

Groundwater level forecasting using Wavelet-Artificial Neural networks (Case study: Maragheh-Bonab Plain-East Azarbaijan)

Jaefar Nikbakht^{*1}, Samaneh Noury²

Abstract

Understanding the behavior of the groundwater system and forecasting it's fluctuations in the future are essential to achieve comprehensive and sustainable management of groundwater resources. The purpose of this study was clustering of Maragheh-Bonab Aquifer's observation wells and groundwater level prediction using Wavelet-Artificial Neural networks. Initially, 20 observation wells of Maragheh-Bonab Aquifer with 15 years and more groundwater level records were clustered using hierarchical-WARD clustering method. Cluster with 6 homogenous subcluster and representative well of each subcluster were selected. Using wavelet, input time series noise were removed. Then groundwater level of representative wells were forecasted by Artificial Neural Networks. Results showed, considering of temperature time series data as input was confused Artificial Neural Networks and Wavelet-Artificial Neural Networks. On results, taking 3 to 12 months consecutive time delay in input data decreased different between recorded and forecasted data. Minimum value of RMSE (0.03 m) and maximum value of R^2 (0.999) were in WNN. Mentioned values in ANN were 0.32 m and 0.885 (respectively). Based on the results of this research, de-noising of input data decreased difference between recorded and forecasted data as 11 cm averagely.

Keywords: Groundwater level, Hierarchical-WARD clustering method, Maragheh-Bonab (East Azarbaijan) Plain, Wavelet-Artificial Neural Networks, Wavelet transform.

Received: 2016/02/23
Accepted: 2016/04/17

پیش‌بینی تراز آب زیرزمینی با کمک شبکه‌های موجک-عصبی (مطالعه موردی: دشت مراغه-آذربایجان شرقی)

جعفر نیکبخت^{*}، سمانه نوری²

چکیده

لازمه دستیابی به مدیریت جامع و پایدار منابع آب زیرزمینی، شناخت رفتار سیستم آب زیرزمینی و پیش‌بینی نوسانات سطح آن در آینده می‌باشد. هدف از پژوهش حاضر خوش‌بندی چاههای مشاهده‌ای آبخوان دشت مراغه-بناب و پیش‌بینی تراز آب زیرزمینی به کمک شبکه‌های موجک-عصبی (WNN) می‌باشد. به دلیل تعداد زیاد چاههای مشاهده‌ای نصب شده در دشت، به کمک روش خوش‌بندی سلسه مراتبی-وارد ۲۰ چاه مشاهده‌ای محدوده دشت مراغه-بناب با طول دوره آماری بیش از ۱۵ سال خوش‌بندی شد. سپس خوش‌بندی ۶ چاههای مشاهده‌ای مشاهده شد. با نویززدایی از داده‌های ورودی با کمک روش موجک، مقادیر سطح آب زیرزمینی با کمک شبکه‌های عصبی مصنوعی (ANN) پیش‌بینی شد. نتایج نشان داد در نظر گرفتن دمای متوسط هوا باعث اختشاش شبکه‌های عصبی مصنوعی و شبکه‌های موجک-عصبی شد. هم چنین بر اساس نتایج با در نظر گرفتن تأخیر زمانی متولی ۳ تا ۱۲ ماه در داده‌های ورودی، اختلاف مقادیر پیش‌بینی شده و واقعی کاهش یافت. کمترین مقدار RMSE و بیشترین مقدار R^2 در شبکه WNN به ترتیب ۰/۰۳ متر و ۰/۹۹۹ متر داشت. این مقادیر در شبکه ANN به ترتیب ۰/۳۲ متر و ۰/۱۱۵ متر بود. بنابراین بر اساس نتایج پژوهش حاضر، با نویززدایی از داده‌های ورودی اختلاف مقادیر سطح آب زیرزمینی پیش‌بینی شده و واقعی به طور متوسط به ۱۱ سانتی‌متر کاهش یافت.

واژه‌های کلیدی: تبدیل موجک، تراز آب زیرزمینی، خوش‌بندی سلسه مراتبی وارد، دشت مراغه-بناب آذربایجان شرقی، شبکه‌های موجک-عصبی.

تاریخ دریافت مقاله: ۱۳۹۴/۱۲/۰۴
تاریخ پذیرش مقاله: ۱۳۹۵/۰۱/۲۹

1- Associate professor, Department of Water Engineering, University of Zanjan, E-Mails: Nikbakht.jaefar@znu.ac.ir
2- Graduate Student of Irrigation and Drainage, University of Zanjan.

*- Corresponding Author

۱- دانشیار، گروه مهندسی آب، دانشگاه زنجان.
۲- دانش آموخته آبیاری و زهکشی، دانشگاه زنجان.
* نویسنده مسئول

مقدمه

برخوردار بودند. حامد و همکاران (۲۰۱۵) طی پژوهشی به منظور پیش‌بینی تراز آب زیرزمینی در ۴ چاه واقع در جنوب ریاض از شبکه‌های عصبی مصنوعی با معماری ۱-۶-۲ و تابع سیگموئید در لایه پنهان استفاده کرد. نتایج نشان داد افت سطح آب این آبخوان در آینده، از ۳۰ درصد افت رخ داده در ۳۰ سال گذشته تجاوز نخواهد کرد. چیتسازان و همکاران (۲۰۱۵) به منظور پیش‌بینی تراز آب زیرزمینی منطقه عقلی در جنوب غربی ایران از مدل عددی اجزای محدود و شبکه‌های عصبی مصنوعی استفاده کردند. نتایج نشان داد سطح آب زیرزمینی پیش‌بینی شده با شبکه‌های عصبی مصنوعی دقت بالایی نسبت به مدل عددی داشت. حبیبی و همکاران (۱۳۹۴) به منظور پیش‌بینی سطح آب زیرزمینی دشت هادیشهر-آذربایجان‌شرقی از روش‌های هوش مصنوعی نروفازی و برنامه‌ریزی ژنتیک و ترکیب آن‌ها استفاده کردند. بر اساس نتایج دقت مدل برنامه‌ریزی ژنتیک بیشتر بود. بنابراین در نهایت ایشان با ترکیب این مدل با مدل زمین‌آمار کریجینگ، پیش‌بینی زمانی-مکانی سطح آب زیرزمینی برای کل دشت را انجام دادند. کیانی سلمی و نظیفی (۱۳۹۴) به منظور شبکه‌های عصبی میزان تخلیه آب زیرزمینی شرق جلگه اصفهان از پیش‌بینی نشان داد تا سال ۱۳۹۴ میزان برداشت منطقه به ۵۱۹ میلیون متر مکعب افزایش خواهد یافت. سلطانی و همکاران (۱۳۹۳) به منظور تخمین نقشه‌های همتراز سطح آب زیرزمینی در روزهای مختلف سال در دشت بهبهان، از شبکه‌های عصبی مصنوعی استفاده کردند. ایشان پس از تخمین مقادیر سطح آب زیرزمینی با ضریب همیستگی 0.99 با داده‌های واقعی، نقشه خطوط همتراز سطح ایستابی دشت را برای ۴ روز مختلف سال (هر نقشه برای یک فصل از سال ۱۳۸۴ ترسیم نمودند. لوهانی و کریمیان (۲۰۱۵) به منظور شبیه‌سازی و پیش‌بینی سطح آب زیرزمینی مناطق آمریتسار و گوردادسپور ایالت پنجاب هند، انواع عماری‌ها و الگوریتم‌های آموزش شبکه‌های عصبی مصنوعی را مورد بررسی و مقایسه قرار دادند. بهترین نتایج از طریق شبکه پیش‌خور استاندارد با تابع آموزش لونبرگ-مارکوارت حاصل شد. سان و همکاران (۲۰۱۵) با شبیه‌سازی سطح آب زیرزمینی جنگل‌های باتلاقی

با توجه به اهمیت منابع آب زیرزمینی در تأمین آب شرب، صنعت و کشاورزی به ویژه در مناطق خشک و نیمه‌خشک، مطالعات این منبع آبی می‌تواند کمک شایانی به تصمیم‌سازی در برداشت بهینه و پایدار از این منبع آبی در دراز مدت داشته باشد (محتمم و همکاران، ۱۳۸۹؛ اسریکت و همکاران، ۲۰۰۹). در همین راستا و به منظور شناخت مستقیم رفتار یک سیستم آب زیرزمینی، لازم است تعداد زیادی چاه اکتشافی حفر گردد و آزمایشات متعدد پمپاژ و ژئوفیزیک صورت پذیرد. هم چنین سطح آب زیرزمینی به صورت مداوم اماربرداری و ثبت گردد. کلیه موارد ذکر شده نیازمند صرف هزینه‌های فراوان می‌باشد. امروزه بر اساس پیشرفت‌های صورت گرفته در بخش ساخت‌افزاری و نرم‌افزاری کامپیوترا، به منظور کاهش هزینه‌های مطالعات آب زیرزمینی، شبیه‌سازی شرایط طبیعی سفره و جریان آب زیرزمینی توسط مدل‌های ریاضی و کامپیوترا با استفاده از یک سری روابط ریاضی به عنوان یک روش غیرمستقیم مطالعه شبیه‌سازی می‌گردد (نکوآمال کرمانی و همکاران، ۱۳۸۶). با توجه به روابط غیرخطی و پیچیده حاکم بر جریان آب‌های زیرزمینی، امروزه جهت مدل‌سازی آبخوان و پیش‌بینی نوسانات تراز آب زیرزمینی در اثر اعمال شرایط مدیریتی متفاوت، از سیستم‌های هوش مصنوعی استفاده می‌شود. یکی از سیستم‌های هوشمند که در پیش‌بینی نوسانات سطح آب زیرزمینی مورد استفاده قرار می‌گیرد، شبکه‌های عصبی مصنوعی می‌باشد (امیری ده‌احمدی و حسامی کرمانی، ۱۳۹۱؛ خاشعی سیوکی و همکاران، ۱۳۹۲). پژوهش‌های زیادی برای شبیه‌سازی آبخوان به کمک شبکه‌های عصبی مصنوعی صورت گرفته است که به علت زیادی این تحقیقات در ادامه فقط به برخی از آن‌ها اشاره می‌شود. تأثیرمینا و همکاران (۲۰۱۲)، طی پژوهشی با کمک شبکه‌های عصبی مصنوعی پس انتشار خطاباً الگوریتم آموزشی لونبرگ-مارکوارت با تابع فعال سازی تائزانت هایپربولیک با ۴ نرون در لایه پنهان، نوسانات ساعتی تراز آب زیرزمینی آبخوان ساحلی تالاب و نیز ایتالیا را مدل‌سازی نمودند. بر اساس نتایج پژوهش پورمحمدی و همکاران (۱۳۹۲) هر دو تکنیک شبکه عصبی مصنوعی و سری‌های زمانی (آریما) از دقت و کارایی بالایی در پیش‌بینی سطح ایستابی ۳۵ چاه مشاهده‌ای یکی از زیرحوزه‌های بختگان

قابلیت برآش بهتری را بر داده‌های مشاهداتی دارد (حسن‌زاده و همکاران، ۱۳۹۱). آداموسکی و فونگ چان (۲۰۱۱) طی پژوهشی به منظور پیش‌بینی سطح آب زیرزمینی حوضه شاتوگه در ایالت کبک کانادا از ۳ مدل میانگین متحرک خود همبسته یکپارچه (ARIMA)، شبکه‌های عصبی مصنوعی و شبکه‌های موجک-عصبی استفاده کردند. بر اساس نتایج، مقادیر سطح آب زیرزمینی پیش‌بینی شده با شبکه موجک-عصبی از دقت بالایی برخوردار بود. نخعی و صابری نصر (۲۰۱۲) به منظور پیش‌بینی سطح آب زیرزمینی دشت قروه-کردستان از شبکه‌های موجک-عصبی استفاده کردند. بر اساس نتایج، در این پژوهش بهترین تبدیل‌ها برای نویزدایی از داده‌های ورودی db_4 , db_2 ^۱ به دست آمد. هم چنین نتایج نشان داد که از مدل شبکه‌های موجک-عصبی می‌توان در زمان‌هایی که داده کافی برای مدل‌سازی با مدل عددی MODFLOW وجود ندارد برای پیش‌بینی سطح آب زیرزمینی استفاده گردد. رحیمی و ملکی‌نژاد (۱۳۹۲) به منظور شبیه‌سازی نوسانات سطح آب زیرزمینی دشت نمدان فارس، از داده‌های نویزدایی شده و بدون نویزدایی و شبکه‌های عصبی پیش‌بینی استفاده نمودند. نتایج پژوهش نشان داد که هر دو مدل شبکه‌های عصبی مصنوعی و موجک-عصبی توانایی بالایی در پیش‌بینی نوسانات سطح آب زیرزمینی داشت. نتایج پژوهش رضوی قهقهخی و همکاران (۱۳۹۲) نشان داد که اختلاف مقادیر سطح آب زیرزمینی پیش‌بینی شده با مدل شبکه‌های موجک-عصبی نسبت به مقادیر واقعی اندازه‌گیری شده در دشت شهرکرد کمتر از پیش‌بینی‌های مدل شبکه‌های عصبی مصنوعی بود. نتایج پژوهش رجایی و ابراهیمی (۱۳۹۳) نشان داد مقادیر سطح آب زیرزمینی (دشت قم) پیش‌بینی شده برای یک ماه آینده از طریق مدل ترکیبی موجک-عصبی نسبت به دو مدل شبکه عصبی مصنوعی و رگرسیون خطی چند متغیره تطابق بهتری با مقادیر واقعی داشت. نتایج پژوهش سوریانارایانا و همکاران (۲۰۱۴) نشان داد کارایی مدل ترکیبی تبدیل موجک و ماشین بردار پشتیبان برای پیش‌بینی سطح آب زیرزمینی ۳ چاه واقع در شهر یساخاپاتنام هند از مدل شبکه‌های عصبی مصنوعی، ماشین بردار پشتیبان و ARIMA بهتر است. بروجردی و فریدونی (۱۳۹۴) طی پژوهشی با استفاده از مقادیر

سنگاپور با کمک شبکه‌های عصبی مصنوعی، نتیجه گرفتند که از این تکنیک می‌توان تراز آب زیرزمینی را تا ۷ روز آینده با دقت قابل قبول پیش‌بینی نمود ولی با طولانی‌تر شدن زمان پیش‌بینی دقت مقادیر کاهش یافت. جبیبی و همکاران (۱۳۹۵) به منظور پیش‌بینی زمانی و مکانی سطح آب زیرزمینی دشت هادیشهر از ترکیب مدل‌های هوش مصنوعی و زمین آمار استفاده کردند. در این پژوهش پس از دسته‌بندی پیزومترهای دشت با روش خوش‌بندی سلسه مراتی، به کمک شبکه‌های عصبی و فازی ساجنو هر دسته از پیزومترها مدل‌سازی شد. بر اساس نتایج، مدل شبکه عصبی با الگوریتم لونبرگ-مارکوارت با میانگین RMSE=28cm کارایی بهتری داشت. در نهایت ایشان با کمک روش کریجینگ و کوکریجینگ عصبی سطح آب زیرزمینی دشت را پیش‌بینی نمودند. در این مرحله نیز مشاهده شد که مقدار RMSE روش کوکریجینگ (۰/۷۶ متر) از روش کریجینگ (۱/۲۳ متر) کمتر بود.

یکی از معایب شبکه‌های عصبی مصنوعی، محدودیت کار با داده‌های غیرایستا (داده‌های با خصوصیات آماری متغیر در زمان) می‌باشد. در علم هیدروژئولوژی، داده‌ها عموماً غیرایستا هستند. برای رفع این مشکل، امروزه از تبدیل موجک استفاده می‌گردد. داده‌های غیرایستا ممکن است ترکیبی از چند داده ایستا باشند. با استفاده از تبدیل‌های موجک، می‌توان سری‌های زمانی غیرایستا را به چند سری زمانی ایستا تجزیه کرد و از این سری‌های جدید با خصوصیات ثابت در طول زمان می‌توان به عنوان ورودی شبکه‌های عصبی مصنوعی بهره گرفت (رجایی و ابراهیمی، ۱۳۹۳). تبدیل موجک یکی از مهم‌ترین تبدیلات ریاضی در حوضه‌ی پردازش سیگنال و تصویر است که ایده اصلی آن از تبدیل فوریه برگرفته شد. در تبدیلات موجک، برخلاف تبدیل فوریه، سیگنال‌ها، توان در دو بعد زمان و مقیاس مورد بررسی قرار می‌گیرد (نوری و همکاران، ۱۳۸۶؛ قیامی باجگیرانی و همکاران، ۱۳۸۹). پژوهش‌گران اخیراً به منظور افزایش عملکرد شبکه‌های عصبی مصنوعی، مفاهیم شبکه‌های عصبی را با تئوری تبدیل موجک تلفیق نموده و شبکه جدیدی تحت عنوان شبکه‌های موجک-عصبی (ویونت^۲) تولید می‌کنند. بر اساس نتایج مشاهده شده، مدل ترکیبی

داد (ایزدی و همکاران، ۱۳۸۷). خوش به مجموعه‌ای از داده‌ها گفته می‌شود که به هم شباهت دارند. در خوش‌بندی سعی می‌شود تا کل داده‌های موجود، به خوش‌هایی تقسیم شوند که شباهت بین داده‌های درون هر خوش به بیشینه و شباهت بین داده‌های خوش‌های متفاوت، کمینه شود. در خوش‌بندی داده‌ها، بر خلاف طبقه‌بندی کلاسیک داده‌ها، تعداد خوش‌های از داده‌ها، به منظور پیش‌بینی سطح آب زیرزمینی داشت (۱۳۹۲) استخراج می‌شوند (پیری و همکاران، ۱۳۹۲). ایزدی و همکاران (۱۳۸۷) به منظور پیش‌بینی سطح آب زیرزمینی داشت نیشاپور، ابتدا چاههای موجود در سطح داشت (۵۰ عدد) را به کمک روش WARD، خوش‌بندی نمودند. سپس با انتخاب یک چاه به عنوان نماینده هر خوش، سطح آب زیرزمینی چاه نماینده را با کمک مدل داده‌های ترکیبی با اثرات مشترک، پیش‌بینی نمودند. هدف از پژوهش حاضر خوش‌بندی چاههای مشاهدهای داشت مراغه-بناب و انتخاب نماینده برای هر خوش‌بندی به منظور پیش‌بینی سطح آب زیرزمینی با کمک مدل شبکه‌های موجک-عصبی و مقایسه آن با شبکه‌های عصبی مصنوعی بود.

مواد و روش‌ها

این مطالعه بر روی آبخوان داشت مراغه-بناب با موقعیت جغرافیایی 46° تا $46^{\circ} 11'$ طول شرقی و $37^{\circ} 28'$ عرض شمالی و ارتفاع متوسط حدود ۱۳۰۰ متر از سطح آبهای آزاد انجام گرفت. داده‌های مورد نیاز پژوهش شامل داده‌های هواشناسی ایستگاه سینوپتیک مراغه و کلیه اطلاعات منابع آب زیرزمینی داشت مراغه-بناب به ترتیب از سازمان هواشناسی کشور و شرکت آب منطقه‌ای استان آذربایجان شرقی تهیه شد. مرزهای آبخوان داشت مراغه-بناب جهت انجام مدل‌سازی از طریق نقشه زمین‌شناسی منطقه، محدوده دریاچه ارومیه و نقشه هم‌تراز سطح آب زیرزمینی، معین شد (شکل ۱). در مرحله بعد پس از مرتب‌سازی آمار و اطلاعات چاههای مشاهداتی محدوده آبخوان، ۲۰ چاه از بین ۱۳۱ چاه موجود که دارای آمار بیش از ۱۵ سال بودند (۱۳۷۷-۱۳۹۱) برای انجام مراحل بعدی پژوهش از بقیه چاهها جدا شد. با آزمون ران-تست، تصادفی بودن مقادیر ماهانه تراز آب زیرزمینی ثبت شده در هر چاه در سطح احتمال ۹۵ درصد بررسی و داده‌های پرت اصلاح گردید. به منظور خوش‌بندی مجموعه چاههای گستره

سطح آب زیرزمینی و بارش صورت گرفته در دشت شیراز، سطح آب زیرزمینی داشت را با کمک ۳ تکنیک فازی-عصبی، ماشین بردار پشتیبان و موجک-عصبی مدل‌سازی کردند. بر اساس نتایج، ضریب رگرسیون بین مقادیر پیش‌بینی شده و واقعی 0.986 برای فازی-عصبی، 0.993 برای موجک-عصبی و 0.767 ماشین بردار پشتیبان حاصل شد که بیان گر دقت بالای فازی عصبی و موجک-عصبی نسبت به ماشین بردار پشتیبان بود. مبارکی و فربیدونی (۱۳۹۴) در پژوهشی کارایی مدل‌های استنتاج فازی-عصبی و تلفیقی موجک-فازی عصبی برای شبیه‌سازی تراز آب زیرزمینی داشت نی‌ریز را مورد بررسی قرار دادند. نتایج حاکی از کارایی بالای مدل تلفیقی موجک-فازی عصبی بود. نورانی و موسوی (۲۰۱۶) به منظور پیش‌بینی سطح آب زیرزمینی پیزومترهای نصب شده در دشت میاندوآب آذربایجان غربی، با نویززدایی از داده‌های ورودی، مقادیر تراز آب زیرزمینی داشت را با کمک شبکه‌های عصبی مصنوعی و سیستم استنتاج فازی-عصبی پیش‌بینی نمودند. نتایج نشان داد که نویززدایی از داده‌های ورودی موجب افزایش کارایی هر دو مدل تا $13/4$ درصد شد. نورانی و همکاران (۲۰۱۵) طی پژوهشی کارایی مدل شبکه‌های عصبی پیش‌خور^۳، مدل آماری میانگین متحرک خود همبسته یکپارچه با ورودی بروندزاد (ARIMAX) و مدل ترکیب یافته شبکه عصبی پیش‌خور با تبدیل موجک را در دشت اردبیل مورد بررسی قرار دادند. نتایج نشان داد استفاده از تبدیل موجک در داده‌های سطح آب زیرزمینی باعث افزایش کارایی مدل شبکه‌های عصبی پیش‌خور از طریق آشکارسازی دوره‌های غالب فرایند عملیات تا به طور متوسط $15/3$ درصد شد.

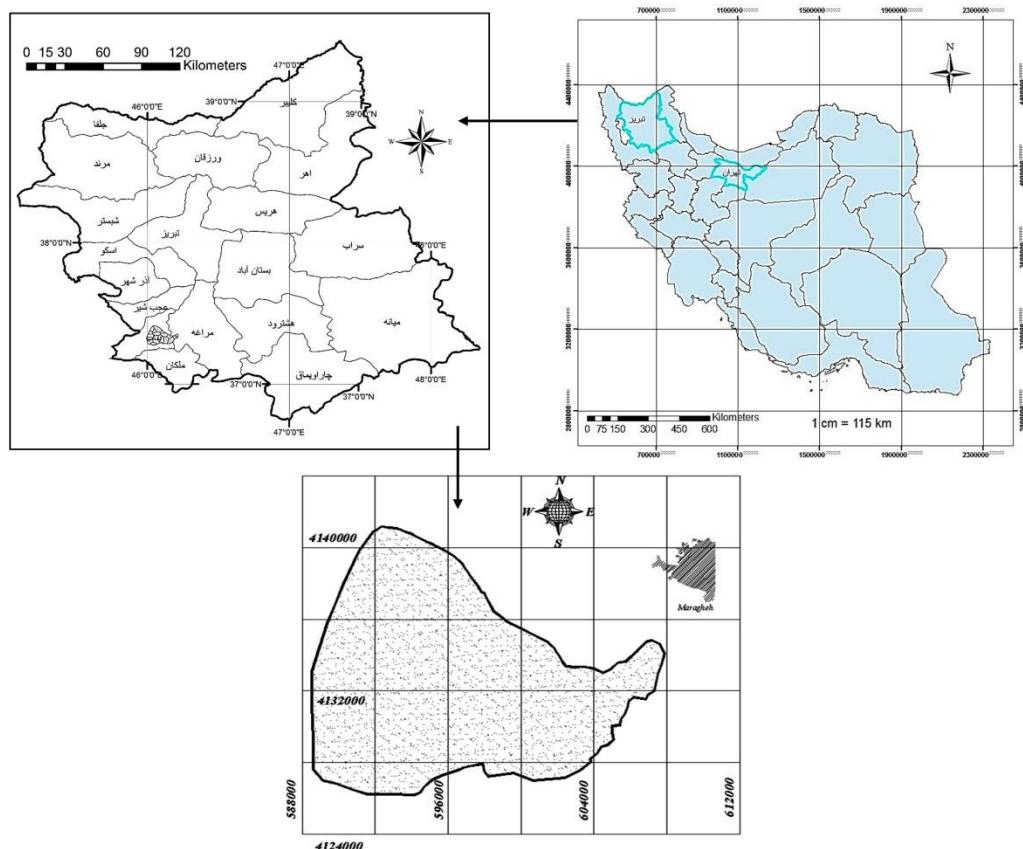
یکی از مشکلات مدل‌سازی آبخوان و پیش‌بینی نوسانات سطح آب زیرزمینی از طریق مدل‌های رگرسیونی و هوشمند، تعداد زیاد چاههای مشاهدهای نصب شده در گستره داشت و آبخوان می‌باشد که باعث می‌شود تحلیل تک‌تک آن‌ها مشکل و بسیار وقت‌گیر گردد. یکی از راه حل‌هایی که در این گونه موقع می‌توان استفاده کرد، خوش‌بندی مجموعه چاهها و قرار دادن چاههای مشابه در یک خوش می‌باشد. سپس رفتارهای یکسان را در قالب یک چاه مشاهدهای که به عنوان نماینده آن خوش برجزیده می‌شود، مورد بررسی و تحلیل قرار

3- Feedforward Neural Network model

$$y = 0.5 * \frac{x - \bar{x}}{x_{\max} - x_{\min}} + 0.5 \quad [1]$$

\bar{x} : میانگین سری داده‌های مشاهداتی، x : مقدار داده مشاهداتی، x_{\min} و x_{\max} : حداقل و حدکثر سری داده‌های مشاهداتی و y : داده نرمال شده می‌باشد (ستهی و همکاران، ۲۰۱۰).

دشت، مقادیر سطح آب زیرزمینی در هر چاه، به کمک رابطه ۱ نرم‌السازی شده و برای انجام خوشبندی وارد نرم‌افزار SPSS گردید. در این تحقیق از روش سلسله مراتبی WARD، برای انجام خوشبندی استفاده شد. این روش دقیق‌ترین روش خوشبندی سلسله مراتبی بوده و اعضای قرار گرفته در یک خوش، از نظر موقعیت جغرافیایی بر روی نقشه، در همسایگی یکدیگر واقع می‌شوند بنابراین پیوستگی جغرافیایی اقلیمی حفظ می‌شود (ستاری، ۱۳۹۱).



شکل ۱- موقعیت محدوده دشت مراغه-بناب.

دسترس آن، کمترین اختلاف را از انحراف معیار کل زیرخوشه داشت به عنوان نماینده آن زیرخوشه انتخاب شد. پس از انتخاب چاه نماینده برای هر زیرخوشه، مقادیر سطح آب زیرزمینی در دو حالت شبکه‌های عصبی مصنوعی و شبکه موجک-عصبی مدل‌سازی و شبیه‌سازی شد. در پژوهش حاضر برای طراحی شبکه‌ها، ترکیبی از اطلاعات هواشناسی شامل بارندگی، تبخیر از تشک، دمای متوسط هوا و منابع آب

بعد از انجام خوشبندی، با در نظر گرفتن خصوصیات توپوگرافی دشت، متوسط سطح آب زیرزمینی چاه‌های مشاهداتی هر زیرخوشه و همچنین نظر کارشناسی، تعداد زیرخوشه‌های مناسب جهت ادامه پژوهش انتخاب شد. هم چنین از بین چاه‌های عضو یک زیرخوشه، چاهی که انحراف معیار و ضریب تغییرات تراز آب زیرزمینی کل دوره آماری قابل

$$R^2 = \frac{\sum_{i=1}^n (q_i - \bar{q}_i)(\hat{q}_i - \bar{\hat{q}}_i)^2}{\sum_{i=1}^n (q_i - \bar{q}_i)^2 \sum_{i=1}^n (\hat{q}_i - \bar{\hat{q}}_i)^2}$$

[۲]

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (q_i - \hat{q}_i)^2}$$

[۳]

در این روابط، q_i مقدار سطح آب زیرزمینی مشاهده شده، \hat{q}_i مقدار سطح آب زیرزمینی برآورد شده با شبکه‌های عصبی مصنوعی، \bar{q}_i میانگین مقادیر سطح آب زیرزمینی مشاهداتی، $\bar{\hat{q}}_i$ میانگین مقادیر سطح آب زیرزمینی محاسباتی، n تعداد داده‌ها می‌باشد (ستهی و همکاران، ۲۰۱۰).

جدول ۱- معماری‌های در نظر گرفته شده برای پیش‌بینی سطح آب زیرزمینی با کمک مدل‌های ANN و Wave-Net

پارامتر	پارامترهای بردار ورودی	نام شبکه
بردار		
خروجی		
سطح	دماه متوسط، بارندگی و تبخیر از تشت	ANN _{3;1;1}
ایستایی	دماه متوسط، بارندگی، تبخیر از تشت و مقادیر تخلیه تأثیرگذار	ANN _{4;1;1}
	پارامترهای اول و دوم با در نظر گرفتن چندین گام زمانی تأخیر برای هر پارامتر هم جنبن از تأخیر زمانی تراز ایستایی نیز به عنوان ورودی استفاده شد	ANN _{i;1;1}

در مدل‌سازی سطح آب زیرزمینی با شبکه‌های موجک-عصبی، ابتدا داده‌های اولیه موحکی شده و به دو دسته تقسیم می‌شوند. دسته اول که تقریب نامیده می‌شوند، دارای فرکانس کم (پریود زیاد) بوده و نشان‌دهنده روند کلی داده‌های موجود می‌باشند. این دسته در محاسبات نقش بسیار مهمی ایفا می‌کنند. دسته دوم جزئیات نام دارند که فرکانس بالا (پریود کم) دارند و مبین تغییرات محدود در داده‌ها هستند (نوری و همکاران، ۱۳۹۰؛ امیری ده‌احمدی و حسامی کرمانی، ۱۳۹۱؛ پورمحمدی و همکاران، ۱۳۹۲)، در این پژوهش برای مدل‌سازی سطح آب زیرزمینی با ANN، از شبکه پیش‌خور (MLP) پس‌انتشار خطا (BP) (شبکه‌های پرسپترون چندلایه) با توابع آموخته‌شی لونبرگ-مارکوات استفاده شد. برای تابع محرک جهت تعیین شبکه بهینه از کلیه توابع محرک تعریف شده در نرم‌افزار استفاده شد. برای ارزیابی کارایی شبکه‌های عصبی مصنوعی طراحی شده، از آمارهای ضربی تبیین (رابطه ۲) و جذر مربعات کمترین خطای میانگین (رابطه ۳) استفاده شد.

$$D.L. = Int(\log n)$$

[۴]

DL: سطح تجزیه، Int: جزء صحیح، Log: لگاریتم در

پایه ۱۰ و n : اندازه سری زمانی داده‌ها را نشان می‌دهد. با توجه

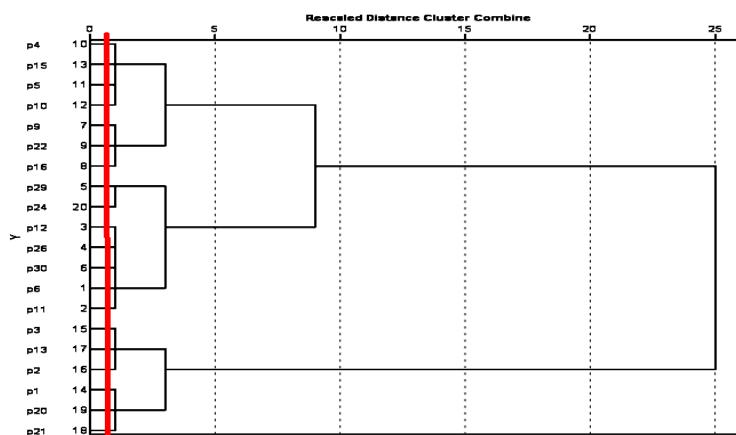
شامل تراز سطح ایستایی و آب برداشتی از آبخوان از طریق چاه استفاده شد. جدول ۱ معماری‌های متفاوت در نظر گرفته برای پیش‌بینی سطح آب زیرزمینی در هر چاه برای مدل‌های ANN و Wave-Net را نشان می‌دهد. با توجه به جدول ۱ مشاهده می‌شود که در تمام معماری‌ها، خروجی شبکه‌ها، تراز ثبت شده سطح آب زیرزمینی در چاه مشاهده‌ای بود. هم چنین با توجه به جدول ۱، در معماری سوم برای هر پارامتر تأخیر زمانی، ۱، ۳، ۶، ۹ و ۱۲ ماه و ترکیبی از آن‌ها (به عنوان نمونه ۳ و ۶ یا ۳، ۹ و ۱۲ یا ۶ و ۱۲ ماه تأخیر) در نظر گرفته شد. جهت محاسبه مقادیر تخلیه تأثیرگذار بر سطح آب هر چاه از روش پلی‌گون‌بندی استفاده گردید (محتشم و همکاران، ۱۳۸۹). به این منظور، مجموع مقادیر تخلیه آب توسط چاه‌های بهره‌برداری قرار گرفته در داخل پلی‌گون نماینده هر خوش بعد از کسر آب برگشتی به آبخوان محاسبه و به عنوان تخلیه از آن پلی‌گون که بر سطح آب آن چاه مشاهده‌ای تأثیرگذار است لحاظ شد.

به منظور شناسایی ارتباط بین ورودی‌ها و خروجی‌های مدل با کمک شبکه‌های عصبی مصنوعی، ابتدا کل داده‌ها به ۳ بخش تفکیک شد. ۷۰ درصد کل داده‌ها برای آموزش، ۱۵ درصد برای صحبت‌سنجی داده‌ها به منظور کنترل و نظارت بر یادگیری صحیح شبکه و ۱۵ درصد مابقی داده‌ها به عنوان داده‌های آزمون جهت ارزیابی عملکرد شبکه و بررسی دقیق پیش‌بینی مدل پیشنهادی استفاده شد. نرم‌افزار مورد استفاده در این پژوهش 5.0 NeuroSolutions بود. بر اساس مطالعات صورت گرفته و نیز پیشنهاد محققین (زارع ابیانه و همکاران، ۱۳۹۰؛ امیری ده‌احمدی و حسامی کرمانی، ۱۳۹۱؛ پورمحمدی و همکاران، ۱۳۹۲)، در این پژوهش برای مدل‌سازی سطح آب زیرزمینی با ANN، از شبکه پیش‌خور (MLP) پس‌انتشار خطا (BP) (شبکه‌های پرسپترون چندلایه) با توابع آموخته‌شی لونبرگ-مارکوات استفاده شد. برای تابع محرک جهت تعیین شبکه بهینه از کلیه توابع محرک تعریف شده در نرم‌افزار استفاده شد. برای ارزیابی کارایی شبکه‌های عصبی مصنوعی طراحی شده، از آمارهای ضربی تبیین (رابطه ۲) و جذر مربعات کمترین خطای میانگین (رابطه ۳) استفاده شد.

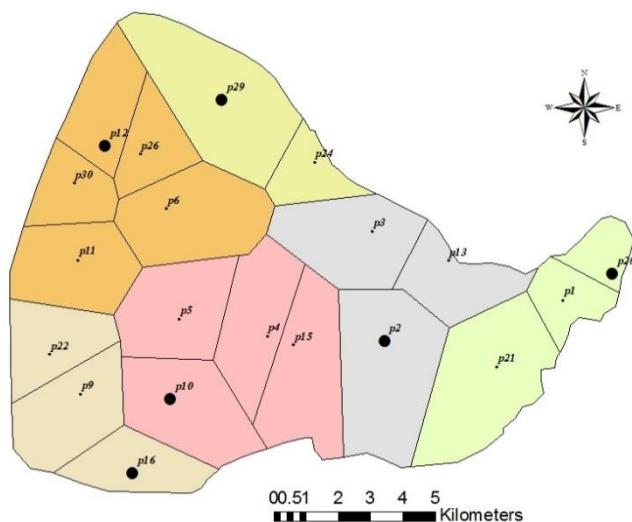
نتایج و بحث

شکل ۲ دندروگرام حاصل از خوشبندی ۲۰ چاه مشاهده‌ای مورد مطالعه دشت مراغه-بناب را با روش سلسله مراتسی-WARD نشان می‌دهد. در این پژوهش بهمنظور در نظر گرفتن بیشینه سطح داشت برای تحلیل‌های بعدی، خطی عمودی از فاصله مقیاس‌بندی شده $1/5$ عبور داده شده و تعداد ۶ زیرخوشه برای پیش‌بینی سطح آب زیرزمینی با ANN و Wave-ANN انتخاب شد. شکل ۳ محدوده آبخوان داشت مراغه-بناب، پلی‌گون هر چاه مشاهده‌ای و چاه‌های هر زیرخوشه را نشان می‌دهد. چاه مشاهده‌ای نماینده هر زیرخوشه، در شکل ۳، با دایره بزرگ‌تر نسبت به بقیه نشان داده شده است.

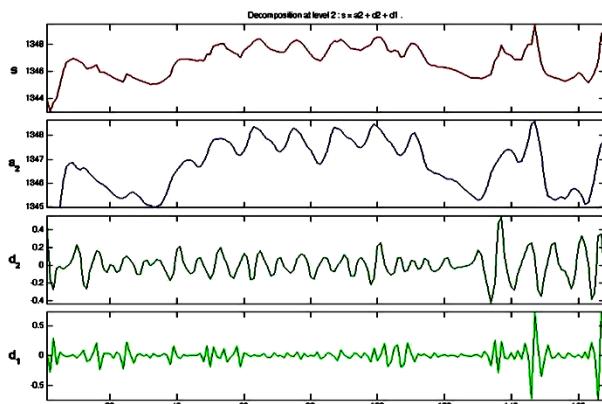
به طول سری زمانی داده‌های قابل دسترس در این پژوهش (۲۲۸ عدد)، سطح تجزیه ۲ در نظر گرفته شد. در این پژوهش، برای انجام تحلیل موجک از نرم‌افزار Matlab R2014a استفاده شد. ابتدا داده‌های کلیه سری‌های جدول ۱ با کمک رابطه Matlab نرم‌افزاری شد. سپس جهت نویززدایی وارد نرم‌افزار Matlab شد. به منظور تعیین بهترین نتیجه از تبدیل موجک، انواع موجک‌های مادر (db2, db4, db5, Coif5 و Sym2) انتخاب شد که این مسئله منجر به خروجی‌های متفاوت گردید. به همین منظور بهترین سری داده نویززدایی شده بر اساس آماره‌های ۲ و ۳، انتخاب شد. در مرحله بعد، کلیه مراحل اجرا شده با استفاده از شبکه‌های عصبی مصنوعی برای داده‌های اولیه (بدون نویززدایی)، عیناً برای داده‌های نویززدایی شده انجام گرفت.



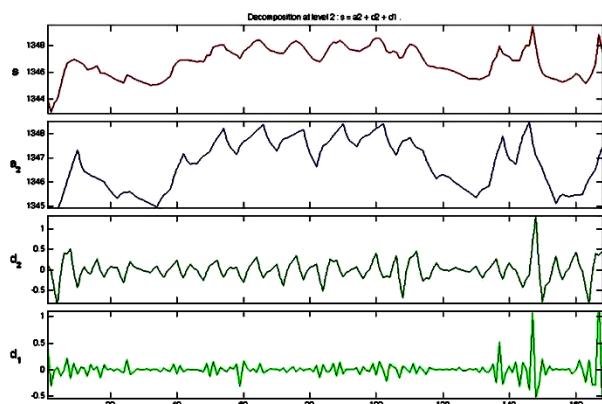
شکل ۲- دندروگرام خوشبندی چاه‌های مشاهده‌ای دشت مراغه-بناب با روش سلسله مراتسی-WARD.



شکل ۳- محدوده آبخوان دشت مراغه-بناب، پلیگون هر چاه مشاهده‌ای و چاه‌های هر زیرخوشه.



شکل ۴- تجزیه سیگنال مقادیر سطح آب زیرزمینی چاه مشاهده‌ای P29 با موجک مادر db4 با ۲ سطح تجزیه.



شکل ۵- تجزیه سیگنال مقادیر سطح آب زیرزمینی چاه مشاهده‌ای P29 با موجک مادر Sym2 با ۲ سطح تجزیه.

همان طور که بیان شد، هر یک از سری زمانی داده‌های مورد استفاده در این پژوهش، با استفاده از انواع موجک مادر در ۲ سطح گسسته‌سازی شد. سپس بر اساس آماره‌های ۲ و ۳، بهترین موجک مادر تعیین شد. به عنوان نمونه جدول ۲ نتایج مقایسه آماری مقادیر واقعی و نویزدایی شده سطح آب زیرزمینی چاه مشاهده‌ای P29 با کمک انواع موجک‌های مادر را نشان می‌دهد. با توجه به نتایج جدول ۲، برای داده‌های اخیر، موجک مادر db4 بهترین انطباق را با داده‌های اصلی داشت. هم چنین شکل‌های ۴ و ۵ به طور نمونه، نتایج تجزیه مقادیر سطح آب زیرزمینی چاه مشاهده‌ای P29 را با دو موجک مادر db4 و sym2 (به ترتیب بهترین و بدترین موجک مادر) و دو سطح تجزیه نشان می‌دهد.

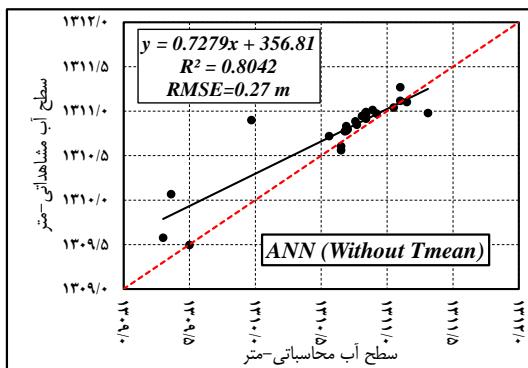
جدول ۲- مقایسه آماری مقادیر واقعی و نویزدایی شده با انواع P29 سطح آب زیرزمینی چاه مشاهده‌ای موجک‌های مادر مختلف.

موجک مادر	R^2	RMSE (m)	a	b
db2	0.92	0.29	1/0.1	-9/80
db4	0.96	0.20	1/0.0	0/80
dmev	0.96	0.21	1/0.0	4/99
coif5	0.96	0.20	1/0.0	4/92
sym2	0.92	0.29	1/0.1	-9/80

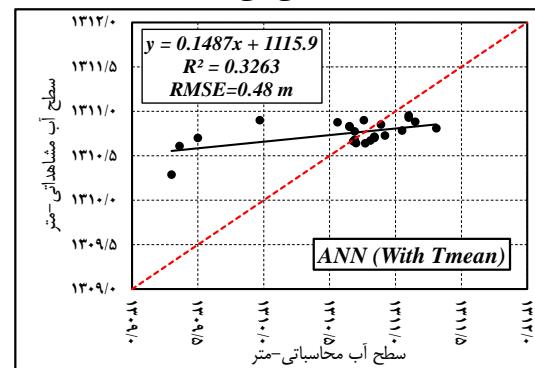
و a و b را شیب و عرض از میدا بهترین خط عبور از بین نقاط پیش‌بینی شده و واقعی می‌باشد.

نتایج حاصل از اجرای معماري‌های مختلف (جدول ۱) نشان داد، در هر معماري با پارامترهای ورودی معین، در نظر گرفتن تأخیر زمانی برای پارامترهای ورودی، باعث کاهش اختلاف مقادیر پیش‌بینی شده با مقادیر واقعی گردید. جدول ۳ ورودی‌ها و خروجی‌های بهترین شبکه عصبی مصنوعی و شبکه‌های موجک-عصبی طراحی شده برای چاه مشاهده‌ای نماینده هر زیرخوشه را نشان می‌دهد. با توجه به نتایج جدول ۳، مدت زمان تأخیر در بهترین شبکه‌ها، از ۳ ماه برای دو چاه P2 و P10 تا ۱۲ ماه برای چاه‌های P12، P16 و P29 متغیر بود. هم زمان تأخیر بهترین شبکه چاه P21 نیز ۹ ماه بدست آمد. هم چنین نتایج نشان داد که برای دستیابی به شبکه بهینه در هر دو روش ANN و WNN، بهتر است مقادیر سطح آب زیرزمینی ماههای قبل نیز به عنوان ورودی در شبکه‌ها در نظر گرفته شود. با توجه به جدول ۳، تأخیر زمانی در نظر گرفته شده برای این پارامتر در شبکه‌های بهینه، منطبق با سایر پارامترها بود.

هم چنین نتایج اجرای معماري‌های جدول ۱ نشان داد که در نظر گرفتن دمای متوسط ماهانه (حتی با تأخیر زمانی در معماري سوم) به همراه بقیه پارامترها به عنوان ورودی، باعث اغتشاش شبکه‌ها گردید. به عنوان نمونه نتایج حاصل از اجرای شبکه‌های عصبی مصنوعی با در نظر گرفتن دمای متوسط به عنوان ورودی و بعد از حذف آن از ورودی‌ها (سایر ورودی‌ها، بارندگی، تبخیر از تشت و مقادیر تخلیه تأثیرگذار بود) در چاه مشاهده‌ای P2 در شکل ۶ نشان داده شده است. با توجه به شکل ۶، با حذف دمای متوسط هوا از ورودی‌ها، مقدار RMSE از 0.48°C به 0.27°C کاهش، مقدار ضریب تبیین (R^2) از ۰.۴۸ به ۰.۸۰۴۲ افزایش و شبکه بهترین خط عبوری از بین مقادیر (a)، ۰.۵۸ افزایش یافت. شکل ۷، مقادیر واقعی و پیش‌بینی شده سطح آب زیرزمینی با WNN پس از نویززدایی از داده‌ها را نشان می‌دهد. ورودی‌ها و شرایط در نظر گرفته شده در شکل ۷ همانند شکل ۶ بود. نتایج شکل ۷ بیان‌گر بهتر شدن پیش‌بینی‌ها بعد از حذف داده‌های دما از ورودی‌های شبکه موجک-عصبی می‌باشد.

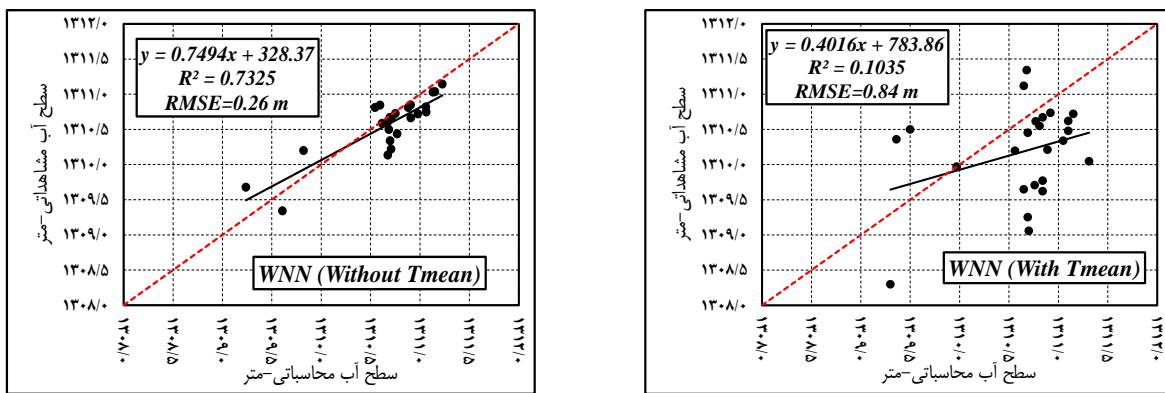


ب.



الف.

شکل ۶- مقادیر سطح آب زیرزمینی مشاهده شده و پیش‌بینی شده با شبکه‌های عصبی مصنوعی در چاه مشاهده‌ای P2 با در نظر گرفتن دمای متوسط به عنوان ورودی (الف) و حذف دمای متوسط از ورودی‌ها (ب).



شکل ۷- مقادیر سطح آب زیرزمینی مشاهده شده و پیش‌بینی شده با شبکه‌های موجک-عصبی در چاه مشاهده‌ای P2 با در نظر گرفتن دمای متوسط به عنوان ورودی (الف) و حذف دمای متوسط از ورودی‌ها (ب).

می‌گردد که به جز دو چاه P16 و P29 در بقیه چاه‌ها، توابع انتقال حاصل برای ANN و WNN متفاوت بود. یکسان نبودن توابع انتقال، همان گونه که در بخش مواد و روش‌ها نیز اشاره شد به دلیل استفاده از کلیه توابع انتقال تعریف شده در نرم‌افزار مورد کاربرد در این پژوهش بود. هم چنین با توجه به نتایج جدول ۴، تعداد لایه پنهان و تعداد نرون در بهترین شبکه ANN و WNN حاصل برای کلیه چاه‌ها برابر بود (به ترتیب یک لایه پنهان و ۴ عدد نرون). نتایج اجرای شبکه‌های طراحی شده با تعداد لایه مخفی و تعداد نرون بیشتر نشان داد که افزایش تعداد لایه‌های پنهان تأثیری در نتایج نداشته و فقط زمان محاسبات را افزایش داد و افزایش تعداد نرون در لایه پنهان نیز باعث افزایش اختشاش در شبکه و افزایش اختلاف بین مقادیر سطح آب زیرزمینی مشاهده‌ای و محاسباتی گردید. فقیه (۱۳۸۹) در طی پژوهشی مشاهده کرد با افزایش تعداد لایه پنهان از یک لایه به ۴ لایه، مقادیر RMSE کاهش نیافت و کمترین مقدار این آماره در شبکه با یک لایه پنهان مشاهده شد. هم چنین از بین شبکه‌های عصبی مصنوعی اجرا شده با تعداد ۱ تا ۱۲ نرون در لایه پنهان، شبکه با ۴ نرون کمترین مقدار RMSE را داشت.

جدول ۳- پارامترهای ورودی و خروجی بهترین شبکه WNN و ANN برای چاه‌های مشاهده‌ای نماینده.

شماره مشاهده‌ای	چاه	ورودی	خروجی
Wl _i	P2	$\begin{cases} P_i, P_{i-1}, P_{i-2}, P_{i-3}; E_i, E_{i-1}, E_{i-2}, E_{i-3} \\ O_i, O_{i-1}, O_{i-2}, O_{i-3}; Wl_{i-1}, Wl_{i-2}, Wl_{i-3} \end{cases}$	
Wl _i	P10	$\begin{cases} P_i, P_{i-1}, P_{i-2}, P_{i-3}; E_i, E_{i-1}, E_{i-2}, E_{i-3} \\ O_i, O_{i-1}, O_{i-2}, O_{i-3}; Wl_{i-1}, Wl_{i-2}, Wl_{i-3} \end{cases}$	
Wl _i	P12	$\begin{cases} P_i, P_{i-1}, \dots, P_{i-12}; E_i, E_{i-1}, \dots, E_{i-12} \\ O_i, O_{i-1}, \dots, O_{i-12}; Wl_{i-1}, \dots, Wl_{i-12} \end{cases}$	
Wl _i	P16	$\begin{cases} P_i, P_{i-1}, \dots, P_{i-12}; E_i, E_{i-1}, \dots, E_{i-12} \\ O_i, O_{i-1}, \dots, O_{i-12}; Wl_{i-1}, \dots, Wl_{i-12} \end{cases}$	
Wl _i	P21	$\begin{cases} P_i, P_{i-1}, \dots, P_{i-9}; E_i, E_{i-1}, \dots, E_{i-9} \\ O_i, O_{i-1}, \dots, O_{i-9}; Wl_{i-1}, \dots, Wl_{i-9} \end{cases}$	
Wl _i	P29	$\begin{cases} P_i, P_{i-1}, \dots, P_{i-12}; E_i, E_{i-1}, \dots, E_{i-12} \\ O_i, O_{i-1}, \dots, O_{i-12}; Wl_{i-1}, \dots, Wl_{i-12} \end{cases}$	

P: بارندگی ماهانه، E: تبخیر ماهانه از تشت تبخیر، O: مقدار ماهانه تخلیه تأثیرگذار و Wl: سطح ماهانه آب زیرزمینی.

جدول ۴ مشخصات بهترین شبکه عصبی مصنوعی و شبکه موجک-عصبی طراحی شده برای چاه مشاهده‌ای نماینده هر زیرخوشه را نشان می‌دهد. با توجه به جدول ۴ ملاحظه

جدول ۴- مشخصات بهترین شبکه عصبی مصنوعی و موجک-عصبی طراحی شده برای چاههای مشاهدهای نماینده هر زیرخوشه.

شماره چاه مشاهدهای	نوع شبکه	قانون آموزش	تابع انتقال	تعداد نمونه	تعداد لایه پنهان	تعداد تکرار
۱۰۰۰	۴	۱	SigmoidAxon	LM	ANN	P2
۱۰۰۰	۴	۱	Axon	LM	WNN	
۱۰۰۰	۴	۱	TanhAxon	LM	ANN	P10
۱۰۰۰	۴	۱	Bias Axon	LM	WNN	
۱۰۰۰	۴	۱	Bias Axon	LM	ANN	P12
۱۰۰۰	۴	۱	SigmoidAxon	LM	WNN	
۱۰۰۰	۴	۱	Axon	LM	ANN	P16
۱۰۰۰	۴	۱	Axon	LM	WNN	
۱۰۰۰	۴	۱	SigmoidAxon	LM	ANN	P21
۱۰۰۰	۴	۱	Bias Axon	LM	WNN	
۱۰۰۰	۴	۱	Bias Axon	LM	ANN	P29
۱۰۰۰	۴	۱	Bias Axon	LM	WNN	

کدام از چاهها، مقدار آن از ۹۰ درصد بیشتر نشد در حالی که پس از نویززدایی از داده‌های ورودی، در تمام چاه مقدار R^2 از ۹۰ درصد بیشتر شد (دامنه تغییرات بین ۰/۹۳۱ تا ۰/۹۹۹ در چاه P2 تا ۰/۹۹۹ در چاه P12). بر اساس مقادیر آماره‌های جدول ۵ آورده شده است. لازم به توضیح است که مقادیر پیش‌بینی شده برای مرحله آزمون می‌باشد. با توجه به جدول ۵، بیشترین و کمترین مقدار RMSE حاصل در روش ANN به ترتیب با مقادیر ۰/۷۷ و ۰/۳۲ متر در چاههای P12 و P21 نزدیک‌تر شد بود که بعد از نویززدایی از داده‌های ورودی، این مقادیر به ۰/۰۴ و ۰/۰۳ (P21) و ۰/۰۳ (P12) متر کاهش یافت (به ترتیب ۷۳ و ۲۹ سانتی‌متر کاهش). هم‌چنین در شبکه ANN، دامنه تغییرات مقدار R^2 بین ۰/۷۱۶ (P21) تا ۰/۸۸۵ (P10) بود و در هیچ

نتایج آماره‌های مورد استفاده جهت مقایسه مقادیر واقعی و پیش‌بینی شده سطح آب زیرزمینی با بهترین شبکه ANN و WNN در چاههای مشاهدهای نماینده هر زیرخوشه در جدول ۵ آورده شده است. لازم به توضیح است که مقادیر پیش‌بینی شده برای مرحله آزمون می‌باشد. با توجه به جدول ۵، بیشترین و کمترین مقدار RMSE حاصل در روش ANN به ترتیب با مقادیر ۰/۷۷ و ۰/۳۲ متر در چاههای P12 و P21 نزدیک‌تر شد بود که بعد از نویززدایی از داده‌های ورودی، این مقادیر به ۰/۰۴ و ۰/۰۳ (P21) و ۰/۰۳ (P12) متر کاهش یافت (به ترتیب ۷۳ و ۲۹ سانتی‌متر کاهش). هم‌چنین در شبکه ANN، دامنه تغییرات

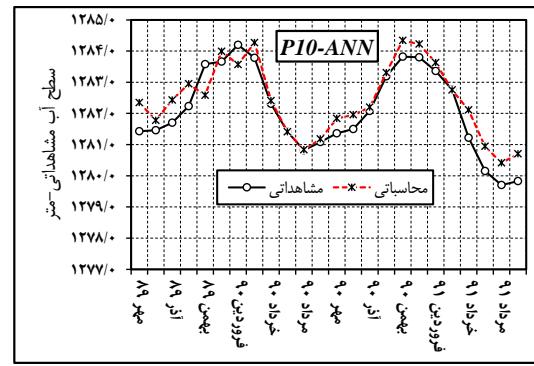
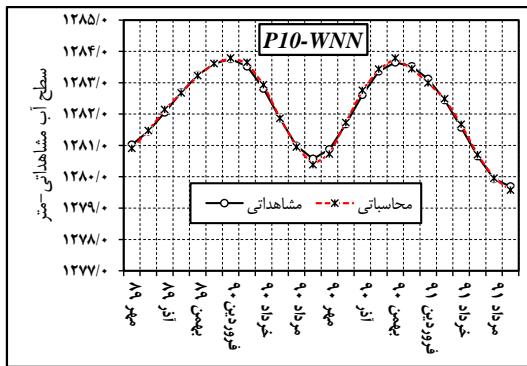
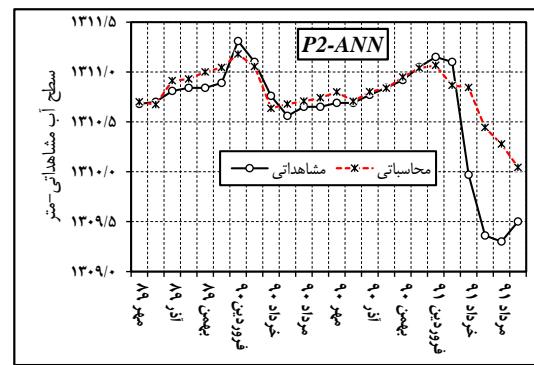
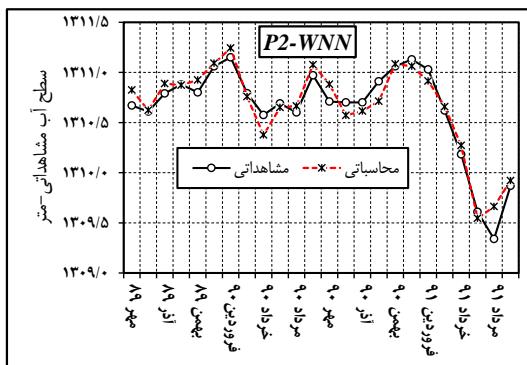
جدول ۵- نتایج مقایسه آماری مقادیر واقعی و پیش‌بینی شده سطح آب زیرزمینی با بهترین شبکه ANN و WNN

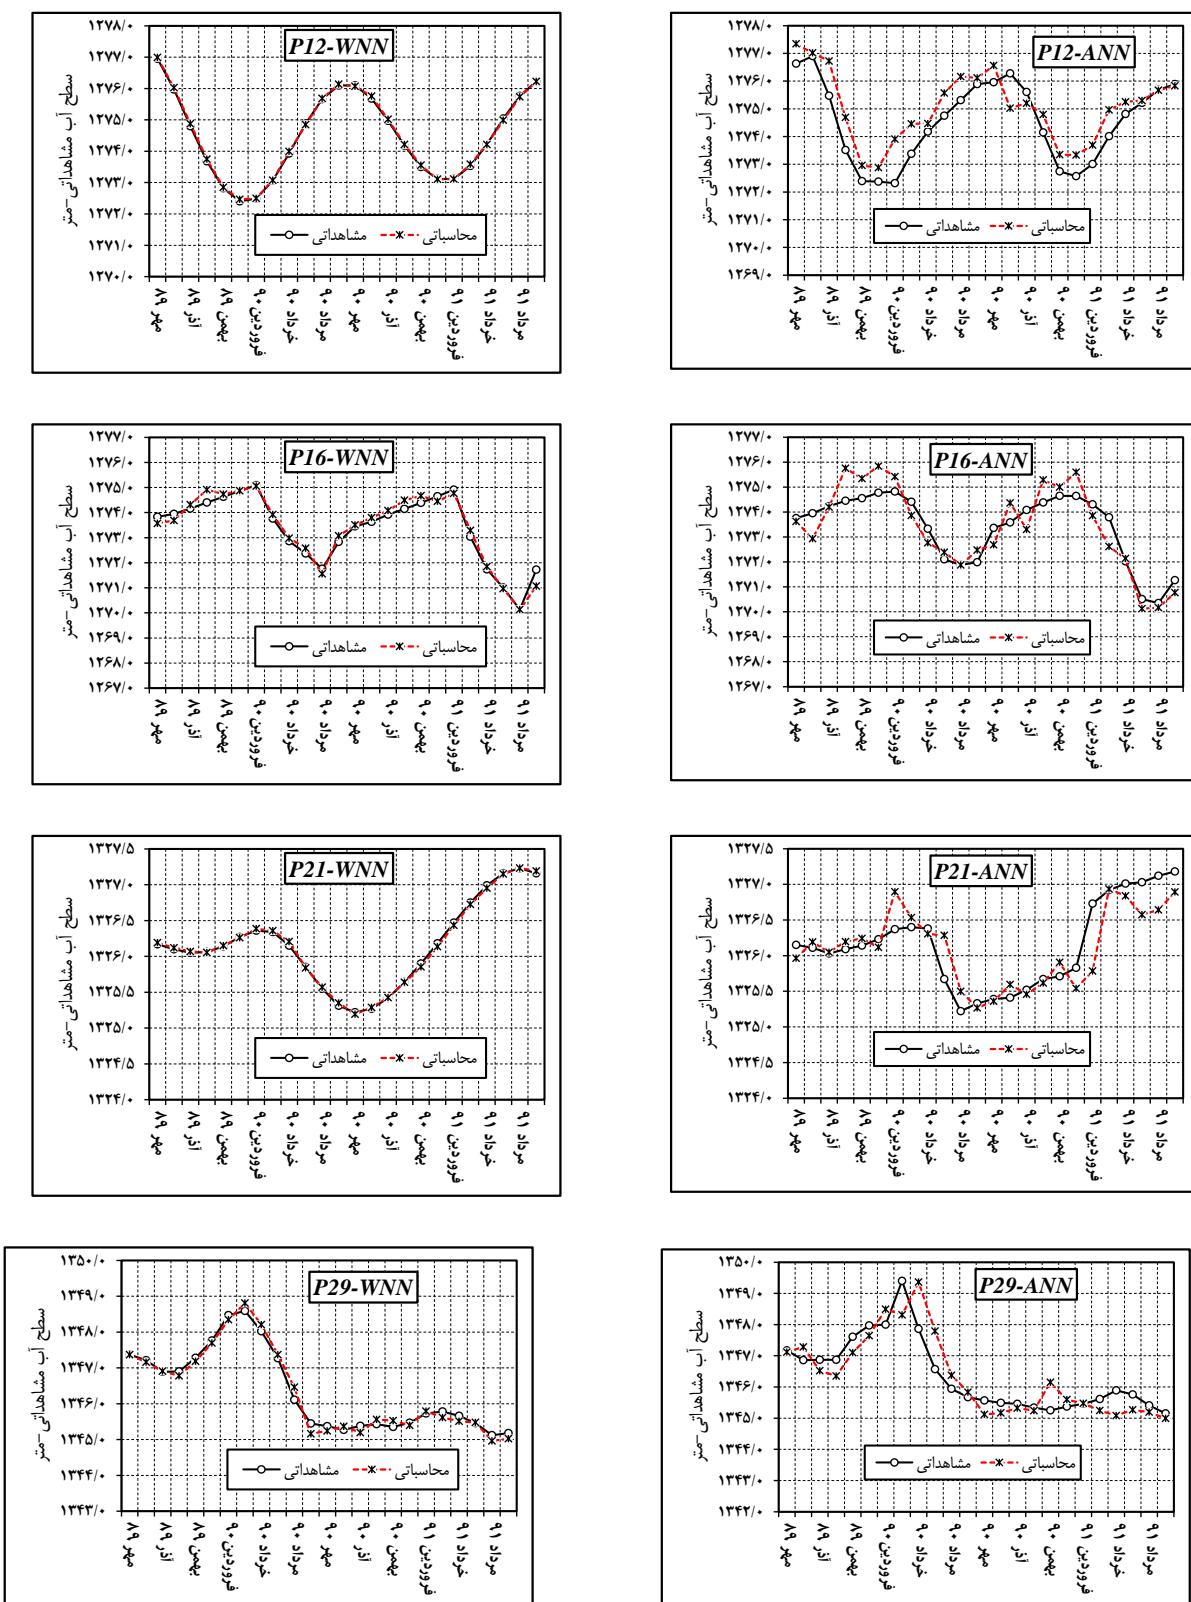
آماره	شبکه	اختلاف (Cm)	P2	P10	P12	P16	P21	P29	متوسط
ANN			۰/۵۶	۰/۵۶	۰/۳۲	۰/۶۹	۰/۷۷	۰/۷۷	۰/۵۵
RMSE(m)	WNN		۰/۱۲	۰/۰۹	۰/۰۴	۰/۲۴	۰/۰۳	۰/۱۵	۰/۱۱
(%)		اختلاف (%)	۲۶	۴۶	۷۳	۴۴	۲۹	۴۵	۴۴
ANN			۰/۷۳۵	۰/۸۸۵	۰/۸۴۱	۰/۸۴۷	۰/۷۱۶	۰/۷۷۰	۰/۷۹۹
R^2	WNN		۰/۹۳۱	۰/۹۹۶	۰/۹۹۹	۰/۹۷۱	۰/۹۹۸	۰/۹۸۴	۰/۹۸۰
(%)	اختلاف (%)		۲۰	۱۱	۱۶	۱۲	۲۸	۲۱	۲۱
ANN			۱/۸۰	۱/۰۷	۱/۰۶	۰/۷۴	۰/۹۸	۰/۷۹	۱/۰۷
a	WNN		۱/۰۲	۰/۹۷	۰/۹۰	۰/۹۴	۱/۰۰	۰/۹۵	۰/۹۸
(%)	اختلاف (%)		۷۶	۱۱	۱	۲۱	۲	۱۷	۹

فاصله کاهش یافت. همان طور که در جدول ۵ نیز ملاحظه می‌شود در ۳ چاه مشاهده‌ای P10، P12 و P21 R^2 روشن WNN از ۹۹ درصد بیشتر بود هم چنین مقادیر WNN نزدیک صفر بود که این حالت بیان‌گر دقت بالای روش در پیش‌بینی مقادیر سطح آب زیرزمینی بود. این مسئله در شکل ۸ از انطباق کامل داده‌های واقعی و پیش‌بینی شده کاملاً نمایان است.

نتایج پژوهش حاضر با نتایج تحقیق صورت گرفته توسط نخعی و صابری نصر (۲۰۱۲)، رضوی قهفرخی و همکاران (۱۳۹۲) و رجایی و ابراهیمی (۱۳۹۳) هم‌خوانی داشت. ایشان نیز در تحقیق خود از تلفیق شبکه‌های عصبی مصنوعی و موجک، برای پیش‌بینی سطح آب زیرزمینی استفاده کردند و به این نتیجه رسیدند مدل ترکیبی موجک-عصبی نتایج دقیق‌تری نسبت به مدل شبکه‌های عصبی مصنوعی و سایر مدل‌های عددی داشت.

تغییرات ماهانه سطح آب زیرزمینی اندازه‌گیری شده و پیش‌بینی شده در مرحله آزمون شبکه‌های ANN و WNN در چاه‌های مشاهده‌ای نماینده هر زیرخوشه در شکل ۸ نشان داده شده است. با توجه به شکل ۸، نتیجه می‌شود که در هر ۶ چاه نماینده، روند تغییرات ماهانه مقادیر سطح آب زیرزمینی پیش‌بینی شده با ANN و WNN همانند روند تغییرات مقادیر واقعی بود فقط در برخی از ماه‌ها، مقادیر پیش‌بینی شده با ANN در مقایسه با مقادیر پیش‌بینی شده با WNN اختلاف بیش‌تری نسبت به مقادیر واقعی داشت که نشان دهنده تأثیر نویززدایی از داده‌های ورودی بر کاهش اختلاف بین مقادیر واقعی و پیش‌بینی شده می‌باشد. دلیل اختلاف بین مقادیر واقعی و پیش‌بینی شده با ANN در مقایسه با WNN در جدول ۵، به وضوح در شکل ۸ قابل مشاهده می‌باشد. به عنوان نمونه، با توجه به شکل ۸ در چاه P2 مقادیر سطح آب زیرزمینی پیش‌بینی شده با ANN در ۴ ماه آخر دوره پیش‌بینی از مقادیر واقعی فاصله داشت که پس از نویززدایی از داده‌های ورودی این





شکل ۸- تغییرات سطح آب زیرزمینی مشاهده شده نسبت به پیش‌بینی شده با ANN و WNN در چاههای مشاهده‌ای نماینده.

نتیجه‌گیری

بروجردی، آ.، فریدونی، م.، ۱۳۹۶. شبیه‌سازی تراز آب زیرزمینی با استفاده از مدل‌های بردار پشتیبان و مقایسه آن با مدل‌های عصبی فازی و موجک عصبی (مطالعه موردنی دشت شیراز). کنفرانس و نمایشگاه مهندسی آب، ۲۵-۲۶ مهرماه، مرکز هماشگاه‌های بین‌المللی شهید بهشتی، تهران.

پورمحمدی، س.، ملکی‌نژاد، ح.، پورشرعياتی، ر.، ۱۳۹۲. مقایسه کارایی روش‌های شبکه عصبی و سری‌های زمانی در پیش‌بینی سطح آب زیرزمینی (مطالعه موردنی: زیرحوضه بختگان استان فارس). حفاظت آب و خاک، شماره ۲۰، جلد ۴، ۲۵۱-۲۶۲.

پیری، ح.، عباسزاده، م.، راهداری، و.، ملکی‌فیض، س.، ۱۳۹۲. ارزیابی تطبیقی نمایه خشکسالی هواشناسی با استفاده از روش تحلیل خوشه‌ای (مطالعه موردنی استان سیستان و بلوچستان). مهندسی منابع آب، دوره ۱۷، شماره ۱۷، ۲۵-۳۶.

حبیبی، م.ح.، ندیری، ع.، اصغری مقدم، ا.، ارائه مدل ترکیبی ژنتیک-کریجینگ برای پیش‌بینی زمانی و مکانی سطح آب زیرزمینی. تحقیقات منابع آب ایران، دوره ۱۱، شماره ۳، ۹۹-۱۰۵.

حبیبی، م.ح.، ندیری، ع.، اصغری مقدم، ا.، نادری، ک.، ۱۳۹۵. ترکیب روش‌های هوش مصنوعی و زمین آمار برای پیش‌بینی زمانی و مکانی سطح آب زیرزمینی دشت هادی شهر. علوم و مهندسی آبخیزداری ایران، دوره ۱۰، شماره ۳۲، ۲۷-۳۲.

حسن‌زاده، ی.، عبدالکردانی، ا.، فاخری‌فرد، ا.، ۱۳۹۱. پیش‌بینی خشکسالی با استفاده از الگوریتم ژنتیک و مدل ترکیبی شبکه عصبی-موجکی. مجله آب و فاضلاب، دوره ۲۳، شماره ۳، ۲۹-۴۱.

خاشعی سیوکی، ع.، قهرمان، ب.، کوچک‌زاده، م.، ۱۳۹۲. مقایسه مدل‌های شبکه عصبی مصنوعی، ANFIS و رگرسیونی در برآورد سطح ایستایی آبخوان دشت نیشابور. نشریه آبیاری و زهکشی ایران، دوره ۷، شماره ۱، ۱۰-۲۲.

رجایی، ط.، ابراهیمی، م.، ۱۳۹۳. مدل‌سازی نوسان‌های ماهانه آب زیرزمینی به وسیله تبدیل موجک و شبکه

به منظور بررسی تأثیر استفاده از شبکه‌های موجک-عصبی و عصبی بر پیش‌بینی سطح آب زیرزمینی، پژوهش حاضر بر روی آبخوان دشت مراغه-بناب اجرا شد. به دلیل تعداد زیاد چاههای مشاهده‌ای نصب شده در دشت، با انجام خوشه‌بندی، کلیه چاههای مشاهده‌ای با روش سلسله مراتبی-WARD در ۶ زیرخوشه، خوشه‌بندی شد. سپس یک چاه به عنوان نماینده هر زیرخوشه انتخاب شد. با نویززدایی از داده‌های ورودی با کمک روش موجک، مقادیر سطح آب زیرزمینی با کمک شبکه‌های عصبی مصنوعی پیش‌بینی شد. نتایج نشان داد در نظر گرفتن دمای متوسط هوا باعث اختشاش شبکه‌های عصبی مصنوعی و شبکه‌های موجک-عصبی می‌شود. هم چنین بر اساس نتایج با در نظر گرفتن تأخیر زمانی متوالی ۳ تا ۱۲ ماه در داده‌های ورودی، اختلاف مقادیر پیش‌بینی شده و واقعی کاهش یافت. نتایج مقایسه آماری مقادیر سطح آب زیرزمینی پیش‌بینی شده با ANN و WNN نشان داد مقادیر پیش‌بینی شده با ANN در مقادیرهای مختلف کمتری با مقادیر واقعی داشت. با توجه به نتایج پژوهش حاضر در حالت کلی می‌توان چنین نتیجه گرفت که نویززدایی از داده‌های ورودی باعث افزایش کارایی تکنیک مورد استفاده جهت پیش‌بینی سطح آب زیرزمینی گردد که این حالت را می‌توان برای روش‌های هوش مصنوعی دیگر نیز مورد بررسی قرار داد.

منابع و مراجع

اصغری مقدم، ا.، نورانی، و.، ندیری، ع.، ۱۳۸۸. پیش‌بینی زمانی و مکانی سطح آب زیرزمینی محدوده متروی شهر تبریز توسط روش کریجینگ عصبی. تحقیقات منابع آب ایران، دوره ۵، شماره ۱، ۱۴-۲۴.

امیری ده‌احمدی، ف.، حسامی کرمانی، م.ر.، ۱۳۹۱. از بررسی پیش‌بینی نوسانات آب زیرزمینی با استفاده هوش مصنوعی. هماشگاه ملی مهندسی آب و فاضلاب، ۱-۹ اسفند، دانشگاه تحصیلات تکمیلی صنعتی و فناوری پیشرفت، دانشگاه شهید باهنر کرمان. ایزدی، ع.، داوری، ک.، علیزاده، ا.، قهرمان، ب.، ۱۳۸۷. کاربرد مدل داده‌های ترکیبی در پیش‌بینی سطح آب زیرزمینی. آبیاری و زهکشی ایران، دوره ۲، شماره ۱۳۳-۱۴۴.

تحقیقات منابع آب ایران، دوره ۶، شماره ۲، ۲۷-۳۵.

کیانی سلمی، ص، نظیفی، م. ۱۳۹۴. کاربرد مدل شبکه عصبی در برآورد میزان برداشت از آب‌های زیرزمینی (نمونه موردی: شرق جلگه اصفهان). مهندسی اکوسیستم بیابان، شماره ۴، جلد ۷، ۹۹-۱۰۹.

مبارکی، م، فریدونی، م. ۱۳۹۴. شبیه‌سازی تراز آب زیرزمینی با استفاده از ترکیب مدل‌های موجک، فازی عصبی و مقایسه آن با مدل فازی عصبی (مطالعه موردی: دشت نی‌ریز). کنفرانس بین‌المللی عمران، معماری و زیرساخت‌های شهری، ۷-۸.

محتشم، م، دهقانی، ا.ا، اکبرپور، ا. مفتاح هلقی، م، اعتباری، ب. ۱۳۹۴. پیش‌بینی سطح ایستابی با استفاده از شبکه عصبی، (مطالعه موری: دشت بیرجند). آبیاری و زهکشی ایران، دوره ۱، شماره ۴، ۱۰-۱.

نکوآمال کرمانی، م، کشکولی، ح، رهنما، م. ۱۳۸۶. کاربرد نرم‌افزار MODFLOW در مطالعه نوسانات سطح آب زیرزمینی دشت بوچیر-همیران. نهمین سمینار سراسری آبیاری و کاهش تبخیر، ۱۶-۱۸.

بیهمن، دانشگاه شهید باهنر کرمان. نوری، م، میرحسینی، س.م، زینالزاده، ک. رهنما، م.ح. ۱۳۸۶. الگوی جدید بارش-رواناب حوضه‌ی آبریز هلیل‌رود با استفاده از مدل هیبرید شبکه عصبی موجکی. زمین‌شناسی مهندسی، دوره ۲، شماره ۲، ۴۵۱-۴۷۲.

نیک‌منش، م.ر، رخشنده‌رو، غ.ر. ۱۳۸۹. ارزیابی توانایی شبکه‌های مختلف عصبی مصنوعی در پیش‌بینی تراز آب زیرزمینی در آبخوان محدوده سعادت شهر فارس. تحقیقات منابع آب ایران، دوره ۷، شماره ۱، ۸۶-۸۲.

Adamowski, J., Fung Chan, H. 2011. A wavelet neural network conjunction model for groundwater level forecasting. Journal of Hydrology, 407, 28–40.

Chitsazan, M., Rahmani, Gh., Neyamadpour, A. 2015. Forecasting groundwater level by artificial neural networks as an alternative approach to groundwater modeling. Journal of Geological Society of India, 85, 98-106.

عصبی پویا. مدیریت آب و آبیاری، شماره ۴، جلد ۱، ۷۳-۷۷.

رحیمی، ا.، ملکی‌نژاد، ح. ۱۳۹۲. بررسی و مقایسه مدل شبکه عصبی و شبکه عصبی-موجکی در پیش‌بینی نوسانات سطح آب زیرزمینی (مطالعه موردی: دشت نمدان استان فارس). پنجمین کنفرانس مدیریت منابع آب ایران، ۳۰-۳۱ بهمن، دانشگاه شهید بهشتی، تهران.

رضوی قهفرخی، س.ب، کریمی گوغری، ش. و رهنما، م. ۱۳۹۲. مدل‌سازی سطح آب زیرزمینی دشت شهرکرد به وسیله‌ی شبکه‌های عصبی مصنوعی و آنالیز موجک. دومین کنفرانس بین‌المللی گیاه، آب، خاک و هوا، ۱۸-۱۹ اردیبهشت، مرکز بین‌المللی علوم و تکنولوژی پیشرفت‌ه و علوم محیطی کرمان.

زارع ابیانه، ح، بیات ورکشی، م، معروفی، ص، ایلدرومی، ع. ۱۳۹۰. شبیه‌سازی دشت ملایر بر اساس داده‌های هواشناسی با استفاده از شبکه‌های عصبی مصنوعی. مجله پژوهش‌های جغرافیای طبیعی، دوره ۴۳، شماره ۷۱، ۱۷-۲۸.

ستاری، ن. ۱۳۹۱. پنهان‌بندی مناطق همگن تبخیر و تعرق با روش‌های WARD، PCA و GIS (مطالعه موردی استان‌های آذربایجان شرقی، غربی و اردبیل). پایان‌نامه کارشناسی ارشد آبیاری و زهکشی، دانشگاه زنجان.

سلطانی محمدی، س، لک، م، محمدی، س، کربلا، م.ا. ۱۳۹۳. تخمین ارتفاع سطح ایستابی در روزهای مختلف سال با استفاده از شبکه عصبی مصنوعی شعاعی؛ مطالعه موردی: دشت بهبهان. محاسبات نرم، شماره ۵، جلد ۲، ۱۲-۹۳.

فقیه، م. ۱۳۸۹. ارزیابی کاربرد شبکه عصبی مصنوعی و بهینه‌سازی آن با روش الگوریتم ژنتیک در تخمین داده‌های بارش ماهانه (مطالعه موردی: منطقه کردستان). علوم و فنون کشاورزی و منابع طبیعی، علوم آب و خاک، دوره ۱۴، شماره ۵۱، ۲۷-۴۲.

قیامی باجگیرانی، ع، شریفی، م.ب، فغفور مغربی، م، عارفی جمال، ع.ا. ۱۳۸۹. استفاده از تبدیلات فوریه و موجک برای استخراج هیدرولوگراف واحد لحظه‌ای.

- basin by using artificial neural network.* *International Journal of Water Resources and Environmental Engineering* 2(4), 95-102.
- Sreekanth, P.D., Geethanjali, N., Sreedevi P.D., Shakeel, A., Ravi Kumar, N. and Kamala Jayanthi, P.D. 2009. Forecasting groundwater level using artificial neural networks. Current Science, 96(7), 933-939.*
- Sun, Y., Wendi, D., Kim, D.E., Liong, S.Y. 2015. Application of artificial neural networks in groundwater table forecasting—a case study in Singapore swamp forest. Hydrology and Earth System Science, 12, 9317–9336.*
- Suryanarayana, Ch., Sudheer, Ch. Mahammad, V., Panigrahi, B.K. 2014. An integrated wavelet-support vector machine for groundwater level prediction in Visakhapatnam, India. Neurocomputing 145, 324–335.*
- Taormina, R., Chau K., Sethi, R., 2012. Artificial neural network simulation of hourly groundwater levels in a coastal aquifer system of the Venice lagoon. Engineering Applications of Artificial Intelligence, 25(8), 1670–1676.*
- Wang, W., Ding J. 2003. Wavelet Network Model and Its Application to the Prediction of Hydrology. Nature and Science, 1(1), 67-71.*
- Hamed, Y., Elkiki, M., Al Gahtani, O.S. 2015. Prediction of future groundwater level using artificial neural networks, Southern Riyadh, KSA (Case Study). International Water Technology Journal, 5(2), 149-162.*
- Lohani, A.K., Krishan, G. 2015. Application of artificial neural network for groundwater level simulation in Amritsar and Gurdaspur Districts of Punjab, India. Journal of Earth Science and Climatic Change, 6(4), 1-5.*
- Nakhaei, M., Saberi Nasr, A. 2012. A combined Wavelet-Artificial Neural Network model and its application to the prediction of groundwater level fluctuations. Geopersia, 2(2), 77-91.*
- Nayak, P., Satyaji Rao, Y.R., Sudheer, K.P. 2006. Groundwater level forecasting in a shallow aquifer using artificial neural network approach. Water Resources Management, 2(1), 77-99.*
- Nourani, V., Alami, M.T., Daneshvar Vousoughi, F. 2015. Wavelet-entropy data pre-processing approach for ANN-based groundwater level modeling. Journal of Hydrology, 524, 255–269.*
- Nourani, V., Mousavi, Sh. 2016. Spatiotemporal groundwater level modeling using hybrid artificial intelligence-meshless method. Journal of Hydrology 536, 10–25.*
- Sethi R.R., Kumar A., Sharma S.P., Verma, H.C. 2010. Prediction of water table depth in a hard rock*