



"مقاله پژوهشی"

بهینه‌سازی شبکه ANFIS با استفاده از تبدیل موجک برای شبیه‌سازی بارش دراز مدت شهر رشت

ابراهیم شهنازی^۱، بهروز یعقوبی^۲ و سعید شعبانلو^۳

۱- دانشجوی دکتری منابع آب، گروه مهندسی آب، واحد کرمانشاه، دانشگاه آزاد اسلامی، کرمانشاه، ایران
 ۲- استادیار گروه مهندسی آب، واحد کرمانشاه، دانشگاه آزاد اسلامی، کرمانشاه، ایران، (نویسنده مسؤل: behrouz.yaghoubi.h@gmail.com)
 ۳- دانشیار گروه مهندسی آب، واحد کرمانشاه، دانشگاه آزاد اسلامی، کرمانشاه، ایران
 تاریخ دریافت: ۱۳۹۸/۴/۹ تاریخ پذیرش: ۱۴۰۰/۱/۱۸ صفحه: ۱۹۳ تا ۲۰۴

چکیده مسوط

مقدمه و هدف: 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. هدف از این مطالعه تخمین بارش دراز مدت شهر رشت توسط یک مدل ترکیبی ANFIS و تبدیل موجک می باشد.

مواد و روش‌ها: در این مطالعه، بارش شهر رشت در یک بازه زمانی دراز مدت ۶۲ ساله از سال ۱۹۵۶ تا ۲۰۱۷ توسط یک مدل ترکیبی بهینه‌یافته هوش مصنوعی شبیه‌سازی شد. به‌عبارت دیگر، برای بهبود عملکرد مدل ANFIS از تبدیل موجک بهره‌گرفته شد و مدل ترکیبی WANFIS تعریف گردید. در ابتدا، با استفاده از تابع خود همبستگی تاخیرهای موثر داده‌های سری‌های زمانی شناسایی شدند. سپس با استفاده از این تاخیرها، برای هر یک از مدل‌های ANFIS و WANFIS هشت مدل توسعه داده شد. لازم به ذکر است که برای آموزش مدل‌های هوش مصنوعی از داده‌های ۴۲ سال و برای آزمون آنها از داده‌های ۲۰ سال استفاده گردید. در ادامه، بهینه‌ترین تعداد توابع عضویت مدل ANFIS برابر با دو انتخاب شد.

یافته‌ها: نتایج مدل‌های ANFIS 1 تا ANFIS 8 مورد بررسی قرار گرفتند. سپس اعضای مختلف خانواده موجک برای بهینه‌سازی مدل ANFIS مورد ارزیابی قرار گرفتند. به‌عنوان بهترین عضو خانواده موجک برای بهبود عملکرد مدل ANFIS معرفی گردید. مقایسه مدل‌های ANFIS و WANFIS نشان داد که تبدیل موجک عملکرد مدل ANFIS را به شکل قابل ملاحظه‌ای افزایش داد. سپس نتایج مدل‌های ترکیبی WANFIS تجزیه و تحلیل شدند که مدل WANFIS 8 به‌عنوان مدل برتر معرفی شد. این مدل مقادیر بارندگی را با دقت قابل قبولی تخمین زد. به‌عنوان مثال، مقادیر R، MARE و RMSE برای مدل برتر به ترتیب مساوی با ۰/۹۶۱، ۰/۸۵۵ و ۲۴/۵۱۰ میلیمتر محاسبه شدند.

نتیجه‌گیری: نتایج نشان داد که تاخیرهای شماره (t-1)، (t-2)، (t-3) و (t-2) موثرترین تاخیرها برای تخمین بارش درازمدت شهر رشت توسط مدل ترکیبی WANFIS بودند.

واژه‌های کلیدی: بارش دراز مدت، بهینه‌سازی، تبدیل موجک، شبیه‌سازی، شهر رشت، ANFIS

مقدمه

تخمین و پیش‌بینی الگوی بارش در نواحی مختلف جهان به 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، لی و همکاران (۱۱)، ونگ و همکاران (۲۴)، توس و همکاران (۲۲)، ونگ و همکاران (۲۵)، ناصری و همکاران (۱۷)، ناگامولا و همکاران (۱۶) و کومار و جها (۱۰) مقادیر بارش در بازه‌های زمانی مشخص در نقاط مختلف جهان را با استفاده از تکنیک‌های متفاوت هوش مصنوعی و محاسبات نرم مدل‌سازی نمودند. در ادامه، اکرمی و همکاران (۴) 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 (۱۵) 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. شفیعی و همکاران (۲۱) 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 (۱۲) 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 (۲۰) 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.

دابلال و موری (۸) داده‌های سری زمانی بارش در یک بازه ۱۴ ساله حوضه واقع در شرق کشور هندوستان را توسط مدل ساریما^۱ در بازه‌های زمانی روزانه، هفتگی و ماهانه تخمین زدند. آنها تاخیرهای 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 (۲۷) با استفاده از الگوریتم کرم شبتاب، 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 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 (۲۶) 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. نشان داده شد که شبکه عصبی مصنوعی مقادیر بارش در بازه زمانی دراز مدت با دقت بهتری شبیه‌سازی کرد. آزاد و همکاران (۵) 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 (۶) 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. همچنین، مهر و همکاران (۱۳) یک مدل ترکیبی بهینه یافته 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.

علاوه بر این، خلیلی و همکاران (۲) 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، به عنوان مثال، مقدار ضریب همبستگی مدل برتر آنها مساوی با ۰/۹۲ محاسبه شد. در ادامه، قربانی و همکاران (۳) 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 (۱) مقادیر بارش ماهانه در یک بازه زمانی ۱۰ ساله برای حوضه آبریز دشت کاکارضا استان لرستان را با استفاده از مدل برنامه نویسی بیان ژن تخمین زدند. آنها نشان دادند که ضریب همبستگی مدل عددی مذکور برابر با ۰/۹۷۸ بود. بنابراین مرور مطالعات گذشته نشان می‌دهد که مدل‌های هوش مصنوعی توانایی خوبی در شبیه‌سازی مقدار بارندگی داشت. این مدل‌ها ابزاری قوی و ارزان جهت شبیه‌سازی پارامترهای هیدرولوژیکی پیچیده مانند بارش به‌شکل گسترده‌ای مورد استفاده قرار گرفته‌اند. نودری و توکلی (۱۹) توسط مدل‌های ماشین بردار پشتیبان و تبدیل موجک، یک مدل ترکیبی هوش مصنوعی برای تخمین مقادیر بارش شهر همدان در طی یک دوره ۲۵ ساله ارائه دادند. ولی‌پور و همکاران (۲۳) شبکه باران‌سنجی با استفاده از آنتروپی اطلاعات و الگوریتم کرم شبتاب در حوضه شرق دریاچه ارومیه بهینه‌سازی کردند. از یک طرف، به دلیل تغییر اقلیم و کاهش بارندگی در نواحی مختلف کشور ایران، تخمین و مدل‌سازی بارش دراز مدت در حوضه‌های مختلف از اهمیت بسزایی برخوردار است. علاوه بر این، محققین مختلف با استفاده از مدل‌های ریاضی و عددی متنوع مبادرت به شبیه‌سازی این پدیده در نواحی گوناگون کرده‌اند.

از طرف دیگر، روش‌های هوش مصنوعی بسیار منعطف بوده و توانایی شبیه‌سازی پدیده‌های مختلفی از جمله بارندگی را دارند. این روش‌ها از دقت مناسبی برخوردار هستند و باعث صرفه‌جویی در هزینه‌های مطالعات میدانی و آزمایشگاهی می‌شوند. بنابراین به دلیل این مزایا روز به‌روز بر محبوبیت مدل‌های هوش مصنوعی افزوده می‌شود.

در این مطالعه، برای اولین بار بارش دراز مدت شهر رشت واقع در شمال ایران در یک بازه زمانی ۶۲ ساله توسط یک مدل هوش مصنوعی ترکیبی تخمین زده شد و در انتها مدل برتر و موثرترین تاخیرها شناسایی شدند.

مواد و روش‌ها

منطقه مورد مطالعه

شهر رشت در ۴۹ درجه و ۳۶ دقیقه طول شرقی و ۳۷ درجه و ۱۶ دقیقه عرض شمالی واقع شده است. همچنین شهر رشت با مساحت ۱۸۰ کیلومتر مربع در زمینی مسطح و هموار به‌طور میانگین ۵ متر از سطح آب‌های آزاد قرار دارد. بارندگی‌ها در رشت بر پایه رژیم بارشی سواحل دریای خزر، عمدتاً متأثر از سامانه‌های پرفشار شمالی است. در این مطالعه، بارندگی ماهانه شهر رشت از سال ۱۳۳۴ تا ۱۳۹۶ در یک بازه زمانی ۶۲ ساله برای اعتبارسنجی نتایج مدل‌های هوش مصنوعی استفاده می‌شود. در جدول ۱ مشخصات هیدرولوژیکی ایستگاه رشت مرتب شده است. موقعیت جغرافیایی شهر رشت در شکل ۱ به‌تصویر کشیده شده است.

جدول ۱- مشخصات هیدرولوژیکی ایستگاه رشت

اختلاف حداکثر و حداقل دمای سالانه	Table 1. Hydrological characteristics of Rasht Station
حداقل دمای گزارش شده	۹/۳ درجه
حداکثر دمای گزارش شده	۱۹- درجه
میانگین سالانه بارندگی	۴۰ درجه
کم‌باران‌ترین سال	۱۳۵۹ میلی‌متر
پر باران‌ترین سال	سال ۱۹۷۱ با ۹۵۷/۸ میلی‌متر
تعداد روزهای بارندگی در رشت	سال ۱۹۷۲ با ۱۹۶۷/۶ میلی‌متر
حداکثر بارندگی در ۲۴ ساعت	۱۳۸ روز
	۱۷۰ میلی‌متر



شکل ۱- موقعیت جغرافیایی ناحیه مورد مطالعه
Figure 1. Geographical location of study area

در شکل ۲ ارائه شده است. این شبکه از پنج لایه به شرح زیر تشکیل شده است.

لایه اول، گره‌های ورودی: در این لایه درجه عضویت گره‌های ورودی به بازه‌های مختلف فازی با استفاده تابع عضویت مشخص می‌شود.

$$Q_i^1 = \mu_{A_i}(x) \quad (1)$$

$$Q_i^1 = \mu_{A_i-z}(x) \quad (2)$$

عوامل هر گره، تعیین کننده شکل تابع عضویت آن گره است. تابع عضویت مجموعه‌های فازی استفاده شده در این مطالعه، به شکل گوسی است که به صورت زیر تعریف می‌شود:

$$\mu_{A_i}(x) = e^{-\frac{(x-c)^2}{2\sigma^2}} \quad (3)$$

که در این رابطه، x مقدار ورودی به گره i می‌باشد و $S_1 = \{c, \sigma\}$ عوامل تطبیقی نامیده می‌شوند.

مدل‌های عددی

سیستم استنتاج فازی عصبی تطبیقی (ANFIS)

ایجاد یک سیستم فازی قدرتمند نیازمند به سعی و خطا برای رسیدن به بهترین کارایی ممکن است. یکی از سیستم‌های فازی عصبی معروف برای تخمین توابع، (جانگ (۹)) ANFIS است. ساختار ANFIS شامل قابلیت‌های استنتاج سیستم فازی و انطباق‌پذیری شبکه عصبی است. مدل ANFIS روشی برای بهبود بخشیدن به قوانین سیستم فازی با کمک الگوریتم‌های آموزشی در شبکه‌های عصبی است. در مقایسه با شبکه عصبی مصنوعی، ANFIS به علت تنظیم پذیری پارامترهای سیستم فازی، سریع‌تر آموزش می‌بیند و همچنین دقت بیشتری دارد زیرا یک سیستم فازی سوگنو را در یک ساختار عصبی اجرا می‌کند (مندال (۱۴)). شبکه ANFIS با دو قانون و دو ورودی x و y، و یک خروجی f، دارای ساختار پنج لایه می‌باشد. ساختار یک شبکه ANFIS

که در این رابطه، \bar{w}_i درجه فعالیت بهینه شده قانون i ام است.

لایه چهارم، گره‌های نتیجه: در این لایه، خروجی هر گره به صورت زیر محاسبه می‌شود:

$$O_i^4 = \bar{w}_i f_i = \bar{w}(p_i + q_i + r_i) \quad (6)$$

که مجموعه $S_2 = (p_i + q_i + r_i)$ عامل متعاقب نامیده می‌شوند.

لایه پنجم، گره‌های خروجی: در این لایه مقدار خروجی نهایی هر گره به صورت زیر محاسبه می‌شود:

$$O_i^5 = \sum_{i=1}^n \bar{w}_i f_i \quad (7)$$


لایه دوم، گروه‌های قاعدی: در این لایه هر گره فعالیت یک قانون را محاسبه می‌کند:

$$Q_i^2 = \mu_{A_i}(x) \cdot \mu_{B_i}(y), \quad i=1,2 \quad (4)$$

که در این رابطه $\mu_{A_i}(x)$ درجه عضویت x در مجموعه A_i و $\mu_{B_i}(y)$ درجه عضویت y در مجموعه B_i است.

لایه سوم، گره‌های ثابت: گره‌های این لایه ثابت هستند. در این گره، نسبت درجه فعالیت قانون i ام به مجموعه فعالیت کلیه قوانین، محاسبه می‌شود:

$$O_i^3 = \bar{w}_i = \frac{w_i}{\sum_{i=1}^n w_i} \quad (5)$$




شکل ۲- ساختار یک شبکه ANFIS با دو ورودی
Figure 2. Structure of an ANFIS network with two inputs

تبدیل موجک روش مناسبی برای تحلیل و بدون نوسان کردن داده‌ها می‌باشد. به عبارت دیگر، موجک‌ها توابع ریاضی هستند که یک بیان زمان-مقیاس از سری‌های زمانی و نسبت‌های آن ارائه می‌دهند که این بیان برای تحلیل برای سری‌های زمانی غیر ایستا مفید است. مزیت تبدیل موجک، توانایی در به دست آوردن اطلاعات زمانی، مکانی و فرکانسی یک سیگنال است (شکل ۳) (۱۸).

تبدیل موجک

موجک یک موج کوچک است که انرژی آن در ناحیه کوچکی متمرکز شده و ابزار مناسب برای بررسی پدیده‌های گذرا است. موجک، دارای نوسان حداقل بوده که به سمت صفر نزول می‌کند و این نزول بایستی در جهات مثبت و منفی واقع در دامنه‌اش محدود شود. این مشخصه باعث می‌شود که موج انعطاف پذیر بوده و مانند یک تابع رفتار کند. در واقع،



شکل ۳- شماتیک عملکرد تبدیل موجک
Figure 3. Schematic of wavelet transform performance

تبدیل موجک وجود دارد، پیوسته و گسسته. تبدیل گسسته موجکی جهت پردازش و تحلیل سری‌های زمانی بهتر از تبدیل پیوسته می‌باشد زیرا داده‌های تبدیل یافته با تبدیل موجک گسسته، اجزای اضافی نداشته و بنابراین تبدیل

با استفاده از این تبدیل می‌توان سیگنال اصلی را به سیگنال‌های پایه سازنده‌اش، تجزیه کرد. انتقال موجک به طور ساده به مفهوم به تاخیر انداختن یا جلو انداختن موجک و بیان کننده موقعیت موجک روی محور زمان است. دو نوع

قرار می‌گیرند و بارندگی ماهانه در ۲۰ سال باقیمانده برای آزمون مدل‌های عدی ANFIS و WANFIS بهره گرفته می‌شوند. پس از دسته‌بندی داده‌ها و تعیین داده‌های آموزش، باید اثر تأخیر داده‌های سری زمانی مورد ارزیابی قرار گیرند. به عبارت دیگر، جهت و مقدار همبستگی تأخیرهای داده‌های سری زمانی با یکدیگر مورد بررسی قرار می‌گیرند. بنابراین، با استفاده از تابع خود همبستگی^۲ (ACF)، اقدام به بررسی تأخیرهای داده‌های سری زمانی مختلف می‌شود (شکل ۴). با توجه به این نمودار، اثر قابل توجه تأخیرهای ۱، ۲ و ۳ $[(t-1), (t-2), (t-3)]$ قابل مشاهده است. همچنین، به دلیل دوره‌ای بودن بارش، تأخیر ۱۲ یا $(t-12)$ نیز اثر قابل ملاحظه‌ای دارد. به‌طور کلی داده‌های سری زمانی دارای تأخیرهایی هستند $[(t-1), (t-2), \dots, (t-12)]$ و این تأخیرها در یک بازه زمانی مشخص تکرار می‌شوند. به‌عنوان مثال، تأخیرهای داده‌های بارش با ۱۲ تأخیر که متناظر با تعداد ماه‌های سال هستند مشخص شده‌اند.

در مطالعه حاضر، مقادیر بارندگی به‌عنوان تابع هدف و داده‌های سری زمانی به‌عنوان ورودی‌های مدل هوش مصنوعی ترکیبی استفاده شدند. به بیان دیگر، مقادیر بارش توسط تأخیرهای داده‌های سری زمانی مدل‌سازی شدند و تأثیر سایر پارامترهای اقلیمی در نظر گرفته نشدند. از این رو، ترکیبات مختلف برای مدل‌های هشت‌گانه به‌شکل زیر، پیشنهاد می‌شود:

معکوس را می‌توان برای هر دسته از داده‌های زمان بسامد، به کاربرد. موجک گسسته به صورت زیر بیان می‌شود:


$$g_{m,n}(t) = \frac{1}{\sqrt{a_0^m}} g\left(\frac{t-nb_0a_0^m}{a_0^m}\right) \quad (8)$$

در رابطه فوق، m و n اعداد صحیح هستند که به ترتیب میزان مقیاس و انتقال موجک را کنترل می‌نمایند. همچنین a_0 گام مقیاس کوچک ویژه برای پارامتر انتقال $(a_0 > 1)$ و b_0 پارامتر انتقال موقعیت $(b_0 > 0)$ می‌باشند.

پیش‌بینی بارش با استفاده از WANFIS^۱

پیش از شروع مدل‌سازی مقدار بارش در ماه‌های مختلف با استفاده از WANFIS، داده‌ها به دو دسته آموزش و آزمون تقسیم‌بندی می‌شوند. کل داده‌های استفاده شده در این مطالعه مربوط به ۷۴۴ ماه در بازه زمانی ۱۳۳۴ تا ۱۳۹۶ است. برای آموزش و آزمون مدل‌های هوش مصنوعی داده‌ها به دو دسته با نسبت‌های ۵۰ درصد برای آموزش و ۵۰ درصد برای آزمون، ۶۰ درصد برای آموزش و ۴۰ درصد برای آزمون، ۷۰ درصد برای آموزش و ۳۰ درصد برای آزمون و ۸۰ درصد برای آموزش و ۲۰ درصد برای آزمون تقسیم‌بندی شدند. مدل‌های هوش مصنوعی در شرایطی که این نسبت به ۷۰ درصد برای آموزش و ۳۰ درصد برای آزمون تقسیم شدند، بهترین عملکرد را از خود نشان دادند. جهت آموزش مدل، ۴۹۲ ماه برای آموزش مدل مورد استفاده

Model 1	$h(t) = f(h(t-1))$
Model 2	$h(t) = f(h(t-1), h(t-2))$
Model 3	$h(t) = f(h(t-1), h(t-3))$
Model 4	$h(t) = f(h(t-1), h(t-12))$
Model 5	$h(t) = f(h(t-1), h(t-2), h(t-3))$
Model 6	$h(t) = f(h(t-1), h(t-2), h(t-12))$
Model 7	$h(t) = f(h(t-1), h(t-3), h(t-12))$
Model 8	$h(t) = f(h(t-1), h(t-2), h(t-3), h(t-12))$



شکل ۴- دیاگرام ACF برای داده‌های بخش آموزش مدل
Figure 4. ACF diagram for learning section data

مدل‌سازی، باید نوع تابع موجک و سطح تجزیه آن نیز تعیین شود. از نکات اساسی در انتخاب موجک مادر، نوع سری زمانی

پس از تعیین نمونه‌های مورد استفاده جهت آموزش مدل و همچنین بررسی ترکیبات ورودی مختلف، قبل از شروع به

$$AIC = n \cdot \log \left[\frac{1}{n} \sum_{i=1}^n (O_i - F_i)^2 \right] + 2k \quad (15)$$

در اینجا k برابر تعداد پارامترهای تخمین زده شده مورد استفاده در مدل عددی است. پارامتر ACI به‌عنوان یک معیار برای انطباق مناسب یک مدل آماری در نظر گرفته می‌شود. همچنین این شاخص به‌عنوان ابزاری برای انتخاب مدل استفاده می‌گردد و به طور همزمان پیچیدگی و دقت مدل عددی را توصیف می‌کند. لازم به ذکر است که نتایج مدل‌های هوش مصنوعی برای شرایط آزمون مورد ارزیابی قرار می‌گیرد.

نتایج و بحث

در ادامه، ابتدا تعداد بهینه 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 عضو بهینه شناسایی خواهد شد. در انتها، مدل‌های ترکیبی مورد ارزیابی قرار می‌گیرند و بهترین مدل هوش مصنوعی ترکیبی و موثرترین تاخیرها معرفی می‌شوند.

توابع عضویت (MF)

در این بخش به ارزیابی نحوه تاثیر تعداد توابع عضویت مدل ANFIS بر روی نتایج مدل‌سازی مورد بررسی قرار می‌گیرد. در ابتدا تعداد توابع عضویت مساوی با دو در نظر گرفته شد و با افزایش آن عملکرد مدل ANFIS با استفاده از شاخص‌های آماری مختلف مورد بررسی قرار گرفت. به‌عنوان مثال، برای شرایطی که تعداد توابع عضویت مساوی دو بود مقادیر $RMSE$ و $MARE$ به ترتیب مساوی با $۰/۵۱۴$ ، $۷۵/۶۸۶$ و $۲/۸۳۲$ به دست آمدند. علاوه بر این شاخص‌های آماری AIC و NSC برای این تعداد توابع عضویت به ترتیب برابر با $۱۰۹۰/۳۸۱$ و $-۱/۷۸۹$ تخمین زده شدند. لازم به ذکر است که با افزایش تعداد توابع عضویت دقت مدل ANFIS به شکل محسوس افزایش پیدا نکرد. به‌عنوان مثال، هنگامی که تعداد توابع عضویت مساوی با هفت در نظر گرفته شد، مقادیر شاخص‌های VAF ، $MARE$ و NSC به ترتیب مساوی با $۲۶/۸۹۲$ ، $۲/۸۱۹$ و $-۱/۴۰۶$ محاسبه شدند. بنابراین همان گونه 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 دو برای این مطالعه انتخاب شد. لازم به ذکر است که مقایسه شاخص‌های آماری مختلف برای تعداد توابع عضویت از دو تا هفت در شکل ۵ به تصویر کشیده شده است.

و طبیعت رخداد مورد نظر (در این مطالعه بارندگی) می‌باشد. در واقع، تابع موجک باید به نحوی انتخاب شود که از لحاظ شکل هندسی به خوبی بر منحنی سری زمانی مورد بررسی منطبق شود تا عمل نگاشت بین را با توانایی بالاتری انجام دهد. توابع موجک مادر مورد استفاده در این مطالعه به شرح db, haar, sym, coif, bior, dmeys می‌باشد. علاوه بر آن، جهت تعیین سطح تجزیه از رابطه زیر (۱۸) استفاده می‌شود:

$$l = \text{int}[\log(N)] \quad (9)$$

که l برابر است با سطح تجزیه، N تعداد نمونه‌ها در حالت آموزش و int قسمت صحیح مقدار l می‌باشد. با توجه به اینکه مقدار N برابر با ۵۰۴ است، بنابراین سطح تجزیه برابر با ۲ در نظر گرفته می‌شود.

معیارهای بررسی دقت مدل‌های عددی

در این مطالعه برای بررسی عملکرد و دقت مدل‌های عددی از شاخص‌های آماری مختلفی از جمله ضریب همبستگی (R)، شاخص عملکرد (VAF)، خطای مربعات میانگین ریشه ($RMSE$)، درصد خطای نسبی میانگین ($MARE$) و ضریب بهره‌وری نش ساتکلیف (NSC) به صورت زیر استفاده شده است:

$$R = \frac{\sum_{i=1}^n (F_i - \bar{F})(O_i - \bar{O})}{\sqrt{\sum_{i=1}^n (F_i - \bar{F})^2 \sum_{i=1}^n (O_i - \bar{O})^2}} \quad (10)$$


$$VAF = \left(1 - \frac{\text{var}(F_i - O_i)}{\text{var}(F_i)} \right) \times 100 \quad (11)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (F_i - O_i)^2} \quad (12)$$

$$MARE = \frac{1}{n} \sum_{i=1}^n \left(\frac{|F_i - O_i|}{O_i} \right) \quad (13)$$

$$NSC = 1 - \frac{\sum_{i=1}^n (O_i - F_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (14)$$


در اینجا O_i مقادیر مشاهداتی، F_i مقادیر پیش‌بینی شده به وسیله مدل‌های عددی، \bar{O} میانگین مقادیر مشاهداتی و n برابر تعداد مقادیر مشاهداتی هستند. شاخص‌های آماری معرفی شده، مقایسه همزمانی از میانگین و واریانس از مدل‌ها را ارائه نمی‌کنند. بنابراین شاخص اطلاعات آکیایی (AIC) برای مقایسه مقادیر برآورد شده با مقادیر مشاهداتی به صورت زیر معرفی می‌شود:



شکل ۵- شاخص‌های آماری برای نتایج شبیه‌سازی بارش توسط توابع عضویت مختلف
 Figure 5. Statistical indices for results of precipitation simulation by different membership functions

هدف تخمین زده شدند. این در حالی است که مقادیر تابع ANFIS 5 با استفاده از تاخیرهای شماره (t-1)، (t-2) و (t-3) محاسبه می‌شود. برای این مدل مقادیر *NSC* و *MARE* به ترتیب برابر با ۳/۲۱۸ و ۴/۰۲۳- تخمین زده شدند. مدل ANFIS 6 نیز مقادیر بارش‌ها با ترکیبی از تاخیرهای (t-1)، (t-2) و (t-12) را شبیه‌سازی کرد. مقادیر شاخص عملکرد و ضریب همبستگی برای ANFIS 6 به ترتیب برابر با ۲۵/۱۸۷ و ۰/۵۰۲ بودند. در مقابل مقادیر شاخص‌های آماری *RMSE*، *MARE* و *AIC* برای مدل ANFIS 7 به ترتیب مساوی با ۲/۷۷۶، ۷۶/۲۷۹ و ۱۰۸۰/۳۱۲ تخمین زده شدند. مدل ANFIS 7 توسط تاخیرهای (t-1)، (t-3) و (t-12) مقدار بارندگی را پیش‌بینی نمود و شاخص‌های آماری *R*، *NSC* و *VAF* برای آن به ترتیب برابر با ۰/۴۹۸، ۲۴/۸۴۰ و ۲/۰۵۵ محاسبه شدند. با توجه به نتایج مدل‌سازی‌ها، مقدار شاخص‌های آماری *RMSE*، *R* و *AIC* برای مدل ANFIS 8 نیز به ترتیب مساوی با ۷۵/۶۸۶، ۰/۵۱۴ و ۱۰۹۰/۳۸۱ به دست آمدند. مدل ANFIS 8 مقادیر بارش‌ها را با استفاده از کلیه تاخیرهای ورودی که شامل (t-1)، (t-2)، (t-3) و (t-12) بودند شبیه‌سازی کرد.


مدل‌های ANFIS
 در این قسمت دقت مدل‌های مختلف انفیس مورد سنجش قرار می‌گیرد. در شکل ۶ نتایج شاخص‌های آماری مختلف برای کلیه مدل‌های ANFIS قابل مشاهده است. همان‌گونه که در بخش‌های قبلی بیان شد، در این مطالعه بعد از شناسایی تاخیرهای مهم در داده‌های سری زمانی، هشت مدل ANFIS تعریف گردید. به‌عنوان مثال مدل ANFIS 1 مقادیر بارش‌ها را با استفاده از تاخیر (t-1) شبیه‌سازی کرد. برای این مدل، مقادیر شاخص‌های آماری ضریب همبستگی و شاخص عملکرد به ترتیب مساوی با ۰/۳۷۲ و ۱۳/۸۰۵ به دست آمدند. علاوه بر این، مقادیر *MARE*، *RMSE* و *AIC* برای مدل ANFIS 1 به ترتیب برابر با ۳/۱۸۰، ۸۱/۹۰۳ و ۱۰۷۳/۳۳۰ محاسبه شدند. در مقابل مدل ANFIS 2 مقادیر تابع هدف را توسط تاخیرهای (t-1) و (t-2) تخمین زد. برای این مدل مقادیر *VAF*، *AIC* و *RMSE* نیز به ترتیب برابر با ۱۴/۴۷۹، ۱۰۸۹/۴۴۹ و ۸۱/۶۰۴ محاسبه شدند. این در حالی است که مدل ANFIS 3 تابعی از تاخیرهای شماره (t-1) و (t-3) بود. برای این مدل مقادیر *MARE* و *NSC* نیز به ترتیب برابر با ۳/۲۱۸ و ۴/۰۲۳- بودند. لازم به ذکر است که مدل ANFIS 4 مقادیر بارش‌ها را توسط تاخیرهای (t-1) و (t-12) شبیه‌سازی کرد. برای مدل مذکور شاخص‌های آماری *R*



شکل ۶- شاخص‌های آماری برای نتایج شبیه‌سازی بارش توسط مدل‌های ANFIS
 Figure 6. Statistical indices for results of precipitation simulation by ANFIS models

(t-1)، (t-2)، (t-3) و (t-12) شبیه‌سازی نمود که این تاخیرها نیز به‌عنوان موثرترین تاخیرها معرفی شدند. در شکل ۷ نمودار پراکندگی و مقایسه بارش مشاهداتی با شبیه‌سازی شده مدل ANFIS 8 نشان داده شده است.

بر اساس نتایج مدل‌سازی‌ها، در میان کلیه مدل‌های ANFIS، مدل 8 به‌عنوان مدل برتر شناسایی گردید. این مدل مقادیر بارش دراز مدت شهر رشت را در مقایسه با سایر مدل‌ها با دقت بیشتری تخمین زد. علاوه بر آن، مدل مذکور مقادیر تابع هدف را توسط تاخیرهای شماره




شکل ۷- مقایسه بارش مشاهداتی با شبیه‌سازی شده برای مدل ANFIS برتر
Figure 7. Comparison of observed precipitation with simulated values for superior ANFIS model

اعضای خانواده کویفلتس نیز *coif2* به‌عنوان عضو برتر شناسایی گردید. برای این عضو خانواده موجک، مقادیر شاخص عملکرد و ضریب همبستگی به‌ترتیب مساوی با ۸۵/۹۸۵ و ۰/۹۲۷ محاسبه شدند. بر اساس نتایج شبیه‌سازی مقدار بارینگی، در میان کلیه اعضای مختلف خانواده موجک عضو *dmev* به‌عنوان بهترین عضو این خانواده معرفی شد. برای آن شاخص‌های آماری *NSC* و *RMSE* نیز به‌ترتیب برابر با ۰/۹۱۳ و ۲۴/۵۱۰ تخمین زده شدند. همچنین، مقادیر *R*، *MARE* و *AIC* برای *dmev* به‌ترتیب مساوی با ۰/۹۶۱، ۰/۸۵۵ و ۹۱۵/۷۸۴ به‌دست آمدند. لازم به‌ذکر است که *bior1.1* بهترین عضو خانواده بایورثوگونال شناسایی گردید. به‌بیان دیگر، برای این عضو خانواده بایورثوگونال مقادیر شاخص‌های آماری *R*، *NSC* و *MARE* به‌ترتیب برابر با ۰/۷۰۳، ۰/۱۳۸ و ۱/۴۶۰ بودند. بنابراین، با توجه به نتایج کلیه اعضای خانواده‌های موجک، عضو *dmev* به‌عنوان دقیق‌ترین عضو خانواده‌های موجک معرفی شد و در ادامه مطالعه این عضو برای شبیه‌سازی بارش دراز مدت شهر رشت مورد استفاده قرار گرفت.

خانواده‌های موجک

در این بخش به بررسی خانواده‌های مختلف تبدیل موجک پرداخته می‌شود. به‌طور کلی، تبدیل موجک دارای خانواده‌هایی با عنوان دایوچیز (*db*)، هار (*haar*)، سایملتس (*sym*)، کویفلتس (*coif*)، بایورثوگونال (*bior*) و دی میر (*dmev*) است. بر اساس تجزیه و تحلیل کلیه اعضای خانواده‌های مختلف تبدیل موجک مشخص شد که خانواده *dmev* 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 برای خانواده *haar* مقادیر شاخص‌های آماری *R*، *MARE* و *AIC* به‌ترتیب برابر با ۰/۷۰۳، ۱/۴۶۰ و ۱۱۴۲/۳۵۸ بودند. این در حالی است که برای دایوچیز، عضو برتر *db2* شناسایی شد و مقادیر *RMSE*، *NSC* و *MARE* برای آن به‌ترتیب مساوی با ۴۰/۱۸۲، ۰/۷۳۷ و ۱/۴۶۹ به‌دست آمدند. علاوه بر این، *sym2* به‌عنوان عضو برتر خانواده سایملتس معرفی شد که شاخص‌های آماری *VAF*، *AIC* و *RMSE* برای آن به‌ترتیب برابر با ۷۹/۲۵۴، ۴۰/۱۸۱ و ۱۰۳۴/۴۱۶ تخمین زده شدند. در میان کلیه




شکل ۸- شاخص‌های آماری برای نتایج شبیه‌سازی بارش توسط خانواده‌های مختلف موجک
Figure 8. Statistical indices for precipitation results simulated by different wavelet families

مدل‌های WANFIS


در این قسمت به تجزیه و تحلیل نتایج مدل‌های ترکیبی WANFIS پرداخته می‌شود. همان‌گونه که در بخش‌های قبلی بیان شد این مدل‌ها از ترکیب مدل ANFIS و تبدیل موجک تولید شده‌اند. در شکل ۹ مقایسه شاخص‌های آماری مختلف برای کلیه مدل‌های ترکیبی WANFIS به تصویر کشیده شده است. بر اساس نتایج مدل‌سازی‌ها، مقادیر شاخص عملکرد و ضریب همبستگی برای مدل WANFIS 1 به ترتیب مساوی با ۵۶/۲۸۳ و ۰/۷۵۰ به دست آمدند. همان‌گونه که مشاهده شد تبدیل موجک به شکل قابل ملاحظه‌ای عملکرد مدل ANFIS را بهبود بخشید. به‌عنوان مثال، ضریب همبستگی WANFIS 1 در مقایسه با ANFIS 1 تقریباً دو برابر شد. این در حالی است که شاخص‌های آماری RMSE، MARE و AIC برای WANFIS 1 به ترتیب برابر با ۵۸/۲۸۵، ۱/۵۷۶ و ۱۰۱۵/۶۸۴ محاسبه شدند. در میان کلیه مدل‌های ترکیبی، WANFIS 1 دارای کمترین دقت و بیشترین خطا بود. لازم به‌ذکر است که تبدیل موجک باعث شد که ضریب همبستگی مدل WANFIS 2 در مقایسه با ANFIS 2 حدوداً دو و نیم برابر افزایش یابد. علاوه بر این، مقادیر NSC، VAF و RMSE برای WANFIS 2 به ترتیب به ترتیب ۰/۸۵۹، ۸۷/۸۷۵ و ۳۰/۷۱۷ به دست آمدند. همچنین، مقادیر شاخص‌های آماری AIC، MARE و R برای مدل WANFIS 3 به ترتیب برابر با ۱/۲۷۰، ۹۷۶/۷۰۷ و ۰/۸۷۵ محاسبه شدند. لازم به یادآوری است که تبدیل موجک باعث گردید که مقدار خطا (MARE) مدل WANFIS 3 در مقایسه با ANFIS 3 بیش از ۲/۵ برابر کمتر شود. این در حالی است که مقادیر ضریب همبستگی و شاخص عملکرد برای WANFIS 4 به ترتیب مساوی با ۰/۷۷۹ و ۶۰/۷۲۰ محاسبه شدند. بر اساس نتایج مدل‌سازی، تبدیل موجک مقدار شاخص عملکرد WANFIS 4 را در مقایسه با ANFIS 4 حدوداً ۲/۶ برابر بهبود بخشید. علاوه بر

این، مقادیر AIC، RMSE و NSC برای WANFIS 5 به ترتیب مساوی ۸۸۵/۴۸۷، ۲۵/۰۹۹ و ۰/۹۱۲ بودند. این در حالی است که تبدیل موجک باعث کاهش قابل توجه خطای مدل WANFIS 5 شد به‌گونه‌ای که مقدار MARE برای مدل WANFIS 5 تقریباً ۴/۵ برابر کمتر از مدل متناظر با آن یعنی ANFIS 5 بود. همچنین، برای WANFIS 6 شاخص‌های آماری R، AIC و VAF به ترتیب برابر ۰/۹۴۲، ۹۲۵/۱۹۲ و ۸۸/۷۴۳ محاسبه شدند. لازم به‌ذکر است که تبدیل موجک همبستگی نتایج مدل WANFIS 6 را حدوداً ۱/۸ برابر افزایش داد. در مقابل، برای WANFIS 7 مقادیر NSC، MARE و R حدوداً مساوی با ۰/۷۵۳، ۱/۲۱۵ و ۰/۸۹۷ تخمین زده شدند. این در حالی است که شاخص‌های آماری RMSE، AIC و VAF برای این مدل به ترتیب مساوی با ۳۹/۰۰۱، ۹۹۱/۲۶۰ و ۸۰/۴۹۱ به دست آمدند. بر اساس نتایج مدل‌سازی، در میان کلیه مدل‌های ترکیبی، WANFIS 8 به‌عنوان بهترین مدل هوش مصنوعی این مطالعه معرفی شد. به‌عنوان مثال، برای مدل مذکور مقادیر شاخص عملکرد و ضریب همبستگی برای WANFIS 8 به ترتیب مساوی با ۹۲/۲۷۳ و ۰/۹۶۱ محاسبه شدند. همچنین، برای این مدل مقادیر RMSE، NSC و AIC به ترتیب برابر با ۲۴/۵۱۰، ۰/۹۱۳ و ۹۱۵/۷۸۴ به دست آمدند. با توجه به نتایج شبیه‌سازی‌ها، تبدیل موجک شاخص عملکرد مدل پایه ANFIS را تقریباً ۳/۵ برابر بهبود بخشید.

بنابراین، در میان کلیه مدل‌های هوش مصنوعی ساده و ترکیبی، مدل WANFIS 8 کمترین مقدار خطا و بیشترین همبستگی را با مقادیر بارش مشاهداتی داشت. علاوه بر این، تاخیرهای شماره (t-1)، (t-2)، (t-3) و (t-12) به‌عنوان موثرترین تاخیرها برای شبیه‌سازی بارش درازمدت شهر رشت توسط مدل ترکیبی WANFIS شناسایی شدند. در شکل ۱۰، نمودار پراکندگی و مقایسه مقادیر عددی و مشاهداتی مدل برتر (WANFIS 8) به تصویر کشیده شده است.



شکل ۹- شاخص‌های آماری برای نتایج شبیه‌سازی بارش توسط مدل‌های WANFIS مختلف
 Figure 9. Statistical indices for precipitation results simulated by different WANFIS models



شکل ۱۰- مقایسه بارش مشاهداتی با شبیه‌سازی شده برای مدل WANFIS برتر
Figure 10. Comparison of observed precipitation with values simulated by superior WANFIS model

برتر و موثرترین تأخیرها نیز معرفی شدند. مدل WANFIS 8 که به‌عنوان مدل برتر شناسایی شد مقادیر بارش‌ها را با دقت مناسبی شبیه‌سازی نمود. به‌عنوان مثال، مقادیر ضریب همبستگی و شاخص عملکرد برای مدل برتر ترکیبی به‌ترتیب مساوی ۰/۹۶۱ و ۹۲/۲۷۳ به‌دست آمدند. همچنین، تأخیرهای (t-1)، (t-2)، (t-3) و (t-12) به‌عنوان موثرترین تأخیرها برای تخمین بارندگی دراز مدت شهر رشت توسط مدل WANFIS معرفی شدند.

توصیه می‌شود که برای شبیه‌سازی داده‌های سری زمانی همچون بارش از ترکیب تبدیل موجک با سایر الگوریتم‌های هوش مصنوعی استفاده شود زیرا این تبدیل به‌درستی ماهیت سری زمانی این نوع از داده را به‌خوبی تجزیه و تحلیل می‌کند و دقت شبیه‌سازی را نیز به‌شکل قابل ملاحظه‌ای افزایش می‌دهد.

در انتها باید بیان شود که شبیه‌سازی بارش در نواحی مختلف جهان توسط بسیاری از محققین نیز انجام شده است اما مدل‌سازی پدیده بارش شهر رشت در یک بازه زمانی دراز مدت توسط یک مدل ترکیبی هوش مصنوعی انجام نگرفته است. اصولاً با توجه به ماهیت سری زمانی داده‌های بارش، مقایسه عملکرد مدل هوش مصنوعی توسعه داده شده در مطالعه حاضر قابل مقایسه با مدل‌های هوش مصنوعی استفاده شده توسط سایر محققین برای نواحی دیگر امکان‌پذیر نیست.

بنابراین همان‌طور که ملاحظه شد دقت مدل ترکیبی (WANFIS) به شکل قابل توجهی از مدل ANFIS بیشتر است. به‌عبارت دیگر، تبدیل موجک به‌درستی داده‌های سری زمانی بارش دراز مدت شهر رشت را تجزیه و تحلیل نموده است و دقت مدل ANFIS را نیز بهبود بخشیده است.

نتیجه‌گیری کلی

شبیه‌سازی و تخمین میزان بارش در فلات ایران از اهمیت بسزایی برخوردار است. در این مطالعه، داده‌های سری زمانی بارش دراز مدت شهر رشت در یک بازه ۶۲ ساله از سال ۱۳۳۴ تا ۱۳۹۶ به‌صورت ماهانه توسط مدل ANFIS و یک مدل ترکیبی بهینه‌یافته WANFIS (ترکیب مدل ANFIS و تبدیل موجک) شبیه‌سازی شد. داده‌ها به دو دسته آموزش (۴۲ سال) و آزمون (۲۰ سال) تقسیم شدند. با یک روند سعی و خطا تعداد بهینه توابع عضویت مدل انفیس برابر با دو در نظر گرفته شد. همچنین با استفاده از تابع خود همبستگی موثرترین تأخیرهای داده‌های سری زمانی شناسایی شدند. لازم به‌ذکر است که با بررسی کلیه اعضای خانواده موجک، demy به‌عنوان موجک مادر بهینه معرفی شد. در ادامه توسط این تأخیرها، هشت مدل مختلف برای هر یک از روش‌های ANFIS و WANFIS تعریف گردید. مقایسه مدل‌های ANFIS و WANFIS نشان داد که مدل ترکیبی مقادیر تابع هدف را با دقت بیشتری تخمین زد و تبدیل موجک عملکرد مدل ANFIS را به شکل قابل توجهی بهبود بخشید. با تجزیه و تحلیل نتایج کلیه مدل‌های هوش مصنوعی، مدل

منابع

1. Baba Ali, H. and R. Dehghani. 2017. Comparison of intelligent models in estimating monthly precipitation of Kaka Reza. *Ecology*, 4(1): 1-11.
2. Khalili, N., S.R. Khodashenas, K. Davary, M.M. Baygi and F. Karimaldini. 2016. Prediction of rainfall using artificial neural networks for synoptic station of Mashhad: a case study. *Arabian Journal of Geosciences*, 9(13): 624.
3. Ghorbani, M., A. Azani and S. Mahmoudi Vanolya. 2015. Rainfall-Runoff Modeling Using Hybrid Intelligent Models. *Iran-Water Resources Research*, 11(2): 146-150 (In Persian).
4. 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.
5. 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 modeling. *Journal of Hydrology*, 571: 214-224.
6. 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.

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. Dabral, P.P. and M.Z. Murry. 2017. Modelling and forecasting of rainfall time series using SARIMA. *Environmental Processes*, 4(2): 399-419.
9. Jang, J.S 1993. ANFIS: adaptive-network-based fuzzy inference system. *IEEE transactions on systems, man, and cybernetics*, 23(3): 665-685.
10. Kumar, N and G.K. Jha. 2013. A time series ANN approach for weather forecasting. *Int J Control Theory Comput Model (IJCTCM)*, 3(1): 19-25.
11. 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.
12. 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.
13. 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.
14. Mendel, J.M. 2001. *Uncertain rule-based fuzzy logic systems: introduction and new directions*. Prentice.
15. Mislán, H., S. Hardwinarto and M.A. Sumaryono. 2015. Rainfall monthly prediction based on artificial neural network: a case study in Tenggarong Station, East Kalimantan-Indonesia. *Procedia Computer Science*, 59: 142-151.
16. Nagahamulla, H.R., U.R. Ratnayake and A. Ratnaweera. 2012. An ensemble of artificial neural networks in rainfall forecasting. In *Advances in ICT for Emerging Regions (ICTer)*, 2012 International Conference on (176-181). IEEE.
17. 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.
18. Nourani, V., M.T. Alami and M.H. Aminfar. 2009. A combined neural-wavelet model for prediction of Ligvanchai watershed precipitation. *Engineering Applications of Artificial Intelligence*, 22(3): 466-472.
19. Nozari, H. and F. Tavakoli. 2019. Evaluation of the Efficiency of Linear and Nonlinear Models in Predicting Monthly Rainfall (Case Study: Hamedan Province). *Journal of Watershed Management Research*. 10 (20): 1-12 (In Persian).
20. 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). IOP Publishing.
21. 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.
22. 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.
23. Valipour, E., M.A. Ghorbani and E. Asadi. 2020. Rainfall Network Optimization using Information Entropy and Fire Fly Algorithm Case Study: East Basin of Urmia Lake. *Journal of Watershed Management Research*, 11(21): 11-23 (In Persian).
24. Wong, K.W., P.M. Wong, T.D. Gedeon and C.C. Fung. 1999. Rainfall prediction using neural fuzzy technique. URL: [www. it. murdoch. edu. au/~ wong/publications/SIC97. pdf](http://www.it.murdoch.edu.au/~wong/publications/SIC97.pdf), 213-221.
25. Wong, K.W., P.M. Wong, T.D. Gedeon and C.C. Fung. 2003. Rainfall prediction model using soft computing technique. *Soft Computing*, 7(6): 434-438.
26. 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.
27. 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.

Optimization of ANFIS Network using Wavelet Transform for simulation of Long term Rainfall of Rasht City

Ebrahim Shahbazbeygi¹, Behrouz Yaghoubi² and Saeid Shabanlou³

1- Department of Water Engineering, College of Agriculture, Kermanshah Branch, Islamic Azad University, Kermanshah, Iran

2- Assistant Professor, Department of Water Engineering, College of Agriculture, Kermanshah Branch, Islamic Azad University, Kermanshah, Iran, (Corresponding Author: behrouz.yaghoubi.h@gmail.com)

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

Received: 30 Jun, 2019 Accepted: 7 April, 2021

Extended Abstract

Introduction and Objective: Estimation and forecasting of precipitation pattern in different parts of the world, especially in arid and semi-arid regions such as Iran is very important. In addition, various numerical methods such as artificial intelligence methods due to high accuracy and speed have the ability to simulate the phenomenon of precipitation and similar subjects. The use of these techniques plays an important role in saving time and costs in field and laboratory studies. Therefore, the application and popularity of various artificial intelligence techniques to estimate and simulate different issues such as rainfall is increasing day by day. The purpose of this study is to estimate the long-term rainfall in Rasht by a hybrid ANFIS and wavelet transform model.

Material and Methods: In this study, long-term rainfall of Rasht city was simulated using an optimum artificial intelligence model for a 62 years period from 1956 to 2017. In other words, the wavelet transform was utilized to enhance the performance of the ANFIS model and hybrid WANFIS (Wavelet-ANFIS) model was defined. Firstly, the effective lags of time series data were detected through the autocorrelation function (ACF). Then, using the lags, eight models were developed for each ANFIS and WANFIS model. It should be noted that 42 years data was applied for training and 20 years data to test the artificial intelligence models. Next, the number of optimal membership functions of ANFIS model was selected equal to two.

Results: results of ANFIS 1 to ANFIS 8 were evaluated. Additionally, different mother wavelets were examined to optimize the ANFIS model. This means that the demy was introduced as the best mother wavelet for increasing the performance of the ANFIS model. The comparison between ANFIS and WANFIS models signified that the wavelet transform enhanced the performance of the ANFIS model. Also, results of the hybrid WANFIS models were analyzed, indicating that WANFIS 8 was the superior model. The model estimated the rainfall with an acceptable accuracy. For instance, the R, MARE and RMSE for the superior model were computed 0.961, 0.855 and 24.510, respectively. Additionally, the values of VAF and NSC for this model were respectively estimated as 92.273 and 0.913.

Conclusion: Results showed that (t-1), (t-2), (t-3) and (t-12) were identified as the most influenced lags for estimation of long-term rainfall of Rasht city using the hybrid WANFIS model.

Keywords: ANFIS, Long-term rainfall, Optimization, Rasht city, Simulation, Wavelet transform