده است. همچنین مشخصات معیارهای ارزیابی مدل‌ها، ضریب همبستگی و ریشه میانگین مربعات خطا، با ورودی‌های مدل بهینه در حالت منفرد (مدل شماره ۱۰) برای روش‌های هیبریدی-موجک شبکه عصبی مصنوعی، سامانه استنتاجی فازی عصبی تطبیقی و برنامه‌ریزی بیان ژن در دوره آزمون در جدول ۴ آورده شده است. برای ایجاد مدل‌های هیبریدی سه ترکیب مختلف: ۱- مجموع زیرسری اصلی A2 و دو زیرسری فرعی D1 و D2، ۲- زیرسری اصلی A2 (حذف زیرسری‌های فرعی D1 و D2 یا نویزها)، ۳- مجموع زیرسری اصلی A2 و زیرسری

جدول (۴): مشخصات معیارهای ارزیابی مدل‌ها با ورودی‌های مدل بهینه برای روش‌های هیبریدی-موجک شبکه عصبی مصنوعی، سامانه استنتاجی فازی عصبی تطبیقی و برنامه‌ریزی بیان ژن در دوره آزمون

شماره مدل	توضیحات	مدل	روش	R	RMSE(m^3/s)
۱*	زیرسری اصلی	A2	GEP	۰/۹۷۶	۲/۱۴۱
			ANFIS-SC	۰/۸۸۹	۲/۷۹۸
			WANN	۰/۸۴۳	۳/۲۳۲
۲*	زیرسری‌های فرعی	D2	GEP	۰/۸۸۷	۲/۸۳۶
			ANFIS-SC	۰/۸۱۲	۳/۳۱۷
			WANN	۰/۷۹۸	۳/۵۲۶
۳*		D1	GEP	۰/۸۳۹	۲/۴۴۴
			ANFIS-SC	۰/۷۶۵	۳/۱۴۲
			WANN	۰/۷۵۵	۳/۳۲۲
۱۱	مجموع زیرسری‌ها	A1	WGEP	۰/۹۵۲	۳/۵۴۹
			WANFIS-SC	۰/۸۷۹	۴/۳۹۳
			WANN	۰/۸۵۰	۴/۵۷۲
۱۲		Without D2 and D1	WGEP	۰/۹۳۶	۳/۸۰۸
			WANFIS-SC	۰/۸۵۹	۴/۸۷۹
			WANN	۰/۸۲۴	۵/۰۲۱
۱۳		Without D1	WGEP	۰/۹۷۸	۲/۳۲۶
			WANFIS-SC	۰/۸۹۲	۴/۰۶۶
			WANN	۰/۸۶۴	۴/۴۶۷


جدول (۵): خطای نسبی مدل برتر (مدل شماره ۱۳) در برآورد دبی جریان حداکثر با استفاده از روش هیبریدی- برنامه‌ریزی

بیان ژن


ردیف	مقادیر اندازه‌گیری شده دبی حداکثر	مقادیر برآوردی	خطای نسبی (%)
۱	۵۶/۹۱	۵۵/۰۰	۳
۲	۳۹/۹۳	۳۹/۰۱	۲
۳	۲۶/۸۸	۲۳/۱۰	۱۴
۴	۲۶/۲۸	۲۱/۶۹	۱۷
۵	۲۳/۲۶	۲۳/۰۰	۱
۶	۲۰/۴۲	۲۳/۰۰	۱۳
۷	۲۰/۰۸	۲۳/۰۱	۱۵

می‌گردد که مدل شماره ۱۳ علاوه بر برتری کلی، توانایی بالاتری در تخمین مقادیر حداکثر نسبت به سایر ترکیبات مدل‌های هیبریدی را دارا می‌باشد. یکی از برتری‌های روش برنامه‌ریزی بیان ژن در ارائه رابطه ریاضی حاکم بر پارامتر مدل‌سازی شده است. روابط ریاضی مستخرج از برنامه‌ریزی بیان ژن برای زیرسری‌های اصلی و فرعی مدل بهینه و نهایتاً معرفی رابطه ریاضی مدل بهینه هیبرید-موجک برنامه‌ریزی بیان ژن در جدول ۶ آورده شده است.

جدول ۵ مقادیر اندازه‌گیری شده و برآوردی دبی جریان حداکثر و خطای نسبی مدل برتر (مدل شماره ۱۳) با استفاده از روش هیبریدی- برنامه‌ریزی بیان ژن را نشان می‌دهد. بر اساس مقادیر خطای نسبی، این مدل جهت تخمین مقادیر دبی‌های حداکثر نیز عملکرد بالایی دارد. شکل ۱۲ مقادیر واقعی و برآوردی جریان با اثر فصلی در تاخیرهای زمانی جریان، بارش و دما با روش هیبرید موجک- برنامه‌ریزی بیان ژن در دوره آزمون را نشان می‌دهد. بر اساس شکل ۱۲ مشاهده



جریان واقعی
 ▲ جریان برآوردی روش هیبرید موجک- برنامه‌ریزی بیان ژن- WGEP(All)
 ■ جریان برآوردی روش هیبرید موجک- برنامه‌ریزی بیان ژن- WGEP(Without D2,D1)
 ● جریان برآوردی روش هیبرید موجک- برنامه‌ریزی بیان ژن- WGEP(Without D1)




شکل (۱۲): مقادیر واقعی و برآوردی جریان با اثر فصلی در جریان، بارش و دما با روش هیبرید موجک- برنامه‌ریزی بیان ژن در دوره آزمون

جدول (۶): روابط ریاضی برنامه‌ریزی بیان ژن برای زیرسری‌های اصلی و فرعی مدل بهینه

شماره مدل	رابطه ریاضی	ضرایب
A2	$Y1 = (((d(5)*d(4)*d(4)))*\exp(G1C1)^3)+d(6);$ $Y2 = Y1 + ((\sin((G2C0-d(1)))+(d(6)-d(1))/G2C1)-d(5));$ $varTemp = Y2 + d(6);$	$G1C0 = -5.649475; G1C1 = -4.106323;$ $G2C0 = -6.226135; G2C1 = -5.682129;$ $G3C0 = 3.578888; G3C1 = -9.756043;$
D2	$Y1 = (((\cos(G1C1)*d(5)-d(6))-G1C0)+G1C0);$ $Y2 = Y1 + (\cos(\text{atan}((G2C1-d(6))))*(\text{atan}(\text{atan}(d(4))*d(5)));$ $varTemp = Y2 + \text{atan}(d(3));$	$G1C0 = 6.782227; G1C1 = 9.993775;$ $G2C0 = -5.6651; G2C1 = -5.519806;$ $G3C0 = 8.971711; G3C1 = -0.915741;$
D1	$Y1 = ((\sin((d(1)^2)-(d(6)+d(5)))-\cos(\text{atan}(G1C0)));$ $Y2 = Y1 + (d(4)*\cos(((\text{atan}(G2C0)^2)/(G2C1/G2C1)))));$ $varTemp = Y2 + \cos(\text{atan}((d(4)+\cos((d(6)-d(2))))));$	$G1C0 = 2.158844; G1C1 = 6.642914;$ $G2C0 = 8.882508; G2C1 = 6.642914;$ $G3C0 = 5.967499; G3C1 = 6.642914;$
بهینه	$Qt=A2+D2$	

$d(1)=$ Periodic Number, $d(2)= P$, $d(3)= T$, $d(4)= Qt-3$, $d(5)= Qt-2$, $d(6)= Qt-1$

بهترین ترکیب (حذف نویز D1) نسبت به ضعیف‌ترین ترکیب (حذف هر دو نویز D1 و D2) به مقدار ۳۹ درصد می‌رسد. نتایج این مطالعه در زمینه برتری مدل‌های هیبریدی-موجک نسبت به مدل‌های منفرد محاسبات نرم با نتایج مطالعات Barzegar et al. (2016) و در زمینه ترتیب اولویت عملکرد مدل‌های برنامه‌ریزی بیان ژن، سامانه استنتاجی فازی-عصبی تطبیقی و شبکه عصبی مصنوعی با مطالعه Montaseri et al. (2018) همخوانی دارد. همچنین نتایج این مطالعه در زمینه تاثیر مثبت اعمال ضریب فصلی با مطالعه Sanikhani and Kisi (2012) همسو می‌باشد.

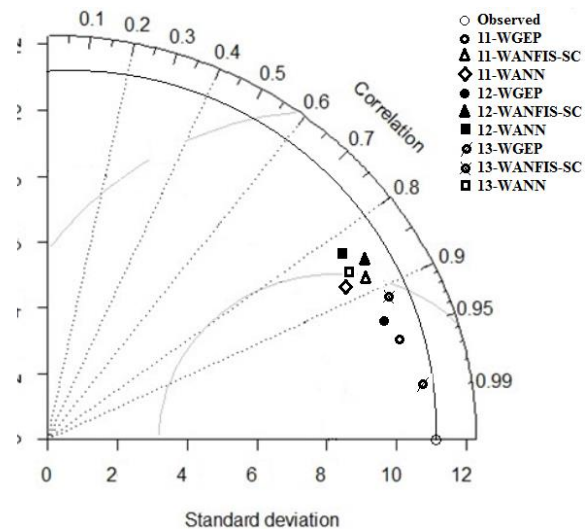


شکل (۱۳): تغییرات R و RMSE مدل بهینه در روش‌های

هیبریدی-موجک شبکه عصبی مصنوعی، سامانه استنتاجی فازی عصبی تطبیقی و برنامه‌ریزی بیان ژن

شکل شماره ۱۳ نمودار تغییرات R و RMSE مدل بهینه در روش‌های هیبریدی-موجک شبکه عصبی مصنوعی، سامانه استنتاجی فازی عصبی تطبیقی و برنامه‌ریزی بیان ژن (مدل‌های شماره ۱۱ تا ۱۳) را نشان می‌دهد. با توجه به این نمودار مشاهده می‌گردد که در مدل‌های هیبریدی نیز روش برنامه‌ریزی بیان ژن دارای عملکرد بالاتری نسبت به روش‌های شبکه عصبی مصنوعی و سامانه استنتاجی فازی عصبی تطبیقی دارد. همچنین عملکرد روش سامانه استنتاجی فازی عصبی تطبیقی بالاتر از روش شبکه عصبی مصنوعی می‌باشد. شکل ۱۴ دیاگرام تیلور مدل‌های هیبریدی-موجکی شبکه عصبی مصنوعی، سامانه استنتاجی فازی عصبی تطبیقی و برنامه‌ریزی بیان ژن را نشان می‌دهد. هر چه مقادیر مدل شده به مقادیر واقعی نزدیک باشد، نشانگر عملکرد بهتر مدل مورد نظر می‌باشد. دیاگرام تیلور بر اساس سه شاخص ضریب همبستگی، ریشه میانگین مربعات خطا و انحراف معیار ترسیم و تحلیل می‌گردد. بر اساس سه شاخص مذکور داده‌های مدل هیبریدی موجکی برنامه‌ریزی بیان ژن با حذف آخرین نویز D1، با افزایش مقدار R و کاهش مقدار RMSE، به داده‌های واقعی نزدیک‌تر بوده و دارای عملکرد بالاتری نسبت به سایر مدل‌ها می‌باشد. از طرفی به ترتیب عملکرد ترکیبات مربوط به مدل‌های ۱۳، ۱۲ و ۱۱ را می‌توان معرفی نمود. درصد بهبود عملکرد بر اساس ریشه میانگین مربعات خطا مدل هیبرید برنامه‌ریزی بیان ژن

مدل سازی میزان جریان در رودخانه نازلوچای با استفاده از پارامترهای اقلیمی بارش و دمای میانگین ماهانه و جریان های تاخیری یک تا سه ماهه به کار گرفته شده است. نتایج حاکی از دارا بودن قابلیت جایگزینی روش های محاسبات نرم با روش های تجربی می باشد. همچنین روش های محاسبات نرم دارای ویژگی ها و مزیت های فراوان از جمله ارائه رابطه ریاضی بین پارامترهای ورودی و خروجی مدل ها نسبت به سایر روش ها می باشند. تبدیل موجک با آنالیز داده ها و تفکیک نویزها توانایی ارتقاء بخشیدن به مدل های هیبریدی نسبت به مدل های منفرد را تا حد زیادی امکان پذیر می نماید. همچنین مقایسه عملکرد مدل ها حاکی از برتری روش برنامه ریزی بیان ژن (در دو حالت منفرد و هیبریدی-موجکی) و تاثیر مثبت ضرایب فصلی (ماهانه) می باشد. نتایج این مطالعه با مطالعات بسیاری از محققین از جنبه های مختلف همخوانی دارد. در نهایت پیشنهاد می گردد که محققین علاوه بر به کارگیری پارامترهای اقلیمی بارش و دما و جریان های تاخیری با گام های زمانی مختلف، سایر پارامترهای اقلیمی را نیز جهت مدل سازی جریان رودخانه ای در حوضه های آبریز مختلف با روش های مختلف منفرد و هیبریدی-موجکی محاسبات نرم بررسی نمایند.



شکل (۱۴): دیاگرام تیلور مدل های هیبریدی-موجکی شبکه عصبی مصنوعی، سامانه استنتاجی فازی عصبی تطبیقی و برنامه ریزی بیان ژن

نتیجه گیری

در این مطالعه، شش روش منفرد و هیبریدی-موجکی شبکه عصبی مصنوعی، سامانه استنتاجی فازی عصبی تطبیقی، برنامه ریزی بیان ژن، شبکه عصبی مصنوعی-موجک، سامانه استنتاجی فازی عصبی تطبیقی-موجک و برنامه ریزی بیان ژن-موجک جهت

منابع

- محمدرضاپور، ا. ۱۳۹۶. پیش بینی تبخیر-تعرق پتانسیل ماهانه با استفاده از مدل های ماشین بردار پشتیبان، برنامه ریزی ژنتیک و سیستم استنتاج عصبی- فازی. فصلنامه علمی پژوهشی مهندسی آبیاری و آب، سال هفتم، شماره ۲۷، ص ۱۵۰-۱۳۵.
- محمدی، ص. ۱۳۹۶. مقایسه مدل های شبکه عصبی مصنوعی و منحنی سنجه رسوب در شبیه سازی میزان رسوب معلق، مطالعه موردی حوزه آبخیز شاهرود. فصلنامه علمی پژوهشی مهندسی آبیاری و آب، سال هفتم، شماره ۲۷، ص ۴۶-۳۲.

Alvisi, S., G. Mascellani, M. Franchini and A. Bardossy. 2005. Water level forecasting through fuzzy logic and artificial neural network approaches. *Journal of Hydrology and Earth System Sciences*, 2: 1107-1145.

Barzegar, R., J. Adamowski and A. Asghari Moghaddam. 2016. Application of wavelet-artificial intelligence hybrid models for water quality prediction: a case study



in Aji-Chay River, Iran. Stochastic Environmental Research and Risk Assessment, DOI 10.1007/s00477-016-1213-y.

Güldal, V and H. Tongal. 2010. Comparison of recurrent neural network, adaptive neuro-fuzzy inference system and stochastic models in Egirdir Lake level forecasting. *Water Resources Management*, 24 (1): 105–128.

Hashmi, M.Z., A.Y. Shamseldin and B.W. Melville. 2011. Statistical downscaling of watershed precipitation using Gene Expression Programming (GEP). *Environmental Modelling & Software*, 26:1639-1646.

Jang, J.S.R. 1993. ANFIS: adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems, Man and Cybernetics*, 23 (3): 665–685.

Kisi, O., J. Shiri and M. Tombul. 2013. Modelling rainfall-runoff process using soft computing techniques. *Computers & Geosciences*, 51: 108–117.

Kisi, O and M. Cimen. 2012. Precipitation forecasting by using wavelet support vector machine conjunction model. *Engineering Application of Artificial Intelligence*, 25:783–792.

Montaseri, M., S. Zamanzad Ghavidel and H. Sanikhani. 2018. Water quality variations in different climates of Iran: Toward modelling total dissolved solid using soft computing techniques. *Stochastic Environmental Research and Risk Assessment*, DOI: 10.1007/s00477-018-1554-9.

Sanikhani, H and O. Kisi. 2012. River flow estimation and forecasting by using two different adaptive neuro-fuzzy approaches. *Water Resources Management*, 26:1715-1729.

Sanikhani, H., O. Kisi, E. Maroufpoor and Z.M. Yaseen. 2018. Temperature-based modeling of reference evapotranspiration using several artificial intelligence models: application of different modelling scenarios. *Theoretical and Applied Climatology*, 1-14.

Shafaei, M and O. Kisi. 2015. Lake Level Forecasting Using Wavelet-SVR Wavelet-ANFIS and Wavelet-ARMA Conjunction Models. *Water Resources Management*, DOI: 10.1007/s11269-015-1147-z.

Traore, S and A. Guven. 2012. Regional-specific numerical models of evapotranspiration using gene-expression programming interface in Sahel. *Water Resources Management*, 26(15): 4367-4380.

Zhang, Z., Q. Zhang, V. P. Singh and P. Shi. 2018. River flow modelling: comparison of performance and evaluation of uncertainty using data-driven models and conceptual hydrological model. *Stochastic environmental research and risk assessment*, 1-16.



Investigating the effects of climate variables on river flow estimation using single and hybrid-wavelet methods of soft computing

Reza Sobhani¹, Sarvin Zamanzad Ghavidel², Hadi Sanikhani^{*3}, Majid Montaseri⁴

Abstract

Climate change and its impact on the status of water resources can endanger the various aspects of life and human life on Earth. In this study, single and hybrid-wavelet artificial neural network, Adaptive neuro-fuzzy inference system and gene expression programming were used modeling flow parameter. For this purpose, monthly climatic data with 21-year (1996-2016) statistical period of flow, temperature and precipitation of Tapik station in the Nazluchay River of West Azerbaijan province has been used. In this study, the effects of delayed flow parameters, precipitation, temperature and periodic effect (monthly coefficient) in models have been investigated. The results show the superior performance of wavelet hybrid models compared to single models of soft computing and the positive effect of applying periodic effects on river flow modeling. Also, wavelet transformation by analyzing data and separating the noise enables the ability to upgrade the performance of hybrid models as compared to single models. For the optimal model (i.e. hybrid wavelet-gene expression programming model, the values of correlation coefficient and root mean square error indices were obtained as 0.98 (maximum) and 326.2 (m³/s) (minimum), respectively.

Keywords: Gene expression programming, neuro-fuzzy, artificial neural network, River flow, Nazluchay.

¹ Ph.D student of Water Structures, Water Eng. Dep., Sari Agricultural Sciences and Natural Resources University. 09147220030, Email: rezasobhani.sn@gmail.com

² Postdoctoral Research Fellow, Department of Irrigation and Reclamation Engineering University of Tehran. 09141066409, Email: snzghavidel@ut.ac.ir

³ * Assistant Professor, Water Sciences and Eng. Dep., University of Kurdistan. 09125550600, Email: h.sanikhani@uok.ac.ir

⁴ Professor, Department of Water Engineering, Urmia University. 09143414779, Email: m.montaseri@urmia.ac.ir