

Optimization of ANFIS Network to Simulate Long Term Rainfall in Babolsar City

ALI JAMALVANDI¹, BEHROUZ YAGHOUBI^{1*}, MOHAMMAD ALI IZADBAKHS¹, SAEID SHABANLOU¹

1. Department of Water Engineering, Kermanshah Branch, Islamic Azad University, Kermanshah, Iran.

(Received: May. 9, 2021- Revised: July. 1, 2021- Accepted: July. 19, 2021)

ABSTRACT

In this study, the long-term rainfall in Babolsar city was simulated using an optimized hybrid artificial intelligence (AI) model over a 68 years period during 1951 to 2019. The ANFIS network and the wavelet transform combined to develop the hybrid model. Firstly, the effective lags of time series data were identified by using the autocorrelation function (ACF). Six ANFIS models were defined through these lags, Subsequently. The best ANFIS model was detected by conducting a sensitivity analysis. For testing the best ANFIS model, the value of correlation coefficient (R), variance accounted for (VAF), and scatter index (SI) were respectively computed to be 0.612, 37.029, and 0.761. In Addition, results of the models analysis showed that the (t-1), (t-2), (t-12), and (t-36) were identified as the most significant lags. Finally, the superior hybrid model was examined in three decomposition level (DL), revealing that the best results were obtained from the second decomposition level (DL2). In testing mode of the model, the R, VAF, and SI were calculated to be 0.972, 94.455, and 0.266, respectively. Therefore, the simulation results showed that the wavelet transform enhanced the performance of the ANFIS network significantly.

Keywords: Wavelet Transform, Sensitivity Analysis, Time Series, Simulation.

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

بهینه‌سازی شبکه ANFIS برای شبیه‌سازی دراز مدت بارندگی شهر بابلسر

علی جمالوندی^۱، بهروز یعقوبی^{۱*}، محمد علی ایزدبخش^۱، سعید شعبانلو^۱

۱. گروه مهندسی آب، واحد کرمانشاه، دانشگاه آزاد اسلامی، کرمانشاه، ایران

(تاریخ دریافت: ۱۴۰۰/۲/۱۹ - تاریخ بازنگری: ۱۴۰۰/۴/۱۰ - تاریخ تصویب: ۱۴۰۰/۴/۲۸)

چکیده

در این مطالعه، مقادیر بارندگی دراز مدت شهر بابلسر در یک بازه زمانی ۶۸ ساله از سال ۱۹۵۱ تا ۲۰۱۹ با استفاده از یک مدل هوش مصنوعی ترکیبی بهینه‌یافته شبیه‌سازی شد. برای توسعه مدل ترکیبی، شبکه انفیس با تبدیل موجک ترکیب شدند. در ابتدا، با استفاده از تابع خودهمبستگی، تاخیرهای موثر داده‌های سری زمانی شناسایی شدند. سپس با استفاده از این تاخیرها، شش مدل انفیس تعریف گردید. با اجرای یک تحلیل حساسیت، بهترین مدل انفیس معرفی شد. مقادیر ضریب همبستگی (R)، شاخص عملکرد (VAF) و شاخص پراکندگی (SI) برای وضعیت آزمون مدل برتر انفیس به ترتیب برابر با ۰/۶۱۲، ۰/۲۹ و ۰/۷۶۱ محاسبه شدند. علاوه بر این، تجزیه و تحلیل نتایج مدل‌سازی‌ها نشان داد که تاخیرهای شماره (t-1)، (t-2)، (t-12) و (t-36) تاثیرگذارترین تاخیرهای داده‌های سری زمانی بودند. در انتها، مدل ترکیبی برتر برای سه سطح تجزیه مختلف مورد ارزیابی قرار گرفت که بهترین نتایج برای سطح تجزیه دوم بدست آمد. در حالت آزمون مقادیر R و VAF و SI برای مدل برتر ترکیبی به ترتیب مساوی با ۰/۹۷۲، ۰/۴۵۵ و ۰/۲۲۶ بودند. بنابراین، نتایج شبیه‌سازی‌ها نشان داد که تبدیل موجک دقت مدل‌سازی را به شکل قابل توجهی افزایش داد.

واژه‌های کلیدی: تبدیل موجک، تحلیل حساسیت، سری زمانی، شبیه‌سازی.

مقدمه

تخمین و پیش‌بینی الگوی بارش در نواحی مختلف جهان به ویژه در نواحی خشک و نیمه خشک کره زمین مانند کشور ایران از اهمیت بسزایی برخوردار است. علاوه بر آن روش‌های عددی مختلف مانند روش‌های هوش مصنوعی به دلیل دقت و سرعت بالا توانایی شبیه‌سازی پدیده بارش و موضوعات مشابه را دارد. استفاده از این روش‌ها نقش بسزایی در صرفه‌جویی در زمان و هزینه‌ها در مطالعات میدانی و آزمایشگاهی دارد. بنابراین، روز به روز به کاربرد و محبوبیت تکنیک‌های متنوع هوش مصنوعی برای تخمین و شبیه‌سازی مسائل متفاوت مانند بارندگی افزوده می‌شود. به عنوان مثال، (Maqsood et al. (2004 با استفاده از روش‌های مختلف شبکه عصبی مصنوعی و مدل‌های رگرسیونی مبادرت به مدل‌سازی پارامترهای مختلف آب و هوایی نمودند و بیان کردند که مدل‌های شبکه عصبی مصنوعی مقادیر تابع هدف را با دقت بیشتری در مقایسه با مدل‌های رگرسیونی تخمین زدند. علاوه بر این، (Riad et al. (2004 توسط شبکه عصبی مصنوعی مقادیر بارش و رواناب در یک حوضه واقع در کشور مراکش را تخمین زدند. آن‌ها با مقایسه نتایج مدل عددی خود با روابط

رگرسیونی نشان دادند که مدل‌های هوش مصنوعی دارای دقت بیشتری هستند. (Nasseri et al. (2008 شبکه عصبی مصنوعی را برای شبیه‌سازی پارامترهای هواشنایی توسط الگوریتم ژنتیک بهینه‌سازی کردند. آنها این مدل بهینه‌سازی شده را برای تخمین میزان بارندگی واقع در یک حوضه در کشور استرالیا استفاده کردند. همچنین (Mekanik et al. (2013 میزان بارش دراز مدت ۱۱۰ ساله در یک ناحیه واقع در جنوب استرالیا را با استفاده از رگرسیون خطی چندگانه و شبکه عصبی مصنوعی شبیه‌سازی نمودند. آنها با ارزیابی نتایج مدل‌های عددی مذکور نشان دادند که شبکه عصبی مصنوعی دارای دقت بیشتری بود. (Mislán et al. (2015 به وسیله مدل شبکه عصبی مصنوعی پسخور^۱ مقدار بارندگی ماهانه در شرق کشور اندونزی را پیش‌بینی کردند. آنها برای کنترل مقدار خطای مدل عددی خود از خطای مربع میانگین بهره گرفتند. (Xiang et al. (2018 توسط روش "تجزیه تجربی گروهی"^۲ 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. نتایج نشان داد که شبکه عصبی مصنوعی مقادیر

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

1 Back-propagation Neural Network

2 Ensemble Empirical Mode Decomposition (EEMD)

شهر بابلسر تاکنون توسط یک مدل هوش مصنوعی ترکیبی شبیه‌سازی نشده است. بنابراین در این مطالعه، برای اولین بار، مقادیر بارندگی شهر بابلسر در یک بازه زمانی ۶۸ ساله از سال ۱۹۵۱ تا ۲۰۱۹ توسط یک مدل هوش مصنوعی ترکیبی بهینه‌سازی شده، شبیه‌سازی خواهد شد. برای تولید مدل هوش مصنوعی ترکیبی که اختصاراً با WANSIS نشان داده می‌شود، از شبکه انفیسی (ANFIS) و تبدیل موجک (wavelet transform) استفاده می‌گردد. سپس با استفاده از تابع خود همبستگی تاخیرهای موثر مربوط به داده‌های سری زمانی شناسایی خواهند شد. در ادامه، شش مدل ANFIS توسط این تاخیرها تعریف می‌گردند. علاوه بر این، اعضای مختلف mother wavelet نیز ارزیابی شده و بهینه‌ترین mother wavelet نیز انتخاب خواهد شد. با تجزیه و تحلیل نتایج مدل‌سازی‌ها، مدل‌های برتر WSAELM به‌همراه موثرترین تاخیرهای ورودی معرفی خواهند شد. لازم به ذکر است که تبدیل موجک دقت مدل ANFIS را به شکل قابل ملاحظه‌ای افزایش خواهد شد.

مواد و روش‌ها

ناحیه مورد مطالعه

در این مطالعه برای آموزش و آزمون مدل‌های هوش مصنوعی از مقادیر بارش‌های گزارش شده توسط سازمان هواشناسی کشوری شهر بابلسر در یک بازه زمانی ۶۸ ساله از سال ۱۹۵۱ تا ۲۰۱۹ استفاده می‌گردد. برای آزمون مدل‌های هوش مصنوعی از ۴۹ سال این داده‌های سری زمانی استفاده خواهد شد و ۱۹ سال باقیمانده برای آزمون این مدل‌ها بکار گرفته می‌شوند. شهر بابلسر در مدار معتدل گرم قرار گرفته و ضریب اعتدال این شهر بسیار معتدل است. این ناحیه با میانگین سالیانه دمای ۴/۱۸ درجه سانتیگراد، بارش سالیانه ۷۹۱ میلی‌متر و ۷۹ 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. این شهر تقریباً هموار بوده و با شیب ملایمی از سوی رشته‌کوه‌های البرز به سوی دریای خزر امتداد دارد. بلندای شهر ۲۱ متر پایین‌تر از سطح دریاهای آزاد و ۷ متر بالاتر از سطح دریای مازندران قرار دارد. طول جغرافیایی بابلسر ۵۲ درجه و ۳۹ دقیقه و عرض آن ۳۶ درجه و ۴۲ دقیقه است.

سیستم استنتاج فازی عصبی تطبیقی (ANFIS)

سیستم استنتاج فازی عصبی تطبیقی (ANFIS) که ترکیبی از

بارش در بازه زمانی دراز مدت را با دقت بهتری شبیه‌سازی کرد. (Azad et al. (2019 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. همچنین، (Mehr et al. (2019 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. لازم به ذکر است که (Khalili et al. (2008 مقدار بارش شهر مشهد را در یک بازه زمانی ۵۳ ساله با استفاده از شبکه عصبی مصنوعی مدل‌سازی کردند. آنها نشان دادند که مدل هوش مصنوعی مذکور مقدار بارش ماهانه را با دقت قابل قبولی شبیه‌سازی کرده است، به عنوان مثال، مقدار ضریب همبستگی مدل برتر آنها مساوی با ۰/۹۲ بدست آمد. سپس (Ghorbani et al. (2015) 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. (Babaali & Dehghani (2017 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.

لازم به ذکر است که مدل‌سازی پدیده بارش در بازه‌های زمانی دراز مدت 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.

بررسی مطالعات گذشته نشان می‌دهد که بارش درازمدت

خروجی (y) و فرض اینکه هر سیستم فازی دارای دو قاعده if-then باشد، داریم:

(رابطه ۱)

Rule 1: if x_1 is A_1 and x_2 is B_1 , then $y_1 = p_1x_1 + q_1x_2 + r_1$


(رابطه ۲)

Rule 2: if x_1 is A_2 and x_2 is B_2 , then $y_2 = p_2x_1 + q_2x_2 + r_2$

که در آن if که بخش مقدم^۱ است دارای ماهیت فازی است در حالی که then که به عنوان بخش تالی^۲ شناخته می شود یک تابعی از متغیرهای مقدم است. باتوجه به معماری ANFIS در شکل ۱، این سیستم دارای پنج لایه مختلف است.

سیستم فازی و شبکه عصبی است، به عنوان ابزاری قدرتمند در حل مسائل غیرخطی برای اولین بار توسط Jang (1993) ارائه شده است. در واقع این روش، قوانین سیستم های فازی را با استفاده از الگوریتم های آموزش شبکه عصبی، تقویت می کند. روش ANFIS در مقایسه با شبکه های عصبی، به دلیل قابلیت تنظیم پارامترهای سیستم فازی از سرعت آموزش بالاتری برخوردار است. علاوه بر این، این روش کارآمدتر است زیرا سیستم فازی سوگنو را در یک ساختار عصبی، اجرا می کند (Mendel, 2017).

با فرض یک سیستم فازی با دو ورودی x_1 و x_2 و یک



شکل ۱- ساختار یک شبکه ANFIS با دو ورودی (Azimi et al. 2018)

لایه اول: هر نود i در این لایه یک نود تطبیقی با تابع نود O_i^1 است که به شکل زیر تعریف می شود:

لایه دوم: این لایه شامل نودهای دایره ای Π است که سیگنال های ورودی ها را در یکدیگر ضرب می کند و خروجی را ارسال می کند. هر نود در این لایه نشان دهنده قدرت آتش^۵ یک قانون می باشد.

$$O_i^1 = \mu_{A_i}(x_1) \quad (\text{رابطه ۳})$$

$$O_i^2 = w_i = \mu_{A_i}(x_1)\mu_{B_i}(x_2) \quad i = 1, 2. \quad (\text{رابطه ۵})$$

که x_1 ورودی نود i -ام و μ تابع عضویت است که یک نشانه زبانی (مانند بالا^۳ و پایین^۴) مربوط به این تابع نود است. مشابه رابطه فوق را می توان برای x_2 نیز نوشت.

لایه سوم: این لایه شامل نودهای دایره ای N است که نسبت قدرت آتش i -امین قانون به مجموع قدرت آتش همه قوانین را حساب می کند. خروجی این لایه تحت عنوان قدرت آتش نرمالایز شده شناخته می شود.

تابع نود O_i^1 تابع عضویت است که درجه ورودی x_1 (با x_2) را مشخص می کند به طوری که کمیت سنج A_i را اقتناع کند. تابع عضویت مورد استفاده در این مطالعه از نوع گوسین است که به شکل رابطه ۴ تعریف می شود.

$$O_i^3 = \bar{w}_i = \frac{w_i}{w_1 + w_2} \quad \text{for } i = 1, 2 \quad (\text{رابطه ۶})$$

$$\mu_{A_i}(x_1) = \exp\left\{-\frac{(x_1 - c_i)^2}{2\sigma^2}\right\} \quad (\text{رابطه ۴})$$

لایه چهارم: همه نودهای این لایه از نوع نودهای تطبیقی با یک تابع نود هستند. پارامترهای این لایه تحت عنوان پارامترهای تالی شناخته میشوند.

که $\{c, \sigma\}$ پارامترهای تابع عضویت گوسی (فاکتورهای تطبیقی) هستند و μ تابع عضویت است. مقادیر مختلف c و σ منجر به ارائه شکل های مختلف از تابع عضویت می شود. پارامترهای این لایه تحت عنوان پارامترهای مقدم، شناخته می شوند.

$$O_i^4 = \bar{w}_i y_i = \bar{w}_i (p_i x_1 + q_i x_2 + r_i) \quad (\text{رابطه ۷})$$

که \bar{w}_i خروجی لایه سوم و $\{p_i, q_i, r_i\}$ مجموعه پارامترها

می باشد.

موجک‌ها دارای جنسیت هستند. موجک پدر اغلب با ϕ و موجک مادر با نماد ψ نمایش داده می‌شود که به صورت زیر تعریف می‌شوند:

$$\varphi_{j,k}(t) = S^{-\frac{j}{2}} \varphi\left(\frac{t - S^j k}{S^j}\right) \quad (\text{رابطه ۹})$$

$$\psi_{j,k}(t) = S^{-\frac{j}{2}} \psi\left(\frac{t - S^j k}{S^j}\right) \quad (\text{رابطه ۱۰})$$

هائطور که ملاحظه می‌شود پارامتر مقیاس (S) نقش تحلیل موجک را از تحلیل فوریه متمایز می‌سازد. تغییر دامنه را تغییر داده و می‌تواند تحلیل را از کلی به موضعی و برعکس تغییر دهد. موجک پدر انتگرالی برابر با یک و موجک مادر انتگرال برابر با صفر دارد. موجک پدر بخش هموار، روند (فرکانس پایین) سیگنال، و موجک مادر در بخش‌های جزئی (فرکانس بالا) را نشان می‌دهد. تبدیل موجک یک تابع مانند f می‌تواند به وسیله معادله زیر، نمایش داده شود:

$$W_{\psi} f(j,k) = 2^{-\frac{j}{2}} \int_{-\infty}^{+\infty} f(t) \psi\left(2^{-\frac{j}{2}} t - k\right) dt \quad (\text{رابطه ۱۱})$$

حال می‌توان رابطه‌ای بین سری‌های زمانی و نمایش موجک برقرار نمود. هر سری زمانی مانند $y(t)$ به صورت زیر نمایش داده می‌شود:

(رابطه ۱۲)

$$y(t) = \sum_k S_{j,k} \varphi_{j,k}(t) + \sum_k d_{j,k} \psi_{j,k}(t) + \sum_k d_{j-1,k} \psi_{j-1,k}(t) + \dots + \sum_k d_{1,k} \psi_{1,k}(t)$$

که در عبارت یاد شده $j=1,2,\dots,J$ است و J حداکثر مقیاس مورد نظر است.

در حقیقت در تبدیل موجک نیز به مانند تبدیل فوریه، یک تابع یا سری زمانی به صورت مجموعه‌ای از جملات با توابع پایه موجک بیان می‌شود با این تفاوت که توابع موجک به مانند سینوس و کسینوس نبوده و در برگزیده پارامتر مقیاس هستند.

روش ترکیبی WANFIS

در این مدل ترکیبی، جهت پیش‌بینی سری زمانی بارندگی ماهانه در بابل، از ترکیب روش‌های سیستم استنتاج فازی عصبی تطبیقی (ANFIS) و تبدیل موجک (Wavelet) استفاده می‌شود. روند مدلسازی در این روش، با تعریف پارامترهای ورودی، آغاز می‌شود. جهت تعیین موثرترین تاخیرها، از تابع خود همبستگی (ACF^2) استفاده می‌شود. نتایج اجرای تابع خود همبستگی برای داده‌های مورد استفاده در مطالعه حاضر در شکل ۳ قابل مشاهده است. بنابراین، مدل‌های تعریف شده برای این

لایه پنجم: تک‌نود دایره‌ای ارائه شده در این لایه به صورت Σ برچسب زده شده است، خروجی‌های کلی به عنوان مجموع تمام سیگنال‌های ورودی را محاسبه می‌کند.

$$O_i^5 = \sum_i \bar{w}_i y_i = \frac{\sum_i w_i y_i}{\sum_i w_i} \quad (\text{رابطه ۸})$$

قبل از شروع به مدلسازی با استفاده از ANFIS، باید الگوریتم بهینه‌سازی و روش تولید سیستم استنتاج فازی، تعریف شوند. در این مطالعه، الگوریتم هیبرید که ترکیبی از الگوریتم‌های پس‌انتشار خطا و حداقل مربعات است، به عنوان الگوریتم آموزش مورد استفاده قرار می‌گیرد. علاوه بر این، روش fuzzy c-means clustering (FCM) که نسبت به روش‌های دیگر دارای پارامترهای کمتری است و منجر به نتایج بهتری می‌شود جهت تولید سیستم استنتاج فازی، مورد استفاده قرار می‌گیرد (Azimi et al. 2018).

تبدیل موجک^۱

تبدیل فوریه یک تابع $f(x)$ را به صورت بی‌نهایت تابع $\sin(ax)$ و $\cos(ax)$ ارائه می‌دهد. برغم قابلیت خوب تبدیل فوریه در تحلیل سیگنال‌ها، این تبدیل دو عیب عمده دارد. اول آنکه توابع پایه فوریه (سینوس و کسینوس) برای نمایش سیگنال‌های پیچیده مناسب نبوده و دیگر آنکه پارامتر زمان را حذف می‌کند. تبدیل موجک مشابه تبدیل فوریه با بسط توابع سروکار دارد ولی این بسط برحسب توابع موجک نوشته می‌شود. موجک یک بازه محدود با میانگین صفر است، در حالیکه فوریه یک تابع سینوسی است که از $-\infty$ تا $+\infty$ گسترده است. از طرف دیگر منحنی سینوسی فوریه یک منحنی نرم قابل پیش‌بینی است در حالیکه موجک‌ها از قاعده خاصی پیروی نمی‌کنند.

موج سینوسی از نظر تعداد و فراوانی دوره‌ها موضعی شده است ولی از نظر زمانی موضعی نیست در حالی که موجک هم از نظر فراوانی و هم از نظر زمانی موضعی شده است. بنابراین یک تبدیل که فرایند را به چند افق زمانی تجزیه کند آن را به شکلی در می‌آورد که دوره‌های تکرار، گروه‌ها و طبقات نوسان‌پذیر و ساختارهای جهش و ویژگی‌های عمومی و موضعی پویایی فرایند، متفاوت می‌شود. موجک‌ها توابع ریاضی هستند که داده‌ها را به اجزا فراوانی (فرکانس) تفکیک کرده و هر جزء را به نمایش متناسب به مقیاس آن جزء مطالعه می‌کنند.

مطالعه، به شرح زیر می باشد:

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


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

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

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

$$M5: R(t) = f(R(t-1), R(t-2), R(t-12), R(t-24))$$

$$M6: R(t) = f(R(t-1), R(t-2), R(t-12), R(t-36))$$



شکل ۲- تابع خود همبستگی مربوط به داده های بارش ماهانه شهر بابلسر

پس از تعیین مدل های مختلف، نوع موجک مادر و همچنین سطح تجزیه، تعریف شود. در این مطالعه، شش نوع موجک مادر شامل Hahr (haar), Daubechies (db), Symlets, Dmeyer و BiorSplines (bior), Coiflects (coif), (sym) می باشد. پس از انتخاب موجک مادر، نوبت به تعیین

سطح تجزیه می رسد. به منظور تعیین سطح تجزیه برای استفاده از موجک مادر، در این مطالعه از رابطه زیر استفاده می شود (Nourani et al., 2014):

$$DL = \text{int}[\text{Ln}(Z)] \quad (\text{رابطه ۱۳})$$

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 مدلسازی 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 بعضا با استفاده از سطح تجزیه های پایین نیز می توان به نتایج قابل قبولی دست یافت. شکل ۳ چگونگی تجزیه توسط تبدیل موجک برای سطوح مختلف را نشان می دهد. اگر هر یک از ورودی های مدل را به صورت In_i در نظر بگیریم، تجزیه این ورودی در سطوح مختلف، منجر به چند برابر شدن ورودی های مدل می شود. اما همانطور که گفته شد، در نظر گرفتن یک الی دو سطح، نه تنها مدل را پیچیده نمی کند، بلکه توانایی پیش بینی و تعمیم پذیری آن را نیز افزایش می دهد. تجزیه ورودی i -ام در سطوح تجزیه مختلف، به صورت زیر انجام می پذیرد:

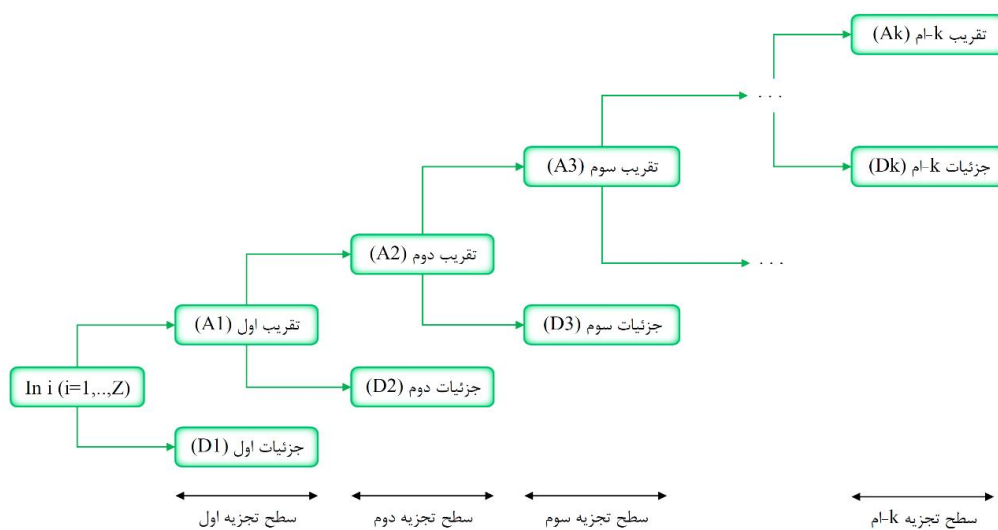
$$DL = 1 \rightarrow In_i = A1 + D1$$

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

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

...

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



شکل ۳- چگونگی تجزیه توسط تبدیل موجک برای سطوح مختلف

شده از شاخص های آماری ضریب همبستگی (R)، شاخص عملکرد (VAF)، خطای مربعات میانگین ریشه (RMSE)، شاخص

معیارهای بررسی دقت مدل های عددی در مطالعه حاضر به منظور ارزیابی دقت مدل های عددی معرفی

مدلی که توابع عضویت آن مساوی با سه هستند به ترتیب برابر با ۰/۶۶۲، ۵۵/۰۳۸ و ۳۹/۹۴۱ تخمین زده شدند. همچنین، در وضعیت آزمون مدلی که تعداد توابع عضویت آن مساوی با چهار است مقادیر R ، $RMSE$ و MAE به ترتیب برابر با ۰/۶۶۱، ۵۴/۹۳۳ و ۳۹/۷۵۵ محاسبه شدند. لازم به ذکر است که با افزایش تعداد توابع عضویت دقت مدل ANFIS به شکل محسوسی افزایش پیدا نکرد. به‌عنوان مثال، هنگامی که تعداد توابع عضویت مساوی با پنج در نظر گرفته شد، در وضعیت آزمون مقادیر شاخص‌های R ، $RMSE$ و MAE به ترتیب مساوی با ۰/۶۶۲، ۵۴/۸۱۶ و ۳۹/۸۰۴ محاسبه شدند. بنابراین همان‌گونه که ملاحظه می‌شود افزایش این پارامتر تاثیر قابل توجهی بر روی عملکرد مدل عددی نداشت و تنها باعث افزایش هزینه‌های محاسباتی شد و تعداد توابع عضویت مساوی با سه برای این مطالعه انتخاب شد. لازم به ذکر است که مقایسه شاخص‌های آماری مختلف برای تعداد توابع عضویت از دو تا پنج در هر دو وضعیت آموزش و آزمون در شکل ۴ نشان شده است. شکل ۵ نیز مقایسه مقادیر بارش‌های شبیه‌سازی شده توسط توابع عضویت برتر با مقادیر مشاهداتی را نشان می‌دهد. همان‌طور که از شکل ۴ مشاهده می‌شود، بعد از مدلی که دارای سه تابع عضویت بود، مدل با پنج تابع عضویت از دقت بیشتر و همبستگی بالاتری برخوردار بود. اما در مقابل زمان انجام محاسبات تقریباً ۱۵ درصد افزایش یافت. در میان کلیه مدل‌های مذکور، مدلی که دارای دو تابع عضویت بود، عملکرد ضعیفی از خود نشان داد. این مدل دارای بیشترین مقدار خطا و کمترین همبستگی با مقادیر مشاهداتی بود.

مدل‌های ANFIS

در این قسمت دقت مدل‌های مختلف ANFIS مورد سنجش قرار می‌گیرد. در شکل ۶ نتایج شاخص‌های آماری مختلف برای کلیه مدل‌های ANFIS در وضعیت‌های آموزش و آزمون نشان داده شده است. همان‌گونه که در بخش‌های قبلی بیان شد، در این مطالعه بعد از شناسایی تاخیرهای مهم در داده‌های سری زمانی، شش مدل ANFIS تعریف گردید. به‌عنوان مثال مدل ANFIS 1 مقادیر بارش‌ها را با استفاده از تاخیر (t-1) و (t-2) شبیه‌سازی کرد. برای این مدل، مقادیر شاخص‌های آماری ضریب همبستگی (R) و شاخص عملکرد (VAF) در وضعیت آزمون به ترتیب مساوی با ۰/۳۹۰ و ۱۴/۶۶۶ بدست آمدند. در مقابل مدل ANFIS 2 مقادیر تابع هدف را توسط تاخیرهای (t-1) و (t-12) تخمین زد. برای وضعیت آزمون این مدل مقادیر VAF و R نیز به ترتیب برابر با ۰/۵۱۲ و ۲۵/۸۸۰ محاسبه شدند. این در حالی است که مدل ANFIS 3 تابعی از تاخیرهای شماره (t-2) و (t-12) بود. برای این

پراکندگی (SI) و خطای مطلق میانگین (MAE) به صورت زیر استفاده می‌گردد:

(رابطه ۱۴)

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

(رابطه ۱۵)

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

(رابطه ۱۶)

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

(رابطه ۱۷)

$$SI = \frac{RMSE}{O}$$

(رابطه ۱۸)

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

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 تعداد توابع عضویت مدل ANFIS شناسایی می‌گردد. سپس با استفاده از تاخیرهای مهم سری زمانی، هشت مدل مختلف ANFIS تعریف شده که 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.

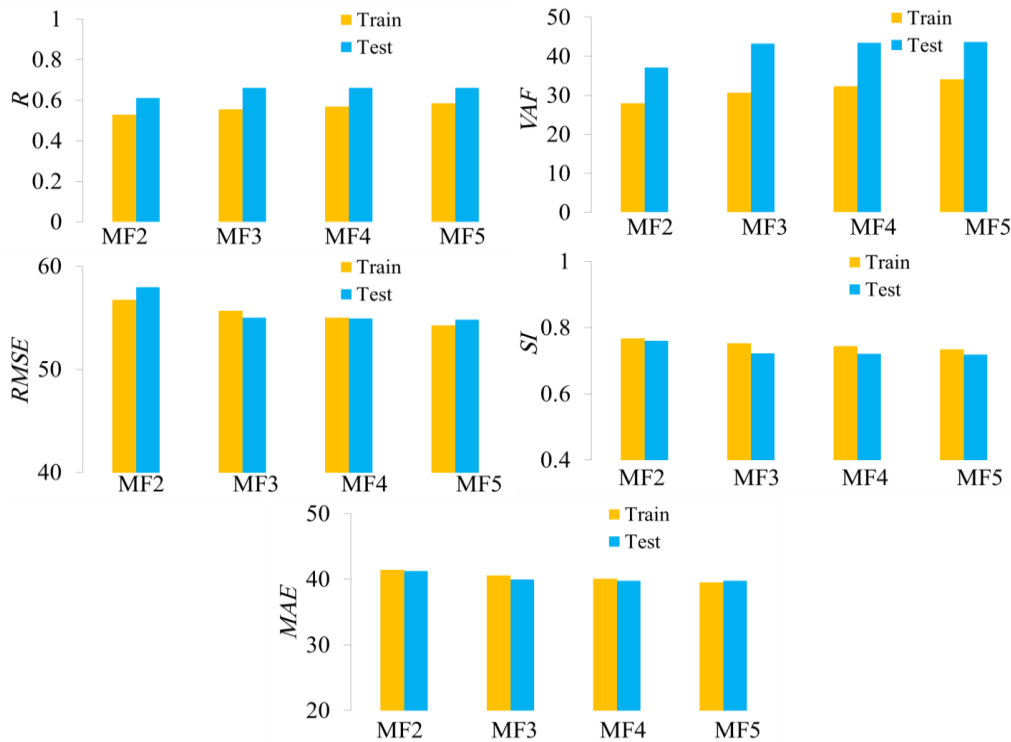
نتایج و بحث

بهینه‌سازی توابع عضویت


در این بخش به ارزیابی نحوه تاثیر تعداد توابع عضویت مدل ANFIS بر روی نتایج مدل‌سازی پرداخته می‌شود. در ابتدا تعداد توابع عضویت مساوی با دو در نظر گرفته شد و با افزایش آن تا پنج، عملکرد مدل ANFIS با استفاده از شاخص‌های آماری مختلف مورد بررسی قرار گرفت. بررسی تعداد توابع عضویت برای مدل ANFIS 6 که تابعی از کلیه تاخیرهای موثر هست، انجام شد. به‌عنوان مثال، برای شرایط آزمون مدلی که تعداد توابع عضویت مساوی دو بود مقادیر R ، $RMSE$ و MAE به ترتیب مساوی با ۰/۶۱۲، ۵۷/۹۶۵ و ۴۱/۲۵۵ بدست آمدند. علاوه بر این برای وضعیت آموزش، شاخص‌های آماری R ، $RMSE$ و MAE برای

(t-24) محاسبه می‌شود. برای این مدل مقادیر R و VAF در شرایط آزمون به ترتیب برابر با $۰/۵۷۷$ و $۳۲/۹۰۶$ تخمین زده شدند. مدل ANFIS 6 نیز مقادیر بارش‌ها با ترکیبی از تاخیرهای (t-1)، (t-2)، (t-12) و (t-36) را شبیه‌سازی کرد. مقادیر شاخص عملکرد و ضریب همبستگی برای ANFIS 6 در وضعیت آزمون به ترتیب برابر با $۳۷/۰۲۹$ و $۰/۶۱۲$ بودند.

مدل مقادیر R و VAF در وضعیت آزمون نیز به ترتیب برابر با $۰/۴۸۴$ و $۲۳/۲۷۰$ بودند. لازم به ذکر است که مدل ANFIS 4 مقادیر بارش‌ها را توسط تاخیرهای (t-1)، (t-2) و (t-12) شبیه‌سازی کرد. برای مدل مذکور شاخص‌های آماری R و VAF برای وضعیت آزمون به ترتیب مساوی با $۰/۴۷۱$ و $۲۲/۱۱۹$ تخمین زده شدند. این در حالی است که مقادیر تابع هدف توسط مدل ANFIS 5 با استفاده از تاخیرهای شماره (t-1)، (t-2) و (t-12)



شکل ۴- شاخص‌های آماری برای نتایج شبیه‌سازی بارش توسط توابع عضویت مختلف در وضعیت‌های آموزش و آزمون



شکل ۵- مقایسه مقادیر بارش‌های شبیه‌سازی شده توسط توابع عضویت برتر با مقادیر مشاهده‌ای


مدل ANFIS 5 بهترین عملکرد را از لحاظ دقت و همبستگی از خود نشان داد. این در حالی بود که مدل‌های ANFIS 4، ANFIS 3 و ANFIS 2 از لحاظ عملکرد به ترتیب مدل‌های شماره سوم،

بر اساس شکل ۶، مدل ANFIS 1 در هر دو وضعیت آموزش و آزمون مقادیر تابع هدف را با بیشترین مقدار خطا و کمترین همبستگی شبیه‌سازی نمود. در مقابل، بعد از مدل ANFIS 6،

چهارم و پنجم بودند.

علاوه بر این، با اجرای تابع خود همبستگی برای داده‌های بارندگی ماهانه در شهر بابلسر، مهمترین تاخیرها به صورت تاخیرهای ۱، ۲ می باشند. علاوه بر این، با توجه به مشاهده روند

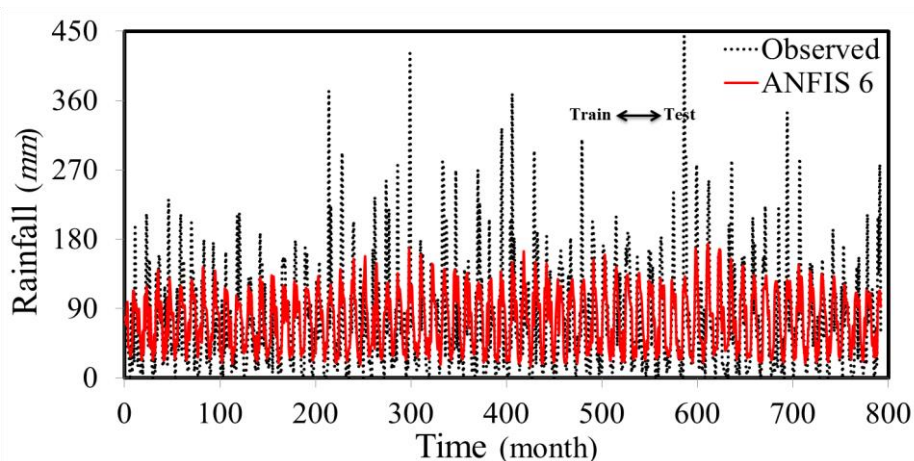
ماهانه تغییرات، اثر تاخیر ۱۲ نیز در نظر گرفته می شود. علاوه بر این، اثر تاخیرهای فصلی بیش از ۱۲، مانند ۲۴ و ۳۶ به صورت مدل های ۵ و ۶، در نظر گرفته می‌شود.



شکل ۶- نتایج شاخص‌های آماری مختلف برای کلیه مدل‌های ANFIS در وضعیت‌های آموزش و آزمون

(36) شبیه‌سازی نمود که این تاخیرها نیز به‌عنوان موثرترین تاخیرها معرفی شدند. به عبارت دیگر، تاخیرهای انتخاب شده همان تاخیرهای موثر داده‌های سری زمانی هستند که با استفاده از تابع خود همبستگی شناسایی و در مطالعه حاضر گزارش شده‌اند.

در شکل (۷) مقایسه مقادیر بارش‌های شبیه‌سازی شده توسط مدل برتر ANFIS با مقادیر مشاهداتی قابل مشاهده است. با تجزیه و تحلیل انجام شده مشخص شد که مدل ANFIS 6 دارای بیشترین دقت و بالاترین همبستگی است و این مدل به‌عنوان مدل برتر معرفی می‌شود. علاوه بر آن، مدل مذکور مقادیر تابع هدف را توسط تاخیرهای شماره (t-1)، (t-2)، (t-12) و (t-




شکل ۷- مقایسه مقادیر بارش‌های شبیه‌سازی شده توسط مدل برتر ANFIS با مقادیر مشاهداتی

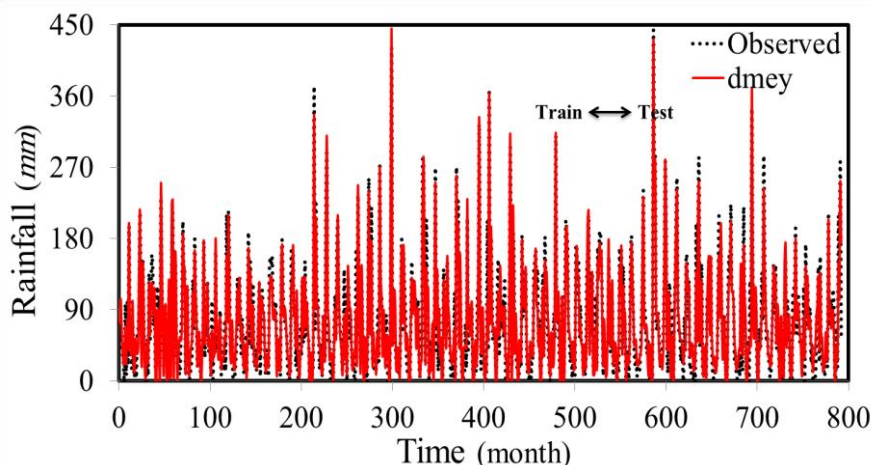
موجک‌های مادر

شاخص‌های آماری R ، MAE و SI برای آن به ترتیب برابر با ۰/۸۹۹، ۲۳/۶۲۷ و ۰/۴۲۰ تخمین زده شدند. برای $coif$ در وضعیت آزمون، مقادیر R ، MAE و SI به ترتیب مساوی با ۰/۹۰۵، ۲۳/۹۵۳ و ۰/۴۰۸ محاسبه شدند. بر اساس نتایج شبیه‌سازی مقدار بارندگی، در میان کلیه اعضای مختلف خانواده موجک عضو $dmey$ به‌عنوان بهترین عضو این خانواده معرفی شد. برای آن شاخص‌های آماری R ، MAE و SI نیز به ترتیب برابر با ۰/۹۴۹، ۱۷/۴۷۴ و ۰/۴۰۸ تخمین زده شدند. لازم به ذکر است که برای شرایط آزمون $bior$ مقادیر شاخص‌های R ، SI و MAE به ترتیب برابر با ۰/۸۸۰، ۰/۴۵۴ و ۲۳/۹۵۳ بودند. بنابراین، با توجه به نتایج کلیه اعضای خانواده‌های موجک، عضو $dmey$ به‌عنوان 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 موجک مادر برتر با مقادیر مشاهداتی در شکل ۹ قابل مشاهده است.

در این بخش به بررسی خانواده‌های مختلف تبدیل موجک پرداخته می‌شود. به طور کلی، تبدیل موجک دارای خانواده‌هایی با عنوان داوبیچیز (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 ۸ نتایج شاخص‌های آماری برای اعضای برتر خانواده‌های مختلف موجک قابل مشاهده است. به‌عنوان مثال در وضعیت آزمون برای خانواده $haar$ مقادیر شاخص‌های آماری R ، MAE و SI به ترتیب برابر با ۰/۷۸۶، ۲۹/۲۲۴ و ۰/۵۹۲ بودند. این در حالی است که در شرایط آزمون موجک مادر db شناسایی شد و مقادیر R ، MAE و SI برای آن به ترتیب مساوی با ۰/۸۹۹، ۲۳/۶۲۴ و ۰/۴۲۰ بدست آمدند. علاوه بر این، برای sym در وضعیت آزمون



شکل ۸- شاخص‌های آماری برای نتایج شبیه‌سازی بارش توسط خانواده‌های مختلف موجک در وضعیت‌های آموزش و آزمون

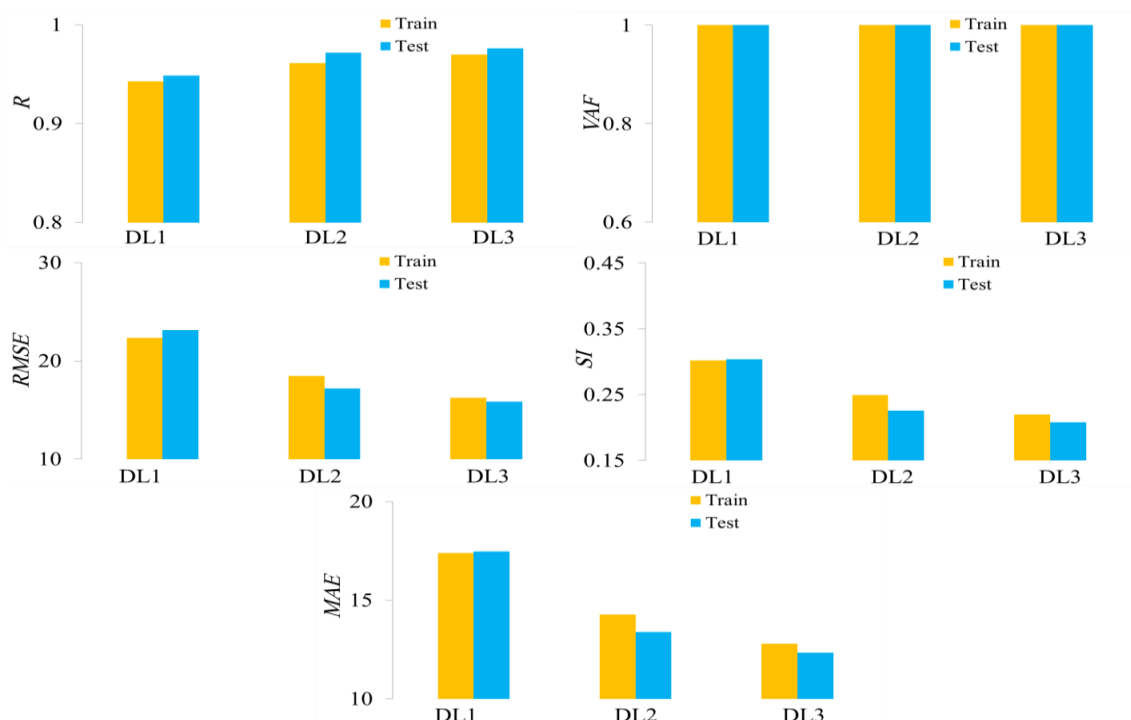


شکل ۹- مقایسه مقادیر بارش‌های شبیه‌سازی شده توسط موجک مادر برتر با مقادیر مشاهداتی


به شکل قابل ملاحظه‌ای افزایش داده است. به‌عنوان مثال، ضریب همبستگی برای وضعیت آموزش هر سه سطح تجزیه DL 1، DL 2 و DL 3 به ترتیب مساوی با ۰/۹۴۳، ۰/۹۶۱ و ۰/۹۷۰ هستند. این در حالی است که برای شرایط آزمون، مقدار VAF برای سطوح تجزیه DL 1، DL 2 و DL 3 به ترتیب برابر با ۰/۹۴۶، ۰/۹۴۵ و ۰/۹۵۲ بدست آمده‌اند. با توجه به نتایج شبیه‌سازی-ها، مدل ترکیبی WANFIS با سطح تجزیه DL 2 دارای بیشترین دقت و کمترین خطا است. بنابراین این مدل با این سطح تجزیه به‌عنوان مدل برتر هوش مصنوعی جهت تخمین بارش دراز مدت شهر بابلسر انتخاب می‌شود.

مدل ترکیبی (WANFIS)

در مطالعه حاضر، ابتدا شبکه انفیس بهینه‌سازی شد و در گام بعدی این شبکه بهینه‌سازی شده با تبدیل موجک ترکیب شد. در ادامه مدل برتر با همان 6 ANFIS با موجک مادر dmey ترکیب شده و مدل ترکیبی WANFIS توسعه داده می‌شود. سپس این مدل هیبریدی برای سه سطح تجزیه مختلف^۱ (DL) مورد بررسی قرار می‌گیرد. نتایج این سه سطح تجزیه مختلف اعم شاخص‌های آماری محاسبه شده و مقایسه مقادیر شبیه‌سازی شده با مشاهداتی در شکل‌های ۱۰ و ۱۱ به‌تصویر کشیده شده است. با توجه به نتایج شبیه‌سازی‌ها، تبدیل موجک دقت شبکه انفیس را



شکل ۱۰- نتایج شاخص‌های آماری برای وضعیت‌های آموزش و آزمون سطوح تجزیه مختلف مدل ترکیبی برتر



شکل ۱۱- مقایسه بارش‌های شبیه‌سازی شده و مشاهداتی برای سطح تجزیه برتر

با استفاده از تابع خود همبستگی تاخیرهای موثر داده‌های سری زمانی معرفی گردیدند. با استفاده از این تاخیرها شش مدل انفیس تعریف شد. مهمترین نتایج این پژوهش به صورت زیر خلاصه می‌شود:

- تعداد بهینه توابع عضویت شبکه انفیس مساوی با سه انتخاب گردید.
- موجک مادر بهینه برای شبیه‌سازی مقادیر بارش معرفی شدند. با توجه به نتایج شبیه‌سازی‌ها، $dmey$ به‌عنوان موجک مادر بهینه برای تخمین بارش معرفی گردید.
- مدل برتر برای تخمین بارش معرفی شد. این مدل برای سه سطح تجزیه مختلف مورد ارزیابی قرار گرفت که نشان داده شد این مدل مقادیر تابع هدف را با دقت بسیار خوبی شبیه‌سازی کرد. به‌عنوان مثال، برای وضعیت آزمون این مدل، مقادیر $RMSE$ ، MAE و VAF برای تخمین رواناب به ترتیب مساوی با $۱۷/۱۹۷$ ، $۱۳/۳۸۷$ و $۹۴/۴۵۵$ محاسبه شدند.
- نتایج این مطالعه نشان داد که تبدیل موجک دقت مدل‌سازی را به شکل قابل توجهی افزایش داد.
- تحلیل حساسیت نشان داد که تاخیرهای $(t-1)$ ، $(t-2)$ ، $(t-36)$ و $(t-12)$ موثرترین تاخیرهای داده‌های سری زمانی بارش بودند.

یکی از مهمترین محدودیت‌های مطالعه حاضر، عدم ارائه یک رابطه صریح جهت تخمین بارندگی در آینده است. توصیه می‌شود در مطالعات آتی از سایر الگوریتم‌های هوش مصنوعی و بهینه‌سازی استفاده شود.

"هیچ‌گونه تعارض منافع بین نویسندگان وجود ندارد"

همان‌گونه که از شکل ۱۰ مشاهده می‌شود، بعد از سطح تجزیه شماره ۳ ($DL=3$)، سطح تجزیه شماره ۲ ($DL=2$) بهترین عملکرد را از خود نشان داد. به بیان دیگر، این سطح تجزیه از لحاظ دقت و همبستگی در جایگاه دوم قرار داشت. علاوه بر آن، سطح تجزیه شماره ۱ ($DL=1$) در میان این سه سطح تجزیه معرفی شده از بدترین عملکرد برخوردار بود. به عبارت دیگر، $DL=1$ دارای بیشترین خطا و کمترین همبستگی با مقادیر مشاهداتی بود.

اخیرا مطالعات بسیاری نشان داده‌اند که تبدیل موجک عملکرد مدل‌های هوش مصنوعی را به شکل محسوسی بهبود بخشیده است (Nourani et al. 2014; Poursaeid et al. 2021). نتایج این مطالعه نشان داد که تبدیل موجک توانایی مناسبی در تجزیه داده‌های سری زمانی دارد. علاوه بر این، تبدیل مذکور دقت مدل انفیس را به شکل قابل ملاحظه‌ای افزایش داد. به‌عنوان مثال، شاخص عملکرد (VAF) مدل برتر ANFIS در شرایط آزمون مساوی با $۳۷/۰۲۹$ محاسبه گردید. این در حالی است که شاخص عملکرد مدل ترکیبی WANFIS در وضعیت آزمون برابر با $۹۷/۴۵۵$ محاسبه گردید. همچنین، تحلیل حساسیت نشان داد که تاخیرهای شماره $(t-1)$ ، $(t-2)$ ، $(t-12)$ و $(t-36)$ به‌عنوان موثرترین تاخیرهای داده‌های سری زمانی بارش شهر بابلسر شناسایی شدند.

نتیجه‌گیری

در این مطالعه، داده‌های دراز مدت سری زمانی بارش شهر بابلسر توسط یک مدل بهینه‌یافته هوش مصنوعی شبیه‌سازی شد. برای تعریف مدل هوش مصنوعی مذکور شبکه انفیس و تبدیل موجک با هم دیگر ترکیب شدند و مدل ترکیبی توسعه داده شد. سپس

REFERENCES

Azad, A., Manoochehri, M., Kashi, H., Farzin, S., Karami, H., Nourani, V., & Shiri, J. (2019).

Comparative evaluation of intelligent algorithms to improve adaptive neuro-fuzzy inference system

- performance in precipitation modelling. *Journal of Hydrology*, 571, 214-224.
- Azimi, H., Bonakdari, H., Ebtahaj, I., & Michelson, D. G. (2018). A combined adaptive neuro-fuzzy inference system–firefly algorithm model for predicting the roller length of a hydraulic jump on a rough channel bed. *Neural Computing and Applications*, 29(6), 249-258.
- Babaali, H.R., & Dehghani, R. (2017). Compare intelligent models to Estimate monthly Precipitation Kakareza Basian, Iranian journal of Ecohydrology, 4(1), 1-11. doi: 10.22059/ije.2017.60911.
- Ghorbani, M., Azani, A., & Mahmoudi Vanolya, S. (2015). Rainfall-Runoff Modeling Using Hybrid Intelligent Models. *Iran Water Resources Research*, 11(2), 146-150.
- Jang JSR. 1993 ANFIS: adaptive-network-based fuzzy inference system. *IEEE Trans. Syst. Manag. Cyber.*, 23(3): 665-685.
- Khalili, N., Khodashenas, S.R., Davari, K., & Mousavi Bayegi, M. (2008). Prediction of daily precipitation using artificial neural networks, case study: synoptic station of Mashhad. *Watershed research*, 89-99.
- Maqsood, I., Khan, M.R., & Abraham, A. (2004). An ensemble of neural networks for weather forecasting. *Neural Computing & Applications*, 13(2), 112-122.
- Mehr, A. D., Nourani, V., Khosrowshahi, V. K., & 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.
- Mekanik, F., Imteaz, M. A., Gato-Trinidad, S., & Elmahdi, A. (2013). Multiple regression and Artificial Neural Network for long-term rainfall forecasting using large scale climate modes. *Journal of Hydrology*, 503, 11-21.
- Mendel, J. M. (2017). Uncertain rule-based fuzzy systems. In *Introduction and new directions* (p. 684). Springer International Publishing.
- Mislan, H., Hardwinarto, S., & Sumaryono, M. A. (2015). Rainfall monthly prediction based on artificial neural network: a case study in Tenggara Station, East Kalimantan-Indonesia. *Procedia Computer Science*, 59, 142-151.
- Nasseri, M., Asghari, K., & 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., Kisi, O. (2014). Applications of hybrid wavelet–Artificial Intelligence models in hydrology: A review. *Journal of Hydrology* 514: 358–377.
- Poursaeid, M., Mastouri, R., Shabanlou, S., & Najarchi, M. (2021). Modelling qualitative and quantitative parameters of groundwater using a new wavelet conjunction heuristic method: wavelet extreme learning machine versus wavelet neural networks. *Water and Environment Journal*, 35(1), 67-83.
- Riad, S., Mania, J., Bouchaou, L., & Najjar, Y. (2004). Rainfall-runoff model using an artificial neural network approach. *Mathematical and Computer Modelling*, 40(7-8), 839-846.
- Xiang, Y., Gou, L., He, L., Xia, S., & Wang, W. (2018). A SVR–ANN combined model based on ensemble EMD for rainfall prediction. *Applied Soft Computing*, 73, 874-883.