



## ارزیابی مدل شبکه عصبی موجک در پیش‌بینی منابع آب زیرزمینی (مطالعه موردی: استان لرستان، ایران)

حسن ترابی پوده\*<sup>۱</sup>، علی حیدر نصرالهی<sup>۲</sup>، رضا دهقانی<sup>۳</sup>

۱- دانشیار گروه مهندسی آب، دانشکده کشاورزی، دانشگاه لرستان، ایران

۲- استادیار گروه مهندسی آب، دانشکده کشاورزی، دانشگاه لرستان، ایران

۳- دانشجوی دکتری سازه‌های آبی، دانشکده کشاورزی، دانشگاه لرستان، ایران

\* نویسنده مسئول: torabi.ha@lu.ac.ir

تاریخ پذیرش مقاله: ۱۳۹۸/۰۷/۲۴

تاریخ دریافت مقاله: ۱۳۹۸/۰۴/۰۸

### چکیده

در سال‌های اخیر، برداشت بی‌رویه آب‌های زیرزمینی باعث افت شدید سطح آب‌های زیرزمینی شده است، که خطراتی همچون نشست زمین را در پی داشته است. لذا پیش‌بینی قابل‌اطمینان سطح آب‌های زیرزمینی برای مدیریت این منابع حائز اهمیت است. در این پژوهش جهت پیش‌بینی سطح آب‌های زیرزمینی محدوده‌های مطالعاتی ازنا-الیگودرز، دورود-بروجرد، سلسله و دلفان واقع در استان لرستان از شبکه عصبی موجک استفاده شد و نتایج آن با روش شبکه عصبی مصنوعی مقایسه گردید. پارامترهای بارش، دما، دبی جریان و تراز سطح ایستابی در دوره زمانی ماه قبل به‌عنوان ورودی و تراز سطح ایستابی در دوره موردنظر به‌عنوان خروجی مدل‌ها در مقیاس زمانی ماهانه در طی دوره آماری (۱۳۸۱-۱۳۹۸) انتخاب گردید. معیارهای ضریب همبستگی، ریشه میانگین مربعات خطا، میانگین قدر مطلق خطا و ضریب نش-ساتکلیف برای ارزیابی و نیز مقایسه عملکرد مدل‌ها مورد استفاده قرار گرفت. نتایج حاصل از تحلیل هیدروگراف نشان داد افزایش میزان بارش تأثیر بسزایی بر منابع آب زیرزمینی دارد و همچنین نتایج حاصل از معیارهای ارزیابی نشان داد مدل شبکه عصبی موجک کارایی بهتر و خطای کمتری نسبت به شبکه عصبی مصنوعی دارد.

**واژه‌های کلیدی:** آب‌های زیرزمینی، شبکه عصبی موجک، شبکه عصبی مصنوعی.

### مقدمه

استفاده از مدل‌های خطی متداول و کلاسیک به‌خوبی قابل توصیف و مدل‌سازی نیستند. بنابراین به‌منظور مدل‌سازی این پدیده‌های هیدروژئولوژیکی لازم است از مدل‌های غیرخطی استفاده نمود. امروزه سیستم‌های هوشمند به‌طور گسترده برای پیش‌بینی پدیده‌های غیرخطی مورد استفاده قرار می‌گیرند. در سال‌های اخیر استفاده از روش‌های هوشمند در مطالعات کمی آب‌های زیرزمینی مورد توجه محققین قرار گرفته است، که از جمله می‌توان به موارد ذیل اشاره نمود:

محتشمی و همکاران (۱۳۸۹) از شبکه عصبی مصنوعی جهت پیش‌بینی سطح ایستابی دشت بیرجند استفاده کردند و نشان دادند که شبکه عصبی مصنوعی خطای ناچیزی در پیش‌بینی

با توجه به رشد روزافزون جمعیت و ضرورت استفاده بهینه از منابع آب، تأمین بیشترین مقدار ممکن آب‌های زیرزمینی برای رفع نیازهای همه انسان‌ها از اهمیت ویژه‌ای برخوردار است. بهره‌برداری بی‌رویه از منابع آب زیرزمینی در سال‌های اخیر باعث به‌هم خوردن تعادل طبیعی آن شده و تراز آب زیرزمینی در آبخوان‌های بسیاری از نقاط کشور منفی شده است. به‌منظور آگاهی از وضعیت این منابع و مدیریت بهینه آنها، لازم است پیش‌بینی دقیقی از نوسانات تراز آب زیرزمینی صورت گیرد. بیشتر سری‌های زمانی هیدروژئولوژیکی نظیر تغییرات سطح آب زیرزمینی همواره شامل فرآیندهای نامانا و پیچیده هستند که با

پیش‌بینی تراز آب زیرزمینی دشت خراسان رضوی با استفاده از پارامترهای بارش، تبخیر و دما در طی سال ۱۹۹۲-۲۰۰۷ مورد بررسی قرار دادند و نشان دادند شبکه عصبی مصنوعی از عملکرد بهتری نسبت به سایر مدل‌ها برخوردار است. از سوی دیگر چیت‌سازان و همکاران (۲۰۱۳) در پژوهشی کارایی شبکه عصبی مصنوعی را جهت پیش‌بینی سطح آب زیرزمینی دشت عقیل با استفاده از پارامترهای باران، تبخیر، رطوبت نسبی و دما در طی دوره آماری ۲۰۰۹-۲۰۱۰ مورد بررسی قرار دادند و نشان دادند که شبکه عصبی مصنوعی برای پیش‌بینی سطح آب زیرزمینی از دقت قابل توجهی برخوردار است. هاسنا و همکاران (۲۰۱۶) شبکه عصبی مصنوعی را جهت پیش‌بینی سطح آب زیرزمینی دشت چاندپور بنگلادش در طی سال ۱۹۸-۲۰۰۷ به کار بردند و نشان دادند شبکه عصبی مصنوعی خطای ناچیزی در پیش‌بینی سطح آب زیرزمینی دارد. کایا و همکاران (۲۰۱۸) در پژوهشی جهت بررسی میزان نوسانات سطح آب زیرزمینی منطقه ریحانی واقع در کشور ترکیه از شبکه عصبی مصنوعی و مدل M5 استفاده کردند و نشان داد دو مدل برای پیش‌بینی نوسانات آب زیرزمینی نتایج نزدیک بهم دارند. تندیا و همکاران (۲۰۱۹) به ارزیابی مدل شبکه عصبی مصنوعی هیبریدی در منطقه شیکاگو ژاپن پرداختند نتایج تحقیقات نشان داد مدل شبکه عصبی مصنوعی هیبریدی عملکرد قابل‌قبولی نسبت به مدل شبکه عصبی مصنوعی دارد. لی و همکاران (۲۰۱۹) به منظور تعیین عملکرد شبکه‌های عصبی مصنوعی به تحلیل میزان نوسانات سطح آب زیرزمینی پرداختند نتایج نشان داد مدل شبکه عصبی مصنوعی پیشرو عملکرد قابل‌قبولی در پیش‌بینی نوسانات سطح آب زیرزمینی دارد. در مجموع با توجه به پژوهش‌های انجام شده و همچنین اهمیت محدوده‌های مطالعاتی ازنا-لیگودرز، دورود-بروجرد، سلسله و دلفان از لحاظ شرب و کشاورزی، که مهم‌ترین محدوده‌های استان لرستان از جهت تولید محصولات کشاورزی بوده و محصولات این دشت جهت رشد و نمو از آب‌های زیرزمینی تغذیه می‌کنند بنابراین تغییرات تراز سطح ایستابی به‌منظور پیش‌بینی و اقدامات مدیریتی جهت بهبود آب آن بیش‌ازپیش ضروری است. لذا هدف از این تحقیق تخمین تراز سطح ایستابی

سطح ایستابی دارد. مختاری و همکاران (۱۳۹۱) در پژوهشی از شبکه عصبی مصنوعی جهت پیش‌بینی تراز آب زیرزمینی دشت شبستر استفاده نمودند و نتایج حاصله نشان داد که شبکه عصبی با تابع آموزش trainlm و تابع محرک tansig در پیش‌بینی سطح آب زیرزمینی از دقت بالایی برخوردار است. نتایج حاصل از پژوهش رجایی و زینی‌وند (۱۳۹۳)، که جهت ارزیابی عملکرد سه مدل رگرسیون خطی چندمتغیر (MLR)، هیبرید موجک-شبکه عصبی (WNN) و شبکه عصبی مصنوعی (ANN)، جهت پیش‌بینی سطح آب زیرزمینی نشان داد. مدل موجک-شبکه عصبی تطابق بهتری با مقادیر مشاهده‌ای تراز آب زیرزمینی دارد. در پژوهشی دیگر رجایی و ابراهیمی (۱۳۹۳) توانایی مدل ترکیبی موجک-شبکه عصبی پویا برای پیش‌بینی یک ماه آینده عمق آب زیرزمینی مورد بررسی قرار دادند و نشان دادند مدل ترکیبی موجک-شبکه عصبی با استفاده از موجک مادر نسبت به سایر مدل‌ها از عملکرد بهتری برخوردار است. سریکانت و همکاران (۲۰۰۹) عملکرد شبکه عصبی استاندارد FFN که با الگوریتم لونبرگ-مارکورت (LM) آموزش داده شده، برای پیش‌بینی نوسانات سطح آب زیرزمینی در حوضه آبریز می‌شی-وارم حیدرآباد هند مورد آزمایش قرار دادند. نتایج این تحقیق نشان داد که مدل مذکور بهترین انطباق و روند پیش‌بینی با داده‌های مشاهداتی دارد. استیل (۲۰۰۹) در مطالعه‌ای کاربرد شبکه‌های عصبی مصنوعی را در زمینه ژئوهیدرولوژی مورد بررسی قرار داد. وی کاربرد انواع شبکه‌های عصبی را با استفاده از الگوریتم‌های متعدد مورد تحلیل قرار داده و بیان داشت که شبکه‌های پیشرو همراه با تأخیر زمانی مؤثرترین نوع شبکه در زمینه ژئوهیدرولوژی هستند. آداموسکی و چان (۲۰۱۱) از شبکه عصبی موجک جهت پیش‌بینی سطح آب زیرزمینی حوضه چاتوگای واقع در کانادا در سال ۲۰۰۲-۲۰۰۹ استفاده نمودند و نشان دادند شبکه عصبی موجک پتانسیل بالایی در پیش‌بینی تراز آب زیرزمینی دارد و می‌تواند این مدل در مدیریت آب‌های زیرزمینی مفید باشد. موسوی و همکاران (۲۰۱۳) کارایی چهار مدل شبکه عصبی موجک، شبکه عصبی مصنوعی، سیستم استنتاج فازی و سیستم فازی تلفیقی با شبکه موجک را جهت

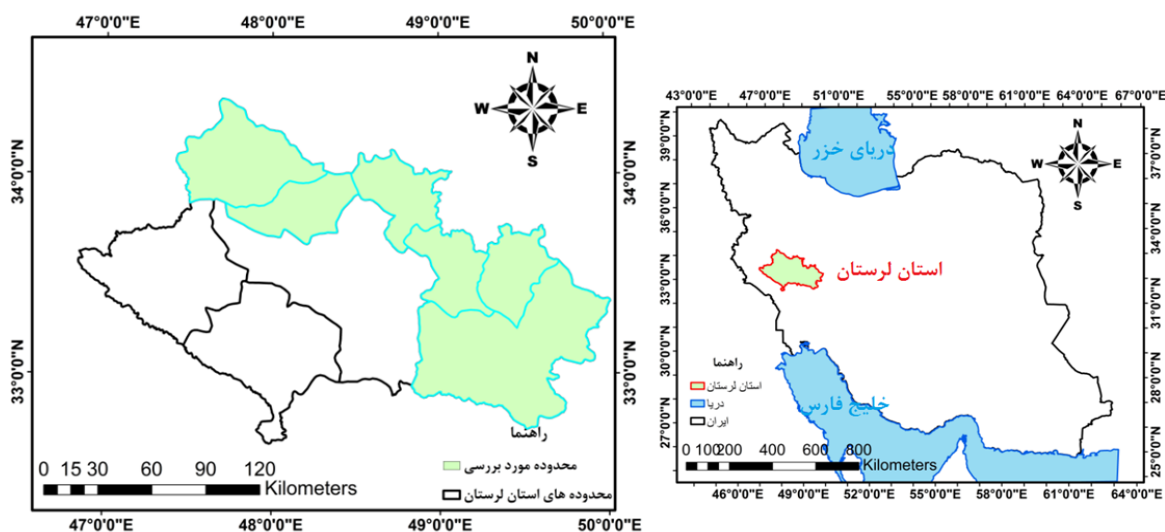
چهارمحال بختیاری و از جنوب غرب و غرب به ایلام محدود می‌شود (شکل ۱). استان لرستان شامل حوضه‌های کرخه و کارون می‌باشد. جغرافیای لرستان به دلیل قرار گرفتن این استان در رشته‌کوه‌های زاگرس جغرافیایی کوهستانی و چهارفصل است. این استان یکی از استان‌های کوهستانی غرب ایران بوده که بیشتر مناطق این استان را کوه‌های زاگرس پوشانده است. آب‌وهوای استان لرستان متنوع و تنوع آب‌وهوا در آن از شمال شرق به جنوب غرب کاملاً مشهود است. از مهم‌ترین محدوده‌های مطالعاتی استان لرستان بروجرد-دورود، ازنا-الیگودرز، سلسله، دلفان که دارای سفره زیرزمینی آبرفتی می‌باشد و دارای وضعیت آب سطحی و زیرزمینی نسبتاً خوبی می‌باشد.

محدوده‌های مطالعاتی ازنا-الیگودرز، دورود-بروجرد، سلسله و دلفان لرستان با استفاده از مدل شبکه عصبی موجک و شبکه عصبی مصنوعی بر اساس پارامترهای بارندگی، دما، دبی جریان و تراز سطح ایستابی در دوره زمانی ماه قبل به‌عنوان پارامترهای ورودی و تراز سطح ایستابی در دوره موردنظر به‌عنوان خروجی مدل در مقیاس زمانی ماهانه می‌باشد.

## مواد و روش‌ها

### منطقه مورد مطالعه

استان لرستان با وسعتی معادل ۲۸۱۶۰ کیلومترمربع در جنوب غرب ایران قرار گرفته و از شمال به استان همدان از شمال شرق به استان مرکزی، از شمال غرب به استان کرمانشاه، از شرق به استان اصفهان، از جنوب به خوزستان و جنوب شرق به استان



شکل ۱- موقعیت منطقه مطالعاتی.

مقیاسی را دارا می‌باشند. در ویونت‌ها از دو دسته توابع ویولت و توابع مقیاس<sup>۱</sup> استفاده می‌شود. یک خانواده از توابع مقیاس  $\phi(x)$  به صورت زیر معرفی می‌شوند.

$$\phi_{m,k}(x) = 2^{-m/2} \phi(2^{-m}x - k) \quad m, k \in \mathbb{Z} \quad (1)$$

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

### شبکه عصبی موجک

شبکه‌های عصبی مبتنی بر ویولت که ویونت نامیده می‌شوند از ترکیب دو تئوری ویولت‌ها و شبکه‌های عصبی به‌وجود آمده‌اند (واپنیک، ۱۹۹۸). این شبکه‌ها هم از مزایا و ویژگی‌های شبکه‌های عصبی برخوردار هستند و هم جذابیت‌ها و انعطاف‌پذیری‌ها و مبانی ریاضی مستحکم ویولت‌ها و آنالیز چند

<sup>1</sup> Scaling functions

شبکه عصبی ویونت بر مبنای روابط (۳) و (۴) شکل می‌گیرد و دارای الگوریتم‌های آموزش مخصوص خود می‌باشد که در پژوهش شین و همکاران (۲۰۰۵) 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.

$$\Psi_{a,b}(t) = \frac{1}{\sqrt{a}} \Psi\left(\frac{t-b}{a}\right) \quad a, b \in \mathbb{R} \quad (5)$$

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

$$W_{a,b}(f) = \tilde{f}_{(a,b)} = \langle \Psi_{a,b}(t), f(t) \rangle = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} f(t) \Psi^*\left(\frac{t-b}{a}\right) dt \quad (6)$$

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. نمونه ایی از ساختار شبکه سه لایه‌ای متشکل از یک لایه ورودی، یک لایه مخفی، و یک لایه خروجی در شکل ۲ نشان داده شده است.

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  $\emptyset_{m,k}(x)$  می‌باشد. بنابراین فضاها برداری  $\{v_m\}$  حاوی تقریب‌های مختلف تابع  $f(x)$  در رزولوشن‌های مختلف می‌باشند. حال اگر  $w_m$  را 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 (وانگ و همکاران، ۲۰۰۰).

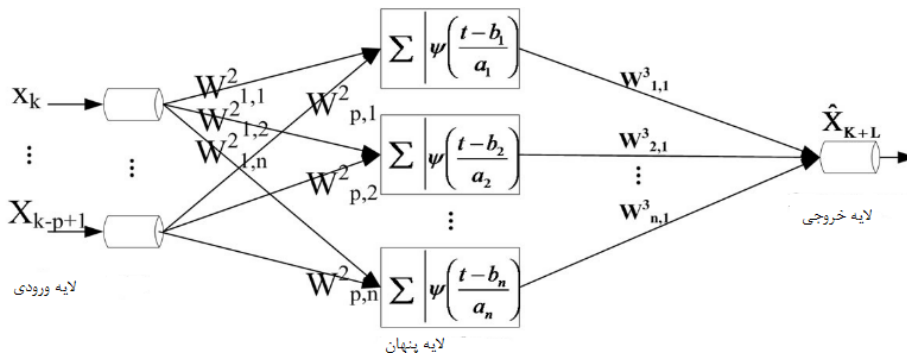
$$\Psi_{m,k}(x) = 2^{-m/2} \Psi(2^{-m}x - k) \quad m, k \in \mathbb{Z} \quad (7)$$

در حالت کلی همه توابع فیزیکی را می‌توان به کمک ویولت‌ها و توابع مقیاس به صورت زیر بیان نمود.

$$f(x) = f_0(x) + \sum_{m=-\infty}^0 \sum_{k=-\infty}^{\infty} d_{m,k} \Psi_{m,k} \quad (8)$$

$$f_0(x) = \sum_k a_{0,k} \emptyset_{0,k} \quad (9)$$

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 موردنظر ادامه داد.



شکل ۲- نمای کلی یک شبکه عصبی موجک سه لایه‌ای.

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

### شبکه عصبی مصنوعی

امروزه شبکه عصبی مصنوعی در مطالعات هیدروژئولوژی و مدیریت منابع آب کاربرد وسیعی دارد (نورانی و همکاران، ۲۰۰۹). ساختار شبکه عصبی معمولاً از لایه ورودی، لایه میانی و لایه خروجی تشکیل شده است. لایه ورودی یک لایه

در روابط بالا،  $x_i$  و  $y_i$  به ترتیب مقادیر مشاهداتی و محاسباتی در گام زمانی  $i$  ام،  $N$  تعداد گام‌های زمانی،  $\bar{x}$  و  $\bar{y}$  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 تحلیل بیشتر نتایج استفاده شده است.

### نتایج و بحث


یکی از مهمترین مراحل در مدل‌سازی، انتخاب ترکیب مناسبی از متغیرهای ورودی است. از این رو ابتدا همبستگی متقابل<sup>۱</sup> بین متغیرهای ورودی و خروجی محاسبه گردید و پارامترهای ورودی به منظور دستیابی به مدل بهینه جهت تخمین میزان سطح ایستابی آب‌های زیرزمینی محدوده‌های مطالعاتی ازنا-الیگودرز، دورود-بروجرد، سلسله و دلفان که هر کدام از محدوده‌های مورد بررسی دارای یک چاه پیزومتر مورد تأیید وزارت نیرو بوده و آمار و اطلاعات آن از شرکت آب منطقه‌ای لرستان اخذ شد، انتخاب و در جدول ۱ ارائه گردید.

جدول ۱- همبستگی متقابل بین پارامترهای ورودی و خروجی.

	S(t-1)	Q(t)	T(t)	P(t)
S(t)	۰/۹۱۰	۰/۸۷۰	۰/۷۵۰	۰/۸۶۰

در این جدول  $S(t-1)$ ،  $Q(t)$ ،  $T(t)$  و  $P(t)$  (به ترتیب سطح ایستابی در دوره زمانی ماه قبل، دبی جریان، دما و بارش در دوره زمانی  $t$ ) به عنوان ورودی و  $S(t)$  (سطح ایستابی در زمان  $t$ ) به عنوان خروجی مدل در مقیاس زمانی ماهانه در نظر گرفته شد. با توجه به همبستگی متقابل و معنی‌دار بین داده‌های ورودی و خروجی، ترکیب‌های مختلفی از پارامترهای ورودی به منظور دستیابی به مدل بهینه جهت تخمین سطح ایستابی استفاده شد که در جدول ۲ آمده است. بدین منظور از داده‌های ایستگاه هیدرومتری واقع در محدوده‌های مطالعاتی ازنا-الیگودرز، دورود-بروجرد، سلسله و دلفان که دارای ۲۰۰ رکورد ثبت‌شده طی بازه زمانی (۱۳۹۸-۱۳۸۱)، در مقیاس زمانی ماهانه می‌باشد، استفاده شد.

شبکه‌های پرسپترون چندلایه<sup>۲</sup> انجام گرفت. در این شبکه‌ها ثابت‌شده است که از میان الگوریتم‌های یادگیری، الگوریتم پس انتشار خطا<sup>۳</sup> با ساختار شبکه پیش‌خور<sup>۴</sup> و تعداد سه لایه به‌طور رضایت بخشی در حل مسائل پیچیده مهندسی، شبیه‌سازی و پیش‌بینی سری‌های زمانی هیدروژئولوژیکی کاربرد دارد (نورانی و همکاران، ۲۰۱۱). از رایج‌ترین توابع محرک استفاده شده در شبکه‌های انتشار برگشتی می‌توان توابع محرک سیگموئید و تانژانت هیپربولیک ذکر کرد (توکارو جانسون، ۱۹۹۹). 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.



شکل ۳- نمای کلی یک شبکه عصبی مصنوعی سه لایه

### معیارهای ارزیابی

در این تحقیق به منظور ارزیابی دقت و کارایی مدل‌ها، از نمایه‌های ضریب همبستگی ( $R$ )، ریشه میانگین مربعات خطا ( $RMSE$ ) و ضریب نش-سانکلیف ( $NS$ ) طبق روابط زیر استفاده گردید. بهترین مقدار برای این سه معیار به ترتیب یک، صفر و یک می‌باشد.

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

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

$$MAE = \frac{1}{n} \sum_{i=1}^n |x_i - y_i| \quad (9)$$

$$NS = 1 - \frac{\sum_{i=1}^N (x_i - y_i)^2}{\sum_{i=1}^N (x_i - \bar{y})^2} \quad -\infty \leq NS \leq 1 \quad (10)$$

<sup>4</sup> Feed Forward

<sup>1</sup> Cross-correlation

<sup>2</sup> Multi-Layer Perceptron

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

ماه افزایش توجهی در منابع آب زیرزمینی ایجاد شده است که از میزان کسری حجم مخازن آب‌های زیرزمینی کاسته شده و این امر در احیا سفره‌های آب زیرزمینی در محدوده‌های مطالعاتی مورد بررسی موثر است.

### نتایج شبکه عصبی موجک

به منظور مدل‌سازی سطح آب زیرزمینی محدوده‌های مطالعاتی ازنا-الیگودرز، دورود-بروجرد، سلسله و دلفان از مدل شبکه عصبی موجکی با لایه‌های پنهان و با تعداد نرون‌های متفاوت استفاده شده است. در مدل عصبی موجکی ابتدا موجک مناسب (سیملت) انتخاب گردید. سپس با اعمال تبدیل روی داده‌ها، ضرایب تقریب و جزئیات آنها استخراج گردید و داده‌ها به وسیله تابع موجک کلاه مکزیکی به عنوان توابع فعال‌سازی که مشتق دوم تابع گوسی بوده، تبدیل می‌یابند. جهت آموزش شبکه از الگوریتم گرادیان نزولی که در یادگیری شبکه‌های عصبی و حداقل‌سازی مقدار خطای و تنظیم پارامترهای شبکه استفاده می‌شود، به کار گرفته شد. همان‌طور که در جدول ۳ مشاهده می‌شود ساختار شماره ۴ در کلیه محدوده‌های مطالعاتی عملکرد قابل قبولی از خود نشان داده است به گونه‌ای که دارای افزایش ضریب همبستگی و کاهش میزان خطای شبکه را دارا می‌باشد. در شکل ۵ نمودار بهترین مدل حاصل شده برای داده‌های بخش صحت‌سنجی نشان داده شده است. که در این شکل تغییرات مقادیر محاسباتی و مشاهداتی نسبت به زمان قابل مشاهده است، همان‌طور که مشاهده می‌شود مدل شبکه عصبی موجکی در تخمین اکثر مقادیر عملکرد قابل قبولی داشته است. همان‌طور که در این شکل نشان داده شده است مدل شبکه عصبی موجک در تخمین اکثر مقادیر کمینه و بیشینه عملکرد خوبی داشته، به طوری که این مقادیر را نزدیک به مقدار واقعی آنها تخمین زده است که این امر با نتایج دانشور و ثوقی (۱۳۹۹)، باباعلی و دهقانی (۱۳۹۶) و نیکبخت و نوری (۱۳۹۵) همخوانی دارد.

در نهایت تعداد ۱۶۰ رکورد برای آموزش طی سال‌های (۱۳۹۴-۱۳۸۱) و تعداد ۴۰ رکورد باقی‌مانده طی سال‌های (۱۳۹۸-۱۳۹۴) برای صحت‌سنجی روش‌های مورد بررسی انتخاب شد.

جدول ۲- ترکیب‌های منتخب پارامترهای ورودی مدل‌های شبکه عصبی موجک و شبکه عصبی مصنوعی.

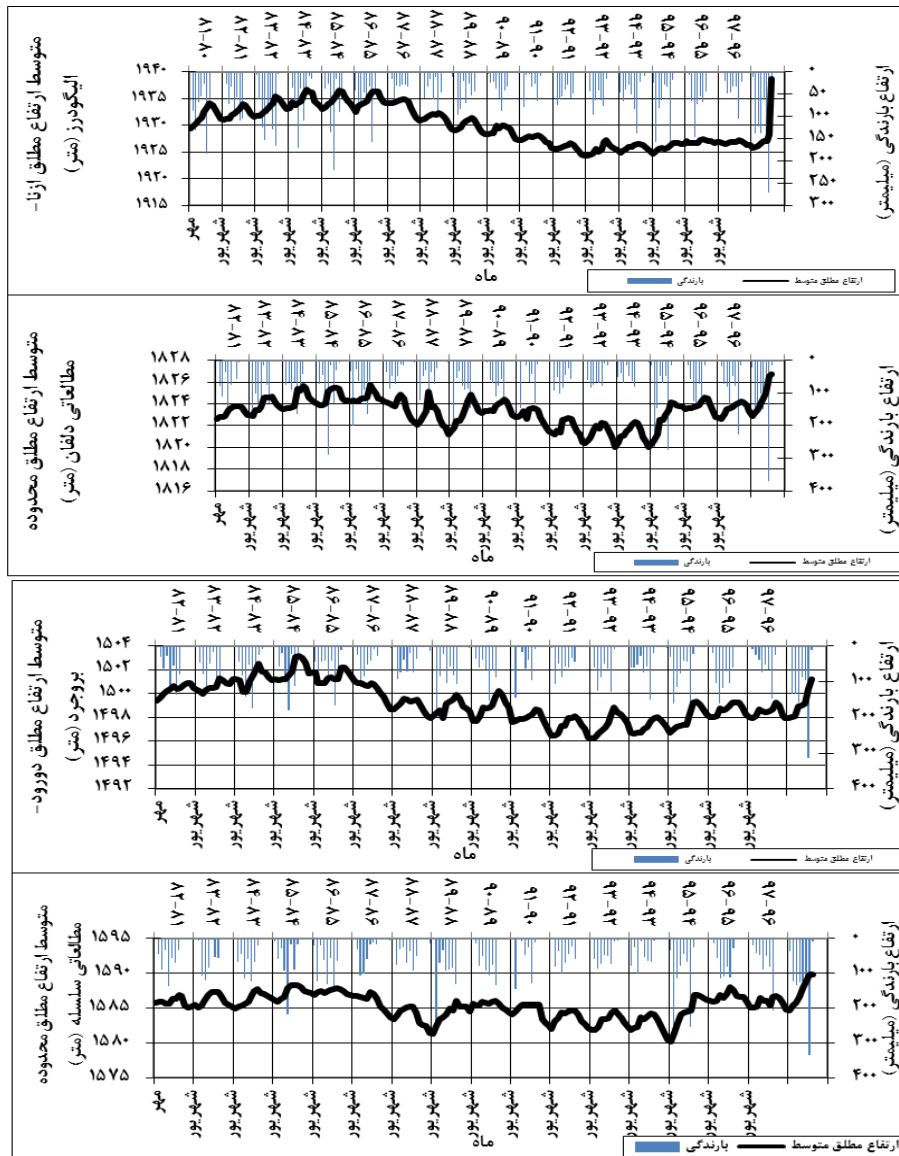
شماره مدل	ساختار ورودی	خروجی
۱	P(t)	S(t)
۲	P(t)T(t)	S(t)
۳	P(t) T(t)Q(t)	S(t)
۴	P(t)T(t)Q(t) S(t-1)	S(t)

در ادامه نتایج مدل مورد استفاده ارائه می‌گردد. همان‌طور که قبلاً نیز اشاره شد ۸۰ درصد از داده‌ها (۱۶۰ کورد)، به منظور آموزش و ۲۰ درصد مابقی (۴۰ رکورد)، برای صحت‌سنجی انتخاب گردید. 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. اصولاً وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و دقت شبکه می‌شود (زو و همکاران، ۲۰۰۷). برای نرمال‌سازی داده‌های تحقیق از رابطه زیر استفاده شده است.

$$X_n = 0.1 + 0.8 \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \quad (11)$$

که در آن  $X_n$  مقدار نرمال‌شده ورودی  $X_i$ ،  $X_{\max}$  و  $X_{\min}$  به ترتیب حداکثر و حداقل داده‌ها می‌باشد.

در شکل ۴ هیدروگراف‌های منابع آب زیرزمینی چهار محدوده مطالعاتی ازنا-الیگودرز، دورود-بروجرد، سلسله و دلفان نشان داده شده است. همان‌طور که در شکل ۴ مشهود است افزایش میزان بارندگی تأثیر بسزایی بر میزان تغذیه سفره آب زیرزمینی دارد بگونه‌ای که در سال آبی (۱۳۹۷-۱۳۹۸) و با توجه به افزایش بارندگی و سیلابی شدن دشت‌ها در فروردین و اردیبهشت



شکل ۴- نمودار مقایسه بارندگی و تغییرات سطح آب زیرزمینی محدوده‌های مطالعاتی استان لرستان از سال آبی (۱۳۸۱-۱۳۸۲) لغایت (۱۳۹۷-۱۳۹۸).

جدول ۳- ساختار و توابع محرک بهینه در مدل‌سازی شبکه‌های عصبی موجک و شاخص‌های آماری در مراحل آموزش و صحت‌سنجی.

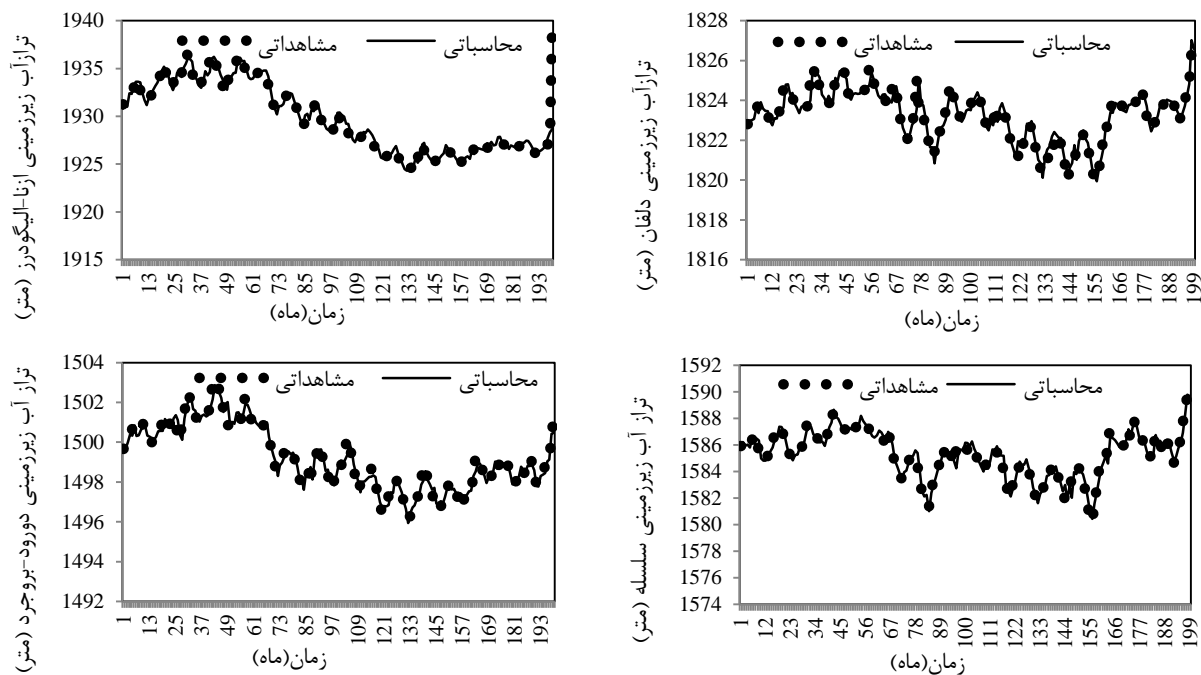
محدوده مطالعاتی	ساختار	تابع محرک			آموزش			صحت‌سنجی		
		لایه پنهان	R <sup>2</sup>	RMSE (m)	MAE (m)	NS	R <sup>2</sup>	RMSE (m)	MAE (m)	NS
ازنا-الیگودرز	۴-۸-۱	کلاه مکزیکی	۰/۹۹۳	۰/۳۷۷	۰/۲۵۸	۰/۹۸۶	۰/۹۸۴	۰/۱۰۷	۰/۰۲۸	۰/۹۱۸
دلفان	۴-۵-۱	کلاه مکزیکی	۰/۹۶۰	۰/۳۳۳	۰/۲۱۶	۰/۹۲۳	۰/۹۵۶	۰/۱۱۲	۰/۰۳۹	۰/۹۰۹
دورود-بروجرد	۴-۷-۱	کلاه مکزیکی	۰/۹۸۰	۰/۳۰۹	۰/۲۰۴	۰/۹۶۰	۰/۹۱۹	۰/۱۲۷	۰/۰۴۳	۰/۸۲۹
سلسله	۴-۶-۱	کلاه مکزیکی	۰/۹۷۸	۰/۳۳۴	۰/۲۵۸	۰/۹۵۳	۰/۹۵۲	۰/۱۵۷	۰/۰۶۱	۰/۹۰۲



### نتایج شبکه عصبی مصنوعی

تعداد نرون‌های موجود در لایه پنهان با سعی و خطا در جهت کاهش مقدار خطا مشخص گردید. روند کار با تعداد نرون‌های کم آغاز و افزودن نرون‌های اضافی تا زمانی ادامه می‌یابد که افزایش نرون‌های بیشتر تأثیری در بهبود خطا نداشته باشد، که شبکه‌ای با ۴ نرون در لایه پنهان اول به‌عنوان بهترین شبکه در فرآیند مدل‌سازی برای چهار محدوده مطالعاتی حاصل شد. در جدول ۴ نتایج حاصل از مقایسه عملکرد ساختارهای مختلف به‌کاررفته به همراه پارامترهای آماری داده‌های بخش آموزش و صحت‌سنجی ارائه شده است. همان‌طور که در جدول ۴ مشاهده می‌شود مدل شبکه عصبی مصنوعی توانایی قابل ملاحظه‌ای در پیش‌بینی نوسانات سطح آب زیرزمینی دارد در شکل ۶ نمودار مقادیر مشاهداتی و محاسباتی و نمودار پراکنش نشان داده شده است همان‌طور که در شکل ۶ مشخص است تطابق مقادیر محاسباتی میزان سطح ایستابی مدل شبکه عصبی مصنوعی با مقادیر مشاهداتی در اکثر نقاط وجود دارد.

همچنین جهت مقایسه نتایج شبکه عصبی موجک به‌منظور مدل‌سازی سطح آب زیرزمینی از مدل شبکه عصبی مصنوعی از نوع شبکه پرسپترون با تعداد نرون‌های متفاوت استفاده شده است. تابع تانژانت هیپربولیک متداول‌ترین شکل از توابع محرک است، که در این تحقیق از آن برای ساخت لایه خروجی شبکه‌های عصبی مصنوعی استفاده گردید. آموزش شبکه‌های پرسپترون چندلایه با استفاده از الگوریتم آموزش پس‌انتشار خطا به نام الگوریتم لونیگ-مارکوورت به دلیل همگرایی سریع‌تر در آموزش شبکه، استفاده شد. همچنین از ترکیبات مختلف توابع محرک در لایه(های) مخفی استفاده گردید. 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 نرون‌های موجود در لایه‌های ورودی و خروجی با توجه به ماهیت مسئله مورد بررسی مشخص شده، حال آنکه




شکل ۵- نمودار حاصل از مقادیر محاسباتی و مشاهداتی نسبت به زمان مدل شبکه عصبی موجک برای داده‌های مرحله آموزش و صحت-سنجی.




جدول ۴- ساختار و توابع محرک بهینه در مدل سازی شبکه های عصبی مصنوعی و شاخص های آماری در مراحل آموزش و صحت سنجی.

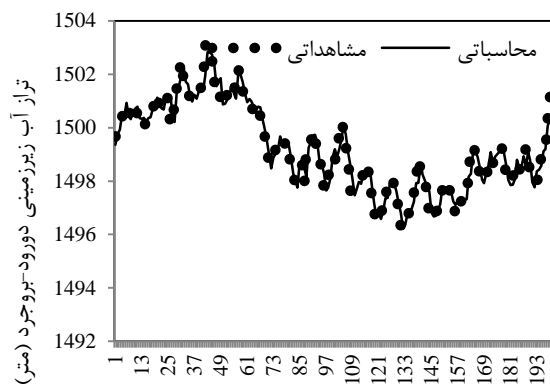
صحت سنجی			آموزش			تابع محرک		ساختار	محدوده مطالعاتی
NS	MAE (m)	RMSE (m)	NS	MAE (m)	RMSE (m)	R <sup>2</sup>	لایه پنهان		
۰/۸۷۱	۰/۰۴۵	۰/۱۳۱	۰/۹۸۳	۰/۳۰۱	۰/۴۲۰	۰/۹۹۲	کلاه مکزیکی	۴-۴-۱	ازنا-الیگودرز
۰/۸۶۴	۰/۰۴۹	۰/۱۳۶	۰/۹۳۱	۰/۲۳۰	۰/۳۵۴	۰/۹۵۵	کلاه مکزیکی	۴-۹-۱	دلفان
۰/۷۵۵	۰/۰۵۰	۰/۱۵۲	۰/۸۷۰	۰/۲۱۱	۰/۳۲۲	۰/۹۷۸	کلاه مکزیکی	۴-۶-۱	دورود-بروجرد
۰/۸۶۹	۰/۰۶۷	۰/۱۸۲	۰/۹۳۴	۰/۲۸۸	۰/۳۸۱	۰/۹۷۱	کلاه مکزیکی	۴-۸-۱	سلسله




زمان (ماه)



زمان (ماه)



زمان (ماه)



زمان (ماه)

شکل ۶- نمودار مقادیر محاسباتی و مشاهداتی نسبت به زمان حاصل از مدل شبکه عصبی مصنوعی برای داده های مرحله آموزش و صحت سنجی.

### مقایسه عملکرد مدل ها

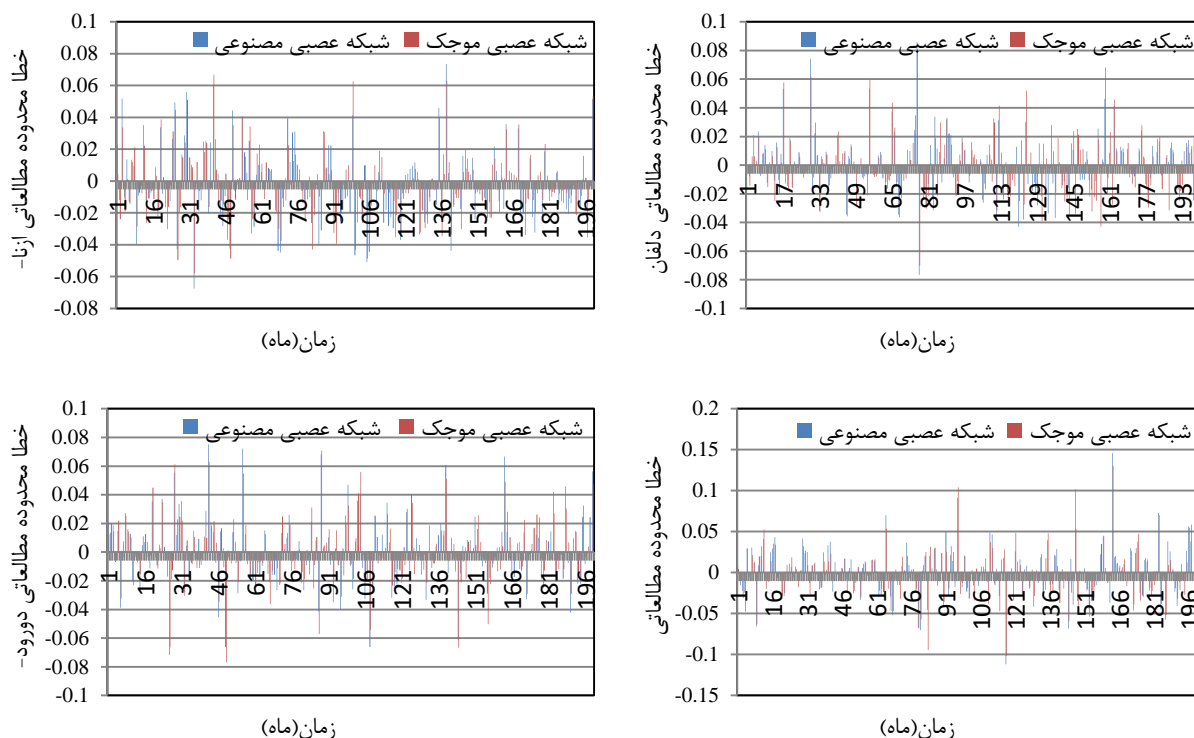
به کاررفته مدل شبکه عصبی موجک، بیشترین ضریب همبستگی و کمترین میزان خطا در مرحله صحت سنجی را دارد. همان طور شکل ۷ قابل مشاهده است نتایج حاکی از برتری کامل مدل پیش بینی شبکه عصبی-موجکی نسبت به مدل شبکه عصبی در پیش سطح آب زیرزمینی می باشد. باین که مدل ANN

در ادامه با انتخاب جواب بهینه هر کدام از مدل ها و مقایسه آنها با یکدیگر مشخص شد، هر دو مدل با دقت خوبی می توانند سطح آب زیرزمینی محدوده های مطالعاتی ازنا-الیگودرز، دورود-بروجرد، سلسله و دلفان را شبیه سازی کنند. که از بین مدل های

از تجزیه موجک، برازش 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.

در نهایت اختلاف مقادیر مشاهداتی میزان سطح ایستابی و محاسباتی بهینه دو مدل به صورت درصدی از میانگین مقادیر مشاهداتی (مقدار خطا)، محاسبه و نمودار آن نسبت به نمونه داده‌های ثبت شده دوره آماری ترسیم گردید (شکل ۷). همان‌طور که در این شکل دیده می‌شود برای مدل‌های مذکور (شبکه عصبی موجک و شبکه عصبی مصنوعی) بیشتر خطا در باند ۱۰ ± در صد قرار گرفته است. و بیشترین میزان خطا را مدل شبکه عصبی مصنوعی دارا می‌باشد و مدل شبکه عصبی موجک خطای کمتری از خود نشان داده است.

به‌خاطر در اختیار داشتن کرنل غیرخطی توانایی مدل‌سازی رفتارهای غیرخطی را دارا است، ولی با توجه به ویژگی‌های نایستایی و غیرخطی بودن سری تراز سطح ایستابی، به‌منظور پیش‌بینی و شبیه‌سازی دقیق ملزم به استفاده از شبکه عصبی-موجکی می‌باشیم. چراکه شبکه عصبی به تنهایی قادر به غلبه بر نایستایی سیگنال نمی‌باشد. درحالی‌که تبدیل موجکی 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. که این نتایج با پژوهش‌های قوردویی میلان و همکاران (۱۳۹۹)، شهرکی و همکاران (۱۳۹۸)، هاسنا و همکاران (۲۰۱۶) و رجایی و ابراهیمی (۱۳۹۳) همخوانی دارد در تبیین این نتایج می‌توان بیان نمود تبدیل موجکی 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 بالاگذر و پایین‌گذر حاصل



شکل ۷- نمودار خطای بهینه هر دو مدل به صورت درصدی از میانگین مقادیر مشاهداتی.

## نتیجه گیری

در پژوهش حاضر عملکرد مدل های شبکه عصبی موجک و شبکه عصبی مصنوعی را جهت مدل سازی سطح آب زیرزمینی محدوده های مطالعاتی ازنا-الیگودرز، دورود-بروجرد، سلسله و دلفان واقع در استان لرستان با استفاده از پارامترهای بارش، دما، دبی جریان و تراز سطح ایستابی در طی دوره آماری (۱۳۸۱-۱۳۹۸) مورد ارزیابی قرار گرفت. مقادیر سطح آب زیرزمینی مشاهداتی با سطح آب زیرزمینی تخمین زده شده این مدل با استفاده معیارهای ارزیابی بررسی گردید. نتایج حاصل از تحلیل هیدروگراف های آب های زیرزمینی نشان داد افزایش میزان بارندگی خصوصاً در سال آبی جاری اثر قابل توجهی بر منابع آب زیرزمینی داشته است. همچنین نتایج حاصل از معیار ارزیابی نشان داد که مدل شبکه عصبی موجک دقت بالا و خطای ناچیز در تخمین سطح آب زیرزمینی و قابلیت بسیار بالایی در تخمین برخی مقادیر کمینه، بیشینه و میانی نسبت به شبکه عصبی مصنوعی دارد. که با نتایج تحقیق هاسنا و همکاران (۲۰۱۶) و آداموسکی و چان (۲۰۱۱) و رجایی و ابراهیمی (۱۳۹۳) مطابقت دارد در تبیین این نتایج می توان بیان نمود شبکه عصبی موجک قادر به پیش بینی سطح آب زیرزمینی در حجم بالا، احتیاج به اندازه گیری و کارهای آزمایشگاهی آنها پرهزینه و زمانبر هستند، می باشد. همچنین دقت بالای شبکه عصبی موجک ناشی از تجزیه سیگنال با کمک تابع گسسته موجک، منجر به ساده تر شدن این سیگنال ها شده و باعث ایجاد برتری محسوسی نسبت به مدل شبکه عصبی مصنوعی می باشد. در مجموع این تحقیق نشان می دهد استفاده از مدل شبکه عصبی موجک می تواند در زمینه تخمین سطح آب زیرزمینی مؤثر باشد. و همچنین این مدل می تواند در نوبه خود برای تسهیل توسعه و پیاده سازی استراتژی های مدیریت آب های زیرزمینی مفید باشد. و گامی در اتخاذ تصمیمات مدیریتی در جهت بهبود آب سطح آب زیرزمینی حوضه های آبخیز می باشد.

## منابع

باباعلی، ح، دهقانی، ر، ۱۳۹۶. مقایسه مدل های شبکه عصبی موجک و شبکه عصبی مصنوعی در پیش بینی سطح آب زیرزمینی. هیدروژئولوژی، دوره ۲، شماره ۲، ۹۶-۱۰۸.

دانشور و ثوقی، ف، ۱۳۹۹. استفاده از رفع نویز موجکی در بررسی روند تراز آب زیرزمینی (مطالعه موردی: دشت اردبیل). هیدروژئولوژی، دوره ۵، شماره ۱، ۶۱-۷۲.

رجایی، ط، ابراهیمی، ه، ۱۳۹۳. مدل سازی نوسان های ماهانه آب زیرزمینی به وسیله تبدیل موجک و شبکه عصبی پویا. مدیریت آب و آبیاری، جلد ۴، شماره ۱، ۷۳-۸۷.

رجایی، ط، زینی وند، الف، ۱۳۹۳. مدل سازی تراز آب زیرزمینی با بهره گیری از مدل هیبرید موجک-شبکه عصبی مصنوعی (مطالعه موردی: دشت شریف آباد). عمران و محیط زیست، جلد ۴/۴، شماره ۷۷، ۵۱-۶۳.

شهرکی، ن، یونسی، م، طاهری تیزرو، ع، ۱۳۹۸. مقایسه مدل های شبکه عصبی مصنوعی، سری زمانی آریمای و رگرسیون خطی چندمتغیره در پیش بینی تغییرات سطح آب زیرزمینی. هیدروژئولوژی، دوره ۴، شماره ۱، ۱۲۹-۱۳۹.

قوردویی میلان، س، آریا آذر، ن، جوادی، س، رازدار، ب، ۱۳۹۹. شبیه سازی تراز سطح آب زیرزمینی با استفاده از مدل حداقل مربعات ماشین بردار پشتیبان و مقایسه آن با شبکه عصبی مصنوعی و رگرسیون خطی چندمتغیره. هیدروژئولوژی، دوره ۵، شماره ۱، ۱۱۸-۱۳۳.

محتشمی، م، دهقانی، الف، اکبرپور، ا، مفتاح هلقی، م، اعتباری، ب، ۱۳۸۹. پیش بینی سطح ایستابی با استفاده از شبکه عصبی مصنوعی (مطالعه موردی: دشت بیرجند). مجله آبیاری و زهکشی ایران، جلد ۴، شماره ۱، ۱-۱۰.

مختاری، ز، ناظمی، الف، ندیری، ع، ۱۳۹۱. پیش بینی تراز آب زیرزمینی با استفاده از مدل شبکه های عصبی مصنوعی (مطالعه موردی: دشت شبستر). زمین شناسی ژئوتکنیک (زمین شناسی کاربردی)، جلد ۸، شماره ۴، ۳۴۵-۳۵۳.

نیکبخت، ج، نوری، س، ۱۳۹۵. پیش بینی تراز آب زیرزمینی با کمک شبکه های موجک-عصبی (مطالعه موردی: دشت

- Srekanth, P.D., Geethanjali, N., Sreedevi, P.D., Shakeel A., Ravi Kumar, N., Kamala Jayanthi, P.D., 2009. Forecasting groundwater level using artificial neural networks, *Current science*, 96(7): 99-112.
- Steyl, G., 2009. Application of Artificial Neural Networks in the Field of Geohydrology. University of the Free State, South Africa.
- Thendiyath, R., Madan, K., Deo, R., Vandana, A., 2019. Development and Evaluation of Hybrid Artificial Neural Network Architectures for Modeling Spatio-Temporal Groundwater Fluctuations in a Complex Aquifer System. *Water Resources Management*, 33(7): 2381-2397.
- Tokar, A.S., Johnson, P.A., 1999. Rainfall-Runoff modeling using artificial neural networks. *Journal of Hydrology Engineering*, 3(2): 232-239.
- Vapnik, V.N., 1988. *Statistical Learning Theory*. Wiley, New York.
- 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.
- Zhu, Y.M., Lu, X.X., Zhou, Y., 2007. Suspended sediment flux modeling with artificial neural network: An example of the Longchuanjian River in the Upper Yangtze Catchment. *Geomorphology*, 84(1): 111-125.
- Ziya Kaya, Y., Unes, F., Demirci, M., Tasar, B., 2018. Groundwater Level Prediction Using Artificial Neural Network and M5 Tree Models. *Air and Water Components of the Environment Conference*, 4(3): 195-201.
- Qureshi, M., Muzaffar K., Kamran; Bessaih, N., Al-Mawali, K., Al-Sadrani, K., 2014. An empirical Relationship between In-situ Permeability and RQD of Discontinuous Sedimentary Rocks. *EJGE*, 19: 4781-4790.
- Soleymani, S. Akhtarpour, A., 2011. Seepage Analysis for Shurijeh Reservoir Dam Using Finite element Method, *Geo-Frontiers Congress 2011*, American society of civil engineering, 4 (211): 3227-3234.
- مرآغه-آذربایجان شرقی). هیدروژئولوژی. دوره ۱، شماره ۱، ۲۹-۴۳.
- Adamowski, J., Chan., H. 2011. A wavelet neural network conjunction model for groundwater level forecasting, 407(1-4): 28-40.
- Ashmaul Husna, N.E., Hefzul bari, S., Shouroy, H., Rahman, T., 2016. Ground water level prediction using artificial neural network. *International Journal of Hydrology Science and Technology*, 6(4): 371-381.
- Chitsazan, M., Rahmani, G., Neyamadpour, A., 2013. Groundwater level simulation using artificial neural network: a case study from Aghili plain, urban area of Gotvand, south-west Iran. *JGeope*, 3(1): 35-46.
- Hornik, K., 1998. Multilayer feed-forward networks are universal approximators. *Neural Networks*, 2(5): 359-366.
- Li, H., Lu, Y., Zheng, C., Yang, M., Li, S., 2019. Groundwater Level Prediction for the Arid Oasis of Northwest China Based on the Artificial Bee Colony Algorithm and a Back-propagation Neural Network with Double Hidden Layers. *Water Resources Management and Governance*, 11(4): 2-20.
- Moosavi, V., Vafakhah, M., Shirmohammadi, B., Behnia, N., 2013. A Wavelet-ANFIS Hybrid Model for Groundwater Level Forecasting for Different Prediction Periods. *Water Resources Management*, 27(5): 1301-1321.
- Nourani, V., Kisi, Ö., Komasi, M., 2011. Two hybrid artificial intelligence approaches for modeling rainfall-runoff process. *Journal of Hydrology*, 402(1-2): 41-59.
- Nourani, V., Alami, MT., Aminfar, MH., 2009. A combined neural-wavelet model for prediction of Ligvanchai watershed precipitation. *Engineering Applications of Artificial Intelligence*, 22(2): 466-472.
- Shin, S., Kyung, D., Lee, S., Taik & Kim, J., Hyun, J., 2005. An application of support vector machines in bankruptcy prediction model. *Expert Systems with Applications*, 28(1): 127-135.