



Comparing the Wavelet Neural Network and Artificial Neural Network Models in Groundwater Level Prediction

Hamidreza Babaali¹, Reza Dehghani^{*2}

Abstract

Assessing of Groundwater level variation In the hydrogeology issues, is very important. In this research to predicting the groundwater level in Nourabad plain of Lorestan Province, the wavelet neural networks were used and the results compared with artificial neural network. Parameters of precipitation, temperature, flow rate and water level within time period of the previous month were used as input and water table in each period were selected as output through monthly scale (2001-2012). Criterion of correlation coefficient, root mean square error and coefficient of mean absolute error of Nash sutclif were used for evaluating the performance of models. The results showed that the both models are able to estimating the water levels with acceptable level, But in terms of accuracy, wavelet neural network model with the highest correlation coefficient (0.920), the lowest root mean square error (0.074m), mean absolute error (0.048m) and the criterion Nash Sutcliffe (0.835) in validation phase was selected. The results showed that the wavelet neural network model has a great ability in estimating the minimum and maximum values of groundwater level.

Keywords: Artificial Neural Network, Neural Network, Nourabad, Water Table, Wavelet.

Received: 2016/12/28
Accepted: 2017/02/26

مقایسه مدل‌های شبکه عصبی موجک و شبکه عصبی مصنوعی در پیش‌بینی سطح آب زیرزمینی

حمیدرضا باباعلی^۱، رضا دهقانی^{*۲}

چکیده

در مطالعات آب‌های زیرزمینی، تغییرات سطح ایستابی از اهمیت فراوانی برخوردار است. در این پژوهش جهت پیش‌بینی سطح آب‌های زیرزمینی دشت نورآباد واقع در استان لرستان از شبکه عصبی موجک استفاده شد و نتایج آن با روش شبکه عصبی مصنوعی مقایسه گردید. پارامترهای بارندگی، 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 (۱۳۸۰-۱۳۹۱) 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 حاصله نشان داد دو مدل مورد استفاده با دقت قابل قبولی توانسته به تخمین تراز سطح ایستابی بپردازد، لیکن از لحاظ دقت، مدل شبکه عصبی موجک با بیشترین ضریب همبستگی (۰/۹۲۰)، کمترین ریشه میانگین مربعات خطا (۰/۰۷۴m)، میانگین قدر مطلق خطا (۰/۰۴۸m) و نیز معیار نش ساتکلیف (۰/۸۳۵) در مرحله صحت‌سنجی انتخاب شد. در مجموع نتایج نشان داد که مدل شبکه عصبی موجک توانایی بالایی در تخمین مقادیر کمینه و بیشینه تراز سطح ایستابی دارد.

واژه‌های کلیدی: سطح ایستابی، شبکه عصبی موجک، شبکه عصبی مصنوعی، نورآباد.

تاریخ دریافت مقاله: ۱۳۹۵/۰۹/۱۲

تاریخ پذیرش مقاله: ۱۳۹۵/۱۲/۰۹

1-Professor of Islamic Azad University, Khorramabad Branch
2- PhD student of Hydraulic Structures, Lorestan University
*- Corresponding Author: E-mail: reza.dehghani67@yahoo.com

۱- هیات علمی دانشگاه آزاد اسلامی واحد خرم آباد
۲- دانشجوی دکتری سازه‌های آبی دانشگاه لرستان
* - نویسنده مسئول



مقدمه

موجک- شبکه عصبی پویا برای پیش‌بینی یک ماه آینده عمق آب زیرزمینی موردبررسی قرارداداند 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 لونیبرگ- مارکورت (LM) آموزش داده شده، برای پیش‌بینی نوسانات سطح آب زیرزمینی در حوضه آبریز میثی وارم حیدرآباد هند مورد آزمایش قرارداداند. 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 زمینه‌ی هیدروژئولوژی مورد بررسی قرارداد. 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 پیش‌بینی تراز آب زیرزمینی دشت خراسان رضوی با استفاده از پارامترهای بارش، تبخیر و دما در طی سال ۱۹۹۲-۲۰۰۷ مورد بررسی قراردادند 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 قراردادند و نشان دادند که شبکه عصبی مصنوعی برای پیش‌بینی سطح آب زیرزمینی از دقت قابل‌توجهی برخوردار است. هاسنا و همکاران (۲۰۱۶)

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 مهر و موم‌های اخیر باعث به هم 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 هیدرولوژیکی نظیر تغییرات سطح آب زیرزمینی همواره شامل فرایندهای نامانا و پیچیده هستند که با استفاده از مدل‌های خطی متداول و کلاسیک به‌خوبی قابل توصیف و مدل‌سازی نیستند. بنابراین به‌منظور مدل‌سازی این پدیده‌های هیدرولوژیکی لازم است از مدل‌های غیرخطی استفاده نمود. امروزه سیستم‌های هوشمند به‌طور گسترده برای پیش‌بینی پدیده‌های غیرخطی مورد استفاده قرار می‌گیرد. 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 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 تابع محرک tansig در پیش‌بینی سطح آب زیرزمینی از دقت بالایی برخوردار است. نتایج حاصل از پژوهش رجایی و زینی وند (۱۳۹۳)، که جهت ارزیابی عملکرد سه مدل رگرسیون خطی چندمتغیره (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




موردنظر به عنوان خروجی مدل در مقیاس زمانی ماهانه می‌باشد.

۲. مواد و روش‌ها

۲-۱. منطقه مورد مطالعه

منطقه مورد مطالعه شهرستان نورآباد واقع در استان لرستان می‌باشد. این منطقه بین طول‌های $34^{\circ} 4' 48''$ شرقی و عرض‌های $47^{\circ} 58' 12''$ شمالی واقع شده است. محدوده مطالعاتی نورآباد دارای ۸۱۱ کیلومترمربع مساحت است که از این مقدار ۱۵۹ کیلومترمربع دشت با ارتفاع متوسط ۱۶۲۰ متر و ۶۵۲ کیلومترمربع با ارتفاع متوسط ۲۲۴۰ متر می‌باشد. این دشت دارای یک سفره زیرزمینی آبرفتی می‌باشد و دارای وضعیت آب سطحی و زیرزمینی نسبتاً خوبی می‌باشد. در شکل ۱ نشان داده شده است و همچنین در جدول ۱ مشخصات چاه‌های مشاهداتی نشان داده شده است.

شبکه عصبی مصنوعی را جهت پیش‌بینی سطح آب زیرزمینی دشت چاندپور بنگلادش در طی سال ۱۹۸-۲۰۰۷ بکار بردند و نشان دادند شبکه عصبی مصنوعی خطای ناچیزی در پیش‌بینی سطح آب زیرزمینی دارد. در مجموع با توجه به پژوهش‌های انجام شده و همچنین اهمیت دشت نورآباد لرستان از لحاظ شرب و کشاورزی، که مهم‌ترین دشت 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 به منظور پیش‌بینی و اقدامات مدیریتی جهت بهبود آب آن بیش‌ازپیش ضروری است. لذا هدف از این تحقیق تخمین تراز سطح ایستابی دشت نورآباد 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 به عنوان پارامترهای ورودی و تراز سطح ایستابی در دوره



شکل ۱- موقعیت منطقه مورد مطالعه

جذابیت‌ها و انعطاف‌پذیری‌ها و مبانی ریاضی مستحکم ویولت‌ها و آنالیز چند مقیاسی را دارا می‌باشند. در ویولت‌ها از دودسته توابع ویولت و توابع مقیاس (scaling functions) استفاده می‌شود. یک خانواده از توابع مقیاس $\phi(x)$ به صورت زیر معرفی می‌شوند

۲-۲. شبکه عصبی موجک

شبکه‌های عصبی مبتنی بر ویولت که ویولت نامیده می‌شوند از ترکیب دو تئوری ویولت‌ها و شبکه‌های عصبی به وجود آمده‌اند (واپنیک، ۱۹۹۸). این شبکه‌ها هم از مزایا و ویژگی‌های شبکه‌های عصبی برخوردارند و هم



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

در اینجا پارامتر a به عنوان پارامتر گسترش و متناسب با فرکانس می باشد (به عبارت دیگر پارامتر تأخیر کوچک متناظر با فرکانس بالا و پارامتر تأخیر بزرگ متناظر با فرکانس پایین می باشد) و پارامتر b به عنوان پارامتر انتقال و متناسب با زمان می باشد.

۲-۱-۲ الگوریتم ویولت

تلفیق تئوری موجک با مفاهیم شبکه عصبی منجر به ایجاد شبکه عصبی موجک می گردد و به کارگیری آن می تواند جایگزین مناسبی در شبکه های عصبی پیشخور جهت تخمین و تقریب توابع غیرخطی اختیاری باشد. در شبکه های عصبی پیشخور، دارای تابع فعال سازی سیگموئید در لایه پنهان می باشد در حالی که در شبکه های عصبی موجک، توابع موجک به عنوان تابع فعال سازی لایه پنهان شبکه پیشخور در نظر گرفته می شوند در این شبکه ها هر دو پارامتر انتقال و تغییر مقیاس موجکها در کنار وزن هایشان بهینه می گردند. در مجموع گام های مهم در آموزش و صحت سنجی شبکه عصبی موجک به صورت زیر است.

الف- داده های ورودی به دودسته جهت آموزش شبکه و صحت سنجی مورد استفاده قرار می گیرند.

ب- موجک مادر با احراز شرایط یادشده پس از اعمال ضرایب انتقال و مقیاس مناسب به موجک فرزند تبدیل می شود.

ج- توابع فعال سازی نرون های لایه پنهان شبکه عصبی با انواع موجک های فرزند جایگزین می شود.

د- شبکه عصبی ویولت ایجادشده با استفاده از مجموعه داده های مربوط به آموزش شبکه، آموزش داده می شود.

ه- عملکرد کلی شبکه موجک با تجزیه و تحلیل نحوه تخمین داده های صحت سنجی مورد بررسی قرار می گیرد. و با رضایت بخش بودن عملکرد شبکه مرحله آموزش به اتمام می رسد. در غیر این صورت مراحل قبل تا دستیابی به بهترین حالت مورد ارزیابی قرار می گیرد (کاو و ایرانمنش، ۲۰۰۵). نمونه ایی از ساختار شبکه سه لایه ای متشکل از یک لایه ورودی، یک لایه مخفی، و یک لایه خروجی در شکل ۲ نشان داده شده است.

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

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 ، $\phi_{m,k}(x)$ در اصل پایه های متعامد فضای برداری V^m در رزولوشن m می باشند. به عبارتی فضای برداری V^m حاوی کلیه تقریب های تابع $f(x)$ با رزولوشن m و توسط توابع $\phi_{m,k}(x)$ می باشد. بنابراین فضاهای برداری $\{V^m\}$ حاوی تقریب های مختلف تابع $f(x)$ در رزولوشن های مختلف می باشند. حال اگر w_m را فضای برداری متعامد با V^m در رزولوشن m فرض کنیم آنگاه می توان دسته ای دیگر از پایه های متعامد فضای w_m که ویولت $\psi(x)$ نامیده می شوند را نیز به صورت زیر بیان نمود (وانگ و همکاران، ۲۰۰۰):

$$\psi_{m,k}(x) = 2^{-m/2} \psi(2^{-m}x - k) \quad m, k \in \mathbb{Z} \quad [2]$$

در حالت کلی همه توابع فیزیکی را می توان به کمک ویولت ها و توابع مقیاس به صورت زیر بیان نمود:

$$f(x) = f_0(x) + \sum_{m=-\infty}^0 \sum_{k=-\infty}^{\infty} d_{m,k} \psi_{m,k}(x) \quad [3]$$

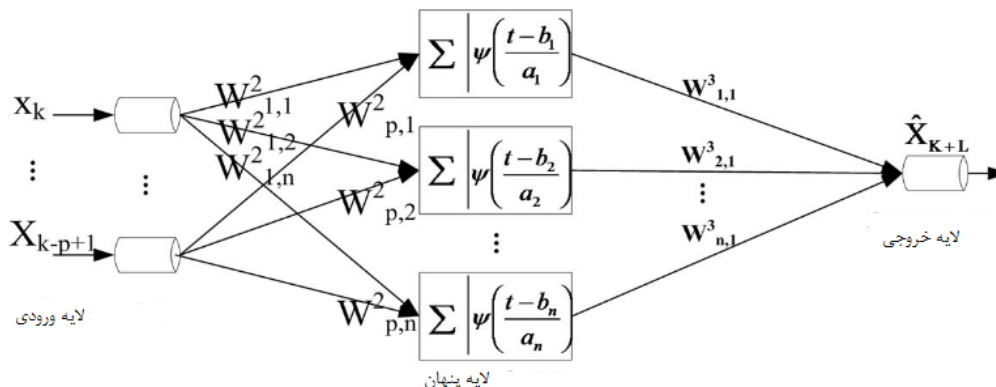
$$f_0(x) = \sum_k a_{0,k} \phi_{0,k}(x) \quad [4]$$

روابط فوق بیان می دارند که هر تابع فیزیکی را می توان ابتدا به کمک تعدادی توابع مقیاس در رزولوشن صفر تقریب زد و سپس به کمک توابع ویولت در رزولوشن های مختلف آن تقریب را تا میزان دقت مورد نظر ادامه داد.

شبکه عصبی ویولت بر مبنای روابط (۳) و (۴) شکل می گیرد و دارای الگوریتم های آموزش مخصوص خود می باشد 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 می شود:


$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi \left(\frac{t-b}{a} \right) \quad a, b \in \mathbb{R} \quad [5]$$

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



شکل ۲- نمای کلی یک شبکه عصبی موجک سه لایه‌ای

از رایج‌ترین توابع محرک استفاده شده در شبکه‌های انتشار برگشتی می‌توان توابع محرک سیگموئید و تانژانت هیپربولیک ذکر کرد (توکارو جانسون، ۱۹۹۹). نمونه‌ایی 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

۲-۳. شبکه عصبی مصنوعی

امروزه شبکه عصبی مصنوعی در مطالعات هیدرولوژی 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 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 گرفت. در این شبکه‌ها ثابت شده است که از میان الگوریتم‌های یادگیری، الگوریتم پس انتشار خطا^۲ با ساختار شبکه پیش‌خور^۳ و تعداد سه لایه به‌طور رضایت بخشی در حل مسائل پیچیده مهندسی، شبیه‌سازی و پیش‌بینی سری‌های زمانی هیدرولوژیکی کاربرد دارد (نورانی و همکاران، ۲۰۱۱).

¹ Multi-Layer Perceptron

² Back Propagation (BP)

³ Feed Forward



۲-۴. 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 ساتکلیف (NS) طبق روابط زیر استفاده گردید. بهترین مقدار برای این سه معیار به ترتیب یک، صفر و یک می‌باشد.

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

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

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

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

در روابط بالا، x_i و y_i به ترتیب مقادیر مشاهداتی و محاسباتی در گام زمانی i ، 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.

۳. نتایج و بحث

یکی از مهم‌ترین مراحل در مدل‌سازی، انتخاب ترکیب مناسبی از متغیرهای ورودی است.

از این رو ابتدا همبستگی متقابل^۱ بین متغیرهای ورودی و خروجی محاسبه گردید و پارامترهای ورودی به منظور دستیابی به مدل بهینه جهت تخمین میزان سطح ایستایی آب‌های زیرزمینی دشت نورآباد انتخاب و در جدول ۱ ارائه شد.

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 ایستایی در دوره زمانی ماه قبل، دبی جریان، دما و بارش در دوره زمانی t) به‌عنوان ورودی و S(t) (سطح ایستایی در زمان t) به‌عنوان خروجی مدل در نظر گرفته شد. با توجه به همبستگی متقابل و معنی‌دار بین داده‌های ورودی و خروجی، ترکیب‌های مختلفی از پارامترهای ورودی به‌منظور دستیابی به مدل بهینه جهت تخمین سطح ایستایی استفاده شد که در جدول ۲ آمده است. بدین منظور از داده‌های ایستگاه هیدرومتری کفراج واقع در دشت نورآباد که دارای ۱۳۲ رکورد ثبت‌شده طی بازه زمانی (۱۳۹۱-۱۳۸۰)، در مقیاس زمانی ماهانه می‌باشد، استفاده شد. درنهایت تعداد ۱۰۴ رکورد برای آموزش و تعداد ۲۸ رکورد باقی‌مانده برای صحت‌سنجی روش‌های موردبررسی انتخاب شد.

¹ Cross-correlation



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

شماره	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)

اصولاً وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و دقت شبکه می‌شود (ژو 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 مقدار نرمال شده ورودی X_i و X_{\max} و X_{\min} به ترتیب حداکثر و حداقل داده‌ها می‌باشد.

در جدول ۳ خصوصیات آماری پارامترهای استفاده‌شده، مشاهده می‌شود. در ادامه نتایج مدل مورداستفاده ارائه می‌گردد. همان‌طور که قبلاً نیز اشاره شد ۸۰ درصد از داده‌ها (۱۰۴ رکورد)، به منظور آموزش و ۲۰ درصد مابقی (۲۸ رکورد)، برای صحت سنجی 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.

جدول ۳- محدوده پارامترهای مورداستفاده جهت آموزش و صحت سنجی داده‌ها

صحت سنجی			آموزش			پارامتر
مینیمم	میانگین	ماکزیمم	مینیمم	میانگین	ماکزیمم	
۰	۱/۵۳۱	۵/۹۸۳	۰	۱/۲۰۰	۱۰/۶۶۱	$p_t(\text{mm})$
-۱/۸۰۰	۱۱/۸۹۶	۲۵/۵۰۰	-۵/۸۰۰	۱۲/۰۰۸	۲۵/۹۰۰	$T_t(^{\circ}\text{C})$
۰/۲۵۸	۱/۷۴۵	۶/۹۶۳	۰/۱۰۴	۴/۱۱۰	۲۳/۹۱۲	$Q_t(\text{m}^3/\text{s})$
۲/۴۵۰	۳/۲۵۲	۴/۱۵۰	۱/۱۵۰	۲/۰۰۹	۳/۸۵۰	$S_{t-1}(\text{m})$
۲/۴۵۰	۳/۲۹۲	۴/۱۵۰	۱/۱۵۰	۲/۰۱۳	۳/۸۵۰	$S_t(\text{m})$ پارامتر خروجی

۰/۹۲۰ و کمترین ریشه میانگین مربعات خطا ۰/۰۷۴ متر و کمترین میانگین قدر مطلق خطا ۰/۰۴۸ متر و ضریب نش ساتکلیف ۰/۸۳۵ در مرحله صحت سنجی نسبت به سایر ساختارها جهت مدل‌سازی سطح آب زیرزمینی در مقیاس زمانی ماهانه مناسب‌تر خواهد بود. در شکل (۴- الف) 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

۳-۱. نتایج شبکه عصبی موجک

به منظور مدل‌سازی سطح آب زیرزمینی دشت نورآباد از مدل شبکه عصبی موجکی با لایه‌های پنهان و با تعداد نورون‌های 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، بکار گرفته شد. همان‌طور که در جدول ۴ مشاهده می‌شود، ساختار شماره ۴ با ضریب همبستگی

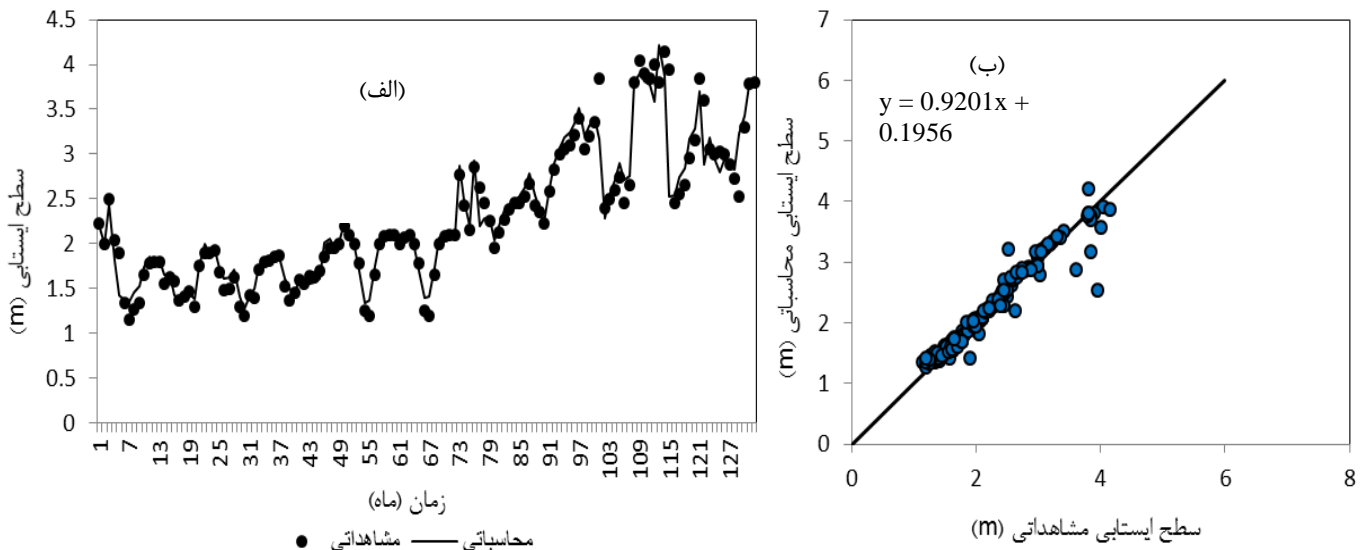


نیمساز واقع شده که دلالت بر برابری مقادیر محاسباتی و مشاهداتی دارد.

این مقادیر را نزدیک به مقدار واقعی شان تخمین زده است. که در شکل (۴-ب) این امر قابل مشاهده است در این شکل به غیر از چند نقطه سایر نقاط بر روی خط

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

شماره	ساختار	تابع محرک			آموزش			صحت سنجی		
		لایه پنهان	R	RMSE (m)	MAE (m)	NS	R	RMSE (m)	MAE (m)	NS
۱	۱-۸-۱	کلاه مکزیکی	۰/۸۸۲	۰/۰۹۷	۰/۰۷۸	۰/۷۸۳	۰/۸۴۱	۰/۱۲۷	۰/۱۰۱	۰/۷۱۲
۲	۲-۹-۱	کلاه مکزیکی	۰/۸۹۴	۰/۰۷۳	۰/۰۶۳	۰/۷۹۹	۰/۸۳۶	۰/۱۱۲	۰/۰۸۱	۰/۷۲۶
۳	۳-۵-۱	کلاه مکزیکی	۰/۹۱۲	۰/۰۶۱	۰/۰۳۰	۰/۸۲۸	۰/۸۸۰	۰/۰۹۵	۰/۰۷۰	۰/۷۴۱
۴	۴-۷-۱	کلاه مکزیکی	۰/۹۷۵	۰/۰۳۴	۰/۰۲۲	۰/۹۴۹	۰/۹۲۰	۰/۰۷۴	۰/۰۴۸	۰/۸۳۵



شکل ۴- نمودار حاصل از مقادیر بهینه مدل شبکه عصبی موجک برای داده های مرحله آموزش و صحت سنجی
الف) مقادیر محاسباتی و مشاهداتی نسبت به زمان ب) نمودار پراکنش میان مقادیر مشاهداتی و محاسباتی

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 نوروں های موجود در لایه های ورودی و خروجی با توجه به ماهیت مسئله مورد بررسی مشخص شده، حال آنکه تعداد نوروں های موجود در لایه پنهان با سعی و خطا در جهت کاهش مقدار خطا مشخص گردید. روند کار با تعداد نوروں های کم آغاز و افزودن نوروں های اضافی تا زمانی ادامه می یابد که افزایش نوروں های بیشتر تأثیری در بهبود خطا نداشته باشد، که شبکه ای با ۴ نوروں در لایه پنهان اول به عنوان بهترین شبکه در فرآیند مدل سازی حاصل شد. در جدول ۵ نتایج حاصل از مقایسه عملکرد

۲-۳. نتایج شبکه عصبی مصنوعی

همچنین جهت مقایسه نتایج شبکه عصبی موجک به منظور مدل سازی سطح آب زیرزمینی از مدل شبکه عصبی مصنوعی از نوع شبکه پرسپترون با تعداد نوروں 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 استفاده گردید. آموزش شبکه های پرسپترون چندلایه با استفاده از الگوریتم آموزش پس انتشار خطا بنام الگوریتم لونیبرگ - مارکوارت به دلیل همگرایی سریع تر در آموزش شبکه، استفاده شد. همچنین از ترکیبات مختلف توابع محرک در لایه (های) مخفی

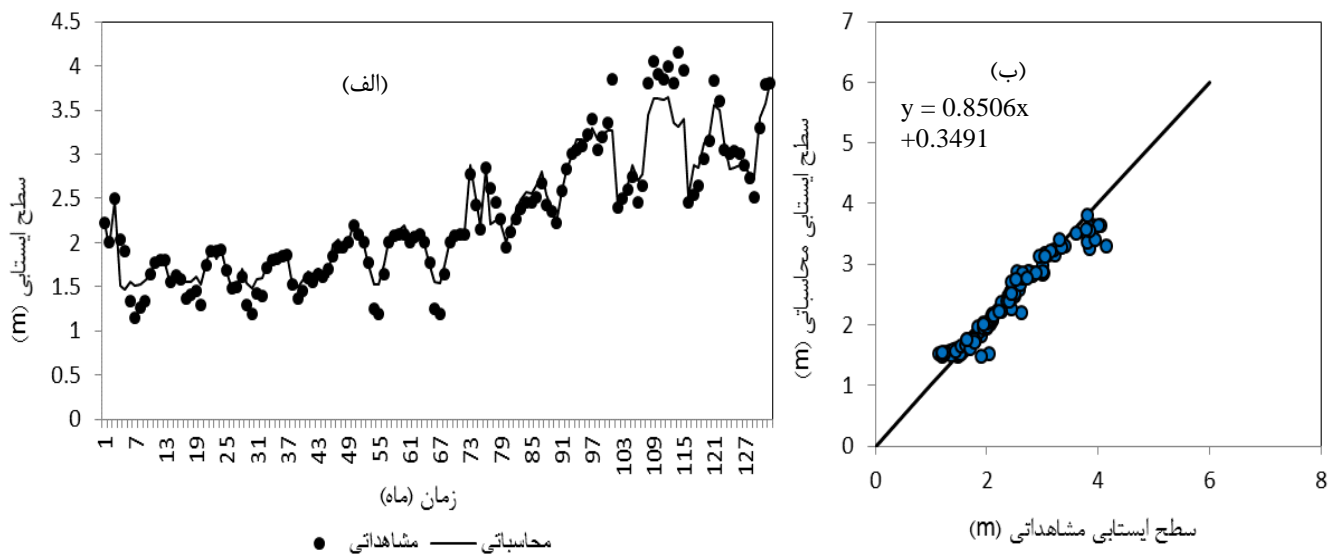


محاسباتی و نمودار پراکنش نشان داده شده است همان طور که در شکل (۵-الف) مشخص است تطابق مقادیر محاسباتی میزان سطح ایستابی مدل شبکه عصبی مصنوعی با مقادیر مشاهداتی در برخی نقاط وجود دارد. به گونه‌ای که در شکل (۵-ب) این امر مشهود است که مدل مذکور در تخمین نقاط بیشینه و کمینه ضعیف عمل کرده است که این نقاط را نزدیک به مقداری واقعی‌شان تخمین زده است.

ساختارهای مختلف به کار رفته به همراه پارامترهای آماری داده‌های بخش آموزش و صحت سنجی ارائه شده است. همان طور که در جدول ۵ مشاهده می‌شود ساختار شماره ۴ با بیشترین ضریب همبستگی ۰/۸۸۹ و کمترین ریشه میانگین مربعات خطا ۰/۱۱۴ متر و کمترین میانگین قدر مطلق خطا ۰/۰۸۶ متر و ضریب نش ساتکلیف ۰/۶۲۲ در مرحله صحت سنجی نسبت به سایر ساختارها جهت مدل‌سازی سطح آب زیرزمینی دشت نورآباد مناسب‌تر خواهد بود. در شکل ۵ نمودار مقادیر مشاهداتی و

جدول ۵- ساختار و توابع محرک بهینه در مدل‌سازی شبکه‌های عصبی مصنوعی و شاخص‌های آماری در مراحل آموزش و صحت سنجی

شماره	ساختار	تابع محرک			آموزش			صحت سنجی		
		لایه پنهان	R	RMSE (m)	MAE (m)	NS	R	RMSE (m)	MAE (m)	NS
۱	۱-۷-۱	تانژانت هیپربولیک	۰/۷۹۲	۰/۱۰۲	۰/۰۷۶	۰/۶۸۴	۰/۸۰۸	۰/۱۵۱	۰/۱۰۴	۰/۴۱۴
۲	۲-۵-۱	تانژانت هیپربولیک	۰/۸۲۴	۰/۰۹۴	۰/۰۶۰	۰/۷۲۹	۰/۸۰۶	۰/۱۵۳	۰/۰۹۷	۰/۴۵۷
۳	۳-۸-۱	تانژانت هیپربولیک	۰/۸۳۸	۰/۰۷۷	۰/۰۵۹	۰/۷۶۸	۰/۸۱۴	۰/۱۱۶	۰/۰۶۸	۰/۶۰۸
۴	۴-۴-۱	تانژانت هیپربولیک	۰/۹۶۷	۰/۰۴۰	۰/۰۲۶	۰/۹۲۸	۰/۸۸۹	۰/۱۱۴	۰/۰۸۶	۰/۶۲۲





۳-۳. مقایسه عملکرد مدل‌ها

در ادامه با انتخاب جواب بهینه هر کدام از مدل‌ها و مقایسه آن‌ها با یکدیگر مشخص شد، هر دو مدل با دقت خوبی می‌توانند سطح آب زیرزمینی دشت نورآباد را شبیه‌سازی کنند، که از بین مدل‌های به کار رفته مدل شبکه عصبی موجک، بیشترین دقت $R=0/920$ و کمترین ریشه میانگین مربعات خطا $RMSE=0/074$ m و کمترین میانگین قدر مطلق خطا $MAE=0/048$ m و بیشترین ضریب ناش-ساتکلیف $NS=0/835$ در مرحله صحت‌سنجی را دارد.

همان‌طور که از جدول ۶ و شکل ۶ قابل مشاهده است نتایج حاکی از برتری کامل مدل پیش‌بینی شبکه عصبی موجک نسبت به مدل شبکه عصبی در پیش‌سطح آب زیرزمینی می‌باشد. با اینکه مدل ANN به خاطر در اختیار داشتن کرنل غیرخطی توانایی مدل‌سازی رفتارهای غیرخطی را داراست، ولی با توجه به ویژگی‌های نا ایستایی و غیرخطی بودن سری تراز سطح ایستابی، به منظور پیش‌بینی و شبیه‌سازی دقیق ملزم به استفاده از شبکه عصبی - موجک می‌باشیم. چراکه شبکه عصبی به تنهایی قادر به غلبه بر نا ایستایی سیگنال نمی‌باشد. در حالی که تبدیل موجک 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 هاسنا و همکاران (۲۰۱۶) و رجایی و ابراهیمی (۱۳۹۳) هم‌خوانی دارد در تبیین این نتایج

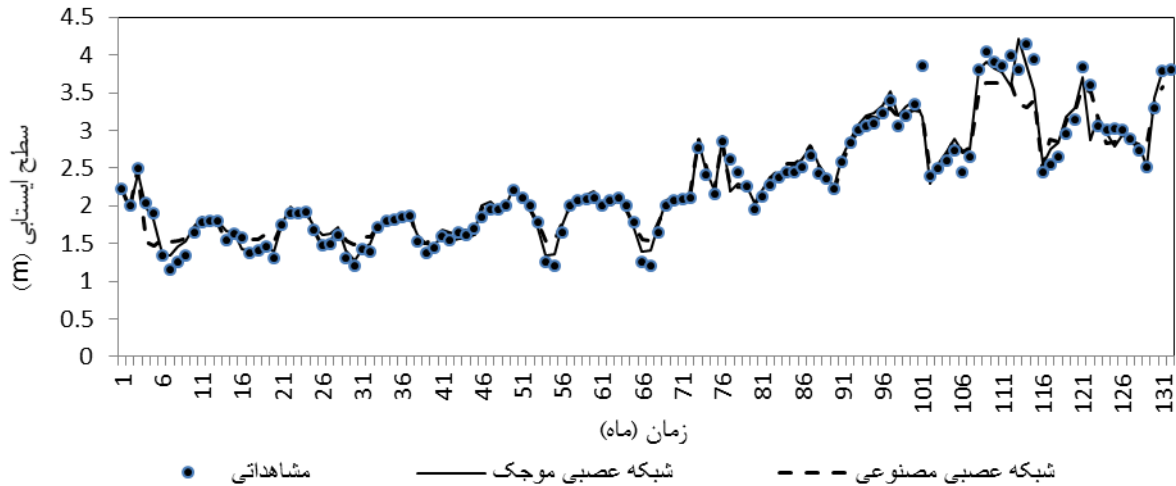
می‌توان بیان نمود تبدیل موجک با جدا نمودن سیگنال به فرکانس‌های بالا و پائین ویژگی‌های چند مقیاسی سیگنال را در اختیار داشته و دقت مدل را تا حد قابل توجهی، بالا می‌برد. سیگنال‌های بالا گذر و پایین گذر حاصل از تجزیه موجک، برآزش بسیار خوبی با معادلات مجموع سینوسی دارند که هر چه تعداد مراتب این معادلات بیشتر 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.

از سوی دیگر همان‌طور که در شکل ۶ نتایج هر دو مدل نسبت به مقادیر مشاهداتی در طی زمان نشان داده شده است مدل شبکه عصبی موجک در تخمین اکثر مقادیر عملکرد قابل قبولی دارد به گونه‌ای که کلیه مقادیر را نزدیک به مقدار واقعی تخمین زده است. 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 ± 10 در صد قرار گرفته است و بیشترین میزان خطای مدل‌های شبکه عصبی موجک و شبکه عصبی مصنوعی به ترتیب $20/087$ و $25/566$ درصد از میانگین مقادیر مشاهداتی می‌باشد.

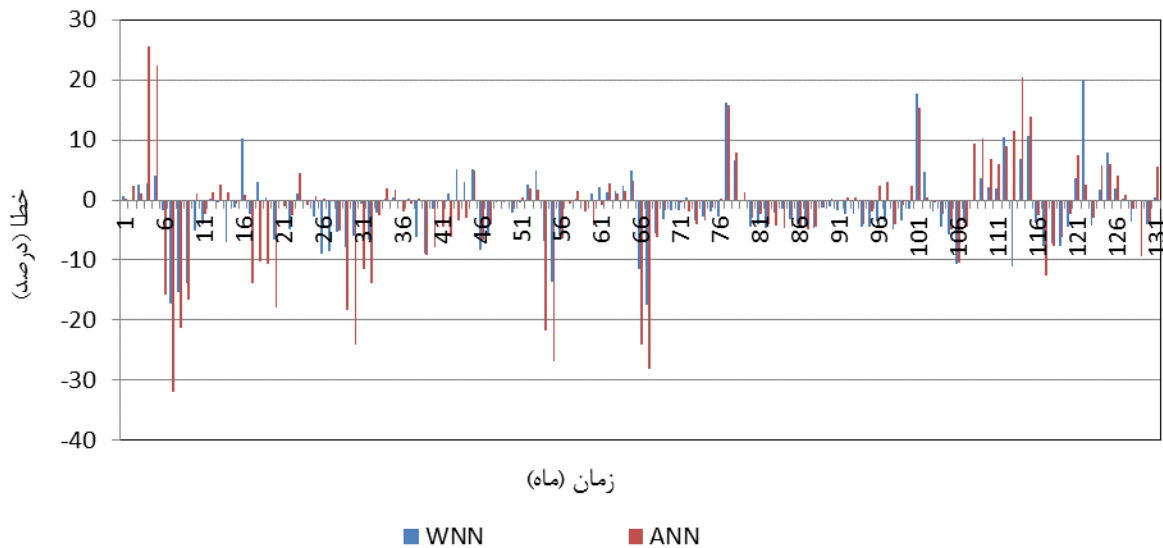


جدول ۶- نتایج نهایی حاصل از آموزش و صحت‌سنجی مدل‌های شبکه عصبی موجک و شبکه عصبی مصنوعی

صحت سنجی				آموزش				مدل
NS	MAE (m)	RMSE (m)	R	NS	MAE (m)	RMSE (m)	R	
۰/۸۳۵	۰/۰۴۸	۰/۰۷۴	۰/۹۲۰	۰/۹۴۹	۰/۰۲۲	۰/۰۳۴	۰/۹۷۵	شبکه عصبی موجک
۰/۶۲۲	۰/۰۸۶	۰/۱۱۴	۰/۸۸۹	۰/۹۲۸	۰/۰۲۶	۰/۰۴۰	۰/۹۶۷	شبکه عصبی مصنوعی



شکل ۶- نمودار پراکنش و مشاهداتی - محاسباتی مقادیر بهینه مدل شبکه عصبی موجک و شبکه عصبی مصنوعی برای داده‌های ثبت‌شده مرحله آموزش و صحت سنجی



شکل ۶- نمودار خطای بهینه هردو مدل به صورت درصدی از میانگین مقادیر مشاهداتی



مطابقت دارد در تبیین این نتایج می‌توان بیان نمود شبکه عصبی موجک قادر به پیش‌بینی سطح آب زیرزمینی در حجم بالا، احتیاج به اندازه‌گیری و کارهای آزمایشگاهی آن‌ها پرهزینه و زمان‌بر هستند، می‌باشد. همچنین دقت بالای شبکه عصبی موجک ناشی از تجزیه سیگنال با کمک تابع گسسته موجک، منجر به ساده‌تر شدن این سیگنال‌ها شده و باعث ایجاد برتری محسوسی نسبت به مدل شبکه عصبی مصنوعی می‌باشد. در مجموع این تحقیق نشان می‌دهد استفاده از مدل شبکه عصبی موجک می‌تواند در زمینه تخمین سطح آب زیرزمینی مؤثر باشد. و همچنین این مدل می‌تواند در نوبه خود برای تسهیل توسعه و پیاده‌سازی استراتژی‌های مدیریت آب‌های زیرزمینی مفید باشد و گامی در اتخاذ تصمیمات مدیریتی در جهت بهبود آب سطح آب زیرزمینی حوضه‌های آبخیز می‌باشد.

۴. نتیجه‌گیری

در پژوهش حاضر عملکرد مدل‌های شبکه عصبی موجک و شبکه عصبی مصنوعی را جهت مدل‌سازی سطح آب زیرزمینی دشت نورآباد واقع در استان لرستان با استفاده از پارامترهای بارش، دما، دبی جریان و تراز سطح ایستابی در طی دوره آماری (۱۳۸۰-۱۳۹۱) مورد ارزیابی قرار گرفت. مقادیر سطح آب زیرزمینی مشاهداتی با سطح آب زیرزمینی تخمین زده‌شده این مدل با استفاده معیارهای ارزیابی بررسی گردید. نتایج تحقیق 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)

۵. منابع

- رجایی، ط.، ابراهیمی، ه.، ۱۳۹۳. مدل‌سازی نوسان‌های ماهانه آب زیرزمینی به‌وسیله تبدیل موجک و شبکه عصبی پویا. مدیریت آب و آبیاری، جلد ۴، شماره ۱: ۷۳-۸۷
- رجایی، ط.، زینی وند، الف.، ۱۳۹۳. مدل‌سازی تراز آب زیرزمینی با بهره‌گیری از مدل هیبرید موجک- شبکه عصبی مصنوعی (مطالعه موردی: دشت شریف‌آباد). عمران و محیط‌زیست، جلد ۴۴/۴، شماره ۷۷: ۵۱-۶۳
- کاوه، ع.، ایران‌منش، ع.، ۱۳۸۴. شبکه عصبی مصنوعی در بهینه‌سازی سازه‌ها. چاپ سوم. انتشارات مرکز تحقیقات ساختمان و مسکن. ۶۴ صفحه.
- محتشمی، م.، دهقانی، الف.، اکبرپور، ا.، مفتاح هلقی، م.، اعتباری، ب.، ۱۳۸۹. پیش‌بینی 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. پیش‌بینی تراز آب زیرزمینی با استفاده از مدل شبکه‌های عصبی مصنوعی (مطالعه موردی: دشت شبستر). زمین‌شناسی ژئوتکنیک (زمین‌شناسی کاربردی)، جلد ۴، شماره ۴: ۳۴۵-۳۵۳.
- Adamowski, J., Chan, H., 2011. A wavelet neural network conjunction model for groundwater level forecasting. *Water Resources Management journal*. 407(1-4): 28-40.
- Ashmaul Husna, NE., 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. *Journal of Geope*. 3(1): 35-46.
- 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 journal*. 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 journal*. 28(1): 127-135.
- Sreekanth, PD., Geethanjali, N., Sreedevi, PD., Shakeel A., Ravi Kumar, N., Kamala Jayanthi, PD., 2009. Forecasting groundwater level using artificial neural networks. *Journal of Hydrology*. 96(7): 99-112.
- Steyl, G. 2009. Application of Artificial Neural Networks in the Field of Geohydrology. University of the Free State, South Africa.
- Tokar, AS., Johnson, P A., 1999. Rainfall- Runoff modeling using artificial neural. *Journal of Hydrology*. 300 (1-5): 89-98.
- Vapnik, VN., 1988. *Statistical Learning Theory*. Wiley, New York. 89 p.
- Wang, D., Safavi, AA., Romagnoli, JA., 2000. Wavelet-based adaptive robust M-estimator for non-linear system identification. *AIChE Journal*. 46(8):1607-1615.
- Zhu, YM., Lu, XX., Zhou, Y., 2007. Suspended sediment flux modeling with artificial neural network: An example of the Longchuanjian River in the Upper Yangtze Catchment. *Journal of Geomorphology*. 84(1): 111-125.