



## پیش‌بینی بارش ماهانه استان اردبیل با استفاده از مدل‌های ANN و WANN

محمد رضا نیک‌پور<sup>۱\*</sup>، سجاد عبداللهی اسدآبادی<sup>۲</sup>

تاریخ ارسال: ۱۳۹۷/۱۱/۱۲

تاریخ پذیرش: ۱۳۹۸/۰۱/۲۷

مقاله برگرفته از طرح پژوهشی

### چکیده

بارش یکی از مهم‌ترین رخدادهای هیدرولوژیکی بوده و پیش‌بینی آن می‌تواند به عنوان یک ابزار کاربردی در بهره‌برداری و مدیریت بهینه منابع آب مورد استفاده قرار گیرد. در پژوهش حاضر از مدل‌های شبکه عصبی مصنوعی (ANN) و موجک-عصبی (WANN) برای شبیه‌سازی بارش ماهانه در ایستگاه‌های سینوپتیک منتخب استان اردبیل شامل اردبیل، خلخال، مشگین‌شهر و پارس‌آباد طی دوره آماری مشترک ۲۲۵ ماهه در سال‌های ۱۳۹۵-۱۳۷۵ استفاده شد. برای پیش‌بینی کوتاه مدت بارش ماهانه (یک ماه بعد) سناریوهای مختلف بر اساس تأخیرهای بارش تعریف شد. نتایج بیانگر عملکرد قابل قبول و برتری مدل WANN با بیشترین ضریب تعیین ( $R^2$ ) و کمترین ریشه میانگین مربعات خطا (RMSE) برای همه ایستگاه‌ها و به‌زای بهترین الگو در مرحله صحت‌سنجی بود. مقادیر  $R^2$  و RMSE برای ایستگاه اردبیل به ترتیب برابر ۰/۸۸ و ۷/۱۳ میلی‌متر، ایستگاه خلخال برابر ۰/۹۱ و ۶/۰۳ میلی‌متر، ایستگاه مشگین‌شهر برابر ۰/۹۲ و ۶/۵۷ میلی‌متر و برای ایستگاه پارس‌آباد برابر ۰/۸۷ و ۸/۵۶ میلی‌متر به دست آمد. در همه ایستگاه‌ها، اعمال سناریوی ترکیبی تأخیرهای بارش، کمینه و بیشینه دما توسط مدل برتر (مدل WANN) باعث بهبود جزئی نتایج مدل گردید اما هزینه محاسباتی مدل را نیز به مراتب افزایش داد. هم‌چنین در همه ایستگاه‌ها، اضافه شدن رطوبت نسبی و سرعت باد به عنوان متغیرهای ورودی تا حدودی باعث کاهش عملکرد مدل شد. نتایج کلی پژوهش حاضر نشان داد که با استفاده از مدل WANN به همراه تأخیرهای مناسب بارش در مقیاس زمانی ماهانه، می‌توان بارش ماهانه (ماه آینده) ایستگاه‌های منتخب استان اردبیل شامل اردبیل، خلخال، مشگین‌شهر و پارس‌آباد را با دقت قابل قبول پیش‌بینی نمود.

واژه‌های کلیدی: استان اردبیل، بارش ماهانه، تأخیرهای بارش، شبکه عصبی مصنوعی، موجک-عصبی.

<sup>۱</sup> استادیار گروه مهندسی آب، دانشکده کشاورزی و منابع طبیعی، دانشگاه محقق اردبیلی، اردبیل، ایران. ۰۹۱۳۲۲۲۰۴۸۵

m\_nikpour@uma.ac.ir (نویسنده مسئول)

<sup>۲</sup> دکترای مهندسی منابع آب، وزارت نیرو، شرکت مدیریت منابع آب ایران، شرکت آب منطقه‌ای استان چهارمحال و بختیاری. شهرکرد، ایران.

sajad1998@gmail.com .۰۹۱۳۲۸۰۸۲۴۶



## مقدمه

پیش‌بینی بارش ماهانه نه تنها در مدیریت علمی منابع آب نقش مهمی ایفا می‌کند بلکه می‌تواند دقت سامانه‌های هشدار سیل را به‌طور موثری افزایش دهد. در واقع استفاده بهینه از آب برای مصارفی همچون آبیاری اراضی، تولید برق، حمل و نقل آبی، کنترل سیلاب و تأمین نیازهای بخش شرب و صنعت نیازمند پیش‌آگاهی از میزان بارش می‌باشد. همچنین پیش‌بینی میزان بارش نقش مهمی در مطالعات کیفیت آب و مدیریت مسائلی مانند مسطحی ایفا می‌کند که از جمله می‌توان به کاهش آلودگی‌ها، کنترل کیفیت بدنه‌های آبی، حفاظت از آبیان و حیات وحش اشاره کرد (Lou et al., 2016). روش‌های تخمین بر مبنای پایگاه داده به علت صرفه جویی در زمان، حداقل اطلاعات مورد نیاز و سهولت اجرا در زمان واقعی بارش سریع در حال متداول شدن می‌باشند. نظر به اینکه در پیش‌بینی‌های کوتاه مدت و بلند مدت بارش نیاز به مدل‌های پیش‌بینی با دقت اعتبار و توانایی بالا می‌باشد تا کنون تحقیقات متعددی در این خصوص با استفاده از مدل‌های هوشمند انجام گرفته است. ستاری و همکاران (۱۳۹۳) از مدل‌های درختی M5 و شبکه عصبی مصنوعی (ANN) برای تخمین بارش ماهانه منطقه اهرا استفاده کردند. یافته‌های آن‌ها نشان داد که هر دو روش نتایج نسبتاً دقیقی را برای پیش‌بینی بارش ماهانه منطقه ارائه می‌کند. کدخداحسینی و همکاران (۱۳۹۵) از دو مدل ANN و ماشین بردار پشتیبان<sup>۲</sup> برای بازسازی داده‌های بارش ماهانه و فصلی چهار ایستگاه باران سنجی واقع در استان همدان، در دوره آماری ۱۳۸۹-۱۳۷۰ استفاده کردند. بر اساس نتایج حاصل شده، در بهترین حالت، مدل ANN در بازسازی داده‌های بارش ماهانه و مدل SVM در بازسازی داده‌های بارش فصلی نسبت به مدل دیگر از عملکرد بهتری برخوردار بود. در

تحقیقات انجام گرفته توسط معروفی و همکاران (۱۳۹۶) و قاسمی و همکاران (۱۳۹۶) نیز مدل ANN از عملکرد قابل قبول در پیش‌بینی کوتاه مدت بارش ماهانه برخوردار بود. (Lou et al., 2016) برای پیش‌بینی بارش ماهانه در کشور چین از مدل‌های پس‌انتشار<sup>۳</sup>، تابع پایه شعاعی<sup>۴</sup> و کریجینگ استفاده کردند. از بین مدل‌های مذکور، مدل RBF بهترین عملکرد را به همراه داشت و با استفاده از آن بارش ماهانه برای سال‌های ۲۰۱۹-۲۰۱۰ پیش‌بینی شد. Sofian et al. (2018) با به‌کارگیری مدل‌های پس‌انتشار (BP) و تابع پایه شعاعی (RBF) بارش ماهانه منطقه‌ای واقع در اندونزی را شبیه‌سازی کردند. برای این منظور از داده‌های بارش طی سال‌های ۲۰۱۳-۱۹۹۴ استفاده کردند. بر اساس شاخص‌های آماری خطا، مدل RBF عملکرد بهتری را به همراه داشت. Liu and Shi (2019) از مدل برنامه‌ریزی ژنتیک (GP) به همراه یک الگوریتم بازگشتی برای پیش‌بینی طولانی مدت بارش ماهانه برای حوزه آبریزی واقع در کشور چین استفاده کردند. آن‌ها با به‌کارگیری داده‌های بارش طی سال‌های ۲۰۱۴-۱۹۶۱ توانستند میزان بارش ماهانه تا سال ۲۰۵۰ را پیش‌بینی نمایند. Yaseen et al. (2019) از تلفیق سه الگوریتم تکاملی مختلف به نام‌های بهینه‌سازی مجموعه ذرات<sup>۵</sup> (PSO)، الگوریتم ژنتیک (GA) و تکامل دیفرانسیلی<sup>۶</sup> (DE) با مدل ANFIS برای پیش‌بینی سری زمانی بارش ماهانه حوزه آبریز پاهانگ واقع در مالزی استفاده کردند. شبیه‌سازی بارش در سه مقیاس زمانی ماهانه، فصلی و سالانه انجام شد. نتایج حاکی از آن بود که مدل‌های هیبرید از عملکرد بهتری در مقایسه با مدل ANFIS برخوردار بودند.

در دهه‌های اخیر ارتقاء توان پردازشی رایانه‌ای و توسعه مدل‌های هوشمند و تطبیق‌پذیر که توانایی‌های بسیار مناسبی در مدل‌سازی پدیده‌های غیرخطی را دارند موجب گردیده تا افق‌های جدیدی در زمینه بهبود

<sup>4</sup> Radial Basis Function (RBF)

<sup>5</sup> Particle Swarm Optimization (PSO)

<sup>6</sup> Differential Evolution (DE)

<sup>1</sup> Artificial Neural Networks (ANN)

<sup>2</sup> Support Vector Machine (SVM)

<sup>3</sup> Back Propagation (BP)

پیش‌بینی بارش ماهانه در ایستگاه‌های منتخب استان اردبیل از مدل شبکه‌های عصبی مصنوعی (ANN) و موجک-عصبی (WANN) استفاده شود.

## مواد و روش‌ها

### منطقه مورد مطالعه

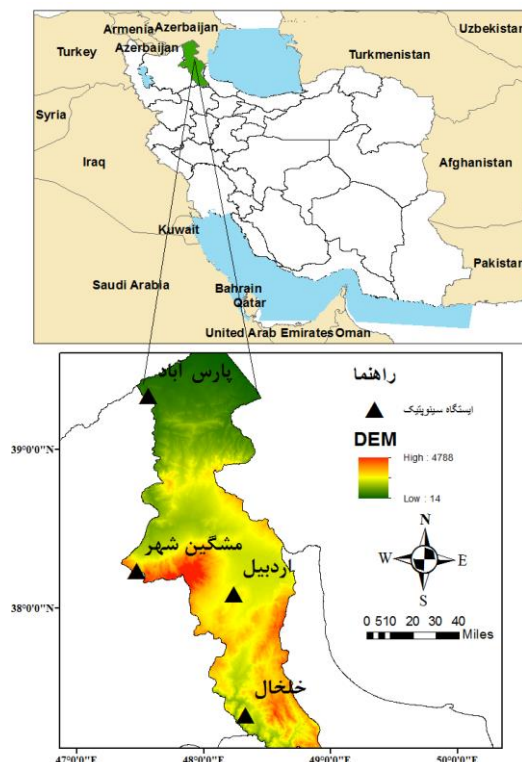
استان اردبیل با وسعتی معادل  $17867/3$  کیلومتر مربع ( $1/1$  در صد از مساحت کشور) در شمال غرب فلات ایران بین  $37/75$  تا  $39/70$  درجه عرض شمالی و  $47/50$  تا  $48/92$  درجه طول شرقی واقع شده است. میانگین ارتفاع آن از سطح دریا  $2400$  متر است. پست‌ترین نقطه آن با ارتفاع  $100$  متر در شهرهای پارس‌آباد و بیله سوار و بلندترین نقطه آن قله سبلان با ارتفاع  $4811$  متر می‌باشد. در پژوهش حاضر از بین ۹ ایستگاه سینوپتیک واقع در استان اردبیل، داده‌های ایستگاه‌های اردبیل، پارس‌آباد، مشگین‌شهر و خلخال که دارای دوره آماری کامل‌تری هستند و ضمناً در نقاط مختلف استان واقع شده‌اند، استفاده شد. داده‌های مورد استفاده در مقیاس زمانی ماهانه و شامل دماهای کمینه و بیشینه، میانگین رطوبت، میانگین سرعت باد و بارش به‌ازای دوره آماری  $1375-1395$  بود. داده‌های مذکور از اداره هواشناسی اردبیل اخذ شد. در شکل ۱ موقعیت تقریبی ایستگاه‌های سینوپتیک منتخب استان اردبیل نمایش داده شده است. در جدول ۱ متغیرهای آماری مربوط به داده‌های اندازه‌گیری شده بارش در ایستگاه‌های سینوپتیک در بازه زمانی مذکور نشان داده شده است. لازم به ذکر است که برای شبیه‌سازی بارش ماهانه در ایستگاه‌های سینوپتیک منتخب، دوره آماری مشترک ۲۲۵ ماهه در نظر گرفته شد. ضمناً برای هر ایستگاه،  $80$  درصد داده‌ها برای دوره آموزش و  $20$  درصد داده‌ها برای دوره آزمون (صحت‌سنجی) مورد استفاده قرار گرفت.

روش‌های پیش‌بینی متغیرهای هیدرولوژیکی پیش‌روی محققان عرصه منابع آب قرار گیرد. با این وجود یکی از مشکلات استفاده از این مدل‌ها و سایر روش‌های خطی و غیرخطی ضعف آن‌ها در مواجهه با سری داده‌های ناپایستا<sup>۱</sup> می‌باشد (Adamowski, 2008). در دهه گذشته تحلیل موجک<sup>۲</sup> ابتدا در رشته‌های مختلف علوم و سپس در هیدرولوژی و منابع آب مورد استفاده قرار گرفته است. مدل مذکور، روش مناسبی در تجزیه و تحلیل سری‌های هیدرولوژیکی و هواشناسی ناپایستا می‌باشد (Adamowski, 2008). Abdollahi et al. (2017) از مدل‌های ANN و GEP و همچنین ترکیب آن‌ها با موجک (WANN و WGEP) برای تخمین جریان روزانه رودخانه‌های دائمی و فصلی در منطقه‌ای نیمه خشک واقع در کوه‌های زاگرس استفاده کردند. آن‌ها علاوه بر مقادیر دبی، داده‌های بارش ۱۷ ایستگاه هواشناسی موجود در منطقه را طی ۹ سال دوره آماری به‌کار گرفتند. نتایج تحقیق نشان داد که از بین چهار مدل مذکور، مدل WANN عملکرد بهتری را در پیش‌بینی دبی رودخانه‌های دائمی و فصلی به همراه داشت. همچنین در برآورد مقادیر دبی پیک، مدل GEP از دقت بیشتری برخوردار بود. در تحقیقات انجام گرفته توسط مظفری و همکاران (۱۳۹۴)، طوفانی و همکاران (۱۳۹۴)، سلگی و همکاران (۱۳۹۵)، Nourani et al. (2009) و Venkata-Ramana et al. (2013) قابلیت و توانایی بالای مدل موجک-عصبی<sup>۳</sup> (WANN) در پیش‌بینی بارش ماهانه نشان داده شد. تاکنون در محدوده استان اردبیل، مطالعه جامعی در مورد ارزیابی عملکرد مدل‌های هوشمند در تخمین بارش ماهانه انجام نشده است. با توجه به اهمیت مطالعه بارش در برنامه‌ریزی‌ها و مدیریت بحران و نظر به کارآمد بودن مدل موجک-عصبی در پیش‌بینی این متغیر، در پژوهش حاضر تلاش گردید به‌منظور

<sup>3</sup> Wavelet- ANN (WANN)

<sup>1</sup> Nonstationary

<sup>2</sup> Wavelet Analysis



شکل (۱): موقعیت جغرافیایی ایستگاه‌های سینوپتیک مورد مطالعه

جدول (۱): خصوصیات آماری مقادیر بارش ماهانه ایستگاه‌های منتخب استان اردبیل به‌ازای دوره آماری مشترک

نام ایستگاه سینوپتیک	میانگین (mm)	بیشینه (mm)	کمینه (mm)	انحراف معیار	ضریب تغییرات	چولگی
اردبیل	۲۴/۶۵	۱۵۸/۹	۰	۲۳/۴۳	۰/۹۵	۱/۷۶
پارس آباد	۲۳/۲۴	۱۶۴/۴	۰	۲۳/۱۹	۰/۹۹	۱/۹۹
خلخال	۳۱/۱۵	۱۵۰/۷۲	۰	۲۷/۵۴	۰/۸۸	۱/۲۱
مشگین شهر	۳۲/۰۸	۱۵۹/۶	۰	۲۷/۸۶	۰/۸۷	۱/۵۵

آستانه مشخصی تجاوز نماید. تعداد نرون‌های موجود در لایه‌های ورودی و خروجی با توجه به ماهیت مسأله مورد بررسی، مشخص می‌شود. حال آنکه تعداد نرون‌های موجود در لایه‌های پنهانی و همچنین تعداد این لایه‌ها با سعی و خطا در جهت کاهش مقدار خطا توسط طراح ارائه می‌شود (شفائی و همکاران، ۱۳۹۲). متغیرهای مؤثر که در مدل‌سازی شبکه‌های عصبی نقش اساسی دارند شامل تعداد تکرار، نوع تابع آموزش، تعداد لایه‌های شبکه و تعداد نرون‌های لایه میانی می‌باشد. گام مهم قبل از وارد کردن داده‌ها به مدل، نرمال

### شبکه عصبی مصنوعی (ANN)

امروزه، شبکه‌های عصبی مصنوعی به‌عنوان یک ابزار توانمند برای مدل‌سازی سامانه‌های غیرخطی پیچیده پذیرفته شده است و به‌طور گسترده‌ای برای پیش‌بینی پارامترهای مختلف هیدرولیکی و هیدرولوژیکی مورد استفاده قرار می‌گیرد. این شبکه‌ها قادر هستند با انتخاب مناسب لایه‌ها و پردازشگرهایی به نام نرون، نگاشت غیرخطی بین ورودی‌ها و خروجی‌ها ارائه دهند (طوفانی و همکاران، ۱۳۹۴). هر نرون زمانی فعال می‌شود که که مجموع سیگنال‌های رسیده به آن از حد

رساندن خطای مدل‌سازی پس از انجام تحلیل حساسیت، توابع و مقادیر بهینه در نظر گرفته شده برای شبکه عصبی مورد استفاده در تحقیق حاضر به شرح جدول ۲ می‌باشد.

$$X_n = 0.1 + 0.8 \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \quad (1)$$

سازی داده‌ها می‌باشد. این عمل خصوصاً وقتی دامنه تغییرات ورودی‌ها زیاد باشد کمک شایانی به آموزش بهتر و سریع‌تر مدل می‌کند. اصولاً وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و دقت شبکه می‌شود (He et al., 2014). برای نرمال‌سازی داده‌های تحقیق حاضر از رابطه ۱ استفاده شد. در این رابطه،  $X_n$  مقدار نرمال شده ورودی  $X_i$ ،  $X_{\max}$  و  $X_{\min}$  به ترتیب مقادیر بیشینه و کمینه داده‌ها می‌باشد. به منظور به حداقل

جدول (۲): مقادیر پارامترهای مورد استفاده در مدل ANN

پارامتر	بهترین مقدار
نوع شبکه عصبی	Multi-Layer Perceptron
تعداد لایه پنهان	1
الگوریتم آموزش	Levenberg-Marquardt
تعداد نرون	1-10
تابع انتقالی برای لایه میانی	TANSIG
تابع انتقالی برای لایه خروجی	Linear
تعداد تکرار	1000

موجی نامنظم پدیده‌های هیدرولوژیکی، قابلیت مدل‌سازی این پدیده‌ها توسط امواج نامنظم (موجک‌ها) نسبت به امواج منظم (امواج سینوسی) بیشتر است (Nourani et al., 2009). موجک دارای سه مشخصه تعداد نوسان محدود، بازگشت سریع به صفر در هر دو جهت مثبت و منفی در دامنه خود و میانگین صفر است که شرط مقبولیت نامیده می‌شود و به شکل رابطه ۲ بیان می‌شود.

$$\int_{-\infty}^{+\infty} \phi(t) dt = 0 \quad (2)$$

در رابطه فوق،  $\phi(t)$  تابع تبدیل موجک (موجک مادر) است. عبارت مادر به این دلیل به کار رفته است که توابع (موجک‌های) متفاوت به وجود آمده بر اساس پارامترهای مقیاس و انتقال همگی از تابع پایه (موجک مادر) ناشی می‌شوند. تبدیل موجک عملگری است که یک تابع را به مجموعه‌ای از تبدیل موجک‌های مادر اصلاح شده تبدیل می‌کند که این تبدیل موجک‌های اصلاح شده همان تبدیل

### موجک - عصبی (WANN)

به هر کمیت متغیر در زمان یا مکان که قابل اندازه‌گیری باشد، سیگنال گفته می‌شود. برای تحلیل سیگنال‌ها از مبدل‌های ریاضی استفاده می‌شود تا بتوان اطلاعاتی به دست آورد که از سیگنال‌های خام به راحتی قابل دسترس نیست. تبدیل موجک یکی از مبدل‌های ریاضی کارآمد در زمینه پردازش سیگنال است (طوفانی و همکاران، ۱۳۹۴). مزیت مهم تبدیل موجک این است که اطلاعات زمان و فرکانس را به طور مؤثری از سیگنال متغیر در زمان دریافت می‌کند (پورحقی و همکاران، ۱۳۹۷). موجک، یک موج کوچک است که انرژی آن در ناحیه کوچکی متمرکز شده و ابزار مناسبی برای بررسی پدیده‌های گذرا است. موجک نوسان حداقلی دارد که به سمت صفر نزول می‌کند و این نزول باید در جهت‌های مثبت و منفی واقع در دامنه‌اش محدود شود. این مشخصه باعث می‌شود که موجک انعطاف‌پذیر بوده و مانند دیگر تابع رفتار کند، بنابراین با توجه به رفتارهای

### معیارهای ارزیابی عملکرد مدل

در تحقیق حاضر به منظور ارزیابی دقت و کارایی مدل‌ها از آماره‌های ضریب تعیین ( $R^2$ )، ریشه میانگین مربعات خطا (RMSE) و ضریب نش- ساتکلیف (NS) طبق روابط زیر استفاده گردید. بهترین مقدار برای معیارهای مذکور به ترتیب یک، صفر و یک می‌باشد.

$$R^2 = \left( \frac{\sum_{i=1}^N (R_i^O - \overline{R^O})(R_i^P - \overline{R^P})}{\sqrt{\sum_{i=1}^N (R_i^O - \overline{R^O})^2 \sum_{i=1}^N (R_i^P - \overline{R^P})^2}} \right)^2 \quad (4)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (R_i^O - R_i^P)^2}{N}} \quad (5)$$

$$NS = 1 - \frac{\sum_{i=1}^N (R_i^O - R_i^P)^2}{\sum_{i=1}^N (R_i^O - \overline{R^O})^2} \quad (6)$$

در روابط فوق،  $R_i^O$  و  $R_i^P$  به ترتیب مقادیر بارش مشاهداتی و محاسباتی توسط مدل در گام زمانی  $i$ ام،  $N$  تعداد گام‌های زمانی،  $\overline{R^O}$  و  $\overline{R^P}$  نیز به ترتیب میانگین مقادیر بارش مشاهداتی و محاسباتی می‌باشد. علاوه بر معیارهای فوق از نمودارهای پراکنش حول خط یک به یک و سری زمانی مقادیر مشاهداتی و محاسباتی برای مقایسه و تحلیل بیشتر نتایج استفاده شد.

### نتایج و بحث

**توسعه مدل‌های هوشمند به‌ازای تأخیرهای بارش**  
در این بخش، توسعه مدل‌های ANN و WANN برای شبیه‌سازی بارش ماهانه در ایستگاه‌های سینوپتیک منتخب، طی دوره آماری مشترک ۲۲۵ ماهه ارائه می‌شود. در پژوهش حاضر، معیار انتخاب مناسب‌ترین تأخیرهای بارش ماهانه (نسبت به مبدأ زمان پیش‌بینی) مقادیر توابع خود همبستگی<sup>۸</sup> (ACF) و خود همبستگی جزئی<sup>۹</sup> (PACF) بود. در شکل ۲ نمودارهای مقادیر ACF و PACF بارش ماهانه برای ایستگاه اردبیل نشان داده شده است. لازم به ذکر است

موجک دخت‌ر می‌باشند (معروفی و همکاران، ۱۳۹۲). از انواع موجک‌های مادر می‌توان به موجک میرا، سیملت<sup>۲</sup> مورلت<sup>۳</sup>، هار<sup>۴</sup> و دابچیز<sup>۵</sup> اشاره کرد. تبدیل‌های موجکی به دودسته موجک پیوسته<sup>۶</sup> و گسسته<sup>۷</sup> تقسیم می‌شوند (طوفانی و همکاران، ۱۳۹۴). برای کاربردهای عملی، هیدرولوژیست‌ها اغلب سیگنال‌های زمانی پیوسته در اختیار ندارند، بلکه بیشتر سیگنال‌های زمانی گسسته در اختیار آن‌ها می‌باشد. از این‌رو تبدیل موجک گسسته در طرح‌های هیدرولوژی بیشتر مورد استفاده قرار می‌گیرد (پورحقی و همکاران، ۱۳۹۷). آموزش شبکه عصبی مصنوعی با پیش‌پردازش داده‌ها با استفاده از تبدیل موجک نقش مؤثری در بالا بردن دقت پیش‌بینی‌ها دارد. در تحقیق حاضر از تابع موجک دابچیز مرتبه چهار (db-4) استفاده گردید. بعد از تعیین نوع موجک مادر، مهم‌ترین اقدام تعیین سطح تجزیه بود. استفاده از حداکثر سطح تجزیه موجب کند شدن فرآیند آموزش و در برخی موارد می‌تواند موجب کاهش دقت مدل نیز گردد. جهت انتخاب سطح تجزیه تبدیل موجک گسسته، رابطه<sup>۳</sup> استفاده شد (Nourani et al., 2009). در این رابطه،  $L$  سطح تجزیه،  $N_s$  تعداد داده‌های سری زمانی و  $\text{int}$  تابع جزء صحیح می‌باشد. در نهایت داده‌های حاصل از تجزیه توسط موجک پس از نرمال‌سازی (با استفاده از رابطه ۱) به‌عنوان ورودی شبکه عصبی تعریف شد.

$$L = \text{int} \left[ \log(N_s) \right] \quad (3)$$

<sup>6</sup> Continuous Wavelet Transform (CWT)

<sup>7</sup> Discrete Wavelet Transform (DWT)

<sup>8</sup> Auto Correlation Function

<sup>9</sup> Partial Auto Correlation Function

<sup>1</sup> Meyer

<sup>2</sup> Symlet



<sup>3</sup> Morlet

<sup>4</sup> Haar

<sup>5</sup> Daubechies (db)

الگوهای مختلف برای پیش‌بینی بارش ماهانه ارائه شده است. در جدول مذکور،  $P(t)$  و  $P(t+1)$  به ترتیب نشانگر میزان بارش در ماه آینده و ماه فعلی بوده و  $P(t-1)$ ...  $P(t-11)$  معرف تأخیرهای بارش به‌ازای ۱ تا ۱۱ ماه می‌باشد.

که نمودارهای مذکور در محیط نرم‌افزار Minitab ترسیم شده‌اند. برای سایر ایستگاه‌ها نیز نمودارهای مقادیر  $ACF$  و  $PACF$  مشابه ایستگاه اردبیل به‌دست آمد. با توجه به شکل مذکور می‌توان تأخیرهای زمانی ۱ تا ۱۲ ماه را برای تعریف الگوهای مختلف به منظور توسعه مدل‌ها در نظر گرفت. در جدول ۲ ساختار



شکل (۲): نمودارهای مقادیر خود همبستگی و خود همبستگی جزئی بارش برای ایستگاه اردبیل

جدول (۲): ساختار الگوهای مورد استفاده در تحقیق حاضر برای پیش‌بینی بارش ماهانه بر اساس تأخیرهای بارش

شماره الگو	ساختار الگو
۱	$P(t+1) = P(t)$
۲	$P(t+1) = P(t), P(t-1), P(t-2)$
۳	$P(t+1) = P(t), P(t-1), P(t-2), P(t-3), P(t-4)$
۴	$P(t+1) = P(t), P(t-1), P(t-2), P(t-3), P(t-4), P(t-5), P(t-6), P(t-7)$
۵	$P(t+1) = P(t), P(t-1), P(t-2), P(t-3), P(t-4), P(t-5), P(t-6), P(t-7), P(t-8), P(t-9), P(t-10), P(t-11)$

WANN به‌طور قابل توجهی بهبود یافته است. لذا می‌توان نتیجه گرفت که در سری‌های زمانی بلند مدت (مثل بارش)، تجزیه داده‌ها قبل از ورود آن‌ها به مرحله آموزش، باعث آموزش بهتر شبکه خواهد شد که از این نظر با نتیجه بدست آمده در تحقیقات طوفانی و همکاران (۱۳۹۴)، پورحقی و همکاران (۱۳۹۷) و Abdollahi et al. (2017) هم‌خوانی دارد. با بررسی نتایج بدست آمده برای ایستگاه اردبیل مشخص می‌شود که مدل WANN به‌ازای الگوی شماره ۵ با بیشترین ضریب تعیین ( $R^2=0/88$ )، کمترین ریشه میانگین مربعات خطا ( $RMSE=7/13$ ) و همچنین ضریب نش-ساتکلیف برابر  $0/87$  در مرحله صحت‌سنجی بهترین

### بررسی عملکرد مدل‌های هوشمند به‌ازای الگوهای تأخیرهای بارش

در جدول ۳ عملکرد مدل‌های ANN و WANN به‌ازای الگوهای ورودی تعریف شده، مطابق با جدول ۲ در قالب شاخص‌های آماری خطا برای ایستگاه‌های منتخب در دوره آزمون نشان داده شده است. با توجه به جدول مذکور مشاهده می‌شود که کارایی مدل ANN در شبیه‌سازی بارش ماهانه کلیه ایستگاه‌ها بسیار ضعیف است. اما پس از پردازش (تجزیه) داده‌ها توسط تبدیل موجک، نتایج بدست آمده توسط مدل

WANN به ترتیب به ازای الگوهای ۳ و ۴ بهترین عملکرد را به دنبال داشته‌اند. نتایج حاکی از آن است که در ایستگاه مشگین‌شهر الگوی شماره ۴ مدل WANN با  $R^2$  برابر با ۰/۹۲، RMSE برابر با ۶/۵۷ میلی‌متر و ضریب نش- ساتکلیف برابر ۰/۹۱ می‌تواند به عنوان الگوی مناسب برای شبیه‌سازی بارش ماهانه انتخاب شود. در ایستگاه پارس‌آباد نیز مدل WANN به ازای الگوی شماره ۴ در شبیه‌سازی بارش ماهانه با  $R^2$  برابر با ۰/۸۷، RMSE برابر با ۸/۵۶ میلی‌متر و ضریب نش- ساتکلیف برابر ۰/۸۶ بهترین کارایی را به همراه داشته است. لازم به ذکر است که مقدار ضریب نش- ساتکلیف مدل WANN در تحقیق حاضر به ازای الگوهای مطلوب، بزرگتر از ۰/۸ حاصل شده است که حاکی از عملکرد قابل قبول آن می‌باشد (He et al., 2014; Shu and Ouarda, 2008).

عملکرد را در شبیه‌سازی بارش ماهانه به همراه داشته است. بنابراین می‌توان نتیجه گرفت که در ایستگاه اردبیل با افزایش تعداد تأخیرهای سری زمانی بارش، دقت شبیه‌سازی بارش ماهانه نیز افزایش می‌یابد. در خصوص ایستگاه خلخال نیز ملاحظه می‌شود که افزایش تأخیرهای زمانی، نتایج مدل‌های ANN و WANN را بهبود داده است، به طوری که به ازای الگوی ۵، مدل‌های مذکور بهترین عملکرد را به همراه داشته‌اند. نتایج نشان می‌دهد که در ایستگاه خلخال مدل WANN به ازای الگوی ۵، با  $R^2$  برابر با ۰/۹۱، RMSE برابر با ۶/۰۳ میلی‌متر و ضریب نش- ساتکلیف برابر ۰/۹۱ می‌تواند برای شبیه‌سازی بارش ماهانه انتخاب شود. در مورد ایستگاه‌های مشگین‌شهر و پارس‌آباد، مدل‌های مورد استفاده کارایی مشابهی را نشان داده‌اند. به طوری که در ایستگاه‌های مذکور، مدل‌های ANN و

جدول (۳): مقادیر شاخص‌های آماری عملکرد مدل‌های هوشمند به ازای الگوهای مختلف تأخیر بارش


WANN			ANN			شماره الگو	ایستگاه
NS	RMSE (mm)	$R^2$	NS	RMSE (mm)	$R^2$		
۰/۴۶	۱۷/۹۰	۰/۲۱	-۰/۱۹	۲۰/۶۵	۰/۰۳	۱	اردبیل
۰/۵۹	۱۳/۶۲	۰/۵۶	۰/۰۳	۱۹/۴۰	۰/۱۱	۲	
۰/۷۴	۹/۳۴	۰/۷۶	-۰/۲۰	۲۱/۷۲	۰/۱۰	۳	
۰/۸۴	۷/۵۵	۰/۸۵	-۰/۲۶	۲۳/۲۴	۰/۰۶	۴	
۰/۸۷	۷/۱۳	۰/۸۸	۰/۰۴	۱۹/۴۷	۰/۲۸	۵	
۰/۱۴	۱۷/۱۸	۰/۳۲	۰/۰۹	۱۹/۱۷	۰/۱۵	۱	خلخال
۰/۶۶	۱۰/۶۷	۰/۷۰	-۰/۲۸	۲۱/۳۳	۰/۰۶	۲	
۰/۷۲	۹/۳۰	۰/۷۸	۰/۲۲	۱۶/۴۴	۰/۲۹	۳	
۰/۷۷	۹/۲۷	۰/۷۹	۰/۱۶	۱۷/۹۲	۰/۱۵	۴	
۰/۹۱	۶/۰۳	۰/۹۱	۰/۲۹	۱۶/۹۹	۰/۳۴	۵	
۰/۳۷	۱۸/۷۳	۰/۵۶	-۱/۸۷	۴۵/۶۸	۰/۰۷	۱	مشگین‌شهر
۰/۷۰	۱۳/۹۸	۰/۷۶	-۰/۹۴	۲۸/۲۹	۰/۰۶	۲	
۰/۴۴	۱۷/۷۷	۰/۵۹	-۰/۱۱	۲۲/۰۰	۰/۱۹	۳	
۰/۹۱	۶/۵۷	۰/۹۲	-۰/۸۳	۲۴/۰۴	۰/۰۴	۴	
۰/۷۷	۱۰/۷۳	۰/۷۷	-۱/۲۲	۳۳/۱۱	۰/۰۴	۵	
۰/۴۶	۱۸/۲۵	۰/۳۵	-۰/۴۹	۲۴/۷۱	۰/۰۷	۱	پارس‌آباد
۰/۴۰	۱۸/۲۹	۰/۴۸	-۰/۷۲	۲۸/۲۶	۰/۰۲	۲	
۰/۶۱	۱۱/۷۰	۰/۷۶	-۰/۲۵	۲۰/۹۱	۰/۰۷	۳	
۰/۸۶	۸/۵۶	۰/۸۷	-۰/۳۸	۲۳/۱۹	۰/۰۱	۴	
۰/۷۴	۱۱/۶۸	۰/۷۴	-۰/۹۲	۳۱/۷۸	۰/۰۳	۵	




در WANN عملکرد قابل قبول را به همراه داشت. در جدول ۴ تا ۷ مقادیر بیشینه بارش به دست آمده از بهترین الگوهای مدل‌های ANN و WANN و مقادیر مشاهداتی متناظر آنها به همراه قدر مطلق خطای نسبی هر مدل، برای ایستگاه‌های منتخب ارائه شده است. لازم به ذکر است که برای محاسبه خطای نسبی از رابطه ۷ استفاده شد. در رابطه مذکور، RE معرف خطای نسبی،  $R_p$  و  $R_o$  به ترتیب مقادیر بارش بیشینه مشاهداتی و شبیه‌سازی شده می‌باشد.

$$RE(\%) = \left| \frac{R_o - R_p}{R_o} \right| \times 100 \quad (7)$$



با توجه به نتایج جدول مذکور مشاهده می‌شود که خطای مدل WANN در برآورد بارش پیک ماهانه در ایستگاه‌های خلخال و مشگین‌شهر مشابه یکدیگر و به ترتیب برابر با ۱۱/۲ و ۱۱/۶ درصد به دست آمد. در ایستگاه‌های اردبیل و پارس‌آباد خطای مدل WANN در تخمین بارش پیک با اندکی افزایش، به ترتیب ۱۶/۸ و ۱۶/۰ درصد حاصل شد. همچنین مدل ANN در این خصوص، عملکرد ضعیفی به همراه داشته است.




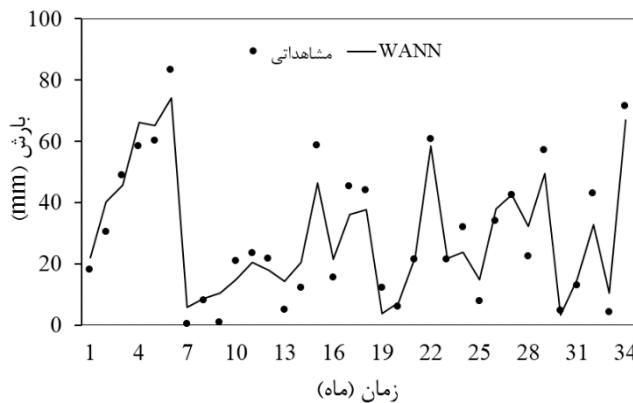
در شکل‌های ۳ تا ۶ نمودارهای پراکندگی حول نیمساز ۴۵ درجه و تغییرات سری زمانی مقادیر مشاهداتی و پیش‌بینی شده حاصل از مدل WANN به‌زای بهترین الگو برای ایستگاه‌های اردبیل، خلخال، مشگین‌شهر و پارس‌آباد در دوره آزمون نمایش داده شده است. همان‌گونه که شکل‌های مذکور نشان می‌دهد، در ایستگاه اردبیل، مدل WANN از لحاظ پراکندگی نقاط حول نیمساز ۴۵ درجه، انطباق مقادیر مشاهداتی و مدل و همچنین تخمین مقادیر پیک عملکرد قابل قبولی را به همراه داشته است. در ایستگاه خلخال نیز نتایج به دست آمده مشابه ایستگاه اردبیل می‌باشد. به طوری که نتایج بدست آمده توسط مدل WANN عملکرد مناسبی را از خود نشان داده است. برای ایستگاه مشگین‌شهر می‌توان دید که اگر چه مقدار ضریب تعیین مدل جهت پیش‌بینی بارش ماهانه قابل قبول و معنی‌دار می‌باشد، اما عمده ضعف مدل در پیش‌بینی مقادیر پیک بوده است و حالت کم‌برآورد مدل در تخمین مقادیر پیک بارش نمایان است. در ایستگاه پارس‌آباد نیز از بین مدل‌های مورد استفاده، مدل





شکل (۳): نمودارهای پراکندگی و سری زمانی مقادیر مشاهداتی و پیش‌بینی شده برای ایستگاه اردبیل در دوره آزمون



شکل (۴): نمودارهای پراکندگی و سری زمانی مقادیر مشاهداتی و پیش‌بینی شده برای ایستگاه خلخال در دوره آزمون



شکل (۵): نمودارهای پراکندگی و سری زمانی مقادیر مشاهداتی و پیش‌بینی شده برای ایستگاه مشگین‌شهر در دوره آزمون



شکل (۶): نمودارهای پراکندگی و سری زمانی مقادیر مشاهداتی و پیش‌بینی شده برای ایستگاه پارس‌آباد در دوره آزمون



جدول (۴): کارآیی مدل‌های مورد مطالعه در پیش‌بینی مقادیر بیک بارش ماهانه ایستگاه اردبیل

خطای نسبی (درصد)		مقادیر پیش‌بینی شده (mm)		مقادیر بارش بیک مشاهداتی (mm)
WANN	ANN	WANN	ANN	
۱۸/۹	۴۳/۳	۳۶/۰	۴۳/۴	۳۰/۳
۲۰/۱	۱/۶	۲۵/۷	۳۱/۶	۳۲/۱
۱۱/۲	۹۷/۲	۲۹/۲	۰/۹	۳۲/۹
۲۸/۱	۳۸/۰	۴۴/۷	۲۱/۶	۳۴/۹
۲۹/۴	۷۲/۷	۲۴/۸	۶۰/۶	۳۵/۱
۱۰/۶	۹۶/۵	۴۲/۵	۱/۳	۳۸/۴
۲۷/۵	۷/۲	۴۰/۲	۵۱/۵	۵۵/۵
۲/۳	۲۵/۱	۸۰/۴	۵۸/۹	۷۸/۶
۳/۲	۳۴/۳	۸۷/۸	۵۹/۶	۹۰/۷
۱۶/۸	۴۶/۲	میانگین قدر مطلق خطا (درصد)		

جدول (۵): کارآیی مدل‌های مورد مطالعه در پیش‌بینی مقادیر بیک بارش ماهانه ایستگاه خلخال

خطای نسبی (درصد)		مقادیر پیش‌بینی شده (mm)		مقادیر بارش بیک مشاهداتی (mm)
WANN	ANN	WANN	ANN	
۱/۹	۱/۳	۳۹/۲	۴۰/۴	۳۹/۹
۸/۰	۳/۳	۳۷/۴	۳۹/۴	۴۰/۷
۳۵/۳	۱۱/۰	۲۷/۰	۳۷/۱	۴۱/۷
۲۷/۳	۱۲/۸	۶۱/۶	۴۲/۲	۴۸/۴
۱۰/۲	۱/۸	۴۴/۱	۵۰/۰	۴۹/۱
۲/۰	۱۸/۰	۵۴/۲	۴۳/۶	۵۳/۱
۲/۰	۳۳/۸	۶۶/۵	۴۳/۲	۶۵/۲
۶/۹	۵۳/۷	۶۱/۳	۳۰/۵	۶۵/۸
۷/۳	۴۷/۱	۸۸/۲	۴۳/۵	۶۲/۲
۱۱/۲	۲۰/۳	میانگین قدر مطلق خطا (درصد)		

جدول (۶): کارآیی مدل‌های مورد مطالعه در پیش‌بینی مقادیر بیک بارش ماهانه ایستگاه مشکین شهر

خطای نسبی (درصد)		مقادیر پیش‌بینی شده (mm)		مقادیر بارش بیک
WANN	ANN	WANN	ANN	مشاهداتی (mm)
۲۰/۲	۶۳/۶	۳۶/۱	۱۶/۵	۴۵/۳
۶/۳	۳۵/۶	۴۵/۶	۳۱/۴	۴۸/۷
۱۳/۵	۳۰/۸	۴۹/۴	۷۴/۷	۵۷/۱
۱۳/۷	۵۳/۶	۶۶/۲	۲۷/۰	۵۸/۲
۲۰/۹	۴۱/۲	۴۶/۳	۳۴/۴	۵۸/۵
۸/۷	۵۱/۸	۶۵/۲	۲۸/۹	۶۰/۰
۳/۸	۲۱/۴	۵۸/۳	۷۳/۶	۶۰/۶
۶/۲	۴۹/۸	۶۶/۹	۳۵/۹	۷۱/۴
۱۰/۷	۲۸/۴	۷۴/۲	۵۹/۵	۸۳/۱
۱۱/۶	۴۱/۸	میانگین قدر مطلق خطا (درصد)		

جدول (۷): کارآیی مدل‌های مورد مطالعه در پیش‌بینی مقادیر بیک بارش ماهانه ایستگاه پارس‌آباد

خطای نسبی (درصد)		مقادیر پیش‌بینی شده (mm)		مقادیر بارش بیک
WANN	ANN	WANN	ANN	مشاهداتی (mm)
۵/۸	۹۳/۸	۴۰/۱	۲/۴	۳۷/۹
۳۹/۸	۶۹/۷	۲۳/۴	۱۱/۸	۳۸/۹
۰/۷	۳۰/۲	۴۰/۷	۵۲/۶	۴۰/۴
۲۰/۴	۲۷/۹	۵۵/۶	۳۳/۳	۴۶/۲
۳۰/۶	۴۵/۰	۳۵/۳	۷۳/۸	۵۰/۹
۵/۰	۵۶/۲	۷۴/۶	۲۷/۳	۶۲/۳
۰/۶	۴۵/۴	۷۴/۴	۳۸/۸	۷۱/۰
۲۴/۸	۲۳/۴	۵۸/۷	۹۲/۳	۷۴/۸
۱۶/۷	۵۷/۷	۹۶/۶	۳۵/۰	۸۲/۸
۱۶/۰	۴۹/۹	میانگین قدر مطلق خطا (درصد)		

نسبت به مبدأ زمانی پیش‌بینی) در نظر گرفته شد، شاخص تابع همبستگی متقاطع<sup>۱</sup> (CCF) بود. در شکل ۷ نمودارهای مقادیر CCF بین متغیرهای حداقل دما ( $T_{min}$ )، حداکثر دما ( $T_{max}$ )، میانگین سرعت باد ( $U_{ave}$ ) و رطوبت نسبی (RH) با متغیر بارش ماهانه به عنوان نمونه برای ایستگاه اردبیل ارائه گردیده است. بر اساس نمودارهای همبستگی متقاطع مشخص شد که در کلیه ایستگاه‌ها، متغیرهای حداقل و حداکثر دما به همراه تأخیرهای زمانی طولانی مدت آن‌ها می‌توانند بر روی بارش ماهانه ایستگاه‌های مورد مطالعه تأثیر معنی‌دار داشته باشند. متغیرهای سرعت باد و رطوبت

### توسعه مدل‌های هوشمند با به‌کارگیری متغیرهای اقلیمی و تأخیرهای بارش

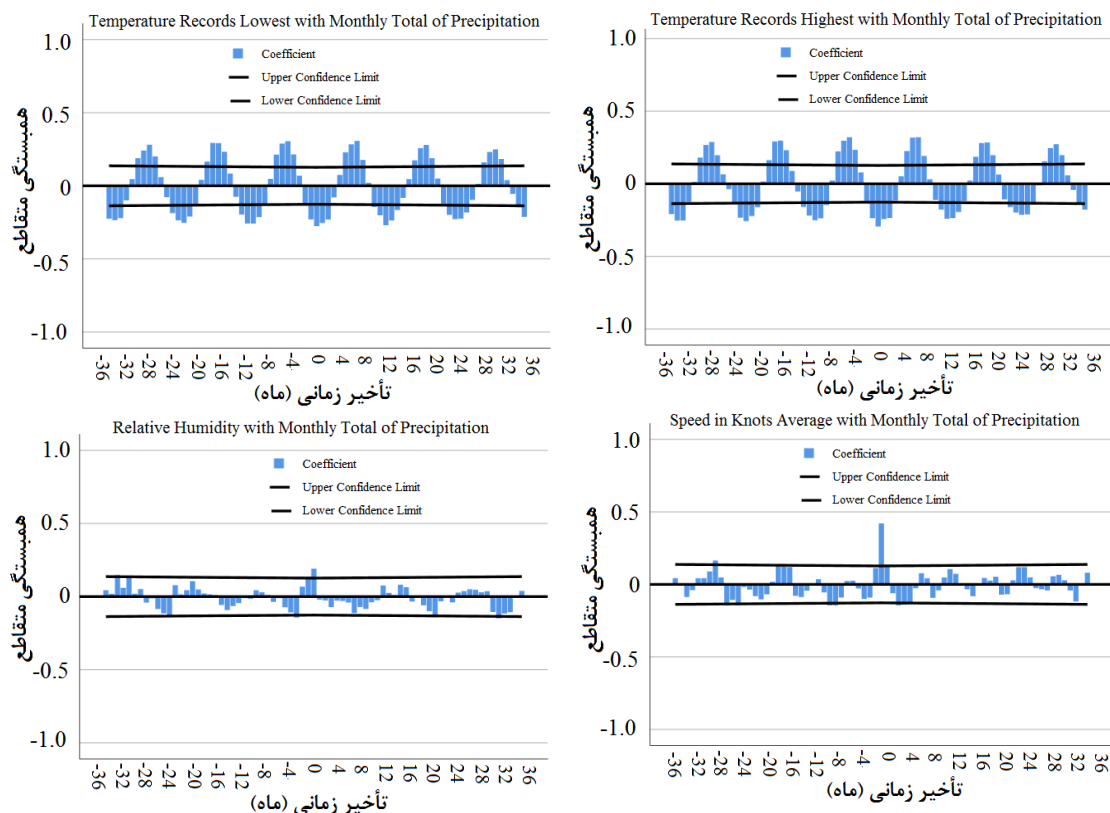
پس از بررسی کارآیی مدل‌های هوشمند به‌ازای تأخیرهای مختلف بارش، و انتخاب بهترین مدل و بهترین الگو برای هر ایستگاه می‌توان به‌منظور بهبود نتایج مدل برتر، متغیرهای اقلیمی تأثیرگذار بر بارش ماهانه شامل دما، سرعت باد و رطوبت نسبی را نیز با اعمال تأخیرهای مناسب به ورودی‌های مدل اضافه نمود. در پژوهش حاضر، معیاری که برای انتخاب مناسب‌ترین تأخیرهای دما، سرعت باد و رطوبت نسبی

<sup>1</sup> Cross section correlation function



منتخب جدول ۳ (بهترین سناریو) و همچنین ترکیبی از متغیرهای اقلیمی و سناریوهای منتخب می‌باشد. نظر به اینکه برای همه ایستگاه‌ها مدل WANN بهترین عملکرد را به همراه داشت، بنابراین کلیه الگوهای تعریف شده در جدول ۸ توسط این مدل اجرا شدند.

نسبی نیز بدون تأخیرهای زمانی می‌تواند بر روی بارش ماهانه تأثیر معنی‌دار داشته باشد. با توجه به نتایج مذکور، ساختار الگوهای ترکیبی شامل متغیرهای اقلیمی و تأخیرهای بارش برای پیش‌بینی بارش ماهانه ایستگاه‌های اردبیل، خلخال، مشگین‌شهر و پارس‌آباد مطابق جدول ۸ می‌باشد. لازم به ذکر است که الگوهای تعریف شده برای هر ایستگاه شامل سناریوهای



شکل (۷): نمودارهای مقادیر همبستگی متقاطع بین متغیرهای اقلیمی و بارش ماهانه ایستگاه اردبیل

جدول (۸): ساختار الگوهای مورد استفاده در پژوهش حاضر برای پیش‌بینی بارش ماهانه بر اساس تأخیرهای بارش و متغیرهای اقلیمی

ساختار الگو	شماره الگو	نام ایستگاه
$P(t+1) = P(t), P(t-1), \dots, P(t-11)$	۱	اردبیل و خلخال
$P(t+1) = P(t), \dots, P(t-11), T_{\min}(t), \dots, T_{\min}(t-5), T_{\max}(t), \dots, T_{\max}(t-5)$	۲	
$P(t+1) = P(t), \dots, P(t-11), T_{\min}(t), \dots, T_{\min}(t-5), T_{\max}(t), \dots, T_{\max}(t-5), RH(t), U_{ave}(t)$	۳	
$P(t+1) = P(t), P(t-1), \dots, P(t-7)$	۱	مشگین‌شهر و پارس‌آباد
$P(t+1) = P(t), \dots, P(t-7), T_{\min}(t), \dots, T_{\min}(t-5), T_{\max}(t), \dots, T_{\max}(t-5)$	۲	
$P(t+1) = P(t), \dots, P(t-7), T_{\min}(t), \dots, T_{\min}(t-5), T_{\max}(t), \dots, T_{\max}(t-5), RH(t), U_{ave}(t)$	۳	



### بررسی عملکرد مدل‌های هوشمند به‌ازای الگوهای ترکیبی متغیرهای اقلیمی و تأخیرهای بارش

در جدول ۹ عملکرد مدل WANN به‌ازای الگوهای تعریف شده در جدول ۸ با استفاده از شاخص‌های آماری خطا در دوره آزمون نشان داده شده است. همان‌طور که نتایج جدول ۹ نشان می‌دهد در همه ایستگاه‌ها سناریوی ترکیبی تأخیرهای بارش، کمینه و بیشینه دما (الگوی شماره ۲) بهترین نتیجه را به همراه داشته است. از سوی دیگر با وجود اینکه، اضافه شدن کمینه و بیشینه دما به عنوان متغیرهای ورودی باعث بهبود جزئی نتایج مدل در مقایسه با

الگوی شماره ۱ شده است اما هزینه محاسباتی مدل را نیز به مراتب افزایش می‌دهد. همچنین، در همه ایستگاه‌ها، اضافه شدن رطوبت نسبی و سرعت باد به عنوان متغیرهای ورودی تا حدودی باعث کاهش عملکرد مدل شده است. از این رو نظر به دقت قابل قبول الگوی شماره ۱ و پایین تر بودن هزینه محاسباتی آن، می‌توان آن را به عنوان الگوی بهینه برای همه ایستگاه‌ها معرفی نمود. بنابراین در حالت کلی، با استفاده از مدل WANN به همراه تأخیرهای مناسب بارش در مقیاس زمانی ماهانه، می‌توان بارش ماهانه (ماه آینده) ایستگاه‌های منتخب استان اردبیل شامل اردبیل، خلخال، مشگین شهر و پارس‌آباد را با دقت قابل قبول پیش‌بینی نمود.

جدول (۹): مقادیر شاخص‌های آماری عملکرد مدل WANN به‌ازای الگوهای ترکیبی تأخیرهای بارش و متغیرهای اقلیمی

نام ایستگاه	شماره الگو	R <sup>2</sup>	RMSE (mm)	NS
اردبیل	۱	۰/۸۸	۷/۱۳	۰/۸۷
	۲	۰/۹۰	۶/۳۶	۰/۹۰
	۳	۰/۸۵	۷/۲۹	۰/۸۴
خلخال	۱	۰/۹۱	۶/۰۳	۰/۹۱
	۲	۰/۹۴	۵/۸۳	۰/۹۵
	۳	۰/۸۹	۶/۸۵	۰/۸۷
مشگین شهر	۱	۰/۹۲	۶/۵۷	۰/۹۱
	۲	۰/۹۳	۶/۳۵	۰/۹۲
	۳	۰/۸۷	۷/۴۱	۰/۸۸
پارس آباد	۱	۰/۸۷	۸/۵۶	۰/۸۶
	۲	۰/۸۹	۷/۹۳	۰/۸۸
	۳	۰/۸۲	۹/۰۳	۰/۸۳

### نتیجه‌گیری

پیش‌بینی بارش ماهانه یکی از مؤلفه‌های مهم و تأثیرگذار در مدیریت منابع آب حوضه آبریز می‌باشد. در پژوهش حاضر توسعه مدل‌های ANN و WANN برای شبیه‌سازی بارش ماهانه در ایستگاه‌های سینوپتیک منتخب استان اردبیل شامل اردبیل، خلخال، مشگین شهر و پارس‌آباد طی دوره آماری

مشترک ۲۲۵ ماهه ارائه گردید. نتایج حاکی از عملکرد ضعیف مدل ANN در شبیه‌سازی بارش ماهانه کلیه ایستگاه‌ها بود. اما پس از تجزیه داده‌ها توسط تبدیل موجک، نتایج بدست آمده توسط مدل WANN به‌طور چشمگیری بهبود یافت. در تحقیقات انجام گرفته توسط مظفری و همکاران (۱۳۹۴)، طوفانی و همکاران (۱۳۹۴)، سلگی و همکاران (۱۳۹۵) و Venkata-

می‌باشد. علاوه بر آن، در کلیه ایستگاه‌ها کاربرد الگوی ترکیبی تأخیرهای بارش، کمینه و بیشینه دما با بهبود جزئی نتایج همراه بود اما هزینه محاسباتی مدل نیز به‌طور قابل توجهی افزایش یافت. هم‌چنین در همه ایستگاه‌ها، اضافه شدن رطوبت نسبی و سرعت باد به‌عنوان متغیرهای ورودی تا حدودی باعث کاهش عملکرد مدل شد. در خصوص تخمین مقادیر بارش پیک ماهانه، خطای مدل WANN در ایستگاه‌های اردبیل، خلخال، مشگین‌شهر و پارس‌آباد به ترتیب برابر با ۱۶/۸، ۱۱/۲، ۱۱/۶ و ۱۶/۰ درصد حاصل شد. نتایج کلی پژوهش حاضر نشان داد که با استفاده از مدل WANN به همراه تأخیرهای مناسب بارش در مقیاس زمانی ماهانه، می‌توان بارش ماهانه (ماه آینده) ایستگاه‌های منتخب استان اردبیل شامل اردبیل، خلخال، مشگین‌شهر و پارس‌آباد را با دقت قابل قبول پیش‌بینی نمود. برای تحقیقات آتی در این خصوص پیشنهاد می‌شود با استفاده از سایر مدل‌های هوشمند نیز اقدام به پیش‌بینی بارش ماهانه ایستگاه‌های مورد مطالعه در پژوهش حاضر شود و نتایج آن با نتایج حاصل از تحقیق حاضر مقایسه شود.

(2013) Ramana et al. نیز برتری مدل WANN نسبت به مدل ANN در پیش‌بینی بارش ماهانه دیده شده است. در تمامی ایستگاه‌ها با افزایش تعداد تأخیرهای سری زمانی بارش، دقت شبیه‌سازی بارش ماهانه افزایش یافت. در ایستگاه‌های اردبیل و خلخال بهترین عملکرد برای پیش‌بینی کوتاه مدت بارش ماهانه (یک ماه بعد) مربوط به سناریوی تعریف شده بر اساس کاربرد بارش ماه فعلی و ۱۱ ماه قبل بود. مقادیر R2 و RMSE به‌ازای بهترین الگو برای ایستگاه اردبیل به ترتیب برابر ۰/۸۸ و ۷/۱۳ میلی‌متر و برای ایستگاه خلخال برابر ۰/۹۱ و ۶/۰۳ میلی‌متر به دست آمد. در ایستگاه‌های مشگین‌شهر و پارس‌آباد سناریوی تعریف شده بر اساس کاربرد بارش ماه فعلی و ۷ ماه قبل به‌عنوان الگوی مناسب برای پیش‌بینی کوتاه مدت بارش ماهانه انتخاب شد. مقادیر R2 و RMSE به‌ازای بهترین الگو برای ایستگاه مشگین‌شهر به ترتیب برابر ۰/۹۲ و ۶/۵۷ میلی‌متر و برای ایستگاه پارس‌آباد برابر ۰/۸۷ و ۸/۵۶ میلی‌متر به دست آمد. شایان ذکر است که مقدار ضریب نشان-ساتکلیف مدل WANN به‌ازای الگوهای مطلوب در تمامی ایستگاه‌ها، بزرگتر از ۰/۸ به دست آمد که حاکی از عملکرد قابل قبول آن

## منابع

- پورحقی، ا.، سلگی، ف. رادمنش و م. شهنی دارابی. ۱۳۹۷. استفاده ترکیبی از تبدیل موجک و مدل‌های هوشمند در شبیه‌سازی جریان رودخانه (مطالعه موردی: رودخانه‌های کاکارضا و سراب صیدعلی). فصلنامه علمی پژوهشی مهندسی آبیاری و آب ایران، سال هشتم، شماره ۳۲، ص ۱۷-۱.
- ستاری، م.، ع. جودی و ف. نهرین. ۱۳۹۳. پیش‌بینی مقادیر بارش ماهانه با استفاده از شبکه‌های عصبی مصنوعی و مدل درختی M5. نشریه پژوهش‌های جغرافیای طبیعی. ۲۴۷-۲۶۰: (۲)۴۶.
- سلگی، الف.، ح. زارعی، الف. پورحقی و ح. خدابخشی. ۱۳۹۵. پیش‌بینی بارش ماهانه با مدل ترکیبی شبکه عصبی مصنوعی موجک و مقایسه با مدل شبکه عصبی مصنوعی. فصلنامه علمی پژوهشی مهندسی آبیاری و آب، سال ششم، شماره ۲۳، ص ۳۳-۱۸.
- شفائی، م.، ا. فاخری‌فرد، ص. دربندی و م.ع. قربانی. ۱۳۹۲. پیش‌بینی جریان روزانه رودخانه با استفاده از مدل هیبرید موجک و شبکه عصبی، مطالعه موردی: ایستگاه هیدرومتری ونیاد در حوضه آبریز آجی‌چای. نشریه مهندسی آبیاری و آب ایران، سال چهارم، شماره ۱۴، ص ۱۲۸-۱۱۳.
- قاسمی، ه.، ا. بذرافشان و ک. بخشایش‌منش. ۱۳۹۶. پیش‌بینی بارش ماهانه با استفاده از الگوهای پیوند از دور و شبکه عصبی مصنوعی (مطالعه موردی: حوزه فلات مرکزی ایران). فیزیک زمین و فضا. ۴۰۵-۴۱۸: (۲)۴۳.

کدخداحسینی م، ش. شامحمدی ر. میرعباسی و ح. نوذری. ۱۳۹۵. ارزیابی عملکرد شبکه‌های عصبی مصنوعی و ماشین بردار پشتیبان در بازسازی داده‌های ماهانه و فصلی بارش در ایستگاه‌های باران سنجی (مطالعه موردی: استان همدان). مجله پژوهش آب ایران، ۱۱(۳): ۹۱-۱۰۰.

طوفانی، پ، ا. فاخری فرد، ا. مساعدی و ا. دهقانی. ۱۳۹۴. پیش‌بینی بارندگی ماهانه با استفاده مستقیم از موجک و شبکه عصبی و موجکی. مجله مرتع و آبخیزداری، جلد ۶۸، شماره ۲، ص ۵۷۱-۵۵۱.

مظفری غ، ش. شفیع‌ی و ح. همتی. ۱۳۹۴. پیش‌بینی بارش ماهانه ایستگاه سینوپتیک کرمانشاه با استفاده از مدل ترکیبی شبکه عصبی و موجک. نشریه پژوهش‌های حفاظت آب و خاک، ۱۵۲-۱۳۵.

معروفی، ص، ک. امیرمرادی و ن. پارسافر. ۱۳۹۲. پیش‌بینی جریان روزانه با استفاده از شبکه‌های عصبی مصنوعی و عصبی-موجکی (مطالعه موردی: رودخانه باراندوزچای). نشریه دانش آب و خاک، جلد ۲۳، شماره ۳، ص ۱۰۳-۹۳.

معروفی ص، ر. نوروز ولا شدی و ف. گلکار. ۱۳۹۶. مدل سازی پیش‌بینی بارش ماهانه در حوضه آبریز بلوچستان جنوبی. فصلنامه تحقیقات جغرافیایی. ۳۲(۱): ۱۴۹-۱۶۲.

Abdollahi, S., J. Raeisi, M. Khalilianpour, F. Ahmadi and O. Kisi. 2017. Daily mean streamflow prediction in perennial and non-perennial rivers using four data driven techniques. *Water Resources Management*, 31(15): 4855-4874.

Adamowski, J. 2008. Development of a short-term river flood forecasting method for snowmelt driven and cross wavelet analysis floods based on wavelet. *Journal of Hydrology*, 353: 247-266.

He, Z., X. Wen, H. Liu and J. Du. 2014. A comparative study of artificial neural network, adaptive neuro fuzzy inference system and support vector machine for forecasting river flow in the semiarid mountain region. *Journal of Hydrology*, 509: 379-386.

Liu, S. and H. Shi. 2019. A recursive approach to long-term prediction of monthly precipitation using genetic programming. *Water Resources Management*, 33(3): 1103-1121.

Lou, J., W. Lu, Y. Ji and D. Ye. 2016. A comparison of three prediction models for predicting monthly precipitation in Liaoyuan city, China. *Water Science and Technology*, 16(3): 845-854.

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: 466-472.

Shu, C. and T.B.M.J. Ouarda. 2008. Regional flood frequency analysis at ungauged sites using the adaptive neuro-fuzzy inference system. *Journal of Hydrology*, 349(1): 31-43.

Sofian, I.M., A.K. Afandi, I. Iskandar and Y. Apriani. 2018. Monthly rainfall prediction based on artificial neural networks with backpropagation and radial basis function. *International Journal of Advances in Intelligent Informatics*, 4(2): 154-166.

Venkata-Ramana, R., B. Krishna, S.R. Kumar and N.G. Pandey. 2013. Monthly Rainfall Prediction Using Wavelet Neural Network Analysis. *Water Resources Management*, 27: 3697-3711.

Yaseen, Z.M., I. Ebtehaj, S. Kim, H. Sanikhani, H. Asadi, M.I. Ghareb, H. Bonakdari, W.H.M. Mohtar, N. Al-Ansari and S. Shahid. 2019. Novel hybrid data-intelligence model for forecasting monthly rainfall with uncertainty analysis. *Water*, 11(502): 1-23.





## Monthly precipitation prediction of Ardabil province using ANN and WANN models

Mohammad Reza Nikpour<sup>\*1</sup>, Sajjad Abdollahi Asadabadi<sup>2</sup>

### Abstract

Precipitation is one of the most important hydrological events and its prediction can be used as a practical tool for optimum utilization and management of water resources. In the present study, artificial neural network (ANN) and wavelet-artificial neural network (WANN) were used for monthly precipitation prediction at selected synoptic stations in Ardabil province, including Ardabil, Khalkhal, Meshginshahr and Parsabad during the 225 months for the years 1996-2016. For the short-term forecast of monthly precipitation (one month later), different scenarios were defined based on precipitation delays. Results indicated that the WANN model with the highest determination coefficient ( $R^2$ ) and minimum root mean square error (RMSE) was acceptable for all stations. The values of  $R^2$  and RMSE for Ardabil station were equal to 0.88 and 7.13 mm, for Khalkhal station were equal to 0.91 and 6.36 mm, for Meshginshahr station were equal to 0.92 and 6.97 mm and for Parsabad station were equal to 0.86 and 8.51 mm, respectively. In all stations, utilization of the superior model (WANN model) with the combination scenarios i.e. rainfall delays, the minimum and maximum temperature improved the results of the model, but on the other hand, increased the computational cost of the model. Also, in all stations, the addition of relative humidity and wind speed as input variables somewhat reduced the performance of the model. The general results of this study showed that the WANN model with appropriate rainfall delays on a monthly scale can be utilized to predict monthly precipitation of selected stations in Ardabil province, including Ardabil, Khalkhal, Meshginshahr and Parsabad with acceptable accuracy.

**Key words:** Ardabil province, Wavelet analysis, Monthly precipitation, Gene expression programming, Artificial neural network.

<sup>1</sup> Assistant Professor, Department of Water Engineering, Faculty of Agriculture and Natural Resources, University of Mohaghegh Ardabili, Ardabil, Iran. [m\\_nikpour@uma.ac.ir](mailto:m_nikpour@uma.ac.ir)

<sup>2</sup> Ph.D., Water Resources Engineering, Regional Water Company of Charmahal and Bakhtiari, Water Resources Management Company, Ministry of Energy, Iran