

ارزیابی مدل‌های فراکاوشی در تخمین میزان تبخیر روزانه (مطالعه موردی: حوضه کاکارضا- استان لرستان)

ایرج ویسکرمی^۱، رضا دهقانی*^۲، رضا چمن پیرا^۳

۱-استادیار پژوهشی بخش تحقیقات حفاظت خاک و آبخیزداری، مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی استان لرستان، سازمان

تحقیقات، آموزش و ترویج کشاورزی، خرم‌آباد، ایران

۲-دکترای علوم و مهندسی آب، بخش تحقیقات حفاظت خاک و آبخیزداری، مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی استان لرستان،

سازمان تحقیقات، آموزش و ترویج کشاورزی، خرم‌آباد، ایران

۳-استادیار پژوهشی بخش تحقیقات حفاظت خاک و آبخیزداری، مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی استان لرستان، سازمان

تحقیقات، آموزش و ترویج کشاورزی، خرم‌آباد، ایران

چکیده

تبخیر یکی از جمله پارامترهای مهم در هیدرولوژی و مهندسی منابع آب است که مورد توجه محققان قرار دارد. در این تحقیق با هدف پیش‌بینی میزان تبخیر روزانه ایستگاه کاکارضا واقع در استان لرستان، از مدل‌های هوشمند شبکه عصبی موجک و شبکه‌های عصبی مصنوعی استفاده شده است. پارامترهای روزانه در نظر گرفته شده در فرآیند مدل‌سازی شامل ساعات آفتابی، حداقل، حداکثر و میانگین دمای هوا، رطوبت نسبی، تعداد روزهای ابری، بارش و سرعت باد در دوره آماری (۱۴۰۲-۱۳۹۲) می‌باشد. از معیارهای ضریب تعیین، ریشه میانگین مربعات خطا و ضریب نش ساتکلیف برای ارزیابی صحت و نیز مقایسه عملکرد مدل‌ها مورد استفاده قرار گرفت. نتایج حاصل نشان داد هر دو مدل به کار رفته با دقت قابل قبولی توانسته به شبیه‌سازی میزان تبخیر روزانه بپردازد، که از بین این مدل‌ها، مدل شبکه عصبی موجک با بیشترین ضریب تعیین (۰/۹۷۰)، کمترین ریشه میانگین مربعات خطا (۰/۲۵۵ mm) و نیز معیار نش ساتکلیف (۰/۹۸۸) در مرحله صحت‌سنجی در اولویت قرار گرفت. علاوه بر آن، متغیرهای مورد استفاده در مدل‌های پیش‌بینی میزان تبخیر توانسته‌اند، نحوه تغییرات تبخیر در ایستگاه مورد بررسی را تشخیص دهند. در مجموع نتایج نشان داد که روش شبکه عصبی موجک توانایی بالایی در تخمین مقادیر کمینه و بیشینه میزان تبخیر دارد.

کلمات کلیدی: ایستگاه کاکارضا، تبخیر روزانه، پیش‌بینی، شبکه عصبی موجک، شبکه‌های عصبی مصنوعی

۱- مقدمه

فرآیند تبخیر یکی از اجزای چرخه هیدرولوژی و توازن آب در طبیعت به شمار می‌آید و در مناطق با بارندگی کم تلفات ناشی از این فرآیند سهم قابل توجهی از بیلان آبی را به خود اختصاص می‌دهد. لذا، باید در طراحی سیستم‌های مختلف آبیاری و منابع آبی تلفات ناشی از تبخیر مورد توجه قرار گیرد. تبخیر از تشت به علت سهولت تفسیر داده‌های آن در سراسر دنیا به عنوان شاخصی برای تعیین میزان تبخیر واقعی یک ناحیه استفاده می‌شود، ولی محدودیت‌های ابزاری و مشکلات عملی شامل خطای ناظر، کدورت آب و مشکلات نگهداری تشت تبخیر از میزان دقت این ابزار می‌کاهد. بنابراین با توجه به مشکلات و محدودیت‌های تشت تبخیر، همچنین تأثیرگذاری عوامل مختلف و وجود رابطه غیرخطی بین پارامترهای تأثیرگذار بر میزان تبخیر، پیش‌بینی این پدیده امری پیچیده است. از اینرو ارائه روش‌هایی برای برآورد میزان تبخیر با استفاده از متغیرهای هواشناسی و اقلیمی ضروری است. (Dehghani and Torabi Poudeh, 2021) امروزه سیستم‌های هوشمند به طور گسترده‌ای برای پیش‌بینی پدیده‌های غیرخطی مورد استفاده قرار می‌گیرند، که روش شبکه‌های عصبی مصنوعی (3ANN) از جمله این روش‌ها است. شبکه‌های عصبی موجک نمایش بامعنی روابط نامشخص مابین پارامترها در یک فرآیند می‌باشد. شبکه‌های عصبی مصنوعی با الهام از سیستم پردازش اطلاعات مغز طراحی که توانایی آن در تقریب الگوهای یک مساله سبب افزایش دامنه کاربرد این شبکه‌ها شده است. در سالهای اخیر استفاده از روش‌های شبکه‌های موجک و شبکه‌های عصبی مصنوعی - در فرآیندهای هیدرولوژیکی و از جمله مدل‌سازی میزان تبخیر بسیار مورد توجه محققین قرار گرفته است، که از جمله می‌توان به موارد زیر اشاره نمود.

در پژوهشی (Wang and Ding (2003 با بررسی قابلیت‌های مدل مدل شبکه عصبی موجکی به این نتیجه رسیدند که این مدل دقت و طول زمان پیش‌بینی را افزایش می‌دهد و در نتیجه برای پیش‌بینی‌های هیدرولوژیکی بسیار مفید می‌باشد. در پژوهشی دیگر (Okkan (2012 مدل شبکه عصبی موجکی برای پیش‌بینی جریان ورودی به مخزن سد کمیر در ترکیه مورد بررسی قرار داده و نشان داد که شبکه

عصبی موجکی یک مدل مناسب برای پیش‌بینی جریان ورودی به مخزن سد بوده و می‌تواند نسبت به سایر روش‌ها عملکرد قابل قبولی داشته باشد. همچنین در پژوهشی Venkata et al (2013) شبکه عصبی موجک را به منظور پیش‌بینی بارش ماهانه ایستگاه دارجلینگ در کوهپایه‌های هیمالیا به کاربرند و نشان دادند که مدل شبکه عصبی موجک عملکرد بهتری نسبت به مدل شبکه عصبی مصنوعی دارد. در پژوهشی (Sharifi et al (2016 با استفاده از سه مدل شبکه عصبی مصنوعی، برنامه ریزی بیان ژن و شبکه عصبی موجک به پیش‌بینی میزان تابش خورشیدی ایستگاه‌های تبریز، ارومیه پرداختند و نشان دادند مدل شبکه عصبی موجک از دقت و عملکرد قابل قبولی در پیش‌بینی تابش خورشیدی برخوردار است. در پژوهشی (Karthika et al (2016 دمای متوسط روزانه حوضه شیموگا واقع در هند را با استفاده از داده‌های سرعت باد، رطوبت نسبی، تعداد ساعات آفتابی و بارش توسط مدل فازی و شبکه عصبی موجک پیش‌بینی کردند. نتایج نشان داد مدل شبکه عصبی موجک در پیش‌بینی دمای متوسط روزانه عملکرد بهتری نسبت به مدل فازی دارد. در پژوهشی (Sahi et al (2021 جهت تخمین میزان تبخیر روزانه شهرستان دامغان از مدل شبکه عصبی مصنوعی استفاده نمودند بدین منظور از داده‌های هواشناسی شامل حداقل و حداکثر دمای روزانه، میانگین رطوبت نسبی، سرعت باد، ساعات آفتابی و تبخیر در طول دوره زمانی آماری ۱۶ سال (۲۰۱۸-۲۰۰۲) بهره‌گرفتند نتایج نشان داد شبکه عصبی مصنوعی دقت بالا و خطای ناچیزی در تخمین میزان تبخیر دارد. در پژوهشی (Dehghani and Dehghani (2022 جهت برآورد دمای هوای شهرستان ساری از مدل‌های شبکه عصبی موجک و شبکه عصبی مصنوعی استفاده کردند. بدین منظور از پارامتر رطوبت نسبی، دمای بیشینه، دمای کمینه، سرعت باد و تبخیر در مقیاس زمانی روزانه در طی سال آبی (۱۳۹۲-۱۳۸۲) بعنوان ورودی شبکه و دمای متوسط روزانه هوا به عنوان خروجی شبکه انتخاب گردید نتایج نشان داد مدل شبکه عصبی موجک در تخمین بیشتر مقادیر دقت بالایی از خود نشان داده است. در مجموع با توجه به پژوهش‌های انجام‌شده و ذکر این نکته که ایستگاه کاکارضا واقع در استان لرستان یکی از مهم‌ترین ایستگاه‌های هواشناسی در شمال استان لرستان را دارا و مهم‌ترین منبع تأمین‌کننده تولید محصولات کشاورزی بوده

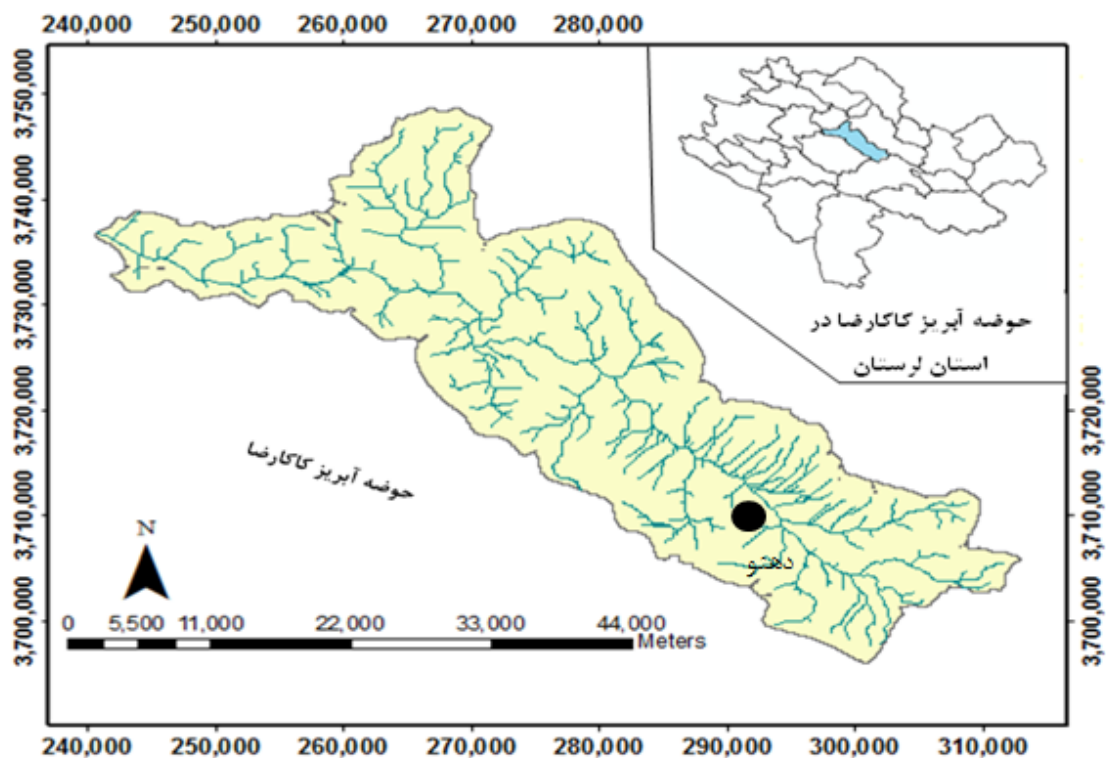
۳۳ درجه عرض شمالی و در استان لرستان و شرق شهرستان خرم‌آباد واقع شده است و قسمتی از سرشاخه‌های رودخانه کرخه را در زاگرس تشکیل می‌دهد. رودخانه کاکارضا در ارتفاع ۱۵۵۰ متری از سطح آب‌های آزاد قرار دارد. مساحت حوضه کاکارضا ۱۱۴۸ کیلومتر مربع و دارای رودخانه‌ای به طول ۸۵ کیلومتر می‌باشد. رودخانه کاکارضا پس از پیوستن به رودخانه‌های کشکان، سیمره و کرخه، در نهایت به خلیج فارس می‌ریزد. که در شکل (۱) موقعیت جغرافیایی منطقه مورد مطالعه نشان داده شده است. در این تحقیق داده‌های بارندگی و رواناب در مقیاس زمانی ماهانه مربوط به ایستگاه هرود (کاکارضا) از سال ۱۳۹۲ تا ۱۴۰۲ که در شرکت آب منطقه‌ای و سازمان هواشناسی استان لرستان در دسترس بود، استفاده گردید. همچنین اطلاعات هواشناسی ایستگاه کاکارضا کاکارضا که در این تحقیق مورد بررسی قرار گرفته، شامل ساعات آفتابی (SQ)، حداقل (TN)، حداکثر (TX) و میانگین دما (TG)، رطوبت نسبی (UG)، تعداد روزهای ابری (NG)، بارش (RH) و سرعت باد (Wind) در مقیاس روزانه می‌باشد. مشخصات آماری داده‌های مورد استفاده در این تحقیق در جدول (۱) منعکس شده است. همچنین در جدول ۲ همبستگی پارامترهای ذکر شده با میزان تبخیر روزانه حوضه کاکارضا نشان داده شده است در این میان ساعات آفتابی، حداقل دما، حداکثر دما و میانگین دما بیشترین تاثیر را در میزان تبخیر روزانه دارند.

است تغییرات میزان تبخیر در این منطقه بر روی رشد و نمو محصولات کشاورزی تاثیر بسزایی دارد، بنابراین مدل‌سازی دقیق میزان تبخیر روزانه ایستگاه کاکارضا به منظور افزایش کارایی اقدامات مدیریت هیدرولوژیک منطقه ضروری است. لذا هدف از این پژوهش تخمین دقیق میزان تبخیر روزانه ایستگاه کاکارضا با استفاده از شبکه عصبی موجک که با جدا نمودن سیگنال به فرکانس‌های بالا و پائین ویژگی‌های چند مقیاسی سیگنال را در اختیار داشته و دقت مدل را تا حد قابل توجهی بالا می‌برد. سیگنال‌های بالا گذر و پایین گذر حاصل از تجزیه موجک، برآزش بسیار خوبی با معادلات مجموع سینوسی دارند که هر چه تعداد مراتب این معادلات بیشتر می‌شود، دقت کار افزایش می‌یابد بسامدهای مراحل پایین‌تر تجزیه، نویز بیشتری دارند، ولی با افزایش سطح تجزیه از میزان نویز کاسته شده و سیگنال نرمتر می‌شود، می‌باشد. (Dehghani et al, 2021)

۲- مواد و روش‌ها

۲-۱- منطقه مورد مطالعه و داده‌های مورد استفاده

منطقه مورد مطالعه ایستگاه کاکارضا واقع در استان لرستان می‌باشد. این ایستگاه در رودخانه ای بنام کاکارضا در استان لرستان که از رودخانه‌های دائمی استان لرستان بوده و از کوه‌های جنوب شرقی شهرستان الشتر و بخش چغلوندی (هرود) سرچشمه گرفته و در محدوده شهرستان الشتر بنام کاکارضا معروف است، قرار گرفته است. این رودخانه بین " ۱۵ ° ۴۸ تا ۴۹ ° درجه طول شرقی و " ۲۲ ° ۳۲ الی " ۵۲ °



شکل ۱- موقعیت محدوده مطالعاتی در استان لرستان

جدول ۱- مشخصات آماری پارامترهای هواشناسی مورد استفاده در بازه زمانی (۱۳۹۲-۱۴۰۲)

صحت سنجی					آموزش					واحد	پارامتر
چولگی	انحراف معیار	ماکزیمم	مینیمم	میانگین	چولگی	انحراف معیار	ماکزیمم	مینیمم	میانگین		
۰/۱۲	۴/۳	۵۴	۴	۱۴/۴	۰/۲۱	۹/۳۲	۹۵	۳	۲۶/۷	m/s	سرعت باد
-۰/۴	۳۹/۸	۱۰۵	-۵۶	۵۴/۲	-۰/۱	۴۰/۴	۱۰۵	-۴۳	۳۵/۳	°C	میانگین دما
-۰/۴	۳۲/۴	۸۴	-۶۶	۴۳/۸	-۰/۲	۳۶/۲	۸۵	-۵۶	۱۴/۵	°C	حداقل دما
-۰/۲	۴۶/۳	۱۲۶	-۴۷	۶۶/۹	۰	۴۴/۲	۱۲۵	-۳۱	۵۷/۹	°C	حداکثر دما
۰/۰۷۸	۲/۸	۵۸	۰	۱۰/۶	۰/۲۸	۱۲/۳	۱۲۰	۰	۲۱/۱	hr	ساعات آفتابی
۳/۸	۵/۱۰۲	۴۲	۰	۲/۱	۴/۸	۶/۱۴۴	۵۷	۰	۱/۹	mm	بارش
۰/۴	۱/۳	۸	۰	۱/۱	۰/۷	۲/۱	۱۲	۰	۲/۳	day	تعداد روزهای ابری
۰/۳	۳/۷	۶۹	۵	۱۲/۲	۰/۴	۴/۲	۶۹	۱۴	۲۳/۳	%	رطوبت نسبی
۰/۱۶۳	۴/۳۲۵	۱۶/۶۰۰	۰	۶/۹۰۹	۰/۰۸۱	۴/۵۴۶	۱۹/۲۰۰	۰	۶/۳۹۴	mm	تبخیر

جدول ۲- همبستگی پارامترهای موثر بر میزان تبخیر روزانه

wind	TG	TN	TX	SQ	RH	NG	UG	
۶/۲۰۰	۴۸/۱۰۰	۳۶/۵۰۰	۵۴/۴۰۰	۶۹/۵۰۰	۴/۶۰۰	۲۷/۷۰۰	۲۷/۶۰۰	ET

۲-۲- شبکه عصبی موجک

$$f(x) = f_0(x) + \sum_{m=-\infty}^0 \sum_{k=-\infty}^{\infty} d_{m,k} \Psi_{m,k}(x) \quad (۳)$$

$$f_0(x) = \sum_k a_{0,k} \phi_{0,k}(x) \quad (۴)$$

روابط فوق بیان می‌دارند که هر تابع فیزیکی را می‌توان ابتدا به کمک تعدادی توابع مقیاس در رزولوشن صفر تقریب زد و سپس به کمک توابع ویولت در رزولوشن‌های مختلف آن تقریب را تا میزان دقت مورد نظر ادامه داد. شبکه عصبی ویولت بر مبنای روابط (۳) و (۴) شکل می‌گیرد و دارای الگوریتم‌های آموزش مخصوص خود می‌باشد که در پژوهش Wang et al (2000) به صورت کامل مورد بررسی قرار گرفته است. لازم به ذکر است در حالت کلی خانواده ویولت-های پیوسته نیز به صورت زیر بیان می‌شود:

$$\Psi_{a,b}(t) = \frac{1}{\sqrt{a}} \Psi\left(\frac{t-b}{a}\right) \quad a, b \in \mathbb{R} \quad (۵)$$

و تبدیل ویولت برای توابع پیوسته به وسیله رابطه زیر محاسبه می‌شود:

$$W_{a,b}(f) = \tilde{f}_{(a,b)} = \langle \Psi_{a,b}(t), f(t) \rangle = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} f(t) \Psi^*\left(\frac{t-b}{a}\right) dt \quad (۶)$$

در اینجا پارامتر a به عنوان پارامتر گسترش و متناسب با فرکانس می‌باشد (به عبارت دیگر پارامتر تأخیر کوچک متناظر با فرکانس بالا و پارامتر تأخیر بزرگ متناظر با فرکانس پایین می‌باشد) و پارامتر b به عنوان پارامتر انتقال و متناسب با زمان می‌باشد. نمونه‌ایی از ساختار شبکه سه لایه‌ای متشکل از یک لایه ورودی، یک لایه مخفی، و یک لایه خروجی در شکل ۲ نشان داده شده است.

شبکه‌های عصبی مبتنی بر ویولت که ویولت نامیده می‌شوند از ترکیب دو تئوری ویولت‌ها و شبکه‌های عصبی به وجود آمده‌اند (Safave and Romangoli, 1997). این شبکه‌ها هم از مزایا و ویژگی‌های شبکه‌های عصبی برخوردارند و هم جذابیت‌ها و انعطاف‌پذیری‌ها و مبانی ریاضی مستحکم ویولت‌ها و آنالیز چند مقیاسی را دارا می‌باشند. در ویولت‌ها از دو دسته توابع ویولت و توابع مقیاس^۱ استفاده می‌شود. یک خانواده از توابع مقیاس $\phi(x)$ به صورت زیر معرفی می‌شوند.


$$\phi_{m,k}(x) = 2^{-m/2} \phi(2^{-m}x - k) \quad m, k \in \mathbb{Z} \quad (۱)$$

اگر $\phi(x)$ را یک تابع مقیاس مادر در نظر بگیریم، مقادیر 2^{-m} و k به ترتیب مربوط به گسترش و انتقال تابع مقیاس مادر هستند. توابع مقیاس رزولوشن m و $\phi_{m,k}(x)$ در اصل پایه‌های متعامد فضای برداری V_m در رزولوشن m می‌باشند. به عبارتی فضای برداری V_m حاوی کلیه تقریب‌های تابع $f(x)$ با رزولوشن m و توسط توابع $\phi_{m,k}(x)$ می‌باشد. بنابراین فضاهای برداری $\{V_m\}$ حاوی تقریب‌های مختلف تابع $f(x)$ در رزولوشن‌های مختلف می‌باشند. حال اگر w_m فضای برداری متعامد با V_m در رزولوشن m فرض کنیم آنگاه می‌تواند دسته‌ای دیگر از پایه‌های متعامد فضای w_m که ویولت $\Psi(x)$ نامیده می‌شوند را نیز بصورت زیر بیان نمود (Safave and Romangoli, 1997):

$$\Psi_{m,k}(x) = 2^{-m/2} \Psi(2^{-m}x - k) \quad m, k \in \mathbb{Z} \quad (۲)$$

در حالت کلی همه توابع فیزیکی را می‌توان به کمک ویولت‌ها و توابع مقیاس به صورت زیر بیان نمود (Wang et al, 2000):

¹ Scaling functions




شکل ۲- نمای کلی یک شبکه عصبی موجک سه لایه‌ای

گرفت (Dehghani and Torabi Poudh, 2021). در این شبکه‌ها ثابت شده است که از میان الگوریتم‌های یادگیری، الگوریتم پس‌انتشار خطا^۲ با ساختار شبکه پیش‌خور^۳ و تعداد سه لایه به طور رضایت بخشی در حل مسائل پیچیده مهندسی، شبیه‌سازی و پیش‌بینی سری‌های زمانی هیدرولوژیکی کاربرد دارد (Nourani et al, 2009). از رایج‌ترین توابع محرک استفاده شده در شبکه‌های انتشار برگشتی می‌توان توابع محرک سیگموئید و تانژانت هیپربولیک ذکر کرد (Nourani et al, 2011). نمونه‌ای از ساختار شبکه سه لایه‌ای متشکل از یک لایه ورودی، یک لایه مخفی، و یک لایه خروجی در شکل ۳ نشان داده شده است.

۲-۳- شبکه عصبی مصنوعی

امروزه شبکه عصبی مصنوعی در مطالعات هیدرولوژی و مدیریت منابع آب کاربرد وسیعی دارد (Hornik, 1998). ساختار شبکه عصبی معمولاً از لایه ورودی، لایه میانی و لایه خروجی تشکیل شده است. لایه ورودی یک لایه انتقال‌دهنده و وسیله‌ای برای تهیه کردن داده‌ها، لایه خروجی شامل مقادیر پیش‌بینی شده توسط شبکه و لایه میانی یا مخفی که از گره‌های پردازشگر تشکیل شده‌اند، محل پردازش داده‌ها است. نخستین کاربرد عملی شبکه‌های عصبی مصنوعی با معرفی شبکه‌های پرسپترون چندلایه^۱ انجام



شکل ۳- نمای کلی یک شبکه عصبی مصنوعی سه لایه

صورت گرفت. بهترین مقدار برای این سه معیار به ترتیب یک، صفر و یک می‌باشد.

$$R^2 = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2 \sum_{i=1}^N (y_i - \bar{y})^2}} \quad -1 \leq R \leq 1 \quad (7)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - y_i)^2} \quad (8)$$

۲-۴- معیارهای ارزیابی

در این تحقیق ارزیابی دقت و قابلیت مدل‌ها با استفاده از نمایه‌های ضریب تعیین (R^2)، ریشه میانگین مربعات خطا (RMSE) و ضریب نش ساتکلیف (NS) طبق روابط زیر

³ Feed Forward

¹ Multi-Layer Perceptron

² Back Propagation (BP)

انتخاب شد (Kisi and Karhan,2006;Nagy et al,2002). در این میان یک نکته مهم در آموزش شبکه‌های عصبی نرمال‌سازی داده‌ها قبل از استفاده در مدل می‌باشد این عمل خصوصاً وقتی دامنه تغییرات ورودی‌ها زیاد باشد کمک شایانی به آموزش بهتر و سریع‌تر مدل می‌کند (Dehghani et al,2020). اصولاً وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و دقت شبکه می‌شود (Zhu et al,2007). برای نرمال‌سازی داده‌ها از رابطه‌ی زیر استفاده شد.

$$X_n = 0.1 + 0.8 \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \quad (10)$$

که در آن X_n مقدار نرمال شده‌ی داده‌ی ورودی X_i و X_{\min} و X_{\max} نیز به ترتیب مقادیر حداقل و حداکثر ورودی مورد نظر می‌باشد.

۳-۱ نتایج شبکه عصبی موجک

به منظور تخمین میزان تبخیر ایستگاه کاکارضا از مدل شبکه عصبی موجک با تعداد نرون‌های متفاوت استفاده شد. در این پژوهش از توابع موجک شامل هار، کلاه مکزیکی، مورلت، دابچیز و سیملت استفاده شد سپس بدلیل افزایش دقت و کاهش خطا موجک کلاه مکزیکی انتخاب گردید. سپس با اعمال تبدیل روی داده‌ها، ضرایب تقریب و جزئیات آن‌ها استخراج گردید و داده‌ها بوسیله تابع موجک کلاه مکزیکی به عنوان تابع فعال‌سازی که مشتق دوم تابع گوسی بوده، تبدیل می‌یابند. جهت آموزش شبکه از الگوریتم گرادیان نزولی استفاده شد که در یادگیری شبکه‌های عصبی و حداقل سازی مقدار خطا و تنظیم پارامتر شبکه بکار گرفته می‌شود. در این روش با توجه به جدول ۴ ساختار ی متشکل از کلیه داده‌های ورودی بصورت شبکه‌ای با ۶ نرون در لایه پنهان اول با بیشترین ضریب همبستگی $R=0.970$ ، جذر میانگین مربعات خطا برابر 0.255 میلی متر و ضریب نش‌ساتکلیف برابر با 0.988 در مرحله صحت سنجی به عنوان بهترین ساختار در فرآیند شبیه‌سازی انتخاب شد. هدف در مدل‌های هوشمند همچون شبکه عصبی موجک کم کردن میزان خطا

$$NS = 1 - \frac{\sum_{i=1}^N (x_i - y_i)^2}{\sum_{i=1}^N (x_i - \bar{y})^2} \quad -\infty \leq NS \leq 1 \quad (9)$$

در روابط بالا، x_i و y_i به ترتیب مقادیر مشاهداتی و محاسباتی در گام زمانی i ام، N تعداد گام‌های زمانی، \bar{y} و \bar{x} نیز به ترتیب میانگین مقادیر مشاهداتی و محاسباتی می‌باشد. علاوه بر معیارهای فوق از نمودارهای پراکنش و سری زمانی مقادیر مشاهداتی - محاسباتی نسبت به زمان نیز جهت مقایسه و تحلیل بیشتر نتایج استفاده شده است.

۳- نتایج و بحث

در این پژوهش به منظور مدل‌سازی متوسط میزان تبخیر روزانه از مدل‌های شبکه عصبی موجک و شبکه عصبی مصنوعی استفاده شد. پارامتر ساعات آفتابی (SQ)، کمینه (TN)، بیشینه (TX) و میانگین دمای هوا (TG)، رطوبت نسبی (UG)، تعداد روزهای ابری (NG)، بارش روزانه (RH) و سرعت باد (Wind) بعنوان ورودی و میزان تبخیر روزانه به عنوان پارامتر خروجی مدل در دوره زمانی روزانه، سال ۱۳۸۲-۱۳۹۲ برای ایستگاه هواشناسی دهنو کاکارضا واقع در شهرستان الشتر استان لرستان بکار برده شد. هدف کلی از مدل‌های هوشمند بیان ارتباط بین متغیرهایی است که یافتن پیچیدگی آنها در طبیعت کاری دشوار با عدم قطعیت بالا است (Dehghani and Torabi Poudeh,2022). میزان تبخیر روزانه از پارامترهای مهم هواشناسی است که تخمین آن در گام‌های زمانی آینده از اهمیت بالایی برخوردار است. به این منظور در جهت کاهش خطا و همچنین برآورد پارامتر میزان تبخیر روزانه با دقت بالا با استفاده از کمترین پارامترهای ورودی روش ذکر شده مورد استفاده قرار گرفت که در مقایسه با روش‌های تقریبی بمراتب عملکرد بهتری را ارائه خواهد داد. هدف از این پژوهش دریافت این پیچیدگی طبیعی بین پارامترهای هواشناسی و ارائه مدل جهت پیش بینی در آینده است و از آنجاییکه میزان تبخیر روزانه از اهمیت بالاتری نسبت به دیگر پارامترها برخوردار می‌باشد بنابراین این پارامتر بعنوان متغیر هدف انتخاب شد (Dehghani et al,2020). لازم به ذکر است جهت مدل‌سازی ۸۰ درصد داده‌ها برای آموزش و ۲۰ درصد باقی مانده جهت تست، بصورت تصادفی، که گستره وسیعی از انواع داده‌ها را پوشش دهد،

استفاده گردید. آموزش شبکه های پرسپترون چند لایه با استفاده از الگوریتم آموزش پس انتشار خطا بنام الگوریتم لونیبرگ - مارکواریت به دلیل همگرایی سریع تر در آموزش شبکه، استفاده شد. از ترکیبات مختلف توابع محرک در لایه (های) مخفی استفاده شد. تعداد تکرارهای لازم در فرآیند یادگیری شبکه ۱۰۰۰ در نظر گرفته شده و عملکرد شبکه به کمک معیار میانگین مربعات خطا مورد ارزیابی قرار گرفته است. تعداد نرون های موجود در لایه های ورودی و خروجی با توجه به ماهیت مساله مورد بررسی مشخص شده، حال آن که تعداد نرون های موجود در لایه پنهان با سعی و خطا در جهت کاهش مقدار خطا مشخص گردید. روند کار با تعداد نرون های کم آغاز و افزودن نرون های اضافی تا زمانی ادامه می یابد که افزایش نرون های بیشتر تاثیری در بهبود خطا نداشته باشد، که شبکه ای با ۷ نرون در لایه پنهان اول به عنوان بهترین شبکه در فرآیند مدل سازی حاصل شد. در جدول (۵) نتایج حاصل از مقایسه عملکرد ساختار های مختلف به کار رفته به همراه پارامترهای آماری داده های بخش آموزش و صحت سنجی ارائه شده است. همانطور که در جدول (۴) مشاهده می شود ساختار ترکیب شامل کلیه پارامترهای ورودی مدل با بیشترین ضریب تعیین $R=0/968$ و کمترین ریشه میانگین مربعات خطا $RMSE=0/531$ mm و $NS=0/970$ در مرحله صحت سنجی نسبت به سایر ساختارها جهت مدلسازی میزان تبخیر مناسب تر خواهد بود. در شکل (۵) نمودار بهترین مدل حاصل شده برای داده های بخش صحت سنجی نشان داده شده است.

جدول ۳- ترکیب‌های منتخب پارامتر ورودی مدل‌های شبکه عصبی موجک و شبکه عصبی مصنوعی

شماره	ساختار ورودی	خروجی
۱	SQ(t)	ET(t)
۲	SQ (t), T _N (t)	ET(t)
۳	SQ (t), T _N (t), T _X (t)	ET(t)
۴	SQ (t), T _N (t), T _X (t), TG(t)	ET(t)
۵	SQ (t), T _N (t), T _X (t), TG (t), UG(t)	ET(t)
۶	SQ (t), T _N (t), T _X (t), TG (t), UG(t), NG(t)	ET(t)
۷	SQ (t), T _N (t), T _X (t), TG (t), UG(t), NG(t), RH(t)	ET(t)
۸	SQ (t), T _N (t), T _X (t), TG (t), UG(t), NG(t), RH(t), Wind(t)	ET(t)


جدول ۴- ساختار و توابع محرک بهینه در مدل‌سازی شبکه‌های عصبی موجک در مراحل آموزش و صحت سنجی

جهت پیش بینی می باشد و افزایش و کاهش تعداد نرون های موجود در لایه های پنهان با توجه به همگرا شدن مدل به کمترین خطای ممکن نسبت به سایر ساختارها صورت می گیرد همانطور که در جدول ۳ مشاهده می شود شبکه عصبی موجک به طور مطلوبی تعمیم داده شده و در نتیجه توانسته داده‌های بخش صحت‌سنجی را بخوبی داده‌های بخش آموزش اجرا نماید. همچنین با توجه به جدول ۴ مشاهده می‌گردد شبکه عصبی موجک عملکرد بالایی در تخمین میزان تبخیر ایستگاه کاکارضا حتی در صورت استفاده از تنها یک پارامتر ورودی نیز از خود نشان داده است که این امر سبب می شود در مناطقی که نواقص آماری وجود دارد این شبکه با در اختیار داشتن پارامترهای ورودی حداقل نظیر رطوبت نسبی عملکرد قابل قبولی در پیش بینی میزان تبخیر روزانه داشته باشد. همان‌طور که در شکل ۴ مشخص است تطابق مطلوبی بین مقادیر محاسباتی تبخیر روزانه مربوط به مرحله صحت‌سنجی مدل شبکه عصبی موجک با مقادیر مشاهداتی وجود دارد. بگونه ای که با توجه به نمودار فوق قابلیت بالای این مدل در تخمین اکثر مقادیر مشهود است.

۲-۳- نتایج شبکه عصبی مصنوعی

به منظور مدل سازی میزان تبخیر ایستگاه کاکارضا واقع در استان لرستان از مدل شبکه عصبی مصنوعی از نوع شبکه پرسپترون چند لایه با لایه های پنهان با تعداد نرون های متفاوت استفاده شده است. تابع تانژانت هیپربولیک متداول ترین شکل از توابع محرک است، که در این تحقیق از آن برای ساخت لایه خروجی شبکه های عصبی مصنوعی

شماره	ساختار	تابع محرک		آموزش			صحت سنجی		
		لایه پنهان	لایه خروجی	R	RMSE (mm)	NS	R	RMSE (mm)	NS
۱	۱-۵-۱	کلاه مکزیکی	خطی	۰/۹۶۸	۰/۴۷۲	۰/۹۲۲	۰/۳۳۸	۰/۹۷۱	
۲	۱-۸-۲	کلاه مکزیکی	خطی	۰/۹۶۵	۰/۴۶۸	۰/۹۳۱	۰/۳۲۵	۰/۹۷۲	
۳	۱-۶-۳	کلاه مکزیکی	خطی	۰/۹۶۰	۰/۴۵۶	۰/۹۳۸	۰/۳۱۰	۰/۹۷۰	
۴	۱-۴-۴	کلاه مکزیکی	خطی	۰/۹۶۶	۰/۴۴۲	۰/۹۴۱	۰/۲۹۲	۰/۹۷۵	
۵	۱-۷-۵	کلاه مکزیکی	خطی	۰/۹۷۰	۰/۴۳۵	۰/۹۴۸	۰/۲۸۶	۰/۹۸۰	
۶	۱-۸-۶	کلاه مکزیکی	خطی	۰/۹۷۴	۰/۴۲۸	۰/۹۵۱	۰/۲۷۵	۰/۹۸۲	
۷	۱-۱۰-۷	کلاه مکزیکی	خطی	۰/۹۷۵	۰/۴۱۸	۰/۹۵۵	۰/۲۶۳	۰/۹۸۶	
۸	۱-۶-۸	کلاه مکزیکی	خطی	۰/۹۸۰	۰/۴۰۶	۰/۹۶۰	۰/۲۵۵	۰/۹۸۸	




شکل ۴- نمودار مقادیر محاسباتی و مشاهداتی حاصل از بهترین مدل به دست آمده از مدل شبکه عصبی موجک برای پیش بینی تبخیر روزانه ایستگاه کاکارضا

جدول ۵- ساختار و توابع محرک بهینه در مدل سازی شبکه های عصبی مصنوعی و شاخص های آماری در مراحل آموزش و صحت سنجی

شماره	ساختار	تابع محرک		آموزش			صحت سنجی		
		لایه(های) پنهان	لایه خروجی	R	RMSE (mm)	NS	R	RMSE (mm)	NS
۱	۱-۴-۱	تانژانت هیپربولیک	خطی	۰/۹۱۱	۰/۶۲۸	۰/۹۰۶	۰/۶۰۸	۰/۹۲۰	
۲	۱-۶-۲	تانژانت هیپربولیک	خطی	۰/۹۲۰	۰/۶۰۵	۰/۹۱۰	۰/۵۹۲	۰/۹۲۹	
۳	۱-۵-۳	تانژانت هیپربولیک	خطی	۰/۹۲۵	۰/۵۹۶	۰/۹۱۸	۰/۵۸۶	۰/۹۳۷	
۴	۱-۷-۴	تانژانت هیپربولیک	خطی	۰/۹۳۶	۰/۵۹۰	۰/۹۲۲	۰/۵۷۳	۰/۹۴۸	

۰/۹۴۱	۰/۵۶۴	۰/۹۵۳	۰/۹۲۷	۰/۵۸۲	۰/۹۴۷	خطی	تانزانته هیپربولیک	۱-۶-۵	۵
۰/۹۵۰	۰/۵۵۱	۰/۹۵۸	۰/۹۳۶	۰/۵۷۴	۰/۹۵۰	خطی	تانزانته هیپربولیک	۱-۸-۶	۶
۰/۹۵۸	۰/۵۴۲	۰/۹۶۲	۰/۹۴۵	۰/۵۶۱	۰/۹۵۸	خطی	تانزانته هیپربولیک	۱-۹-۷	۷
۰/۹۶۸	۰/۵۳۱	۰/۹۷۰	۰/۹۵۰	۰/۵۵۲	۰/۹۶۰	خطی	تانزانته هیپربولیک	۱-۷-۸	۸



شکل ۵- نمودار مقادیر محاسباتی و مشاهداتی حاصل از بهترین مدل به دست آمده از مدل شبکه عصبی مصنوعی برای داده های بخش صحت سنجی به منظور پیش بینی تبخیر روزانه ایستگاه کاکارضا

۳-۳- مقایسه عملکرد مدل ها

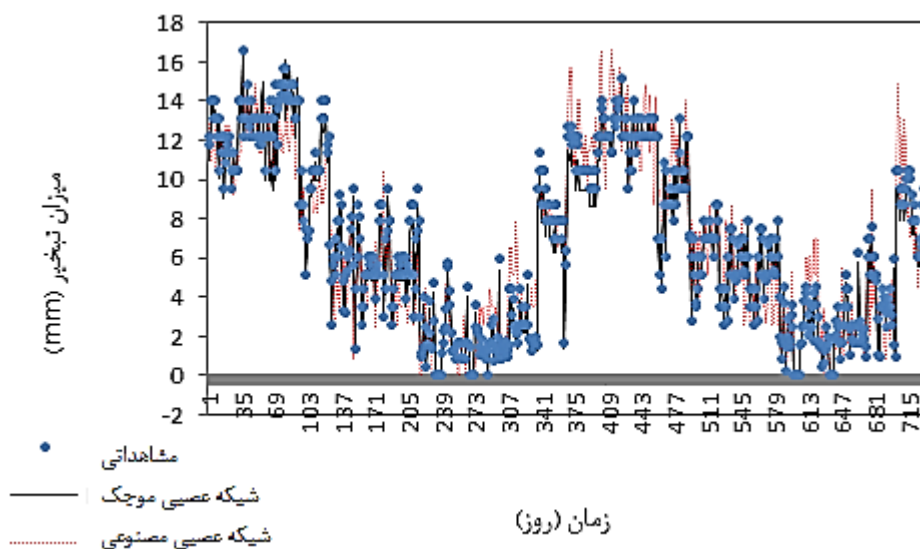
در ادامه با انتخاب جواب بهینه هر کدام از مدل ها و مقایسه آنها با یکدیگر مشخص شد، هر دو روش با دقت خوبی می توانند میزان تبخیر ایستگاه کاکارضا را شبیه سازی کنند. همانطور که در جدول (۶) مشاهده می شود از بین مدل های به کار رفته مدل شبکه عصبی موجک با بیشترین دقت $R=0/970$ و کمترین ریشه میانگین مربعات خطا mm $RMSE = 0/255$ و بیشترین ضریب نش-ساتکلیف $NS=0/988$ در مرحله صحت سنجی دارا می باشد. مقایسه نتایج مدل شبکه عصبی موجک با مدل شبکه عصبی مصنوعی حاکی از نزدیک بودن نتایج این دو مدل می باشد. همانطور که در جدول ۶ مشاهده می گردد مدل شبکه عصبی مصنوعی با توجه به اینکه در مرحله آموزشی دقت مطلوبی داشته اما در مرحله صحت سنجی دقت مدل کمتر از مدل شبکه عصبی

موجک است که این امر را میتوان ناشی از تصادفی بودن میزان وزن ها و بایاس های شبکه عصبی مصنوعی دانست (Mirzania et al,2023). در شکل (۶) نتایج هر دو مدل نسبت به مقادیر مشاهداتی در طی زمان نشان داده شده است همانطور که در این شکل نشان داده شده است شبکه عصبی موجک در نخمین اکثر نقاط عملکرد قابل قبولی از خود نشان داده است. نتایج مطابق شکل ۶ نشان داد مدل شبکه عصبی موجک بدلیل آنکه سیگنال ها یا سری زمانی در مقاطع بالاگذر با قدرت تفکیک پذیری بیشتری تجزیه تحلیل می نماید (Dehghani et al,2022). در این نقاط از عملکرد بهتری و قابلیت مطلوبی برخوردار است همچنین این مدل در برآورد نقاط کمینه و میانی نیز نتایج مطلوبی ارائه نموده است که این امر ناشی از دقت بالا و خطای ناچیز مدل مورد بررسی می باشد.

جدول ۶- نتایج نهایی حاصل از آموزش و صحت سنجی مدل های شبکه عصبی موجک و شبکه عصبی مصنوعی

صحت سنجی			آموزش			مدل
R	RMSE (mm)	NS	R	RMSE (mm)	NS	

۰/۹۷۰	۰/۲۵۵	۰/۹۸۸	۰/۹۶۰	۰/۴۰۶	۰/۹۸۰	شبکه عصبی موجک
۰/۹۶۸	۰/۵۳۱	۰/۹۷۰	۰/۹۵۰	۰/۵۵۲	۰/۹۶۰	شبکه عصبی مصنوعی



شکل ۶- نمودار حاصل از بهترین مدل به دست آمده از روش های شبکه عصبی موجک و شبکه عصبی مصنوعی برای داده های بخش صحت سنجی به منظور پیش بینی میزان تبخیر روزانه ایستگاه کاکارضا

نماینده. دقت بالای شبکه عصبی موجک ناشی از تجزیه سیگنال با کمک تابع گسسته موجک، منجر به ساده تر شدن این سیگنال‌ها شده و باعث ایجاد برتری محسوسی نسبت به مدل شبکه عصبی مصنوعی می‌باشد. در مجموع نتایج این پژوهش نشان می‌دهد استفاده از مدل شبکه عصبی موجک می‌تواند در زمینه تخمین تبخیر روزانه در طی ۱۰ سال آماری برای سایر مناطق نیز مورد استفاده قرار گرفته و به عنوان گامی در راستای اتخاذ تصمیمات مدیریتی مناسب در جهت بهبود منابع آب، کشاورزی و آبرسانی محسوب شود. همچنین پیشنهاد می‌گردد از مدل‌های هیبریدی در پژوهش های آتی جهت برآورد میزان تبخیر روزانه استفاده شود که مدلی با قابلیت مطلوبی جهت پیش بینی این پارامتر هواشناسی ارائه کرد و از بروز خسارات ناشی از افزایش دما که سبب افزایش تبخیر و خشکسالی و نیز افت منابع آب می‌گردد، جلوگیری نمود.

۴- نتیجه گیری

در این تحقیق تلاش شد تا عملکرد مدل‌های شبکه جهت شبیه‌سازی میزان تبخیر ایستگاه کاکارضا واقع در شمال استان لرستان با استفاده از داده‌های روزانه ایستگاه هواشناسی دهنو کاکارضا در طی دوره آماری ۱۴۰۲-۱۳۹۲ مورد ارزیابی قرار گیرد. نتایج حاصل از پژوهش نشان داد افزایش تعداد پارامتر موثر در مدل های مختلف جهت شبیه سازی موجب عملکرد بهتر در تخمین تبخیر روزانه می‌شود. علاوه بر آن مشاهده گردید در مدل شبکه عصبی موجک با داشتن حداقل پارامترهای ورودی قادر به پیش بینی میزان تبخیر روزانه با دقت بالایی می‌باشد. که این موضوع بخصوص در ایستگاه هایی که با نواقص آماری مواجه می‌باشند می‌تواند کمک شایانی به برآورد پارامتر مورد نظر نماید. با توجه به معیارهای ارزیابی، دو مدل مورد بررسی می‌توانند با دقت نسبتاً بالایی تبخیر روزانه را پیش‌بینی

منابع

of Karkheh catchment area. *Arabian Journal of Geosciences*, 14(2), 768-785.

- Dehghani, R. Torabi Poudeh, H. (2021). Applying hybrid artificial algorithms to the estimation of river flow: a case study

- International Journal of Intelligent Systems and Applications*, 8(1), 25-34
11. Kisi, O., Karahan, M., and Sen, Z. (2006). River suspended sediment modeling using fuzzy logic approach. *Hydrol Process*, 20(2), 4351-4362.
 12. Mirzania, E., Vishwakarma, D. K., Anh Thi Bui, Q., S Band, S., Dehghani, R. (2023). A novel hybrid AIG-SVR model for estimating daily reference evapotranspiration. *Arabian Journal of Geosciences*, 16(4), 301-324. <https://doi.org/10.1007/s12517-023-11387-0>
 13. Nagy, H., Watanabe, K., Hirano, M. (2002). Prediction of sediment load concentration in rivers using artificial neural network model. *Journal of Hydraulics Engineering*, 128(4), 558-559.
 14. Nourani, V., Alami, M. T., Aminfar, M. H. (2009). A combined neural-wavelet model for prediction of Ligvanchai watershed precipitation. *Engineering Applications of Artificial Intelligence*, 22(2), 466-472.
 15. Nourani, V., Kisi, Ö., Komasi, M. (2011). Two hybrid artificial intelligence approaches for modeling rainfall-runoff process. *Journal of Hydrology*, 402(2), 41-59.
 16. Okkan, U. (2012). Wavelet neural network model for reservoir inflow prediction. *Journal of Scientia Iranica*, 4(2), 1445-1455
 17. Safavi, A.A., Romagnoli, J. A. (1997). Application of wavelet-based neural networks to modelling and optimisation of an experimental distillation column. *(IFAC Journal of Engineering Applications of Artificial Intelligence)*, 10(3), 301-313
 18. Sahi, S., Mousavi, S.F., Hosseini, K. H. (2021). Simulation of Pan Evaporation Rate by ANN Artificial Intelligence Model in Damghan Region. *Journal of Soft Computing in Civil Engineering*, 5(3), 75-87
 19. Sharifi, S.S., Rezaverdinejad, V., Nourani, V. (2016). Estimation of Daily Global Solar Radiation using Wavelet Regression, ANN, GEP and Empirical Models: A Comparative Study of Selected Temperature-Based Approaches. *Journal of Atmospheric and Solar-Terrestrial Physics*, 149(3), 131-145
 20. <https://doi.org/10.1007/s12517-021-07079-2>
 2. Dehghani, R., Babaali, H. R., Zeidalinejad, N. (2022). Evaluation of Statistical Models and Modern Hybrid Artificial Intelligence in Simulation of Runoff Precipitation Process. *Sustainable Water Resources Management*, 8(5), 154-176. DOI:10.1007/s40899-022-00743-9
 3. Dehghani, R., Dehghani, F. (2022). Application of wavelet neural network in estimation of average air-temperature. *Environmental Resources Research*, 10(2), 1-10
 4. Dehghani, R., Torabi Poudeh, H. (2021). Application of novel hybrid artificial intelligence algorithms to groundwater simulation. *International Journal of Environmental Science and Technology*, 19(3), 4351-4368.
 5. Dehghani, R., Torabi Poudeh, H. (2022). The effect of climate change on groundwater level and its prediction using modern meta-heuristic model. *Groundwater for Sustainable Development*, 16(4):224-238.
 6. Dehghani, R., Torabi Poudeh, H., Izadi, Z. (2021). Dissolved oxygen concentration predictions for running waters with using hybrid machine learning techniques. *Modeling Earth Systems and Environment*, 8(2), 2599-2613.
 7. Dehghani, R., Torabi Poudeh, H., Younesi, H., Shahinejad, B. (2020). Daily Streamflow Prediction Using Support Vector Machine-Artificial Neural Network (SVM-ANN) Hybrid Model. *Acta Geophysica*, 68(4), 1763-1778, <https://doi.org/10.1007/s11600-020-00472-7>
 8. Dehghani, R., Torabi Poudeh, H., Younesi, H., Shahinejad, B. (2020). Forecasting Daily River Flow Using an Artificial Neural Network-Support Vector Machine Hybrid Modeling Approach (Case Study: Karkheh Catchment, Iran). *Air, Soil, and Water Research*, 13(2), 22-35, <https://doi.org/10.1177/1178622120969659>
 9. Hornik, K. (1998). Multilayer feed-forward networks are universal approximators. *Neural Networks*, 2(5), 359-366.
 10. Karthika, B.S., Deka, P. C. (2016). Modeling of Air Temperature using ANFIS by Wavelet Refined Parameters.

artificial neural network: An example of the longchuanjiang river in the upper yangtze catchment. *Geomorphology*, 84(4), 111-125.

20. Venkata Ramana, R., Krishna, B., Kumar, S. R., Pandey, N. G. (2013). Monthly Rainfall Prediction Using Wavelet Neural Network Analysis. *Water Resources Management*, 27(10), 3697-3711
21. Wang, D., Safavi, A. A., Romagnoli, J. A. (2000). Wavelet-based adaptive robust M-estimator for non-linear system identification. *AIChE Journal*, 46(8), 1607-1615
22. Wang, W., Ding, J. (2003). Wavelet Network Model and Its Application to the Prediction of Hydrology. *Nature and Science*, 1(1), 67-71.
23. Zhu, Y. M., Lu, X.X., Zhou, Y. (2007). Suspended sediment flux modeling with