

پیش‌بینی بارش ایستگاه بابلسر توسط مدل بهینه‌یافته موجک – ماشین آموزش نیرومند

حامد کریمی^۱، محمد علی ایزدبخش^{۲*}، بهروز یعقوبی^۲، سعید شعبانلو^۲

۱) دانشجوی دکتری منابع آب، گروه مهندسی آب، واحد کرمانشاه، دانشگاه آزاد اسلامی، کرمانشاه، ایران

۲*) گروه مهندسی آب، واحد کرمانشاه، دانشگاه آزاد اسلامی، کرمانشاه، ایران

*نویسنده مسئول مکاتبات: behrouz.yaghoubi.h@gmail.com

تاریخ پذیرش: ۱۴۰۰/۰۴/۱۲

تاریخ دریافت: ۱۳۹۹/۰۲/۱۰

چکیده:

شبیه‌سازی بارندگی یکی از مهمترین موضوعات علم هیدرولوژی محسوب می‌شود. همچنین، مدل‌های هوش مصنوعی دارای مزایای فراوانی از قبیل دقت قابل قبول، انعطاف‌پذیری مناسب و سرعت بالا هستند. در این مطالعه، بارندگی در ایستگاه بابلسر توسط یک مدل هوش مصنوعی بهینه‌یافته به منظور شناسایی تاخیرهای موثر داده‌های سری زمانی و معرفی مدل برتر شبیه‌سازی شد. برای اینکار، ماشین آموزش نیرومند (ELM) و تبدیل موجک (wavelet transform) با همدیگر ترکیب شدند. لازم به ذکر است که مقادیر بارندگی‌ها به صورت ماهیانه از سال ۱۹۵۱ تا ۲۰۱۹ بکار گرفته شدند که ۷۰ درصد آنها برای آموزش این مدل هوش مصنوعی و ۳۰ درصد باقیمانده برای آزمون آن استفاده گردید. در ابتدا، توابع فعال‌سازی مدل ماشین آموزش نیرومند مورد بررسی قرار گرفتند که بهترین آن شامل تابع فعال‌سازی sigmoid انتخاب شد. همچنین، تاخیرهای داده‌های سری زمانی با استفاده از تابع خود همبستگی معرفی شدند که با استفاده از این تاخیرها، چهار مدل ماشین آموزش نیرومند تعریف گردید. با اجرای یک تحلیل حساسیت، مدل برتر ELM معرفی شد. مقادیر ضریب همبستگی (R)، شاخص عملکرد (VAF) و شاخص پراکندگی (SI) برای مدل برتر ELM در وضعیت آزمون به ترتیب مساوی با ۰/۵۲۴، ۲۷/۰۶۴ و ۰/۸۱۹ محاسبه شدند. علاوه بر این، موجک‌های مادر مختلف مورد بررسی قرار گرفتند که dmey به عنوان بهترین موجک مادر انتخاب شد. تبدیل موجک دقت مدل‌سازی را به شکل قابل توجهی افزایش داد. به عنوان مثال، شاخص عملکرد مدل ترکیبی WELM مساوی با ۸۶/۴۶۱ بدست آمد. لازم به ذکر است که مدل ترکیبی نیز برای سه سطح تجزیه مختلف مورد بررسی قرار گرفت که بهترین سطح تجزیه مدل ترکیبی معرفی گردید. لازم به ذکر است که تاخیرهای شماره (t-1) و (t-12) به عنوان موثرترین تاخیرهای داده‌های سری زمانی شناسایی شدند.

کلید واژه‌ها: بارندگی؛ بابلسر؛ شبیه‌سازی؛ ماشین آموزش نیرومند؛ تبدیل موجک

مقدمه

پوشیده نیست. در مقابل با توجه به اقلیم خشک و نیمه خشک فلات قاره ایران، مدل‌سازی الگوی بارندگی در این منطقه از اهمیت بسیار بالایی برخوردار است. همچنین، تخمین بارندگی بسیار مهم و ارزشمند است زیرا پیش‌بینی میزان بارندگی نقش قابل توجهی در مدیریت سیلاب، پیش‌بینی تر سالی و خشک سالی دارد.

بارندگی یا بارش فرایندی است که طی آن بخار آب تحت شرایط جوی متراکم شده و به صورت مایع یا جامد بر اثر نیروی گرانش زمین بر سطح زمین می‌بارد. اهمیت تخمین و الگوشناسی بارش در مناطق مختلف جهان علل خصوص نواحی خشک و نیمه خشک کره زمین بر کسی

Nagahamulla و همکاران (۲۰۱۲) تکنیک‌های مختلف شبکه عصبی مصنوعی را برای شبیه‌سازی مقدار بارندگی در کشور سریلانکا - استفاده نمودند. آنها با ارزیابی عملکرد مدل‌های بکار گرفته شده نشان دادند که مدل عصبی ENN مقادیر بارش‌ها را با دقت بیشتری تخمین زد. Hardwinarto و Aipassa (۲۰۱۵) بارش ماهانه در یک بازه زمانی ۲۲ ساله یک حوضه واقع در کشور اندونزی را توسط شبکه عصبی مصنوعی شبیه‌سازی کردند. آنها در انتها بیان نمودند که مدل هوش مصنوعی مقادیر بارش را با دقت قابل قبولی تخمین زد. علاوه بر این، Dabral و Murry (۲۰۱۷) داده‌های سری زمانی بارش در یک بازه ۱۴ ساله حوضه‌ای واقع در شرق کشور هندوستان را توسط مدل ساریمان در بازه‌های زمانی روزانه، هفتگی و ماهانه پیش‌بینی کردند. آنها تاخیرهای موثر را نیز شناسایی نمودند و نشان دادند که مدل مذکور مقادیر بارش‌ها را با دقت خوبی شبیه‌سازی کرد. Chang و همکاران (۲۰۱۸) با استفاده از یک مدل نرو-فازی تحت عنوان شبکه استنتاج فازی وابسته به خود مقادیر بارش و رواناب ماهیانه را برای چند حوضه در کشورهای چین، سوئد و استرالیا مدل‌سازی نمودند. آنها نشان دادند که مدل نرو-فازی مذکور از انعطاف مناسبی برای پیش‌بینی بارندگی برخوردار است. Mehr و همکاران (۲۰۱۹) یک مدل ترکیبی بهینه‌یافته را برای پیش‌بینی مقادیر بارش دراز مدت ماهیانه شهر تبریز و ارومیه توسعه دادند. آنها برای بهینه‌سازی مدل هوش مصنوعی رگرسیون بردار پشتیبان از الگوریتم کرم شب‌تاب بهره گرفتند. دهقانی و همکاران (۱۳۹۵) جریان روزانه در حوزه آبخیز کسلیان را با استفاده از شبکه عصبی مصنوعی و شبکه عصبی-فازی تطبیقی پیش‌بینی کردند. علاوه بر این، آنها تأخیرهای داده‌های سری زمانی را با استفاده از نمودار خودهمبستگی جزئی شناسایی کردند. در این مطالعه نشان داده شد که شبکه عصبی-فازی تطبیقی مقادیر جریان روزانه در حوزه آبخیز مورد نظر را با دقت بهتری پیش‌بینی نمود. باباعلی و

علاوه بر این، به دلیل افزایش جمعیت و صنعتی شدن کشور ایران، مدیریت بارش و سایر منابع آب از اهمیت بالایی دارد. بنابراین پیش‌بینی و الگوشناسی پدیده بارندگی در نواحی مختلف کشور بسیار مهم است. در سال‌های اخیر مدل‌های عددی فراوانی برای تخمین و الگوشناسی عوامل مختلف جوی از قبیل بارش در مناطق گوناگون جهان توسط محققین متعدد معرفی شده‌اند. به عنوان مثال؛ Savic و همکاران (۱۹۹۹) توسط شبکه عصبی مصنوعی و برنامه‌نویسی ژنتیک مقادیر بارش در کشور اسکاتلند را پیش‌بینی نمودند. آنها نشان دادند که برنامه‌نویسی ژنتیک توانایی شبیه‌سازی مقادیر بارش برای تاخیرهای بیشتر از سه روز را داشت. همچنین، Wong و همکاران (۲۰۰۳) دو مدل هوش مصنوعی از قبیل یک مدل شبکه عصبی مصنوعی و یک مدل فازی را برای شبیه‌سازی مقادیر بارش در یک ناحیه مشخص در کشور ایتالیا بکار گرفتند. آنها حدوداً ۲۰ درصد مقادیر مشاهداتی را برای آموزش مدل‌های عددی و ۸۰ درصد باقیمانده را نیز برای صحت‌سنجی نتایج استفاده نمودند. با تجزیه و تحلیل نتایج نشان داده شد که مدل فازی عملکرد بهتری برای تخمین تابع هدف داشت. Nasserri و همکاران (۲۰۰۸) شبکه عصبی مصنوعی را توسط الگوریتم ژنتیک برای پیش‌بینی مقادیر بارش در یک حوضه واقع در کشور استرالیا بهینه‌سازی نمودند. آنها همچنین تاخیرهای مختلف را برای توسعه مدل‌های بیشتر استفاده نمودند و در انتها مدل برتر را معرفی کردند. Nourani و همکاران (۲۰۰۹) از سه مدل هوشمند شبکه عصبی مصنوعی، انفیس جهت تخمین رواناب ماهانه و روزانه در حوضه آبریز لبقوانچای، واقع در استان آذربایجان شرقی استفاده نمودند. سپس، نتایج سه مدل مذکور با نتایج به دست آمده از روش‌های رگرسیون خطی و مدل سری زمانی مقایسه شدند. نتایج آنها نشان داد که ARIMA مدل‌سازی فازی (تطبیقی و استنتاجی) از سایر مدل‌ها دقیقتر بوده و بیشترین مقدار نش-ساتکلیف و کمترین خطا را داشت.

شهر بابلسر در مدار معتدل گرم قرار گرفته و ضریب اعتدال این شهر بسیار معتدل است. این ناحیه با میانگین سالیانه دمای $4/18$ درجه سانتی‌گراد، بارش سالیانه 791 میلی‌متر و 79 درصد رطوبت یکی از خوش آب و هواترین مناطق کشور به‌شمار می‌آید. از نظر توپوگرافی سراسر بابلسر در بخش جلگه‌ای و در موقعیت ساحلی قرار دارد و از لحاظ ناهمواری عوارض برجسته توپوگرافیک در آن دیده نمی‌شود. تقریباً هموار بوده و با شیب ملایمی از سوی رشته کوه‌های البرز به سوی دریای خزر امتداد دارد. بلندای شهر 21 متر پایین‌تر از سطح دریای آزاد و 7 متر بالاتر از سطح دریای مازندران قرار دارد. طول جغرافیایی ایستگاه بابلسر 52 درجه و 39 دقیقه و عرض آن 36 درجه و 42 دقیقه است.

ماشین آموزش نیرومند

امروزه استفاده از شبکه‌های عصبی به عنوان یک ابزار قوی در حل مسائل غیرخطی، مورد توجه محققین زیادی در علوم مختلف شده است. الگوریتم‌های کلاسیک در آموزش شبکه‌های عصبی، هر چند که در حل بسیاری از مسائل موفق بوده‌اند، اما همانند تمامی ابزارها، دارای ضعف‌هایی نیز (مانند سرعت پایین مدلسازی، تنظیم اولیه مقدار پارامترها و گیرافتادن در بهینه محلی) می‌باشند. به منظور برطرف کردن مشکلات موجود در الگوریتم‌های کلاسیک مانند پس انتشار^۱، در آموزش شبکه عصبی پیشخور تک لایه ($SLFFNN$)، الگوریتم ماشین آموزش نیرومند^۳ (ELM) توسط Huang و همکاران (۲۰۰۶)، ارائه شده است. از مهم‌ترین مزایای این الگوریتم نسبت به الگوریتم پس انتشار می‌توان به:

۱. سرعت قابل توجه این الگوریتم نسبت به الگوریتم‌های دیگر

دهقانی (۱۳۹۶) مقادیر بارش ماهانه در یک بازه زمانی 10 ساله برای حوضه آبریز دشت کاکارضا استان لرستان را با استفاده از مدل برنامه نویسی بیان ژن پیش‌بینی زدند. آن‌ها نشان دادند که ضریب همبستگی مدل عددی مذکور برابر با $0/978$ بود بنابراین این مدل توانایی خوبی در شبیه‌سازی مقدار بارندگی داشت.

تحقیقات گذشته نشان می‌دهد که استفاده از مدل‌های مختلف هوش مصنوعی به طور گسترده‌ای برای تخمین بارش مورد استفاده قرار می‌گیرند زیرا این مدل‌ها دارای دقت بالایی بوده و بسیار منعطف و مقرون به صرفه می‌باشند. در این مطالعه، بارندگی ماهانه در ایستگاه بابلسر برای اولین بار با استفاده از مدل هوش مصنوعی ترکیبی "موجک- ماشین آموزش نیرومند" در یک بازه زمانی 68 ساله از سال 1951 تا 2019 پیش‌بینی می‌شود. به همین منظور، در ابتدا، تاخیرهای موثر داده‌های سری زمانی توسط تابع خود همبستگی شناسایی می‌شود. سپس با ترکیبات مختلف از این تاخیرها، چهار مدل مختلف ماشین آموزش نیرومند تولید می‌شود و با انجام یک تحلیل حساسیت مدل برتر معرفی می‌شود. در ادامه، مدل برتر با تبدیل موجک و برای سه سطح مختلف تجزیه ترکیب خواهد شد که با تجزیه و تحلیل نتایج مدل‌سازی‌ها، بهینه‌ترین مدل هوش مصنوعی ترکیبی معرفی می‌گردد.

مواد و روش‌ها ناحیه مورد مطالعه

در این مطالعه برای آموزش و آزمون مدل‌های هوش مصنوعی از مقادیر بارش‌های ماهانه گزارش شده توسط سازمان هواشناسی کشوری ایستگاه بابلسر در یک بازه زمانی 68 ساله از سال 1951 تا 2019 استفاده می‌گردد. برای آموزش مدل‌های هوش مصنوعی از 49 سال این داده‌های سری زمانی استفاده خواهد شد و 19 سال باقیمانده برای آزمون این مدل‌ها بکار گرفته می‌شوند.

¹ back propagation

² single layer feedforward neural network

³ Extreme learning Machine

معکوس موورپنروس^۱ که بر روی بردار لایه مخفی اعمال می‌شود (H^+), بدست می‌آید.

$$\beta = H^+ Y \quad (5)$$

در استفاده از روش ماشین آموزش نیرومند، تنها نیاز به تعریف دو پارامتر می‌باشد، تعداد نرون های لایه مخفی و نوع تابع فعال‌سازی. تعداد نرون های لایه مخفی عموماً با استفاده از سعی و خطا تعیین می‌شود به طوری که مدل تا حد امکان ساده باشد و همچنین عملکرد تعمیم پذیری خوبی داشته باشد. توابع فعال‌سازی مختلفی نیز وجود دارد که در مسائل مختلف، عملکرد هر یک از آنها جهت دستیابی به مدل بهینه، مورد ارزیابی قرار می‌گیرد. توابع فعال‌سازی مورد استفاده در این مطالعه شامل Hard limit، سینوسی (Sin)، سیگموئید (Sig)، مستطیلی (tribas) و شعاعی (radbas) می‌باشد.

تبدیل موجک^۲

به منظور دستیابی به جزئیات بیشتر از یک سیگنال، تبدیل‌های فراوانی ارائه شده است. تبدیل موجک یکی از قوی‌ترین و معتبرترین تبدیل‌ها در پیش‌بینی‌های سری‌های زمانی است بطوریکه این تبدیل به‌طور همزمان در زمان و فرکانس، عمل می‌کند. تبدیل موجک توانایی تولید اجزا با فرکانس‌های پایین و بالا در سطوح مختلف را داراست به طوری که دقت مدل‌های پیش‌بینی در سری‌های زمانی را بهبود بخشد. موجک مادر را می‌توان به صورت زیر تعریف کرد:

$$\int_{-\infty}^{+\infty} \psi(t) dt = 0 \quad (6)$$

که $\psi_{a,b}(t)$ به فرم زیر محاسبه می‌گردد:

$$\psi_{a,b}(t) = \left| a \right|^{-\frac{1}{2}} \psi\left(\frac{t-b}{a}\right) \quad (7)$$

۲. تنظیم پارامترهای شبکه به صورت تکرار شونده در طی فرایند آموزش جهت افزایش دقت

۳. همچنین عملکرد تعمیم‌پذیری بهتر نسبت به الگوریتم‌های کلاسیک

۴. استفاده از توابع انتقال مشتق ناپذیر

۵. و مهم‌تر از همه، رفع مشکل گیرکردن در بهینه محلی، اشاره کرد.

الگوریتم ELM دارای سه لایه ورودی، پنهان و خروجی است. هر یک از این لایه توسط ماتریس‌هایی تحت عنوان ماتریس‌های وزن، به یکدیگر متصل هستند. ماتریس وزن ورودی و بایاس‌های لایه پنهان، به صورت تصادفی تعیین می‌شوند در صورتی که ماتریس وزن خروجی، طی حل یک مساله خطی، بدست می‌آید.

با فرض تعداد N نرون در لایه مخفی، یک شبکه عصبی پیش‌خور تک لایه به صورت تعریف می‌شود:

$$y_k = \sum_{i=1}^N \beta_i g(x_k; c_i, a_i) \quad k = 1, 2, 3, \dots, M \quad (1)$$

که β_i و c_i ، $g(\cdot)$ به عنوان تابع انتقال، پارامتر تابع انتقال و بردار وزن خروجی که اتصال دهنده لایه پنهان و لایه خروجی می‌باشد (به ترتیب) شناخته می‌شوند. رابطه فوق را می‌توان به شکل ماتریس زیر بازنویسی کرد:

$$H\beta = Y \quad (2)$$

$$H = \begin{bmatrix} g(x_1; c_1, w_1) & \cdots & g(x_1; c_M, w_M) \\ \vdots & \ddots & \vdots \\ g(x_N; c_1, w_1) & \cdots & g(x_N; c_M, w_M) \end{bmatrix}_{N \times M} \quad (3)$$

$$\beta = (\beta_1^T, \beta_2^T, \dots, \beta_M^T)^T_{m \times M} \quad (4)$$

که Y پارامتر هدف، H رابطه ۳ محاسبه می‌شود و β ماتریس خروجی است که به صورت $N \times M$ می‌باشد به طوری که N تعداد نرون‌های لایه مخفی و M تعداد ورودی‌های مساله است. بردار وزن‌های خروجی با استفاده از روش حداقل مربعات و استفاده از ماتریس شبه

¹ Moore-Penrose generalized inverse

² Wavelet transform


تغییرات، اثر تاخیر شماره ۱۲ نیز در نظر گرفته می‌شود. بنابراین، مدل‌های تعریف شده برای این مطالعه، به شرح زیر می‌باشد:

$$M1: R(t) = f(R(t-1), R(t-2))$$

$$M2: R(t) = f(R(t-1), R(t-12))$$

$$M3: R(t) = f(R(t-2), R(t-12))$$

$$M4: R(t) = f(R(t-1), R(t-2), R(t-12))$$



شکل ۱. تابع خود همبستگی مربوط به داده های بارش ماهانه شهر بابلسر.

پس از تعیین مدل‌های مختلف، نوع موجک مادر و همچنین سطح تجزیه، تعریف شود. در این مطالعه، شش نوع موجک مادر شامل Daubechies (db), Hahr (haar), Symlets (sym), Coiflets (coif), BiorSplines (bior) و Dmeyer (dmey) می‌باشد. پس از انتخاب موجک مادر برتر، نوبت به تعیین سطح تجزیه است. به منظور تعیین سطح تجزیه بهینه برای استفاده از موجک مادر، در این مطالعه از رابطه زیر استفاده می‌شود (Nourani et al., 2014):

$$DL = \text{int}[Ln(Z)] \quad (10)$$

در این رابطه، Z تعداد نمونه های مورد استفاده در آموزش مدل، int جز صحیح مقدار بدست آمده برای سطح تجزیه (DL) است. البته باید توجه داشت که استفاده از سطح تجزیه بالا، هر چند که ممکن است دقت مدل-

که $\psi_{a,b}(t)$ نشان دهنده تبدیل موجک، b پارامتر زمانی و a پارامتر فرکانس است. تبدیلی موجک گسسته به شکل زیر، تعریف می‌شود (Mallat 1989):

$$\psi_{m,n}\left(\frac{t-b}{a}\right) = a_0^{-m/2} \psi\left(\frac{t-nb_0a_0^m}{a_0^m}\right) \quad (8)$$

که a_0 و b_0 پارامترهای موقعیت و مرتبه مقیاس (به ترتیب) هستند، n و m پارامترهای جابجایی و کشش (به ترتیب) می‌باشند. اگر سری زمانی گسسته را به عنوان $f(t)$ در نظر بگیریم، تبدیل موجک گسسته به صورت زیر بیان می‌شود:

$$W_f(m,n) = 2^{-m/2} \sum_{t=0}^{N-1} f(t) \psi(2^{-m}t - n) \quad (9)$$

در این رابطه، $W_f(m,n)$ تحت عنوان پارامترهای تبدیل موجک، در نظر گرفته می‌شود. رابطه فوق به منظور تجزیه سری زمانی مورد نظر به روند آن سری زمانی (جز تقریب^۱) و فرکانس‌های بالا (اجزاء جزئیات^۲). در این مطالعه، سری زمانی مربوط به بارندگی بابلسر با تاخیرهای موثر داده‌های سری زمانی‌های جهت پیش‌بینی مقدار بارندگی ماهانه، در نظر گرفته می‌شود.

مدل ترکیبی WELM

در این مدل ترکیبی، جهت پیش‌بینی سری زمانی بارندگی ماهانه در بابلسر، از ترکیب روش‌های ماشین آموزش نیرومند و تبدیل موجک استفاده می‌شود. روند مدل‌سازی در این روش، با تعریف پارامترهای ورودی، آغاز می‌شود. جهت تعیین موثرترین تاخیرها، از تابع خود همبستگی (ACF^۳) استفاده می‌شود. با رسم این تابع برای داده‌های بارندگی ماهانه در ایستگاه هواشناسی بابلسر (شکل ۱)، مهمترین تاخیرها به صورت تاخیرهای ۱، ۲ می‌باشند. علاوه بر این، با توجه به مشاهده روند ماهانه

¹ Approximate

² details

³ Autocorrelation function

در مطالعه حاضر به منظور ارزیابی دقت مدل‌های عددی معرفی شده از شاخص‌های آماری ضریب همبستگی (R)، شاخص عملکرد (VAF)، خطای مربعات میانگین ریشه ($RMSE$)، شاخص پراکندگی (SI) و خطای مطلق میانگین (MAE) به صورت زیر استفاده می‌گردد:

$$R = \frac{\sum_{i=1}^n (F_i - \bar{F})(O_i - \bar{O})}{\sqrt{\sum_{i=1}^n (F_i - \bar{F})^2 \sum_{i=1}^n (O_i - \bar{O})^2}} \quad (11)$$

$$VAF = \left(1 - \frac{\text{var}(F_i - O_i)}{\text{var}(F_i)}\right) \times 100 \quad (12)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (F_i - O_i)^2} \quad (13)$$

$$SI = \frac{RMSE}{\bar{O}} \quad (14)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |F_i - O_i| \quad (15)$$

در اینجا O_i مقادیر مشاهداتی، F_i مقادیر تراز پیش‌بینی شده به وسیله مدل‌های عددی، \bar{O} میانگین مقادیر مشاهداتی و n برابر تعداد مقادیر مشاهداتی است. در ادامه، ابتدا بهینه‌ترین تابع فعال‌سازی مدل ماشین آموزش نیرومند شناسایی

سازی را افزایش دهد، اما پیچیدگی قابل توجه مدل را به همراه خواهد داشت. بنابراین، نیازی نیست که همیشه بالاترین سطح تجزیه مجاز را مورد استفاده قرار دهیم و بعضاً با استفاده از سطح تجزیه‌های پایین نیز می‌توان به نتایج قابل قبولی دست یافت. شکل ۲ چگونگی تجزیه توسط تبدیل موجک برای سطوح مختلف را نشان می‌دهد. اگر هر یک از ورودی‌های مدل را به صورت In_i در نظر بگیریم، تجزیه این ورودی در سطوح مختلف، منتج به چند برابر شدن ورودی‌های مدل می‌شود. اما همان‌طور که گفته شد، در نظر گرفتن یک الی دو سطح، نه تنها مدل را پیچیده نمی‌کند، بلکه توانایی پیش‌بینی و تعمیم‌پذیری آن را نیز افزایش می‌دهد. تجزیه ورودی i -ام در سطوح تجزیه مختلف، به صورت زیر انجام می‌پذیرد:

$$DL = 1 \rightarrow In_i = A1 + D1$$


$$DL = 2 \rightarrow In_i = A2 + D1 + D2$$

$$DL = 3 \rightarrow In_i = A3 + D1 + D2 + D3$$

...

$$DL = k \rightarrow In_i = Ak + D1 + D2 + D3 + \dots + Dk$$

معیارهای بررسی دقت مدل‌های عددی



شکل ۲. چگونگی تجزیه توسط تبدیل موجک برای سطوح مختلف.


ارزیابی قرار می‌گیرند و در ادامه تابع فعال سازی برتر معرفی می‌شود. در شکل ۳ مقادیر مختلف شاخص آماری برای توابع فعال‌سازی مدل ماشین آموزش نیرومند نشان داده شده است. به‌عنوان مثال مقادیر R ، $RMSE$ و MAE برای تابع فعال سازی sigmoid به‌ترتیب برابر ۰/۵۶۸، ۶۰/۳۳۵ و ۴۲/۱۴۳ محاسبه شده است. علاوه بر این مقدار SI برای این تابع فعال‌سازی مساوی ۰/۷۹۲ تخمین زده شده است. همچنین شاخص آماری R برای توابع فعال‌سازی Sin و Hardlim به‌ترتیب مساوی ۰/۵۴۶ و ۰/۳۳۶ محاسبه گردیده است. علاوه بر این مقادیر $RMSE$ و MAE برای تابع فعال‌سازی tribas به‌ترتیب مساوی ۶۶/۶۳۷ و ۴۸/۱۷۶ تخمین زده شده است. این در حالی است که شاخص‌های آماری MAE و R برای تابع radbas به‌ترتیب برابر ۴۴/۳۲۶ و ۰/۵۲۰ بدست آمده است. بنابراین همان‌گونه که مشاهده می‌شود تابع فعال‌سازی sigmoid مقادیر بارش را با دقت بیشتری شبیه‌سازی می‌کند و این تابع فعال‌سازی برای شبیه‌سازی مقادیر بارش توسط مدل ماشین آموزش نیرومند انتخاب می‌شود. همچنین نتایج بارش شبیه‌سازی شده برای پنج تابع فعال‌سازی مذکور در شکل ۴ به تصویر کشیده شده است.


می‌گردد. سپس با استفاده از تاخیرهای مهم سری زمانی، چهار مدل مختلف ELM تعریف شده، و با تجزیه و تحلیل نتایج آنها بهترین مدل معرفی می‌شود. در ادامه، کلیه اعضای خانواده‌های موجک نیز مورد ارزیابی قرار گرفته و بهینه‌ترین عضو شناسایی خواهد شد. در انتها، مدل‌های ترکیبی مورد ارزیابی قرار می‌گیرند و بهترین سطح تجزیه برای مدل هوش مصنوعی ترکیبی برتر و موثرین تاخیرها معرفی می‌شوند لازم به ذکر است که گام زمانی در مطالعه حاضر به‌صورت ماهانه در نظر گرفته شد. تاخیرهای موثر داده‌های سری زمانی توسط تابع خود همبستگی شناسایی شدند و این تاخیرهای موثر به‌عنوان ورودی‌های مدل هوش مصنوعی در نظر گرفته شد و بارش‌های ماه بعد پیش‌بینی گردید. به‌عبارت دیگر، با استفاده از تاخیرهای مورد داده‌های سری زمانی، مقادیر بارش ماه بعدی پیش‌بینی گردید.

نتایج و بحث

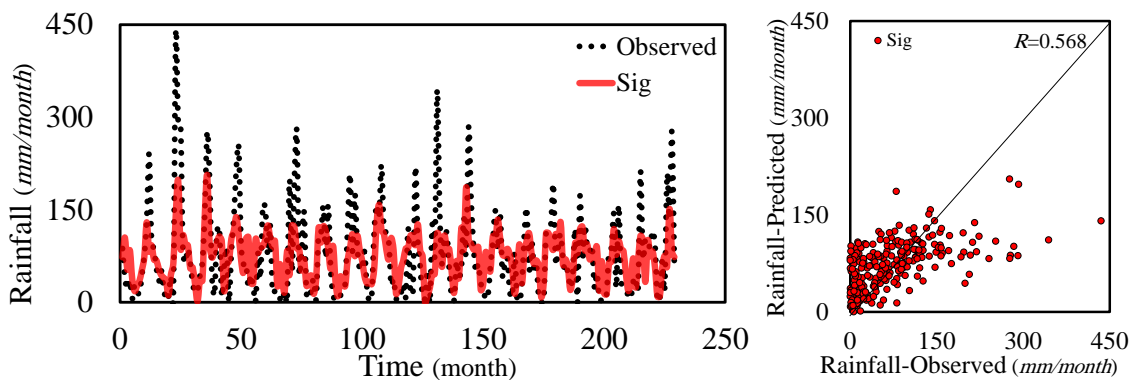
توابع فعال‌سازی

در ابتدا برای مدل ماشین آموزش نیرومند به بررسی توابع فعال‌سازی پرداخته می‌شود. همان‌گونه که بیان شد، مدل ماشین آموزش نیرومند دارای پنج تابع فعال‌سازی با عنوان- های sigmoid، sine، hardlimit، triangle basis و radial basis است. در این قسمت کلیه توابع فعال‌سازی مورد





شکل ۳. نتایج شاخص‌های آماری برای توابع فعال‌سازی مختلف.




شکل ۴. مقایسه مقادیر بارش‌های مشاهده‌ای با مقادیر پیش‌بینی شده توسط تابع فعال‌سازی sig.

موجک‌های مادر


در این بخش به بررسی خانواده‌های مختلف تبدیل موجک پرداخته می‌شود. به طور کلی، تبدیل موجک دارای خانواده‌هایی با عنوان داوپیچیز (db)، هار (haar)، سایملتس (sym)، کویفلتس (coif)، بایورثوگونال (bior) و دی میر (dmey) است. بر اساس تجزیه و تحلیل کلیه اعضای خانواده‌های مختلف تبدیل موجک مشخص شد که خانواده dmey دارای بیشترین دقت و کمترین مقدار خطا در مقایسه با سایر اعضای خانواده‌های موجک بود. در شکل ۵ نتایج شاخص‌های آماری برای اعضای برتر خانواده‌های مختلف موجک قابل مشاهده است. به عنوان مثال برای موجک مادر haar مقادیر شاخص‌های آماری R ، MAE و SI به ترتیب برابر با ۰/۷۲۳، ۳۴/۰۸۵ و ۰/۶۶۳ بودند. این در حالی است که در شرایط آزمون موجک مادر db شناسایی شد و مقادیر $RMSE$ ، MAE و SI برای آن به ترتیب مساوی با ۴۰/۹۰۵، ۲۸/۲۶۱ و ۰/۵۳۷ بدست

آمدند. علاوه بر این، برای sym در وضعیت آزمون شاخص‌های آماری VAF ، R و $RMSE$ برای آن به ترتیب برابر با ۶۸/۶۳۰، ۰/۸۲۹ و ۴۰/۹۰۵ تخمین زده شدند. برای coif در وضعیت آزمون، مقادیر شاخص عملکرد و ضریب همبستگی به ترتیب مساوی با ۷۰/۸۶۶ و ۰/۸۴۲ محاسبه شدند. بر اساس نتایج شبیه‌سازی مقدار بارندگی، در میان کلیه اعضای مختلف خانواده موجک عضو dmey به عنوان بهترین عضو این خانواده معرفی شد. برای آن شاخص‌های آماری MAE و $RMSE$ نیز به ترتیب برابر با ۲۴/۹۶۶ و ۳۲/۰۰۴ تخمین زده شدند. لازم به ذکر است که برای شرایط آزمون bior مقادیر شاخص‌های R ، SI و MAE به ترتیب برابر با ۰/۷۸۸، ۰/۵۹۰ و ۳۳/۶۲۲ بودند. بنابراین، با توجه به نتایج کلیه اعضای خانواده‌های موجک، عضو dmey به عنوان دقیق‌ترین و بهینه‌ترین عضو خانواده‌های موجک معرفی شد و در ادامه مطالعه این عضو برای شبیه‌سازی بارش دراز مدت شهر بابلسر مورد

استفاده قرار خواهد گرفت. همچنین مقایسه مقادیر بارش - های شبیه‌سازی شده توسط موجک‌های مادر مختلف با مقادیر مشاهداتی در شکل ۶ قابل مشاهده است.



شکل ۵. نتایج شاخص‌های آماری برای موجک‌های مادر مختلف.




شکل ۶. مقایسه مقادیر بارش‌های مشاهداتی با مقادیر پیش‌بینی شده توسط موجک‌های مادر مختلف.

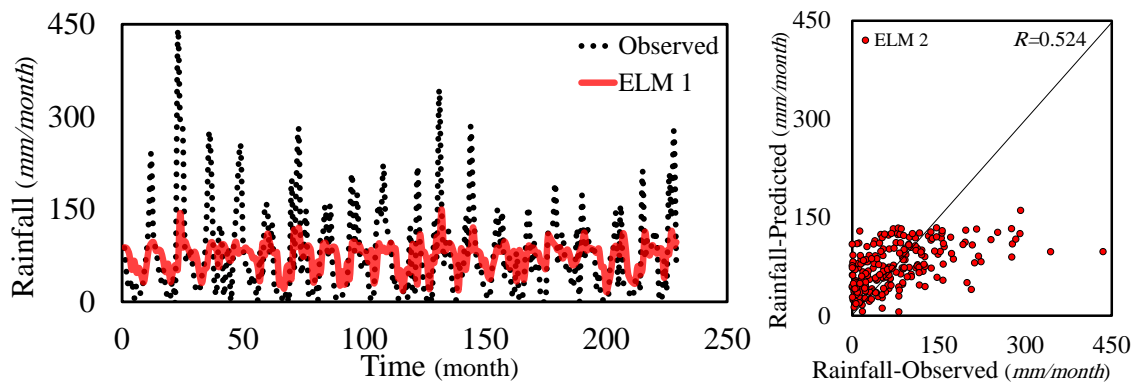
مدل‌های ماشین آموزش نیرومند

به منظور اجرای تحلیل حساسیت، چهار مدل ماشین آموزش نیرومند با ترکیبی از تاخیرهای ورودی معرفی می‌شوند. نتایج شاخص‌های آماری محاسبه شده برای مدل‌های مختلف در شکل ۷ قابل مشاهده است. به عنوان مثال مدل ELM 1 تابعی از تاخیرهای (t-1) و (t-2) است. برای این مدل مقادیر شاخص‌های آماری R ، MAE و VAF به ترتیب مساوی ۰/۳۴۹، ۴۹/۶۴۸ و ۱۲/۱۰۵ تخمین زده شده‌اند. مدل ELM 2 تابعی از تاخیرهای (t-1) و (t-12) است. برای مدل ELM 2 مقادیر MAE و $RMSE$ به ترتیب مساوی ۴۴/۹۶۵ و ۶۲/۳۹۳ محاسبه شده است. علاوه بر این مقدار شاخص‌های آماری R ، VAF و SI برای مدل مذکور به ترتیب مساوی با ۰/۵۲۴، ۲۷/۰۶۴ و ۰/۸۱۹ است. در بین کلیه مدل‌های ماشین آموزش نیرومند، مدل ELM 2 دارای بیشترین دقت و کمترین خطا است. مدل ELM 3 مقادیر

بارش بابل‌س بر حسب تاخیرهای (t-2) و (t-12) شبیه‌سازی می‌کند. به عنوان مثال مقدار ضریب همبستگی برای این مدل برابر با ۰/۵۱۸ محاسبه شد. همچنین برای مدل مذکور مقادیر MAE و $RMSE$ به ترتیب مساوی ۴۵/۳۸۶ و ۶۲/۷۴۰ بدست آمد. در ادامه به بررسی مدل ELM 4 پرداخته می‌شود. این مدل مقادیر تابع هدف را بر حسب تاخیرهای شماره (t-1)، (t-2) و (t-12) شبیه‌سازی می‌کند. این مدل شاخص‌های آماری شامل ضریب همبستگی و شاخص پراکندگی را به ترتیب برابر ۰/۵۶۸ و ۰/۷۹۲ تخمین زده است. علاوه بر این مقادیر MAE و $RMSE$ برای این مدل به ترتیب مساوی ۶۰/۳۳۵ و ۴۲/۱۴۳ می‌باشند. بنابراین مدل ELM 2 به عنوان بهترین مدل ماشین آموزش نیرومند معرفی می‌شود. در شکل ۸ مقایسه مقادیر بارش‌های مشاهداتی با مقادیر شبیه‌سازی شده توسط مدل‌های مختلف ELM قابل مشاهده است.



شکل ۷. نتایج شاخص‌های آماری برای مدل‌های مختلف ELM.



شکل ۸. مقایسه مقادیر بارش‌های مشاهداتی با مقادیر پیش‌بینی شده توسط مدل‌های مختلف ELM.

مدل ترکیبی

در این قسمت مدل برتر ماشین آموزش نیرومند (ELM 2) با مادر موجک برتر (dmey) در سه سطح تجزیه مختلف با هم ترکیب می‌شوند که با ارزیابی این مدل ترکیبی در این سه سطح تجزیه، بهترین مدل معرفی می‌شود. شکل ۹ نتایج شاخص‌های آماری برای سطوح تجزیه مختلف برای مدل ترکیبی برتر را نشان می‌دهد. به‌عنوان مثال، برای سطح تجزیه اول (DL 1) مدل ترکیبی WELM، مقادیر R و VAF به ترتیب مساوی با ۰/۸۹۹ و ۸۰/۷۹۷ محاسبه می‌شوند. همچنین، مقادیر شاخص‌های آماری RMSE و MAE برای این سطح تجزیه به ترتیب مساوی با ۳۲/۰۰۴ و ۲۴/۹۶۶ هستند. برای سطح تجزیه DL 2، مقادیر VAF، SI و MAE به ترتیب مساوی با ۸۲/۸۴۰، ۰/۳۹۸ و ۲۲/۷۳۰ محاسبه شدند. علاوه بر این، مقادیر RMSE و R برای سطح تجزیه شماره سه (DL 3) به ترتیب برابر با ۲۶/۸۷۲، ۰/۹۳۰ و ۸۶/۴۶۱ تخمین زده شدند. بنابراین با توجه به نتایج مدل‌سازی‌ها، مدل ترکیبی با سطح تجزیه DL 3 دارای بهترین عملکرد است. شکل ۱۰ نیز مقایسه مقادیر بارش‌های مشاهداتی با مقادیر شبیه‌سازی شده توسط سطح تجزیه برتر مدل ترکیبی را نشان می‌دهد.

با توجه به تحلیل حساسیت اجرا شده برای پیش‌بینی بارندگی دراز مدت شهر بابلسر توسط مدل ترکیبی موجک - ماشین آموزش نیرومند (WELM)، مدل ELM

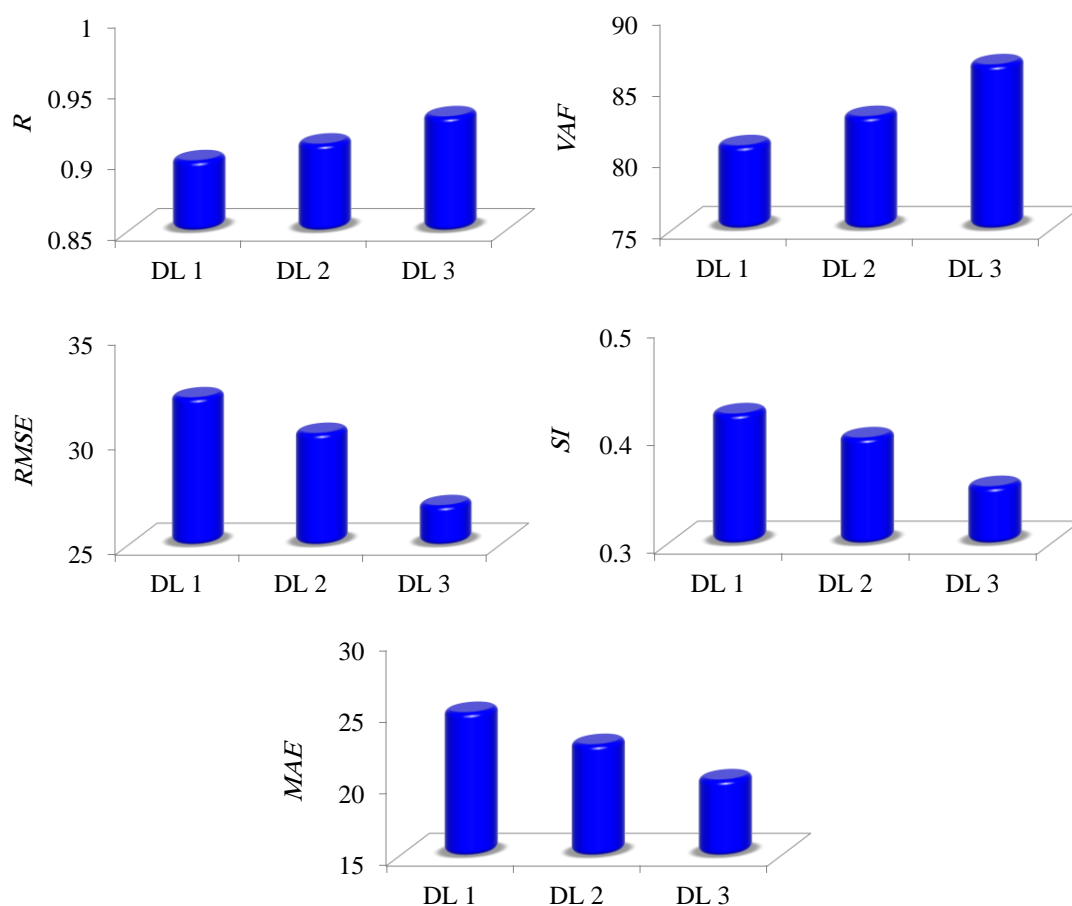
2 به‌عنوان مدل برتر معرفی گردید که با ترکیب با موجک مادر dmey دقت آن به شکل قابل توجهی افزایش یافت. مدل ترکیبی مقادیر تابع هدف را با دقت مناسبی شبیه‌سازی نمود. علاوه بر این، تاخیرهای شماره (t-1) و (t-12) به‌عنوان موثرترین تاخیرهای داده‌های سری زمانی شناسایی شدند.

نتیجه گیری


در این تحقیق، بارندگی دراز مدت داده‌های سری زمانی ایستگاه بابلسر با استفاده از یک مدل بهینه‌یافته هوش مصنوعی ترکیبی پیش‌بینی شد. برای توسعه مدل هوش مصنوعی ترکیبی ماشین آموزش نیرومند (ELM) و تبدیل موجک (WT) با هم ترکیب شدند. در ادامه توسط تابع خود همبستگی (ACF) تاخیرهای موثر داده‌های سری زمانی معرفی شدند. لازم به ذکر است که چهار مدل ELM با استفاده از این تاخیرها تعریف شدند. علاوه بر این، پنج تابع فعال‌سازی مدل ماشین آموزش نیرومند مورد بررسی قرار گرفتند که تابع sig به‌عنوان بهترین آنها انتخاب شدند. سپس با ارزیابی موجک‌های مادر مختلف بهینه‌ترین آنها برای شبیه‌سازی مقادیر تابع هدف (بارندگی) معرفی گردید. به عبارت دیگر، dmey به‌عنوان بهینه‌ترین بهینه‌ترین موجک مادر برای تخمین بارش انتخاب شد. سپس با تجزیه و تحلیل نتایج کلیه مدل‌های هوش مصنوعی، مدل برتر برای تخمین بارندگی شهر

مدل‌سازی تابع هدف توسط مدل ماشین آموزش نیرومند را به شکل محسوسی بهبود داد. علاوه بر این، تحلیل حساسیت اجرا شده نشان داد که تاخیرهای (t-1) و (t-12) موثرترین تاخیرهای داده‌های سری زمانی بارندگی شهر بابل‌سرد هستند.

بابل‌سرد معرفی شد. این مدل برای سه سطح تجزیه مختلف مورد ارزیابی قرار گرفت که نشان داده شد این مدل مقادیر بارش ماهانه را با دقت بسیار خوبی شبیه‌سازی کرد. به عنوان مثال، مقادیر R، MAE و VAF برای تخمین بارش به ترتیب مساوی با ۰/۹۳۰، ۲۰/۲۷۰ و ۸۶/۴۶۱ محاسبه شدند. شایان ذکر است که تبدیل موجک دقت



شکل ۹. نتایج شاخص‌های آماری برای سطوح تجزیه مختلف برای مدل ترکیبی برتر.



شکل ۱۰. مقایسه مقادیر بارش‌های مشاهده‌ای با مقادیر شبیه‌سازی شده توسط سطح تجزیه برتر مدل ترکیبی.

منابع مورد استفاده

- باباعلی، ح. و دهقانی، ر. ۱۳۹۶. مقایسه مدل‌های هوشمند در تخمین بارش ماهانه حوضه کاکارضا. اکولوژی، ۴(۱): ۱-۱۱.
- دهقانی، ن.، وفاخواه، م. و بهره مند، ع. ۱۳۹۵. مدل‌سازی بارش- رواناب با استفاده از شبکه عصبی مصنوعی و شبکه فازی- عصبی تطبیقی در حوزه آبخیز کسلیان. پژوهشنامه مدیریت حوزه آبخیز، ۷(۱۳): ۱۳۷-۱۲۸.
- Chang, T. K., Talei, A., Quek, C. and Pauwels, V. R. 2018. Rainfall-runoff modelling using a self-reliant fuzzy inference network with flexible structure. *Journal of hydrology*, 564: 1179-1193.
- Dabral, P. P. and Murry, M. Z. 2017. Modelling and forecasting of rainfall time series using SARIMA. *Environmental Processes*, 4(2): 399-419.
- Hardwinarto, S. and Aipassa, M. 2015. Rainfall monthly prediction based on artificial neural network: A case study in Tenggara Station, East Kalimantan-Indonesia. *Procedia Computer Science*, 59: 142-151.
- Huang, G.-B., Zhu, Q.-Y. and Siew, C.-K. 2006. Extreme learning machine: theory and applications. *Neurocomputing* 70: 489-501.
- Mallat, S. 1989. Multiresolution approximations and wavelet orthonormal bases of $L_2(\mathbb{R})$. *Trans. Am. Math. Soc.* 315 (1): 69-87.
- Mehr, A. D., Nourani, V., Khosrowshahi, V. K. and Ghorbani, M. A. 2019. A hybrid support vector regression-firefly model for monthly rainfall forecasting. *International Journal of Environmental Science and Technology*, 16(1): 335-346.
- Nagahamulla, H. R., Ratnayake, U. R. and Ratnaweera, A. 2012. An ensemble of artificial neural networks in rainfall forecasting. In *International Conference on Advances in ICT for Emerging Regions (ICTer2012)* (pp. 176-181). IEEE.
- Nasseri, M., Asghari, K. and Abedini, M. J. 2008. Optimized scenario for rainfall forecasting using genetic algorithm coupled with artificial neural network. *Expert systems with applications*, 35(3): 1415-1421.
- Nourani, V., Hosseini Baghanam, A., Adamowski, J. and Kisi, O. 2014. Applications of hybrid wavelet-Artificial Intelligence models in hydrology: A review. *Journal of Hydrology* 514: 358-377.
- Nourani, V., Kaynejad, M.A. and Malekani, L. 2009. Application of neuro- fuzzy inference system in rainfall-runoff modeling. *Journal of Civil of Engineering & Environment*, 39(4): 75-81.
- Savic, D. A., Walters, G. A. and Davidson, J. W. 1999. A genetic programming approach to rainfall-runoff modelling. *Water Resources Management*, 13(3), 219-231.
- Wong, K. W., Wong, P. M., Gedeon, T. D. and Fung, C. C. 2003. Rainfall prediction model using soft computing technique. *Soft Computing*, 7(6): 434-438.



Prediction of Rainfall in Babolsar Station by Using Optimized Wavelet-Extreme Learning Machine

Hamed karimi¹, Mohammad Ali Izadbakhsh^{2*}, Behrouz Yaghoubi² and Saeid Shabanlou²

1) Ph.D. Candidate, Department of Water Engineering, Kermanshah Branch, Islamic Azad University, Kermanshah, Iran

2*) Department of Water Engineering, Kermanshah Branch, Islamic Azad University, Kermanshah, Iran

*Corresponding author: behrouz.yaghoubi.h@gmail.com

Received: 29-04-2020

Accepted: 03-07-2021

Abstract

Simulation of rainfall is considered as one of the most important issues of hydrologic field. Additionally, the artificial intelligence (AI) models own numerous privileges including acceptable accuracy, appropriate flexibility, and high speed. In this study, the long-term rainfall in Babolsar Station was simulated by means of an optimized AI model. To do this, the extreme learning machine (ELM) and the wavelet transform (WT) were combined. It should be stated that the monthly rainfall values from 1951 to 2019 were applied, meaning that 70% of the observed values were employed to training the AI models and 30% of rest were utilized to testing these models. Firstly, the activation functions of the ELM models were evaluated; as a result, the sigmoid was chosen as the best activation function. Moreover, the lags of time series were introduced using the autocorrelation function (ACF) that four ELM models were defined through those identified lags. By performing a sensitivity analysis, the superior ELM model was introduced. The values of correlation coefficient (R), variance accounted for (VAF), and scatter index (SI) for the ELM model were respectively computed to be 0.524, 27.064, and 0.819. Furthermore, different mother wavelets were examined and the “dmey” was opted as the best mother wavelet. The wavelet transform enhanced the accuracy of the simulations significantly. For instance, the VAF index for the hybrid WELM model equaled to 86.461. It is noteworthy that the hybrid model was evaluated for different decomposition levels (DL) and then the best one was detected. Also, the (t-1) and (t-12) lags were identified as the most effective input lags.

Keywords: Rainfall, Babolsar, Simulation, Extreme learning machine, Wavelet transform.