



## "مقاله پژوهشی"

## شبیه‌سازی بارش - رواناب با استفاده از ماشین آموزش نوین در حوضه رودخانه شهرچای

امیر علیزاده<sup>۱</sup>، احمد رجبی<sup>۲</sup>، سعید شعبانلو<sup>۳</sup>، بهروز یعقوبی<sup>۲</sup> و فریبرز یوسفوند<sup>۲</sup>

۱- دانشجوی دکتری، گروه مهندسی آب، واحد کرمانشاه، دانشگاه آزاد اسلامی، کرمانشاه، ایران  
 ۲- استادیار، گروه مهندسی آب، واحد کرمانشاه، دانشگاه آزاد اسلامی، کرمانشاه، ایران (نویسنده مسؤل: ahmad.rajabi1974@gmail.com)  
 ۳- دانشیار، گروه مهندسی آب، واحد کرمانشاه، دانشگاه آزاد اسلامی، کرمانشاه، ایران  
 تاریخ دریافت: ۱۳۹۹/۰۱/۲۹ تاریخ پذیرش: ۱۳۹۹/۰۴/۲۲  
 صفحه: ۲۲۴ تا ۲۲۷

## چکیده

در این مطالعه، داده‌های سری زمانی بارش و رواناب حوضه رودخانه شهرچای از سال ۲۰۰۰ تا ۲۰۱۷ با استفاده از یک مدل هوش مصنوعی نوین ترکیبی شبیه‌سازی شد. برای توسعه مدل هوش مصنوعی مذکور سه الگوریتم ماشین آموزش نیرومند (ELM)، تکامل تفاضلی (DE) و تبدیل موجک (WT) با هم ترکیب شدند و مدل‌های ترکیبی SAELM و WSAELM ارائه شد. در ابتدا، موثرترین تأخیرهای داده‌های سری زمانی با استفاده از تابع خود همبستگی شناسایی شدند. سپس با استفاده از این تأخیرها، برای هر یک از مدل‌های SAELM و WSAELM هفت مدل هوش مصنوعی تعریف گردید. علاوه بر این ۷۰ درصد مقادیر مشاهداتی برای آموزش مدل‌های هوش مصنوعی و ۳۰ درصد باقیمانده نیز برای ارزیابی آن‌ها استفاده شدند. برای مدل WSAELM 7 به‌عنوان مدل برتر، مقادیر  $R^2$ ، شاخص پراکندگی (SI) و ضریب نش (NSC) برای شبیه‌سازی بارش به ترتیب مساوی با ۰/۹۶۷، ۰/۲۰۸ و ۰/۹۶۵ بدست آمدند. همچنین تحلیل حساسیت نشان داد که تأخیرهای (t-1)، (t-2) و (t-12) به‌عنوان موثرترین تأخیرهای ورودی در نظر گرفته شدند. در انتها برای مدل‌های برتر یک تحلیل عدم قطعیت انجام شد.

واژه‌های کلیدی: بارش، تبدیل موجک، تکامل تفاضلی، رواناب، رودخانه شهرچای، دریاچه ارومیه، ماشین آموزش نیرومند

## مقدمه

بارش و رواناب جزء مهمترین پارامترهای اقلیمی هستند که نقش به‌سزایی در شناسایی تغییرات اقلیمی در مقیاس منطقه‌ای و جهانی ایفا می‌کنند. از طرف دیگر، بارش مهمترین منبع تامین آب برای مصارف مختلف روی کره زمین محسوب می‌شود. اهمیت تغییرات دراز مدت پارامترهای بارش و رواناب در نواحی خشک و نیمه‌خشک از جمله فلات قاره ایران از اهمیت به‌سزایی برخوردار است. در مقابل رواناب نیز به‌صورت مستقیم تابع پارامتر بارش و ضریب نفوذپذیری خاک منطقه است که به‌طور کلی به‌دلیل اهمیت قابل توجه این پارامترهای اقلیمی، مطالعات میدانی و عددی فراوانی روی آنها صورت گرفته است. به‌عنوان مثال، حسنپور کاشانی و همکاران (۹)، پورنعمت رودسری (۲۰)، زرعی و همکاران (۲۷)، معماریان و همکاران (۱۷)، لی و همکاران (۱۳)، ونگ و همکاران (۲۴)، توس و همکاران (۲۳)، ناصری و همکاران (۱۸)، کومار و جها (۱۲) مقادیر بارش-رواناب در بازه‌های زمانی مشخص در نقاط مختلف ایران را با استفاده از تکنیک‌های متفاوت هوش مصنوعی و محاسبات نرم مدل‌سازی نمودند.

در ادامه، اکرمی و همکاران (۱) توسط مدل ANFIS، شبکه عصبی مصنوعی و تبدیل موجک، مدل‌های مختلف عددی ترکیبی جهت شبیه‌سازی بارندگی در حوزه رودخانه کلانگ در کشور مالزی ارائه کردند. در این مطالعه نشان داده شد که نتایج مدل‌های موجک-ANFIS و موجک-شبکه عصبی مصنوعی مقادیر بارش را با دقت بهتری پیش‌بینی کردند. همچنین، میسلان و همکاران (۱۶) به‌وسیله مدل شبکه عصبی مصنوعی پسخور مقدار بارندگی ماهانه در شرق

کشور اندونزی را پیش‌بینی کردند. آن‌ها برای کنترل مقدار خطای مدل عددی خود از خطای مربع میانگین بهره گرفتند. شفیع و همکاران (۲۲) داده‌های بارندگی سری زمانی ۴۰ ساله شهرستان نهاوند را توسط یک مدل ترکیبی تخمین زدند. آنها برای توسعه مدل عددی خود مدل‌های شبکه عصبی مصنوعی، ساریما و تبدیل موجک را با هم ترکیب نمودند. آنها نشان دادند مدلی که از ترکیب این سه الگوریتم ساخته شد مقادیر تابع هدف را با دقت بیشتری شبیه‌سازی نمود. مکانیک و همکاران (۱۵) بارش‌های فصلی در کشور استرالیا را توسط مدل انفیس پیش‌بینی نمودند. آنها نتایج مدل انفیس را نیز با مدل شبکه عصبی مصنوعی مقایسه کردند و نشان دادند که مدل انفیس عملکرد بهتری برای شبیه‌سازی این پارامتر هیدرولوژیکی دارد. سپس پورنومو و همکاران (۲۱) جهت شبیه‌سازی مقدار بارندگی در بازه زمانی از سال ۲۰۰۱ تا ۲۰۱۳ در مرکز جاوه کشور اندونزی را به‌صورت ماهانه توسط دو مدل شبکه عصبی مصنوعی مختلف تخمین زدند. آنها نشان دادند که مدل‌های عصبی مقادیر بارندگی را با دقت قابل قبولی تخمین زدند.

دابرال و موری (۶) داده‌های سری زمانی بارش در یک بازه ۱۴ ساله حوضه واقع در شرق کشور هندوستان را توسط مدل ساریما در بازه‌های زمانی روزانه، هفتگی و ماهانه تخمین زدند. آنها تأخیرهای موثر را نیز شناسایی نمودند و نشان دادند که مدل مذکور مقادیر بارش‌ها را با دقت خوبی شبیه‌سازی کرد. علاوه بر این، یاسین و همکاران (۲۶) با استفاده از الگوریتم کرم شب-تاب، مدل ANFIS را برای تخمین بارندگی در یکی از حوزه‌های کشور مالزی بهینه‌سازی نمودند. آنها نشان دادند که مدل ترکیبی مقادیر بارندگی را در مقایسه

ترکیبی ANFIS- بهینه‌سازی کلونی مورچه در مقایسه با سایر مدل‌ها از دقت بیشتری برخوردار بود. همچنین، مهر و همکاران (۱۴) یک مدل ترکیبی بهینه‌یافته را برای تخمین مقادیر بارش دراز مدت شهر تبریز و ارومیه توسعه دادند. آنها برای بهینه‌سازی مدل هوش مصنوعی رگرسیون بردار پشتیبان از الگوریتم کرم شب‌تاب بهره گرفتند.

مدل‌سازی پدیده‌های بارش و رواناب در بازه‌های زمانی بلندمدت قادر خواهد بود که دید جامع‌تری به محققین و مهندسیین هیدرولوژی و محیط زیست جهت بررسی الگوی‌های بارشی ارائه دهد. در مقابل، مدل‌سازی این پدیده‌ها توسط الگوریتم‌های مختلف هوش مصنوعی روزبه روز در حال گسترش است زیرا این مدل‌ها بسیار منعطف بوده و توانایی شبیه‌سازی پدیده‌های پیچیده و غیرخطی را دارند. علاوه بر این، مدل‌های هوش مصنوعی دارای دقت مناسبی هستند و استفاده از آنها باعث صرفه‌جویی در زمان و هزینه‌های مربوط به مطالعات میدانی خواهد شد. بنابراین در این مطالعه، برای اولین بار، مقادیر بارندگی و رواناب حوضه رودخانه شهرچای در یک بازه زمانی ۱۸ ساله از سال ۲۰۰۰ تا ۲۰۱۷ توسط یک مدل هوش مصنوعی ترکیبی بهینه‌سازی شده، شبیه‌سازی خواهد شد. برای تولید مدل هوش مصنوعی ترکیبی که اختصاراً با WSAELM نشان داده می‌شود، از مدل ماشین آموزش نیرومند (ELM)، تکامل تفاضلی (DE) و تبدیل موجک استفاده می‌گردد. سپس با استفاده از تابع خود همبستگی تاخیرهای موثر مربوط به داده‌های سری زمانی شناسایی خواهند شد. در ادامه، هفت مدل SAELM و WSAELM توسط این تاخیرها تعریف می‌گردند. با تجزیه و تحلیل نتایج مدل‌سازی‌ها، مدل‌های برتر SAELM و WSAELM به‌همراه موثرترین تاخیرهای ورودی معرفی خواهند شد. باید توجه شود که تبدیل موجک دقت مدل SAELM را به شکل قابل ملاحظه‌ای افزایش خواهد داد.

#### ناحیه مورد مطالعه

حوضه شهرچای ارومیه یکی از زیرحوضه‌های مهم دریاچه ارومیه بوده که در شمال غرب ایران و در مرز بین ایران و ترکیه قرار گرفته است. موقعیت این حوضه در حدود ۳۷ درجه و ۱۹ دقیقه تا ۳۷ درجه و ۳۷ دقیقه عرض شمالی و ۴۴ درجه و ۳۵ دقیقه تا ۴۵ درجه و ۱۵ دقیقه طول شرقی می‌باشد و ارتفاع آن از ۱۵۱۳ متر در خروجی حوضه در محل دریاچه ارومیه (حدافل) تا ۳۵۹۵ متر در مرز ایران و ترکیه (حداکثر) تغییر می‌کند. مساحت کل حوضه رودخانه شهرچای حدود ۷۱۲ کیلومتر مربع و مساحت حوضه در بالادست ایستگاه هیدرومتری بند ارومیه در حدود ۴۱۸ کیلومتر مربع می‌باشد. ناحیه مورد مطالعه رودخانه شهرچای در غرب دریاچه ارومیه در شکل ۱ به‌تصویر کشیده شده است.

با مدل ANFIS با دقت بهتری تخمین زد. دانلادی و همکاران (۷) توسط مدل ANFIS تغییرات بارش در یک دوره زمانی کوتاه مدت را تخمین زدند. آنها مقادیر بارش را تابعی از دما و رطوبت نسبی فرض کردند و با استفاده از این دو پارامتر مقادیر بارش را مدل‌سازی نمودند. ژیانگ و همکاران (۲۵) توسط روش "تجزیه تجربی گروهی" و الگوریتم‌های هوش مصنوعی از قبیل شبکه عصبی مصنوعی و رگرسیون بردار پشتیبان مقادیر بارش در یکی از استان‌های کشور چین را در بازه‌های زمانی کوتاه و بلند مدت تخمین زدند. نشان داده شد که شبکه عصبی مصنوعی مقادیر بارش در بازه زمانی دراز مدت با دقت بهتری شبیه‌سازی کرد. آزاد و همکاران (۲) عملکرد شبکه ANFIS را برای تخمین بارش شهر اصفهان به‌وسیله چند روش بهینه‌سازی از قبیل الگوریتم ژنتیک، بهینه‌سازی ازدحام ذرات و بهینه‌سازی کلونی مورچه بهبود بخشیدند. آنها بیان کردند که مدل ترکیبی ANFIS- بهینه‌سازی کلونی مورچه در مقایسه با سایر مدل‌ها از دقت بیشتری برخوردار بود.

چانگ و همکاران (۵) با استفاده از یک مدل نرو- فازی تحت عنوان شبکه استنتاج فازی وابسته به خود مقدار بارش- رواناب را برای حوزه مختلف در کشورهای چین، سوئد و استرالیا مدل‌سازی نمودند. آنها نشان دادند که مدل نرو- فازی مذکور از انعطاف مناسبی برای شبیه‌سازی بارندگی برخوردار است. علاوه بر این، خلیلی و همکاران (۱۱) مقدار بارش شهر مشهد را در یک بازه زمانی ۵۳ ساله با استفاده از شبکه عصبی مصنوعی شبیه‌سازی کردند. آنها بیان کردند که مدل هوش مصنوعی مذکور مقدار بارش ماهانه را با دقت قابل قبولی شبیه‌سازی کرده است، به‌عنوان مثال، مقدار ضریب همبستگی مدل برتر آنها مساوی با ۰/۹۲ محاسبه شد. در ادامه، قربانی و همکاران (۸) با ترکیب تبدیل موجک با شبکه عصبی مصنوعی و ماشین بردار پشتیبان، دو مدل ترکیبی هوش مصنوعی توسعه دادند. آنها با تجزیه و تحلیل نتایج مدل‌سازی بارش- رواناب حوضه آبریز بالیخ‌لوچای در جنوب غربی شهرستان اردبیل نشان دادند که مدل‌های ترکیبی از دقت بیشتری برخوردار بودند. باباعلی و دهقانی (۳) مقادیر بارش ماهانه در یک بازه زمانی ۱۰ ساله برای حوضه آبریز دشت کاکارضا استان لرستان را با استفاده از مدل برنامه‌نویسی بیان ژن تخمین زدند. آنها نشان دادند که ضریب همبستگی مدل عددی مذکور برابر با ۰/۹۷۸ بود بنابراین این مدل توانایی خوبی در شبیه‌سازی مقدار بارندگی داشت. در ادامه، آزاد و همکاران (۲) عملکرد شبکه ANFIS را برای تخمین بارش شهر اصفهان به‌وسیله چند روش بهینه‌سازی از قبیل الگوریتم ژنتیک، بهینه‌سازی ازدحام ذرات و بهینه‌سازی کلونی مورچه بهبود بخشیدند. آنها بیان کردند که مدل



شکل ۱- ناحیه مورد مطالعه حوضه رودخانه شهرچای ارومیه  
Figure 1. Geographical location of Shaharchay watershed

سوگیری نرون لایه مخفی  $\lambda_m$ ، ورودی نرون ورودی  $X_{ik}$  برای  $k$  امین نمونه آموزشی و  $H_{ik}$  ماتریس فعال‌سازی زامین نرون لایه مخفی برای  $k$  امین نمونه آموزشی است به طوری که فعال‌سازی همه نرون‌های لایه مخفی برای نمونه‌های مورد استفاده در آموزش توسط این ماتریس ارائه می‌شود. در این ماتریس  $Z$  ستون و  $k$  ردیف است. ماتریس  $H$  به عنوان ماتریس لایه مخفی خروجی شبکه عصبی بیان می‌شود. وزن‌های بین نرون‌های لایه مخفی و خروجی به صورت ریاضی به شکل زیر بیان کرد:

$$H\beta = T \quad (4)$$

$$\beta = (\beta_1, \dots, \beta_j)_{j \times 1} \quad (5)$$

که  $\beta$  نشان‌دهنده وزن بین نرون لایه خروجی و نرون‌های لایه مخفی است و  $T$  بردار نشان‌دهنده مقادیر هدف برای نمونه‌های آموزش است که به صورت زیر بیان می‌شود:

$$T = (T_1, \dots, T_k)_{k \times 1} \quad (6)$$

نهایتاً وزن‌ها را می‌توان از رابطه زیر محاسبه کرد:

$$\beta = HT \quad (7)$$

که در آن:

$$H(\tilde{a}, \tilde{b}, \tilde{x}) = \begin{bmatrix} G(a_1, b_1, x_1) & \dots & G(a_L, b_L, x_L) \\ G(a_1, b_1, x_N) & \dots & G(a_L, b_L, x_N) \end{bmatrix} \quad (8)$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_L^T \end{bmatrix} \quad \text{and} \quad T = \begin{bmatrix} T_1^T \\ \vdots \\ T_L^T \end{bmatrix} \quad (9)$$

که  $\tilde{a} = a_1, \dots, a_L; \tilde{b} = b_1, \dots, b_L; \tilde{x} = x_1, \dots, x_L$  بردار وزن بین نرون‌های لایه‌های مخفی و لایه پنهان و  $H'$  شبه معکوس Moore-Penrose ماتریس  $H$  است. همچنین  $T$  بردار بین وزن‌های نمونه‌های آموزشی است. با

## مدل عددی

### ماشین آموزش نیرومند<sup>۱</sup>

ماشین آموزش نیرومند (ELM) که شبکه عصبی مصنوعی پیشخور تک لایه است که اولین بار توسط هوانگ و همکاران (۱۰) ارائه شد. تنها تفاوت ELM با شبکه عصبی پیشخور تک لایه<sup>۳</sup> (SLFFNN)، عدم استفاده از سوگیری برای نرون خروجی است. نرون‌های لایه ورودی با همه نرون‌های لایه مخفی در ارتباط است. نرون‌های لایه مخفی با استفاده از یک سوگیری بوجود می‌آیند. تابع فعال‌سازی نرون‌های مخفی می‌تواند به صورت تابع پیوسته تکه‌ای<sup>۵</sup> باشد در حالی که برای نرون لایه خروجی به صورت خطی است. توصیف ریاضی شبکه عصبی پیشخور تک لایه با تعداد  $n$  گره مخفی، به صورت زیر بیان می‌شود:

$$f_n(x) = \sum_{i=1}^n \beta_i G(a_i, b_i, x) \quad (1)$$

که  $\beta_i$  وزن بین گره مخفی  $\lambda_m$  و گره خروجی،  $a_i \in R^n$  و  $b_i$  فاکتورهای آموزش گره‌های مخفی و  $G(a_i, b_i, x)$  گره  $i$  ام برای ورودی  $x$  است. تابع فعال‌سازی  $g(x)$  (که دارای انواع مختلفی می‌باشند) برای گره مخفی افزایشده<sup>۶</sup>  $(a_i, b_i, x)$  را می‌توان به شکل زیر بازنویسی کرد:

$$G(a_i, b_i, x) = g(a_i \cdot x + b_i) \quad (2)$$

از توابع فعالیت به منظور محاسبه خروجی پاسخ نرون‌ها استفاده می‌شود. فعال‌سازی نرون‌های لایه مخفی برای هر نمونه آموزشی در یک شبکه ELM با تعداد "ج" نرون در لایه مخفی، "i" نرون ورودی و تعداد "k" نمونه آموزشی، از رابطه زیر محاسبه می‌شود:

$$H_{jk} = g\left(\sum W_{ji} X_{ik}\right) + B_j \quad (3)$$

که  $g(\cdot)$  می‌تواند هر تابع فعال‌سازی غیر خطی پیوسته باشد،  $W_{ji}$  وزن نرون ورودی  $\lambda_m$  و نرون لایه مخفی  $\lambda_m$ ،  $B_j$

1- Extreme Learning Machine (ELM)

2- Feed-forward

3- Single layer feed forward neural network

4- Bias

5- Piecewise continuous function

6- Additive

فعال‌سازی  $g(x)$ ، می‌توان الگوریتم SAELM را فرمول نویسی کرد. بدین‌منظور، ابتدا جمعیت اولیه با استفاده از بردارهای جمعیت (NP) که گره‌های مخفی را در بر می‌گیرند. **موجک**

موجک یا ویولت تبدیلی است که جهت بهینه‌سازی مدل‌های هوش مصنوعی مورد استفاده قرار می‌گیرد. این روش یک آنالیز طیفی مستقل از زمان است که به‌منظور توصیف مقیاس زمانی فرایندها و روابط آنها، سری‌های زمانی را در فضای زمان-فرکانس از هم جدا می‌کند. تبدیل ویولت همانند تبدیل فوریه، سری زمانی را به‌صورت ترکیب خطی از چند تابع اصلی (base)، در نظر می‌گیرد. یکی از مشخصات اصلی تبدیل ویولت این است که این تبدیل توانایی به‌دست آوردن اطلاعات در زمان، تناوب و موقعیت را به‌طور همزمان، داراست. تبدیل ویولت پیوسته توانایی عملکرد در هر مقیاس را دارد هرچند که محاسبه ضرایب ویولت در هر مقیاس بسیار مشکل است و نیازمند زمان محاسباتی بالا و تولید مقدار زیادی داده، می‌باشد. در انفعال تبدیل ویولت تنها یک زیر مجموعه از مقیاس‌ها و موقعیت‌ها به‌منظور انجام محاسبات، انتخاب می‌شود. به‌منظور مدل‌سازی ELM و SAELM با تبدیل موجک، ابتدا داده‌ها باید به دسته‌های مختلف تقسیم شوند. در ابتدا نیاز هست که ورودی مدل شناسایی شود. بدین‌منظور در این مطالعه از تابع خود همبستگی (ACF) استفاده می‌شود. در مطالعه حاضر، با استفاده از تبدیل موجک، سری زمانی اصلی به چندین سری زمانی مختلف که دارای مقیاس‌های مختلفی هستند، تجزیه می‌شود به‌طوری که مجموع سری‌های تجزیه شده با سری اصلی برابر است. هر یک از اجزاء تجزیه شده به‌عنوان ورودی مدل SAELM در نظر گرفته می‌شوند.

با توجه به تاخیرهای موثر داده‌های سری زمانی ارائه شده در شکل ۲، هفت مدل مختلف به‌صورت زیر ارائه می‌گردد:

$$\begin{aligned} M1: R(t) &= f(R(t-1)) \\ M2: R(t) &= f(R(t-2)) \\ M3: R(t) &= f(R(t-12)) \\ M4: R(t) &= f(R(t-1), R(t-2)) \\ M5: R(t) &= f(R(t-1), R(t-12)) \\ M6: R(t) &= f(R(t-2), R(t-12)) \\ M7: R(t) &= f(R(t-1), R(t-2), R(t-12)) \quad (10) \end{aligned}$$

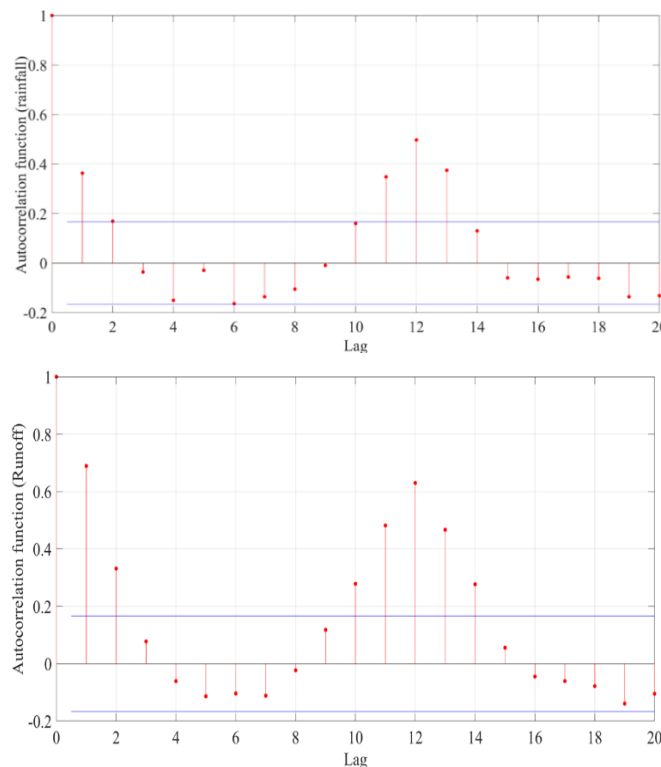
توجه به توضیحات ارائه شده می‌توان گفت که آموزش ELM شامل دو مرحله است: مرحله اول، اختصاص تصادفی وزن‌ها و سوگیری‌ها به نرون‌های لایه پنهان و محاسبه خروجی لایه پنهان ماتریس H و مرحله دوم، محاسبه وزن‌های خروجی با استفاده از شبه معکوس Moore-Penrose ماتریس H و مقادیر هدف برای نمونه‌های آموزشی مختلف. روند آموزش جهت پیدا کردن شبه معکوس Moore-Penrose ماتریس لایه پنهان (H)، سریع است بطوریکه از سرعت بالاتری نسبت به الگوریتم‌های مبتنی بر تکرار رایج مانند لونیگ-مارکوآردت<sup>۱</sup> که در آن هیچ نوع روالی از بهینه‌سازی غیر خطی را در بر نمی‌گیرد، برخوردار است. بنابراین زمان آموزش شبکه به‌طور قابل توجهی کاهش می‌یابد هوانگ و همکاران (۱۰). مدل ELM با استفاده از تعداد زیادی از پیش‌بینی فضای ورودی تصادفی غیرخطی کار می‌کند به‌طوری‌که هر نرون با یک نمونه تصادفی منفرد در ارتباط است.

### تکامل تفاضلی

روش بهینه‌سازی تکامل تفاضلی (DE) یکی از تکنیک‌های نسبتاً جدید در زمینه بهینه‌سازی فراکوشی است که توسط استورن و پرایس ارائه شده است. در سال‌های اخیر الگوریتم تکامل تفاضلی به‌عنوان روشی قدرتمند و سریع برای مسائل بهینه‌سازی در فضاهای پیوسته معرفی شده است و توانایی خوبی در بهینه‌سازی توابع غیرخطی مشتق‌ناپذیر دارد. همانند دیگر الگوریتم‌های تکاملی، این الگوریتم با ایجاد یک جمعیت اولیه شروع به کار می‌کند. سپس با اعمال عملگرهایی شامل ترکیب، جهش و تقاطع، نسل فرزند تشکیل شده و در مرحله بعد که مرحله انتخاب نام دارد، نسل فرزند با نسل والد از برای میزان شایستگی که توسط تابع هدف سنجیده می‌شود، مقایسه می‌گردد. سپس بهترین اعضا به‌عنوان نسل بعدی وارد مرحله بعد می‌گردند. این عمل تا رسیدن به نتایج مطلوب ادامه می‌یابد.

### ماشین آموزش نیرومند خود تطبیقی

استفاده از الگوریتم تکامل تفاضلی به‌صورت خود تطبیقی توانایی غلبه بر محدودیت‌های موجود مانند پارامترهای کنترل در الگوریتم، انتخاب استراتژی بردار trial را داراست. از این‌رو، الگوریتم ماشین آموزش نیرومند خود تطبیقی (SAELM) جهت بهینه‌سازی وزن‌های ورودی شبکه و سوگیری‌های گره مخفی، توسط کائو و همکاران (۴) ارائه شده است. با داشتن مجموعه داده‌های آموزشی، تعداد L گره مخفی و تابع



شکل ۲- تاخیرهای موثر داده‌های سری زمانی شناسایی شده توسط تابع خود همبستگی  
Figure 2. Autocorrelation function for rainfall and runoff time-series

شناسایی خواهند شد. لازم به ذکر است که برای آموزش مدل‌های هوش مصنوعی از ۷۰ درصد مقادیر مشاهداتی و برای تست این مدل‌ها از ۳۰ درصد باقیمانده استفاده شد. مقادیر مشاهداتی بارش و رواناب حوزه رودخانه شهرچای در یک بازه زمانی ۱۸ ساله از سال ۲۰۰۰ تا ۲۰۱۷ مورد استفاده قرار گرفته‌اند. داده‌های این بازه زمانی ۱۷ ساله به صورت ماهانه از ایستگاه هواشناسی بند ارومیه اخذ شده‌اند. علاوه بر این به دلیل محدودیت تعداد صفحات مجله در این مطالعه تنها کلیه نتایج برای شرایط تست مدل‌های هوش مصنوعی گزارش می‌شوند.

### نتایج و بحث بارش

#### مدل‌های SAELM

در این قسمت دقت مدل‌های SAELM1 تا SAELM7 برای تخمین و شبهه‌سازی بارش مورد ارزیابی قرار می‌گیرد. در شکل ۳ مقادیر شاخص‌های آماری مختلف محاسبه شده برای این مدل‌ها قابل مشاهده است. همان‌گونه که در قسمت‌های قبلی بیان شد تاخیرهای شماره (t-1)، (t-2) و (t-12) به عنوان موثرترین تاخیرها شناسایی می‌شوند و با استفاده از این تاخیرهای موثر هفت مدل SAELM متمایز تعریف می‌گردد. به عنوان مثال، مدل SAELM1 مقادیر تابع هدف را با استفاده از تاخیر شماره (t-1) تخمین می‌زند. برای این مدل مقادیر RMSE، VAF و SI به ترتیب مساوی با ۰/۹۳۳، ۰/۵۶۶- و ۱/۱۴۰ بدست آمده‌اند. همچنین برای مدل SAELM1 مقدار NSC مساوی ۳/۴۹۹- محاسبه شد. در

#### معیارهای بررسی دقت مدل‌های هوش مصنوعی

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 ضریب بهره‌وری نش ساتکلیف ( $NSC$ ) به صورت زیر استفاده می‌گردد:

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

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

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


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

$$NSC = 1 - \frac{\sum_{i=1}^n (O_i - F_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (15)$$

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 بخش‌های بعدی، ابتدا مدل‌های SAELM و WSAELM برای تخمین بارش و رواناب مورد ارزیابی قرار می‌گیرند و در ادامه مدل‌های برتر و موثرترین تاخیرها با استفاده از یک تحلیل حساسیت

میان کلیه مدل‌های SAELM که برای شبیه‌سازی بارش تعریف شده‌اند، مدل SAELM5 دارای بیشترین دقت است. مدل SAELM5 تابعی از تاخیرهای شماره (t-1) و (t-12) است و مقادیر شاخص‌های SI و NSC برای آن به ترتیب مساوی با ۰/۷۷۴ و -۰/۰۶۰ بدست آمده‌اند. بعد از مدل SAELM 5، مدل SAELM 6 دارای بیشترین دقت برای تخمین بارش است. به عبارت دیگر مقادیر SI و NSC برای SAELM 6 به ترتیب مساوی با ۰/۸۱۱ و -۰/۰۴۵ محاسبه شده‌اند. مدل SAELM6 مقادیر بارندگی‌ها را با استفاده از تاخیرهای شماره (t-2) و (t-12) پیش‌بینی می‌نماید. مدل SAELM7 نیز مقادیر بارندگی‌ها را توسط کلیه تاخیرهای موثر یعنی (t-1)، (t-2) و (t-12) شبیه‌سازی نمود. برای SAELM7 مقادیر شاخص‌های آماری RMSE و NSC به ترتیب مساوی با ۰/۷۱۲ و -۰/۲۰۹ محاسبه شده‌اند.

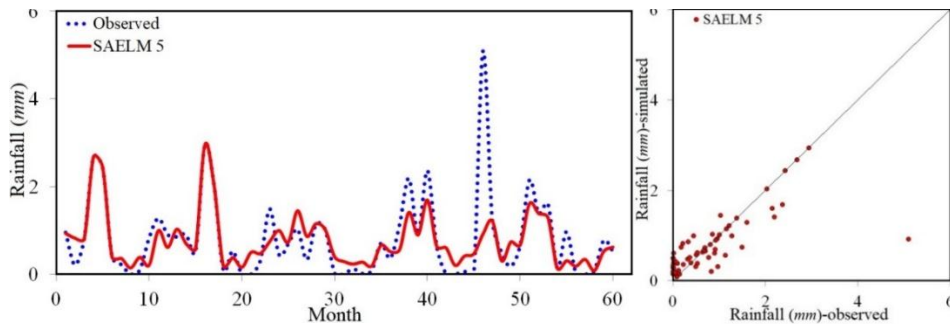
میان کلیه مدل‌های SAELM که برای شبیه‌سازی بارش تعریف شده‌اند، مدل SAELM2 دارای بیشترین مقدار خطا است. به عنوان مثال، مقادیر شاخص‌های آماری SI و RMSE برای این مدل به ترتیب مساوی با ۱/۱۶۲ و ۰/۹۵۱ به دست آمده‌اند. این در حالی است که مدل SAELM 2 مقادیر بارش‌ها را توسط تاخیر (t-2) شبیه‌سازی می‌نماید. در مقابل مدل SAELM3 مقادیر تابع هدف را توسط تاخیر شماره (t-12) شبیه‌سازی می‌نماید. برای SAELM3 مقادیر RMSE و NSC به ترتیب مساوی با ۰/۷۹۶ و -۰/۵۸۲ هستند. همچنین، مدل SAELM4 مقادیر بارش‌ها را بر حسب تاخیرهای شماره (t-1) و (t-2) پیش‌بینی می‌نماید و مقدار شاخص NSC برای آن مساوی با -۰/۷۱۵ می‌باشد. برای SAELM4 مقادیر SI، RMSE و VAF به ترتیب مساوی با ۰/۷۱۵، ۰/۸۷۳ و ۴۱/۰۴۳ تخمین زده شده‌اند. در



شکل ۳- نتایج شاخص‌های آماری محاسبه شده برای مدل‌های SAELM  
Figure 3. Results of calculated statistical indices for different SAELM models

مساوی با ۰/۰۵۳، ۰/۰۲۸ و ۰/۲۸۹ می‌باشند. این در حالی است که مقادیر ضریب تبیین مدل‌های SAELM4، SAELM5 و SAELM6 به ترتیب برابر با ۰/۴۱۴، ۰/۵۴۵ و ۰/۴۹۲ بدست آمده‌اند. همچنین، مقدار شاخص آماری  $R^2$  برای مدل SAELM7 مساوی با ۰/۴۱۷ تخمین زده شده است.

در شکل ۴ نیز یک مقایسه بین مقادیر بارش شبیه‌سازی شده توسط مدل برتر SAELM و مشاهداتی به همراه نمودارهای پراکندگی آنها به تصویر کشیده شده است. بر اساس نتایج مدل‌سازی‌ها، مدل SAELM2 دارای کمترین همبستگی و مدل SAELM5 دارای بیشترین همبستگی با مقادیر مشاهداتی است. به بیان دیگر، مقدار  $R^2$  برای مدل‌های SAELM1، SAELM2 و SAELM3 به ترتیب




شکل ۴- مقایسه مقادیر بارندگی شبهه‌سازی شده توسط مدل‌های SAELEM با مقادیر مشاهده‌ای و نمودارهای پراکندگی  
Figure 4. Comparison of rainfall values simulated by SAELEM with observed data and scatter plots

### مدل‌های WSAELEM

محاسبه شده‌اند این در حالی است که مقادیر NSC برای مدل‌های WSAELEM5 و WSAELEM6 به ترتیب برابر با ۰/۸۷۲ و ۰/۵۲ تخمین زده شده‌اند. برای مدل WSAELEM5 مقادیر شاخص‌های آماری RMSE و VAF به ترتیب مساوی با ۰/۳۰۶ و ۸۹/۵۶۱ هستند در حالی که این شاخص‌ها برای مدل WSAELEM 6 به ترتیب مساوی ۰/۴۱۳ و ۸۰/۳۹۸ بدست آمده‌اند. در میان کلیه مدل‌های هیبریدی، مدل WSAELEM 7 دارای بیشترین دقت برای شبهه‌سازی بارش است. این در حالی است که مقادیر VAF و RMSE برای این مدل هیبریدی به ترتیب برابر با ۹۶/۶۵۶ و ۰/۱۷۰ هستند.


در این قسمت به ارزیابی دقت مدل‌های ترکیبی WSAELEM برای تخمین مقادیر بارش پرداخته می‌شود. مقادیر شاخص‌های آماری محاسبه شده برای مدل‌های WSAELEM1 to WSAELEM7 در شکل ۵ نشان داده شده است. برای مدل WSAELEM1 مقادیر NSC و SI به ترتیب مساوی با ۰/۴۱۶ و ۰/۸۴۵ محاسبه شده‌اند. همچنین، مقادیر NSC و VAF برای SAELEM2 به ترتیب برابر ۰/۷۴۳ و ۷۹/۰۶۵ بدست آمده‌اند. لازم به ذکر است که در میان کلیه مدل‌های هیبریدی مدل WSAELEM3 دارای کمترین دقت و بیشترین مقدار خطا است. برای مدل مذکور مقادیر NSC، SI و RMSE به ترتیب مساوی با ۰/۵۷۱، ۰/۵۶۸ و ۰/۴۶۵



شکل ۵- نتایج شاخص‌های آماری برای شبهه‌سازی توسط مدل‌های WSAELEM مختلف  
Figure 5. Results of statistical indices for simulating rainfall values with different WSAELEM models

همبستگی با مقادیر مشاهداتی است. لازم به ذکر است که مدل WSAELM7 دارای بیشترین مقدار همبستگی با مقادیر مشاهداتی است. برای WSAELM7 مقدار  $R^2$  مساوی با ۰/۹۶۷ است. این در حالی است که این شاخص آماری برای مدل‌های WSAELM4، WSAELM5 و WSAELM6 به ترتیب برابر با ۰/۹۱۳، ۰/۸۹۶ و ۰/۸۰۳ تخمین زده شده است.

در ادامه به مقایسه مقادیر بارش شبیه‌سازی شده توسط مدل‌های WSAELM با مقادیر مشاهداتی به همراه نمودارهای پراکندگی پرداخته می‌شود که در شکل ۶ به تصویر کشیده شده است. با توجه به نتایج مدل‌سازی‌ها، مقادیر ضریب تبیین برای مدل‌های WSAELM1، WSAELM2 و WSAELM3 به ترتیب مساوی با ۰/۸۶۶، ۰/۷۹۱ و ۰/۷۶۸ محاسبه شده‌اند. در میان کلیه مدل‌های هیبریدی هوش مصنوعی، مدل 3 WSAELM دارای کمترین مقدار



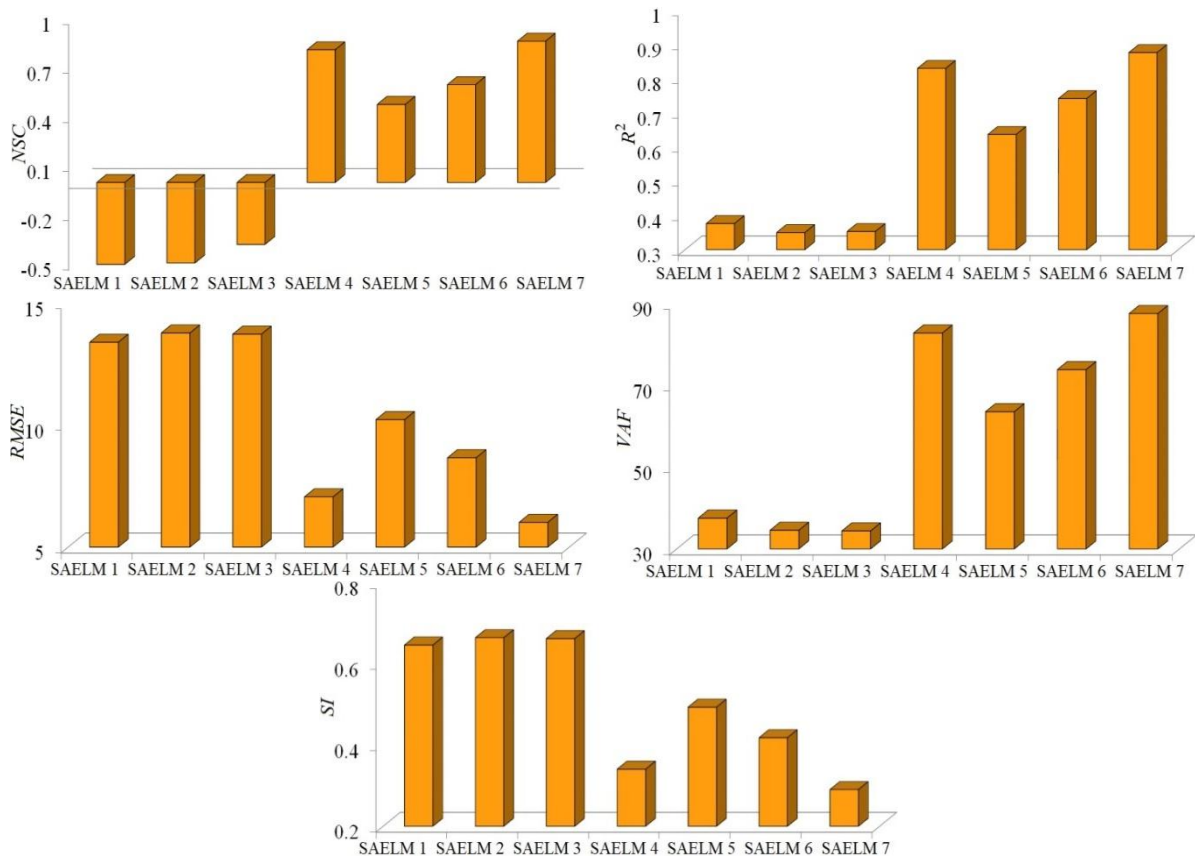
شکل ۶- مقایسه مقادیر بارندگی شبیه‌سازی شده توسط WSAELM با مقادیر مشاهداتی و نمودارهای پراکندگی  
Figure 6. Comparison of rainfall values simulated by WSAELM with observed data and scatter plots

شبیه‌سازی رواناب است. لازم به ذکر است که برای مدل SAELM3 مقادیر SI، RMSE و VAF به ترتیب مساوی با ۱۳/۷۱۸، ۰/۶۶۲ و ۳۴/۳۹۵ محاسبه شده‌اند. همچنین مقدار NSC برای مدل SAELM3 مساوی با ۰/۳۷۸- است. این در حالی است که مقادیر RMSE و VAF برای این مدل نیز به ترتیب برابر با ۷/۰۴۵ و ۸۲/۷۷۹ می‌باشند. لازم به ذکر است که برای مدل SAELM6 نیز مقادیر SI، VAF و RMSE به ترتیب برابر با ۷۳/۸۲۱، ۰/۴۱۸ و ۸/۶۵۹ بدست آمده‌اند. در میان کلیه مدل‌های SAELM تعریف شده برای شبیه‌سازی رواناب، مدل SAELM7 دارای بیشترین دقت و کمترین مقدار خطا است. به بیان دیگر، مقادیر NSC، RMSE و VAF برای مدل SAELM7 به ترتیب مساوی با ۰/۸۶۲، ۶/۰۱۳ و ۸۷/۵۲۸ هستند.

## رواناب

### مدل‌های SAELM


در این بخش به ارزیابی دقت مدل‌های هوش مصنوعی SAELM برای شبیه‌سازی رواناب پرداخته می‌شود. در شکل ۷ نیز نتایج شاخص‌های آماری محاسبه شده برای مدل‌های SAELM1 to SAELM7 به تصویر کشیده شده است. به عنوان مثال، برای مدل SAELM1 مقادیر RMSE و SI به ترتیب مساوی با ۱۳/۳۸۷ و ۰/۶۴۶ بدست آمده‌اند. این در حالی است که شاخص‌های آماری VAF و NSC برای این مدل هوش مصنوعی به ترتیب برابر با ۳۷/۵۳۲ و ۰/۵۰۹- هستند. این در حالی است که مقادیر شاخص‌های آماری NSC، SI و VAF برای این مدل به ترتیب مساوی با ۰/۴۹۱-، ۰/۶۶۵ و ۳۴/۵۴۹ بدست آمده‌اند. لازم به یادآوری است که SAELM2 ضعیف‌ترین مدل هوش مصنوعی برای



شکل ۷- نتایج شاخص‌های آماری برای شبهه‌سازی رواناب توسط مدل‌های SAELM مختلف  
Figure 7. Results of statistical indices for simulating runoff values with different SAELM models

مساوی ۰/۳۵۰ بدست آمده است. این در حالی است که مقدار شاخص R2 برای مدل SAELM 7 برابر ۰/۸۷۶ محاسبه شده است. لازم به ذکر است که مقدار R2 برای مدل‌های SAELM1، SAELM3 و SAELM4 به ترتیب مساوی با ۰/۳۶، ۰/۳۵۳ و ۰/۸۳۰ هستند. در مقابل مقدار ضریب تبیین برای مدل‌های SAELM5 و SAELM6 به ترتیب برابر با ۰/۸۳۷ و ۰/۷۴۱ می‌باشند.

لازم به ذکر است که مقایسه مقادیر رواناب شبهه‌سازی توسط مدل‌های SAELM با مقادیر مشاهداتی به همراه نمودارهای پراکندگی آنها در شکل ۸ قابل مشاهده است. با توجه به نتایج شبهه‌سازی‌ها، مدل SAELM3 و SAELM7 به ترتیب ضعیف‌ترین و بهترین مدل برای شبهه‌سازی رواناب شناسایی شدند. مدل SAELM 2 کمترین مقدار همبستگی را با مقادیر مشاهداتی دارد و مقدار ضریب تبیین برای آن

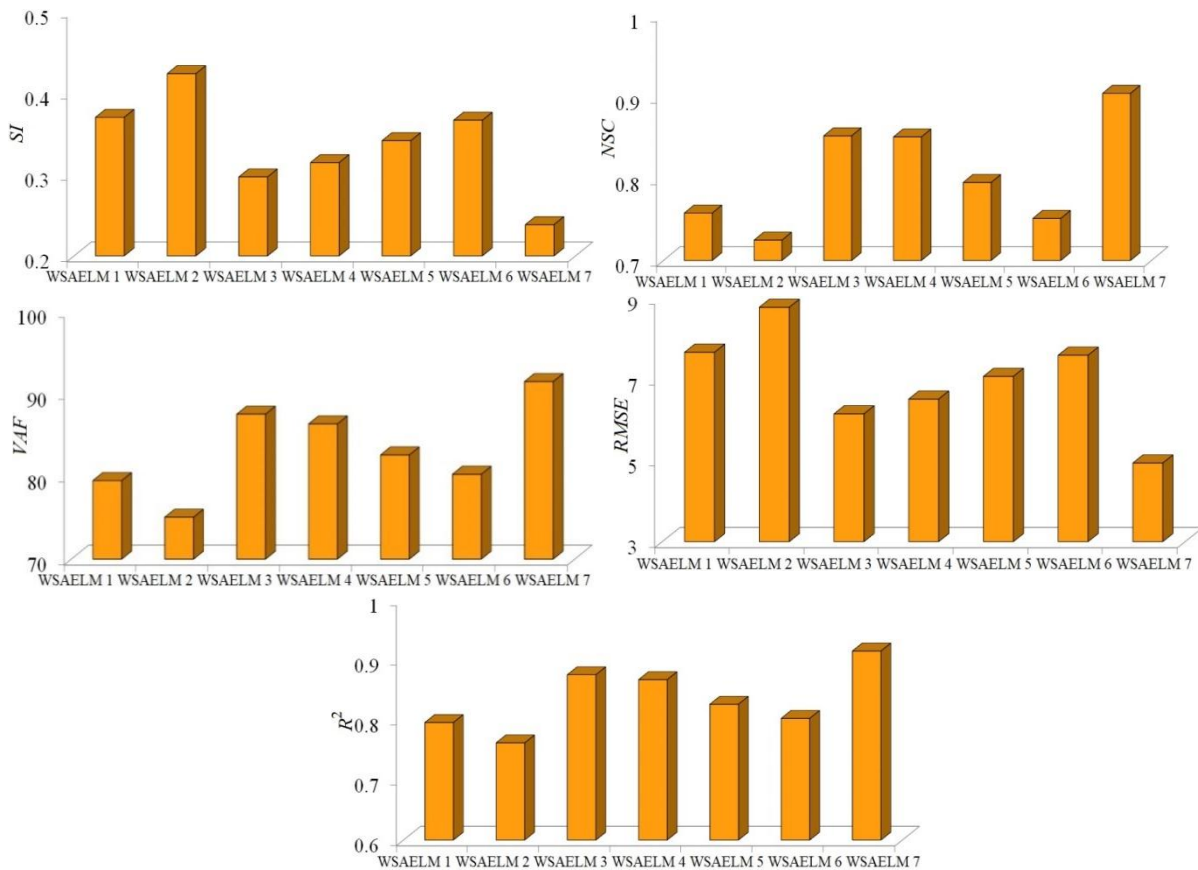


شکل ۸- مقایسه مقادیر رواناب شبهه‌سازی شده توسط SAELM با مقادیر مشاهداتی و نمودارهای پراکندگی  
Figure 8. Comparison of runoff values simulated by SAELM with observed data and scatter plots

### مدل‌های WSAELM

در این قسمت عملکرد مدل‌های هیبریدی WSAELM برای شبیه‌سازی رواناب مورد ارزیابی قرار خواهند گرفت. نتایج شاخص‌های آماری مختلف برای مدل‌های WSAELM1 تا WSAELM7 در شکل ۹ به تصویر کشیده شده است. بر اساس نتایج شبیه‌سازی‌ها، مدل WSAELM7 دارای بیشترین دقت برای تخمین رواناب است. به عبارت دیگر، مقادیر RMSE، VAF و NSC برای WSAELM7 به ترتیب برابر با ۴/۹۳۷، ۹۱/۴۹۲ و ۰/۹۰۵ هستند. در مقابل، مدل WSAELM2 دارای بیشترین خطا برای

شبیه‌سازی مقدار رواناب است و مقادیر SI و NSC برای این مدل هوش مصنوعی به ترتیب مساوی با ۰/۴۲۴ و ۰/۷۲۵ محاسبه شده‌اند. علاوه بر این، مقادیر شاخص‌های VAF و RMSE برای مدل WSAELM1 به ترتیب برابر با ۷۹/۵۰۴ و ۷/۶۶۵ بدست آمده‌اند. این در حالی است که برای WSAELM3 مقادیر NSC و SI به ترتیب مساوی با ۰/۸۵۳ و ۰/۲۹۷ می‌باشند. علاوه بر این، برای مدل WSAELM5 مقادیر VAF، NSC و SI به ترتیب برابر با ۸۲/۶۱۱، ۰/۷۹۵ و ۰/۳۴۱ تخمین زده شده‌اند.

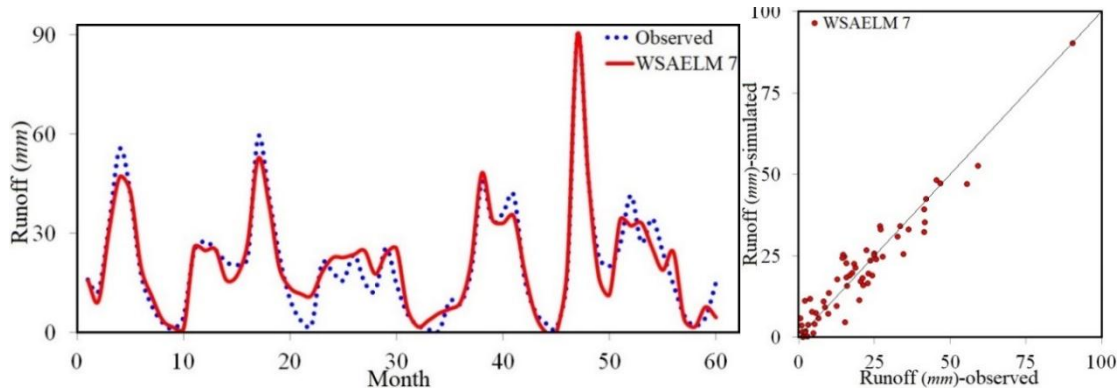


شکل ۹- نتایج شاخص‌های آماری برای شبیه‌سازی رواناب توسط مدل‌های WSAELM مختلف

Figure 9. Results of statistical indices for simulating runoff values with different SAEML models.

مساوی با ۰/۷۶۲ و ۰/۹۱۵ بدست آمده‌اند. لازم به ذکر است که مقدار ضریب تبیین برای مدل‌های WSAELM 1، WSAELM 3 و WSAELM 4 به ترتیب مساوی با ۰/۷۹۶، ۰/۸۶ و ۰/۸۶۷ تخمین زده شده‌اند. این در حالی است که برای مدل‌های هوش مصنوعی هیبریدی WSAELM 5 و WSAELM 6 مقدار شاخص آماری R<sup>2</sup> به ترتیب مساوی با ۰/۸۲۶ و ۰/۸۰۳ بدست آمده‌اند.

در این بخش نیز یک مقایسه بین رواناب شبیه‌سازی شده توسط مدل‌های WSAELM و مقادیر مشاهداتی صورت می‌گیرد. در شکل ۱۰ این مقایسه به همراه نمودارهای پراکندگی این مدل‌ها به تصویر کشیده شده است. بر اساس نتایج شبیه‌سازی‌ها، مدل‌های WSAELM 2 و WSAELM 7 به ترتیب دارای کمترین همبستگی و بیشترین همبستگی با مقادیر رواناب مشاهداتی هستند. به بیان دیگر، مقدار شاخص آماری R<sup>2</sup> برای WSAELM 7 و WSAELM 2 به ترتیب



شکل ۱۰- مقایسه مقادیر رواناب شبه‌سازی شده توسط مدل‌های مختلف WSAELM با مقادیر مشاهداتی و نمودارهای پراکندگی  
Figure 10. Comparison of runoff values simulated by different WSAELM models with observed data and scatter plots

بودن  $\bar{e}$  به معنای overestimated بودن مدل عددی است. همچنین، با استفاده از پارامترهای  $\bar{e}$  و  $S_e$  یک باند اطمینان در اطراف مقادیر خطای پیش‌بینی توسط روش ویلسون ایجاد می‌شود. سپس با استفاده از  $\pm 1.64S_e$  به صورت تقریبی منجر به 95% باند اطمینان می‌گردد. پارامترهای تحلیل عدم قطعیت مدل‌های برتر در در جدول‌های ۱ و ۲ قابل مشاهده است. در این جدول‌ها عرض باند عدم قطعیت با WUB و 95 درصد عدم قطعیت با PEI نشان داده می‌شود. با توجه به نتایج تحلیل عدم قطعیت، مدل‌های WSAELM 3، 1، 6، 7 و WSAELM 2 شبه‌سازی بارش دارای عملکردی بیشتر از واقعی هستند در حالی که مدل‌های هوش مصنوعی WSAELM 4 و WSAELM 5 برای تخمین بارش عملکردی کمتر از واقعی دارند. در مقابل، برای شبه‌سازی رواناب تنها مدل WSAELM 5 دارای عملکردی بیشتر از واقعی است و بقیه مدل‌ها شامل WSAELM 1 تا WSAELM 4، 6 و 7 و WSAELM 5 عملکردی کمتر از واقعی از خود نشان دادند.

### تحلیل عدم قطعیت

در این قسمت با انجام یک تحلیل عدم قطعیت نحوه عملکرد مدل‌های هوش مصنوعی WSAELM که مقادیر بارش و رواناب توسط آنها تخمین زده شده، مورد ارزیابی قرار خواهد گرفت. به‌طور کلی تحلیل عدم قطعیت یک تحلیل کارآمد جهت ارزیابی عملکرد مدل‌های عددی استفاده می‌شوند. به عبارت دیگر، تحلیل عدم قطعیت برای سنجش خطای پیش‌بینی شده توسط مدل‌های عددی و بررسی نحوه عملکرد این مدل‌ها اجرا می‌شود. به طور کلی خطای پیش‌بینی شده توسط مدل عددی برابر است با مقادیر شبه‌سازی شده توسط مدل عددی ( $P_i$ ) منهای مقادیر مشاهداتی ( $O_i$ ) است ( $e_i = P_i - O_i$ ). همچنین، میانگین خطای پیش‌بینی شده بصورت  $e = \sum_{i=1}^n e_i$  محاسبه می‌شود. همچنین، انحراف استاندارد مقادیر خطای پیش‌بینی شده به صورت  $S_e = \sqrt{\sum_{i=1}^n (e_i - \bar{e})^2 / n - 1}$  می‌باشد. لازم به ذکر است که منفی بودن مقدار  $\bar{e}$  نشان می‌دهد که مدل عددی دارای عملکردی underestimated است و مثبت

جدول ۱- نتایج تحلیل عدم قطعیت مدل‌های WSAELM برای تخمین بارندگی

Table 1. Results of uncertainty analysis of WSAELM models for estimating rainfall values

Model	# samples	$\bar{e}$	$S_e$	WUB	95% PEI
WSAELM 1	۶۰	-۰/۰۰۰۴	-۰/۳۴۴	±۰/۰۸۹	-۰/۰۸۸ تا ۰/۰۸۹
WSAELM 2	۶۰	-۰/۰۶۰	-۰/۴۲۹	±۰/۱۱۱	-۰/۱۷۱ تا ۰/۰۵۱
WSAELM 3	۶۰	-۰/۰۶۰	-۰/۴۶۵	±۰/۱۲	-۰/۰۶۰ تا ۰/۱۸۰
WSAELM 4	۶۰	-۰/۰۳۲	-۰/۲۷۹	±۰/۰۷۳	-۰/۱۰۴ تا ۰/۰۴۰
WSAELM 5	۶۰	-۰/۰۵۸	-۰/۳۰۳	±۰/۰۷۹	-۰/۱۳۲ تا ۰/۰۲۰
WSAELM 6	۶۰	-۰/۰۰۳	-۰/۴۱۷	±۰/۱۰۸	-۰/۱۰۵ تا ۰/۱۱۰
WSAELM 7	۶۰	-۰/۰۰۵	-۰/۱۷۲	±۰/۰۴۵	-۰/۰۳۹ تا ۰/۰۵۰

جدول ۲- نتایج تحلیل عدم قطعیت مدل‌های WSAELM برای تخمین رواناب

Table2. Results of uncertainty analysis of WSAELM models for estimating runoff values

Model	# samples	$\bar{e}$	$S_e$	WUB	95% PEI
WSAELM 1	۶۰	-۰/۲۱۱	۷/۷۲۷	±۱/۹۹۷	-۲/۲۰۸ تا ۱/۷۸۵
WSAELM 2	۶۰	-۲/۳۶۰	۸/۵۲۰	±۲/۲۰۰	-۴/۵۶۰ تا -۰/۱۶۰
WSAELM 3	۶۰	-۱/۴۶۱	۶/۰۲۲	±۱/۵۵۶	-۳/۰۱۶ تا ۰/۰۹۵
WSAELM 4	۶۰	-۱/۸۳۹	۶/۳۰۰	±۱/۶۲۸	-۳/۴۶۶ تا -۰/۲۱۱
WSAELM 5	۶۰	-۰/۴۳۵	۷/۱۱۷	±۱/۸۳۹	-۱/۴۰۳ تا ۲/۲۷۴
WSAELM 6	۶۰	-۱/۰۵۶	۷/۵۸۱	±۱/۹۵۹	-۳/۰۱۵ تا ۰/۹۰۲
WSAELM 7	۶۰	-۰/۰۶۶	۴/۹۷۸	±۱/۲۸۶	-۱/۳۵۲ تا ۱/۲۲۰

شدند و دو الگوریتم جدید WSAELM و SAELM توسعه داده شدند. سپس با استفاده از تابع خود همبستگی تاخیرهای موثر، داده‌های سری زمانی معرفی گردیدند. با استفاده از این تاخیرها برای هر یک از مدل‌های WSAELM و SAELM هفت مدل مختلف تعریف شد. سپس با تجزیه و تحلیل نتایج کلیه مدل‌های هوش مصنوعی، مدل برتر برای تخمین بارش و رواناب معرفی شد. این مدل مقادیر تابع هدف را با دقت بسیار خوبی شبیه‌سازی کرد. به‌عنوان مثال، مقادیر RMSE و VAF مدل برتر برای تخمین رواناب به ترتیب مساوی با ۴/۹۳۷ و ۹۱/۴۹۲ محاسبه شدند. لازم به ذکر است که تبدیل ویولت دقت مدل‌سازی را به شکل قابل توجهی افزایش داد. نتایج این مطالعه حاکی از آن بود که تاخیرهای شماره (t-1)، (t-2) و (t-12) موثرترین تاخیرهای داده‌های سری زمانی بارش و رواناب بودند. در انتها نحوه عملکرد مدل‌های هوش مصنوعی برتر توسط یک تحلیل عدم قطعیت مورد ارزیابی قرار گرفتند که نشان داده شد مدل برتر هوش مصنوعی مقادیر بارش‌ها را بیشتر از مقادیر مشاهداتی و مقادیر رواناب را کمتر از مقادیر مشاهداتی را پیش‌بینی کرد.

بنابراین با توجه به نتایج شبیه‌سازی بارش و رواناب توسط مدل هیبریدی هوش مصنوعی WSAELM، مدل WSAELM 7 به‌عنوان مدل برتر شناسایی شد زیرا دارای کمترین خطا و بیشترین همبستگی با مقادیر مشاهداتی بود. این مدل توانایی قابل قبولی برای تخمین و شبیه‌سازی توابع هدف از خود نشان داد. علاوه بر این، تاخیرهای (t-1)، (t-2) و (t-12) به‌عنوان موثرترین تاخیرها برای شبیه‌سازی توابع بارش و رواناب توسط مدل هوش مصنوعی در نظر گرفته شدند. به‌عنوان یکی از مهمترین نتایج این تحقیق باید بیان شود که تبدیل ویولت دقت مدل SAELM را به شکل قابل توجهی افزایش داد.

### نتیجه‌گیری

در این مطالعه، داده‌های بلندمدت سری زمانی بارش و رواناب برای حوضه رودخانه شهرچای که در غرب دریاچه ارومیه واقع شده توسط یک مدل نوین هیبریدی هوش مصنوعی شبیه‌سازی شد. برای تعریف مدل هوش مصنوعی مذکور سه الگوریتم ماشین آموزش نبرومند (ELM)، تکامل تفاضلی (DE) و تبدیل موجک (WT) با هم دیگر ترکیب

### منابع

1. Akrami, S.A., V. Nourani and S.J.S. Hakim. 2014. Development of nonlinear model based on wavelet-ANFIS for rainfall forecasting at Klang Gates Dam. *Water resources management*, 28(10): 2999-3018.
2. Azad, A., M. Manoochehri, H. Kashi, S. Farzin, H. Karami, V. Nourani and J. Shiri. 2019. Comparative evaluation of intelligent algorithms to improve adaptive neuro-fuzzy inference system performance in precipitation modelling. *Journal of Hydrology*, 571: 214-224.
3. Baba Ali, H. and R. Dehghani. 2017. Comparison of intelligent models in estimating monthly precipitation of Kaka Reza. *Ecology*, 4(1): 1-11.
4. Cao, J., Z. Lin. and G. Huang. 2012. Self-Adaptive Evolutionary Extreme Learning Machine. *Neural processing letters*, 36: 285-305.
5. Chang, T.K., A. Talei, C. Quek and V.R. Pauwels. 2018. Rainfall-runoff modelling using a self-reliant fuzzy inference network with flexible structure. *Journal of hydrology*, 564: 1179-1193.
6. Dabral, P.P. and M.Z. Murry. 2017. Modelling and forecasting of rainfall time series using SARIMA. *Environmental Processes*, 4(2): 399-419.
7. Danladi, A., M. Stephen, B.M. Aliyu, G.K. Gaya, N.W. Silikwa and Y. Machael. 2018. Assessing the influence of weather parameters on rainfall to forecast river discharge based on short-term. *Alexandria Engineering Journal*, 57(2): 1157-1162.
8. Ghorbani, M., A. Azani and S. Mahmoudi Vanolya. 2015. Rainfall-Runoff Modeling Using Hybrid Intelligent Models. *Iran Water Resources Research*, 11(2): 146-150.
9. Hasanpour Kashani M., M.A. Ghorbani, Y. Dinpazhouh and S. Shahmorad. 2016. Rainfall-Runoff Simulation in the Navrood River basin using Truncated Volterra Model and Artificial Neural Networks. *Jwmr*, 6(12): 1-10
10. Huang, G.B., Q.Y. Zhu and C.K. Siew. 2004. Extreme learning Machine: a new learning scheme of feedforward neural networks. *International Joint Conference on Neural Networks*, 2: 985-90.

11. Khalili, N., S.R. Khodashenas, K. Davari and M. Mousavi Bayegi. 2008. Prediction of daily precipitation using artificial neural networks, case study: synoptic station of Mashhad. *Watershed research*, 89-99.
12. Kumar, N and G.K. Jha. 2013. A time series an approach for weather forecasting. *Int J Control Theory Comput Model (IJCTCM)*, 3(1): 19-25.
13. Lee, S., S. Cho and P.M. Wong. 1998. Rainfall prediction using artificial neural networks. *Journal of geographic information and Decision Analysis*, 2(2): 233-242.
14. Mehr, A.D., V. Nourani, V.K. Khosrowshahi and M.A. Ghorbani. 2019. A hybrid support vector regression–firefly model for monthly rainfall forecasting. *International Journal of Environmental Science and Technology*, 16(1): 335-346.
15. Mekanik, F., M.A. Imteaz and A. Talei. 2016. Seasonal rainfall forecasting by adaptive network-based fuzzy inference system (ANFIS) using large scale climate signals. *Climate dynamics*, 46(9-10): 3097-3111.
16. Mislán, H., S. Hardwinarto and M.A. Sumaryono. 2015. Rainfall monthly prediction based on artificial neural network: a case study in Tenggara Station, East Kalimantan-Indonesia. *Procedia Computer Science*, 59: 142-151.
17. Memarian H, M. Pourreza Bilondi and Z.K. Zinat Komeh. 2019. Parameters Optimization of KINEROS2 using Particle Swarm Optimization Algorithm for Single Event Rainfall-Runoff Simulation (Case Study: Tamar Watershed, Golestan, Iran). *Jwmr*, 9(18): 91-110
18. Nasserri, M., K. Asghari and M.J. Abedini. 2008. Optimized scenario for rainfall forecasting using genetic algorithm coupled with artificial neural network. *Expert Systems with Applications*, 35(3): 1415-1421.
19. Price, K., R.M. Storn and J.A. Lampinen. 2006. *Differential evolution: a practical approach to global optimization*. Springer Science & Business Media.
20. Purnemat rudsari, A., K. Ghaderi and S. Karimi. 2015. Rainfall Runoff Modeling using Group Method of Data Handling (GMDH) and Artificial Neural Network (ANN) IN in Polrood Basin. *Journal of Watershed Management Research*, 10: 68-84 (In Persian).
21. Purnomo, H.D., K.D. Hartomo and S.Y.J. Prasetyo. 2017. Artificial neural network for monthly rainfall rate prediction. In *IOP Conference Series: Materials Science and Engineering*, 180(1): 012057.
22. Shafaei, M., J. Adamowski, A. Fakheri-Fard, Y. Dinpashoh and K. Adamowski. 2016. A wavelet-SARIMA-ANN hybrid model for precipitation forecasting. *Journal of Water and Land Development*, 28(1): 27-36.
23. Toth, E., A. Brath and A. Montanari. 2000. Comparison of short-term rainfall prediction models for real-time flood forecasting. *Journal of Hydrology*, 239(1-4): 132-147.
24. Wong, K.W., P.M. Wong, T.D. Gedeon and C.C. Fung. 1999. Rainfall prediction using neural fuzzy technique. URL, 213-221.
25. Xiang, Y., L. Gou, L. He, S. Xia and W. Wang. 2018. A SVR–ANN combined model based on ensemble EMD for rainfall prediction. *Applied Soft Computing*, 73: 874-883.
26. Yaseen, Z.M., M.I. Ghareb, I. Ebtehaj, H. Bonakdari, R. Siddique, S. Heddad and R. Deo. 2018. Rainfall pattern forecasting using novel hybrid intelligent model based ANFIS-FFA. *Water resources management*, 32(1): 105-122.
27. Zarei, M.M., M.T. Dastorani, M. Mesdaghi and M. Eshghizadeh. 2018. Evaluation of the Efficiency of Different Artificial Intelligence and Statistical Methods in Estimating the Amount of Runoff (Case Study: Shahid Noori Watershed of Kakhk, Gonabad). *Journal of Watershed Management Research*, 8(16): 11-21 (In Persian).

## Simulation of Rainfall- Runoff using Novel Learning Machine in Shaharchay River Basin

Amir Alizadeh<sup>1</sup>, Ahmad Rajabi<sup>2</sup>, Saeid Shabanlou<sup>3</sup>, Behrouz Yaghoubi<sup>2</sup> and Fariborz Yosefvand<sup>2</sup>

---

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

2- Assistant Professor, Department of Water Engineering, Kermanshah Branch, Islamic Azad University, Kermanshah, Iran (Corresponding author: ahmad.rajabi1974@gmail.com)

3- Associate Professor, Department of Water Engineering, Kermanshah Branch, Islamic Azad University, Kermanshah, Iran

Received: April 17, 2020

Accepted: July 12, 2020

---

### Abstract

In this paper, the precipitation and runoff time-series data of the Shaharchay River basin from 2000 to 2017 were simulated by using a novel hybrid artificial intelligence (AI) technique. In order to develop this AI model, the extreme learning machine (ELM), differential evolution (DE) and wavelet transform (WT) are combined and then the SAELM and WASAELM hybrid models are provided. Initially, the most effective lags of the time-series data are distinguished using the autocorrelation function. After that, using these lags, seven artificial intelligence models are defined for each of the SAELM and the WASAELM models. Additionally, 70% of the observational data are employed for training the artificial intelligence models and the rest (30%) for testing them. For WASAELM7 as the best model, the values of  $R^2$ , the scatter index (SI), and the Nash-Sutcliffe efficiency coefficient (NSC) for simulating precipitation are yielded 0.967, 0.208 and 0.965, respectively. Furthermore, a sensitivity analysis exhibits that the lags (t-1), (t-2) and (t-12) are regarded as the most effective input lags. Ultimately, an uncertainty analysis is carried out for the superior models.

**Keywords:** Differential evolution, Extreme learning machine, Lake Urmia, Rainfall, Runoff, Shaharchay River, Wavelet transform