



Using SOM and Wavelet Transform pre-processing methods in groundwater level prediction (Case Study: AzarShahr plain)

Farnaz Daneshvar Vousoughi^{*1}, Ali Karimi²

Abstract

Prediction of groundwater level play an important role in the groundwater source management. Groundwater plays most important role in providing required water for agricultural, urban and industrial uses, especially in semi-arid regions. The Present study focused on predicting groundwater level in the AzarShahr plain using pre-processing tools in two scenarios. Clustering tool was used by means of Self-Organized Maps (SOM) for conducting spatial pre-processing and wavelet transform (WT) for time pre-processing and also artificial neural system for modeling. SOM based clustering technique was used to identify spatially homogeneous clusters of groundwater data to use in artificial neural network to model groundwater resources. The WT was also used to extract dynamic and multi-scale features of the non-stationary GWL, runoff and rainfall time series. Results showed that using the WT and combining it with artificial neural system in groundwater level modeling of AzarShahr plain led to 11.6 percent improvement in the modeling accuracy, in verification stage the in the first scenario and 23.5 percent improvement in the second scenario. It can be concluded that using new modeling methods such as applying time and spatial pre-processing tools leads to significant increase in the modeling accuracy.

Keywords: Pre-processing, Wavelet Transform, Groundwater Level, AzarShahr Plain, Artificial Neural Network.

Received: 2016/11/07
Accepted: 2017/08/12

استفاده از روش‌های پیش‌پردازش SOM و تبدیل موجک در پیش‌بینی تراز آب زیرزمینی (مطالعه موردی: دشت آذرشهر)

فرناز دانشور وثوقی^{۱*}، علی کریمی^۲

چکیده

پیش‌بینی سطح آب زیرزمینی یک حوضه نقش مهمی را در مدیریت منابع آبی ایفا می‌کند. به‌خصوص در مناطق نیمه‌خشک آب‌های زیرزمینی نقش بسیار مهمی در تعیین آب مورد نیاز، کشاورزی، شهری و امور صنعتی دارد. مطالعه حاضر در دو سناریو به پیش‌بینی تراز آب زیرزمینی در دشت آذرشهر با استفاده از ابزارهای پیش‌پردازش پرداخته است. برای انجام پیش‌پردازش مکانی از ابزار خوشه‌بندی به‌وسیله نقشه‌های خودسازمان‌ده (SOM)، برای پیش‌پردازش زمانی از تبدیل موجک و برای مدل‌سازی از شبکه عصبی مصنوعی استفاده شده است. نقشه‌های خود سازمان‌ده برای تعیین مناطقی همگن از نظر داده‌های آب زیرزمینی جهت استفاده در مدل شبکه عصبی برای مدل‌سازی منابع آب زیرزمینی استفاده شد. تبدیل موجک برای استخراج ویژگی‌های زمانی و نا ایستایی سری‌های زمانی تراز آب زیرزمینی بکار رفت. نتایج نشان داد که استفاده از تبدیل موجک و ترکیب آن با شبکه عصبی مصنوعی در مدل‌سازی تراز آب زیرزمینی دشت آذرشهر باعث بهبودی ۱۱/۶ درصدی در دقت مدل‌سازی، در گام‌های صحت‌سنجی در سناریو اول و بهبودی ۲۳/۵ درصدی در سناریو دوم شد. می‌توان نتیجه گرفت استفاده از روش‌های نوین مدل‌سازی مانند استفاده از ابزارهای پیش‌پردازش زمانی و مکانی باعث افزایش قابل توجه دقت مدل‌سازی می‌گردد.

واژه‌های کلیدی: پیش‌پردازش، تبدیل موجک، تراز آب زیرزمینی، دشت آذرشهر، شبکه عصبی مصنوعی.

تاریخ دریافت مقاله: ۱۳۹۵/۰۸/۱۷

تاریخ پذیرش مقاله: ۱۳۹۶/۰۵/۲۱

1- Department of Civil Engineering, Ardabil Branch, Islamic Azad University, Ardabil, Iran

2- Department of Civil Engineering, Ahar Branch, Islamic Azad University, Ahar, Iran

*- Corresponding Author Email: fdaneshvar.vousoughi@gmail.com

۱- گروه مهندسی عمران، واحد اردبیل، دانشگاه آزاد اسلامی، اردبیل، ایران.

۲- گروه مهندسی عمران، واحد اهر، دانشگاه آزاد اسلامی، اهر، ایران.

*- نویسنده مسئول

مقدمه

در سال‌های اخیر روش‌های هوش مصنوعی (AI^1) توانایی قابل ملاحظه‌ای در مدل‌سازی و پیش‌بینی سری‌های زمانی هیدرولوژیکی از خود نشان داده‌اند. این روش‌ها چون مبتنی بر داده هستند، به دانش اولیه نسبت به پدیده‌ی مورد مطالعه نیاز ندارند. قدرت شبکه عصبی مصنوعی (ANN)، ناشی از توانایی آن در ارائه یک مدل غیرخطی برای سری زمانی چند متغیره است. در حال حاضر، شبکه عصبی به‌عنوان یک تقریب گر خودیادگیر و خود انطباق دهنده، توانایی زیادی در مدل‌سازی و پیش‌بینی سری‌های زمانی هیدرولوژیکی غیرخطی از خود نشان داده است. یک شبکه عصبی آموزش‌دیده² دیده می‌تواند به‌عنوان یک مقوله اطلاعاتی که برای تجزیه تحلیل به آن داده شده به حساب آید. از این متخصص می‌توان برای برآورد وضعیت‌های دلخواه جدید و جواب سؤال‌های "چه می‌شد اگر" استفاده کرد (نورانی و همکاران، 2013). مقالات موفق متعددی از کاربرد شبکه عصبی مصنوعی، در مدل‌سازی فرآیندهای هیدرولوژیکی ارائه شده است به‌عنوان مثال: در مورد پیش‌بینی تراز آب زیرزمینی مطالعاتی توسط پژوهشگران زیر صورت گرفته:

ابراهام و همکاران (2012) یک مرور جامع بر روی کاربرد ANN در مدل‌سازی‌های هیدرولوژی کردند. کومیتته (2000) ضمن بررسی نقش شبکه‌های عصبی مصنوعی در شاخه‌های مختلف هیدرولوژی، شبکه عصبی مصنوعی را ابزاری قدرتمند برای مدل‌سازی بسیاری از فرآیندهای غیرخطی هیدرولوژی بخصوص آب زیرزمینی معرفی می‌کند. نایاک و همکاران (2009) برای پیش‌بینی نوسانات سطح آب زیرزمینی آبخوان، از شبکه عصبی مصنوعی استفاده کردند. نتایج کارایی مدل ANN را در پیش‌بینی سطح آب زیرزمینی برای چهار ماه آینده نشان داد. چن و همکاران (2011) بیان‌داشته در مناطق خشک و نیمه‌خشک، فعالیت‌های انسانی مانند کشاورزی و صنعت اغلب نیاز زیادی به استخراج آب زیرزمینی دارد، تحت این شرایط در این مناطق به سیاست‌های مدیریت آب برای جلوگیری از هدر رفت آب نیاز می‌باشد. شناسایی چنین سیاست‌هایی نیازمند

شبیه‌سازی دقیق از سطح آب زیرزمینی می‌باشد. چن و همکاران برای پیش‌بینی سطح آب زیرزمینی از روش ANN استفاده کردند که نشان دادند این روش از دقت خوبی برخوردار است. ملکی‌نژاد و پورشریعیاتی (1392) مدل آریمای³ و شبکه عصبی مصنوعی را برای پیش‌بینی تراز آب زیرزمینی دشت مرودشت بکار بردند. با توجه نتایج به دست آمده تابع لونبرگ مارکوارت⁴ شبکه عصبی به‌عنوان بهترین تابع آموزشی برای پیش‌بینی سطح تراز آب زیرزمینی انتخاب گردید.

با توجه به ماهیت داده‌های روش‌های محاسباتی، داده‌های مورد استفاده می‌تواند تأثیر بسزایی بر نتایج نهایی مدل‌سازی داشته باشد. لذا به‌منظور کمک به بهبود کیفیت داده‌ها و در نتیجه بهره‌وری و سهولت انجام مدل‌سازی توسط فرایند داده-کاوی لازم است قبل از هر اقدامی پیش‌پردازش مناسب بروی داده‌ها صورت گیرد. پیش‌پردازش و آماده‌سازی داده‌ها شامل تمیز کردن، نرمال و استانداردسازی، تبدیل و فیلتر، استخراج ویژگی‌های مهم، انتخاب، خوشه‌بندی و غیره بوده و به‌عنوان اولین و مهم‌ترین گام در مدل‌سازی‌های مبتنی بر داده، مقدار قابل توجهی از زمان پردازش را در بر می‌گیرد. نتیجه و عملکرد پیش‌پردازش داده‌های هیدرولوژیکی، آماده‌سازی و تبدیل مجموعه داده‌های اولیه می‌باشد که در گام بعدی به‌عنوان ورودی به مدل‌های اصلی وارد می‌شوند. (نورانی و همکاران، 2015). خوشه‌بندی یکی از بهترین روش‌هایی است که برای کار با حجم زیاد داده‌ها ارائه شده است. قابلیت آن در ورود به فضای داده و تشخیص ساختار آن‌ها، خوشه‌بندی را یکی از ایده‌آل‌ترین مکانیزم‌ها برای کار با دنیای عظیم داده‌ها کرده است. روش خوشه‌بندی نقشه‌های خود سازماندهی ابزاری برای پیش‌پردازش مکانی می‌باشد که باعث کاهش حجم داده‌های ورودی و افزایش دقت مدل و همچنین دسته‌بندی داده‌ها، ایستگاه‌ها و نواحی به گروه‌های همگن و بهینه‌سازی ساختار مدل با انتخاب داده‌های مؤثر و کارآمد می‌شود (نورانی و همکاران، 2015). جان و همکاران (2010) قرار دادن داده‌ها درون گروه‌های همسان را یکی از پایه‌ای‌ترین اشکال فرآیند درک و یادگیری توصیف می‌کند. ورن لیاو (2005) بیان داشت که خوشه‌بندی سری‌های زمانی جهت ارائه اطلاعات مفید در

³ Auto Regressive Integrated Moving Average

⁴ Levenberg-Marquardt (LM)

¹ Artificial Intelligence (AI)

² Trained ANN

داد مدل‌های BPN تک ایستگاهی و چند ایستگاهی، بسیار دقیق‌تر از مدل ARIMA بوده و مدل چند ایستگاهی SOM-BPN بسیار بهتر از مدل تک ایستگاهی پیش‌بینی کرد. نورانی و همکاران (2012) با استفاده از روش‌های خوشه‌بندی SOM و K-mean و مدل ANN به پیش‌بینی تراز آب زیرزمینی دشت اردبیل برای پیرومترهای مرکزی هر خوشه پرداخته و نشان دادند که این دو روش، نتایج مشابهی داشته و استفاده از آن‌ها دقت پیش‌بینی تراز را افزایش می‌دهد. هان و همکاران (2016) برای پیش‌پردازش مکانی و زمانی تراز آب زیرزمینی از تکنیک‌های خوشه‌بندی استفاده کردند. برای شناسایی مناطق همگن با روش SOM آن‌ها شش پیرومتر مرکزی را شناسایی کردند. در نهایت مدل AR⁶ را برای پیش‌بینی تراز آب زیرزمینی ماه آینده بکار بستند. نتایج دقت مفیدی را با ابزارهای مورد استفاده برای پیش‌بینی نشان داد. چانگ و همکاران (2016) مدل‌های هوش مصنوعی در ترکیب با SOM و شبکه NARX⁷ را برای پیش‌بینی تراز آب زیرزمینی حوضه رودخانه Zhuoshui تایوان بکار گرفتند. با توجه به معیارهای ارزیابی مدل، نتایج دقت قابل توجهی را نشان داد.

علاوه بر الگوهای مکانی، بعضی ویژگی‌های زمانی در سری‌های زمانی تراز آب زیرزمینی وجود دارند که سبب ناپایداری سری‌های زمانی می‌شوند. برای کنترل این ویژگی‌های زمانی، استفاده از داده‌های پیش‌پردازش شده از نظر زمانی در پیش‌بینی با شبکه عصبی سبب بهبود دقت مدل‌سازی می‌شوند. تبدیل موجک (WT) یک روش پیش‌پردازش زمانی مناسب برای استخراج ویژگی‌های داده‌ها از قبیل نوسانات کوتاه‌مدت و طولانی‌مدت با تجزیه سری‌های زمانی به زیرسری‌ها می‌باشد. موجک، از توابع ریاضی بوده که با ارائه مقیاس زمانی موجود در سری‌های زمانی و روابط آن‌ها، سری‌های زمانی ناپایستا را تحلیل می‌کند. مطالعات اولیه نشان داد آنالیز موجک یک ابزار بسیار مؤثرتری نسبت به تبدیل فوریه در تحلیل سری‌های زمانی ناپایستا می‌باشد (اداموسکی، 2007). اخیراً مدل ترکیبی شبکه عصبی- تبدیل موجک کاربردهای مختلفی در مدل‌سازی هیدرولوژیکی پیدا کرده است. در زمینه شبیه‌سازی متغیر تراز آب زیرزمینی با مدل ترکیبی شبکه عصبی و تبدیل موجک

حوضه‌های مختلف بسیار مفید می‌باشد. مقالات موفق متعددی از کاربرد SOM در مورد تراز آب زیرزمینی توسط پژوهشگران صورت گرفته است. در این مطالعات پژوهشگران از SOM به‌عنوان روشی برای خوشه‌بندی بدون نظارت برای برنامه‌های مختلفی هیدرولوژیکی استفاده کردند و به این نتیجه رسیدند SOM با باعث افزایش دقت مدل و همچنین دسته‌بندی داده‌ها، و بهینه‌سازی ساختار مدل با انتخاب داده‌های مؤثر و کارآمد می‌شود. نورانی و همکاران (2012) یک مدل ریاضی برای تخمین سطح آب زیرزمینی در دشت اردبیل با استفاده از روش ANN همراه SOM ارائه نمودند. چن و لین (2006) توانایی SOM را با دو روش خوشه‌بندی دیگر (روش‌های K-mean و Ward) مقایسه کرده و نتیجه گرفتند، SOM نواحی همگن را دقیق‌تر از دو روش دیگر شناسایی می‌کند. چی و همکاران (2004) با استفاده از روش خوشه‌بندی استاتیکی، ۵۵ ایستگاه اندازه‌گیری پارامترهای شیمیایی آب زیرزمینی را در سه گروه مطابق با مشخصات ژئوشیمیایی خوشه‌بندی کردند. نتایج نشان داد قرار گرفتن پیرومترها در خوشه‌ها متأثر از آلودگی‌های ایجاد شده در سطح زمین بود. داسارس و پیتیر (2006) با استفاده از روش SOM به تحلیل پارامترهای شیمیایی آب زیرزمینی و خوشه‌بندی آن پرداختند. ایشان ۳ منطقه را بعد از خوشه‌بندی تشخیص دادند. کنسه و همکاران (2006) خوشه‌بندی را با روش PCA در محیط GIS برای نمونه‌های آب زیرزمینی بکار بردند. در مطالعات اخیر از روش SOM برای تحلیل داده‌های چندبعدی استفاده شد. در زمینه مدل‌سازی تراز آب زیرزمینی نیز، چن و همکاران (2010) روش ترکیبی SOM و RBFN را برای پیش‌بینی تراز آب زیرزمینی جنوب تایوان برای دوره زمانی ۱۹۹۷ تا ۲۰۰۳ بکار گرفتند. نتایج نشان داد این روش به دلیل ساختاری ساده نسبت به سایر روش‌ها پیش‌بینی‌های منطقی انجام داده و استفاده از روش‌های خوشه‌بندی، کیفیت پیش‌بینی را بهبود بخشید. چن و همکاران (2011) با استفاده از روش ترکیبی BPN⁵ و SOM پیش‌بینی تراز آب زیرزمینی را انجام دادند. در این پژوهش، آن‌ها پنج مدل ARIMA، مدل تک ایستگاهی BPN، مدل تک ایستگاهی SOM-BPN، مدل چند ایستگاهی BPN و مدل چند ایستگاهی SOM-BPN را با همدیگر مقایسه کردند. نتایج نشان

⁶ Auto Regressive

⁷ Nonlinear Autoregressive with Exogenous Inputs

⁵ Back-Propagation Network

در این تحقیق، برای پیش‌بینی سطح آب زیرزمینی دشت آذرشهر از روش خوشه‌بندی SOM برای کاهش حجم داده‌های ورودی همچنین برای دسته‌بندی داده‌ها، ایستگاه‌ها و نواحی به گروه‌های همگن و بهینه‌سازی ساختار مدل با انتخاب داده‌های مؤثر و کارآمد، استفاده شده است و شبکه عصبی تخمین‌گر مورد استفاده برای مدل‌سازی از نوع شبکه عصبی پیشرو *FFNN* می‌باشد. مدل ترکیبی *WANN* به علت نیاز سری‌های زمانی تراز آب زیرزمینی به پیش‌پردازش و غلبه بر پدیده فصلی بودن سری زمانی و برای بهبود در نتایج استفاده شد. ترکیب مدل شبکه عصبی مصنوعی با تبدیل موجک یک ایده نو برای به‌وجود آمدن شبکه‌ای بهتر و مدلی دقیق‌تر می‌باشد. در انتها به مقایسه نتایج حاصل از دو روش *FFNN* و *WANN*، پرداخته و دقیق بودن نتیجه روش مشخص شده گزارش می‌گردد.

مواد و روش‌ها


منطقه مورد مطالعه

شهرستان آذرشهر در استان آذربایجان شرقی واقع در شمال غربی ایران، در ۳۷ درجه و ۴۶ دقیقه عرض شمالی و ۴۵ درجه و ۸۵ دقیقه طول شرقی با وسعت ۸۴۰ کیلومتر مربع در ۳۰ کیلومتری تبریز واقع شده است و ارتفاع آن از سطح دریا ۱۳۴۰ متر می‌باشد. این شهرستان از سمت شمال و شرق با شهرستان اسکو، از سمت غرب با دریاچه ارومیه و از سمت جنوب با شهرستان عجب‌شیر هم‌مرز است. میانگین میزان بارش سالانه آن به ۳۲۹ میلی‌متر می‌رسد. در این پژوهش، از داده‌های ماهانه تراز آب زیرزمینی ۲۰ پیژومتر که در شکل ۱ با حرف *P* نشان داده شده‌اند در دوره آماری ۹۱-۱۳۸۱ استفاده شد. حدود ۷۰ الی ۸۰ درصد از داده‌ها برای آموزش و ۲۰ الی ۳۰ درصد باقیمانده برای صحت‌سنجی مدل‌ها مورد استفاده قرار گرفت. همچنین این حوضه دارای یک ایستگاه رواناب در خروجی حوضه (که با حرف *R* نشان داده شده) و سه ایستگاه بارش (که با حرف *I* مشخص شده‌اند) می‌باشد (شکل ۱).

مطالعات چندی صورت گرفته است. وانگ و دینگ (2003) مدل ترکیبی موجک و شبکه عصبی را برای پیش‌بینی سری‌های زمانی هیدرولوژیکی رواناب روزانه و تراز آب زیرزمینی ماهانه به کار بردند. نتایج مقایسه مدل آشکار کرد که مدل پیشنهادی دارای دقت بالایی نسبت به شبکه عصبی بوده و مدت زمان بیشتری را می‌توان پیش‌بینی کرد. وانگ و زو (2011) مدل ترکیبی *WANN* را برای پیش‌بینی تراز آب زیرزمینی بکار بردند با این تفاوت که از روش (*GA*^۸) (الگوریتم ژنتیک) را برای تعیین اوزان و پارامترهای مدل *WANN* استفاده کردند. نتایج نشان داد مدل ترکیبی *WANN-GA* با کاهش خطای نسبی و مقدار *RMSE* و با افزایش دقت و پایداری، عملکرد بهتری را در پیش‌بینی آب زیرزمینی از خود نشان می‌دهد. نورانی و همکاران (2015) در مطالعه خود از یک نقشه خودسازمان‌ده مبتنی برای شناسایی فضای همگن سطح آب‌های زیرزمینی استفاده کردند و از روش مدل‌سازی از نوع شبکه عصبی پیشرو برای مدل‌سازی و از ترکیب موجک برای استخراج ویژگی‌های پویا استفاده نمودند. نتایج نشان داد شبکه عصبی پیشرو (*FFNN*^۹) همراه با روش خوشه‌بندی *SOM* باعث کاهش ابعاد متغیرهای ورودی و پیچیدگی‌ها شده و از سوی دیگر استفاده از (*WT*) باعث افزایش عملکرد مدل (*FFNN*) گشته است. رجایی و زینی‌وند (۱۳۹۳) در مطالعه خود به پیش‌بینی سطح آب زیرزمینی دشت شریف‌آباد پرداختند. هدف مطالعه ارزیابی عملکرد سه مدل در پیش‌بینی سطح آب زیرزمینی بود که نتایج نشان داد که مدل *WANN* تطابق بهتری با مقادیر مشاهده‌ای تراز آب زیرزمینی دارد. رجایی و ابراهیمی (۱۳۹۳) در مطالعه خود به توانایی موجک- شبکه عصبی در پیش‌بینی سطح تراز آب زیرزمینی برای یک ماه آینده پرداختند و به این نتیجه رسیدند که مدل موجک- شبکه عصبی از دقت بسیار خوبی در پیش‌بینی سطح آب زیرزمینی دارا می‌باشد.

^۸ Genetic Algorithm

^۹ Feed-forward neural network(FFNN)



شکل ۱- نقشه منطقه مورد مطالعه و موقعیت ایستگاه‌ها.

روش انجام کار

همچنین دسته‌بندی داده‌ها، ایستگاه‌ها و نواحی به گروه‌های همگن و بهینه‌سازی ساختار مدل با انتخاب داده‌های مؤثر و کارآمد می‌شود. عموماً شبکه SOM شامل دو لایه است، یک لایه ورودی و یک لایه کوهن. لایه ورودی کاملاً به لایه کوهن متصل است. هیچ‌کدام از المان‌های پردازشی (PE^10) در لایه کوهن به هم متصل نیستند. هر کدام از PE ها n ارزش وزنی دارند. برای هر کدام از المان‌ها مسافت محاسبه شده و PE با کمترین فاصله انتخاب می‌شود. آموزش با بهره‌گیری از یادگیری رقابتی می‌باشد. هنگامی که یک نمونه از داده‌ها برای آموزش به شبکه داده می‌شود، فاصله اقلیدسی آن از تمامی بردارهای وزنی محاسبه می‌شود (کوهن، 1998). نرون بردار وزنی که بیشترین شباهت را با نمونه ورودی دارد با نام (BMU^{11}) بهترین واحد تطبیق نامیده می‌شود. وزن‌های BMU و نرون‌های نزدیک به آن در شبکه SOM نسبت به بردار ورودی تنظیم می‌شوند. مقدار تغییر با گذشت زمان و با فاصله

در این تحقیق برای پیش‌بینی سطح تراز آب زیرزمینی دشت آذرشهر، داده‌های بارش و رواناب در زمان مناسب به همراه داده‌های تراز آب زیرزمینی در زمان حال (t) به‌عنوان ورودی استفاده شد و سطح تراز آب زیرزمینی ماه آینده به‌عنوان خروجی مدل در نظر گرفته شده است. به‌منظور پیش‌پردازش مکانی داده‌ها و همچنین شناسایی پیرومترهایی که دارای بیشترین همبستگی مکانی با یکدیگر هستند، فرآیند خوشه‌بندی با استفاده از روش SOM انجام می‌شود. سپس با استفاده از بیشترین ضریب سیلوهه پیرومتر مرکزی هر خوشه انتخاب می‌شود. در مرحله بعد مدل‌سازی از طریق شبکه عصبی مصنوعی صورت می‌پذیرد. سپس جهت افزایش دقت مدل‌سازی، پیش‌پردازش زمانی داده‌ها توسط تبدیل موجک انجام می‌گیرد.

روش دسته‌بندی SOM

روش SOM ابزاری برای پیش‌پردازش مکانی می‌باشد که باعث کاهش حجم داده‌های ورودی و افزایش دقت مدل و

¹⁰ Processing Elements

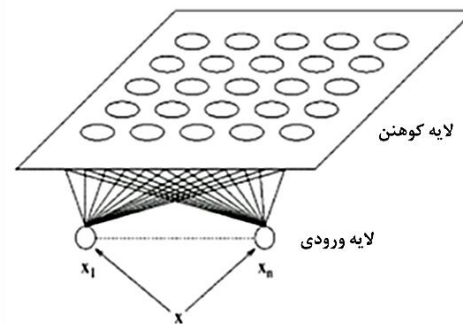
¹¹ Best Matching Unit

زمان را دارد. در آغاز زمانی که تابع همسایگی گسترده می‌شود، خود سازمان‌دهی در مقیاس کلی صورت می‌گیرد. وقتی که تابع همسایگی تا جایی منقبض می‌شود که محدود به یک جفت نرون شود، وزن‌ها به برآوردهای محلی همگرا می‌شوند. روش SOM روشی برای آنالیز، خوشه‌بندی و مدل‌سازی داده‌های ورودی گسترده و چند متغیره است که در بسیاری از فرایندهای مهندسی آب قابل استفاده می‌باشد (کوهنن، 1998). ساختار شبکه SOM با در شکل ۲ نشان داده می‌شود.

از BMU کاهش می‌یابد. فرمول بروز رسانی شده برای نرون با بردار وزن $W_v(t)$ به صورت زیر می‌باشد:

$$W(t+1) = W_v(t) + \phi(v,t) \alpha(t) (D(t) - W_v(t))$$

که در آن، $\alpha(t)$ ضریب کاهش یادگیری به‌طور یکنواخت است، $D(t)$ بردار ورودی و $\phi(v,t)$ تابع همسایگی است. به فاصله شبکه بین BMU و نرون v دارد. در ساده‌ترین حالت مقدار تابع همسایگی برای همه نرون‌های به اندازه کافی نزدیک به BMU یک است و برای سایر نرون‌ها صفر است (کوهنن، 1998). صرف‌نظر از فرم تابعی، تابع همسایگی توانایی انقباض با




شکل ۲- یک نوع SOM مرسوم شامل n داده در لایه ورودی و لایه کوهنن با ابعاد ۵ در ۵ (Hsu and Li, 2010).

یک تابع رفتار کند. یافته‌های سال‌های اخیر نشان داده‌اند که تبدیل موجک برای تحلیل و بدون نویز کردن داده‌ها روش مناسبی هستند.

موجک‌ها توابع ریاضی هستند که یک بیان زمان-مقیاس از سری‌های زمانی و نسبت‌های آن ارائه می‌دهند که این بیان برای تحلیل سری‌های زمانی غیر ایستا مفید است. مزیت تبدیل موجک، توانایی در به دست آوردن اطلاعاتی زمانی، مکانی و فرکانسی یک سیگنال است (شکل ۳) (نورانی و همکاران، 2009).

تبدیل موجک

بعد از مرحله پیش‌پردازش مکانی، پیش‌پردازش زمانی برای پیژومترهای مرکزی حاصل از مرحله خوشه‌بندی با استفاده از تبدیل موجک انجام می‌گیرد. طبق تعریف، موجک یک موج کوچک است که انرژی آن در ناحیه کوچکی متمرکز شده و ابزار مناسبی برای بررسی پدیده‌های گذرا است. موجک، دارای نوسان حداقل بوده که به سمت صفر نزول می‌کند و این نزول بایستی در جهات مثبت و منفی واقع در دامنه‌اش محدود شود. این مشخصه باعث می‌شود که موجک انعطاف‌پذیر بوده و مانند



شکل ۳- تبدیل موجک.

صیحیحی هستند که ترتیب میزان مقیاس و انتقال موجک را کنترل می‌نماید. همچنین a_0 گام مقیاس کوچک ویژه برای پارامتر انتقال ($a_0 > 1$) و b_0 پارامتر انتقال موقعیت ($b_0 > 0$) می‌باشند (نورانی و همکاران، 2009).

$$g_{m,n}(t) = \frac{1}{\sqrt{a_0^m}} g\left(\frac{t - nb_0 a_0^m}{a_0^m}\right) \quad [5]$$

برای تعیین سطح تجزیه از فرمول زیر استفاده شده است:

$$L = \log N$$

L بیان گر طول داده‌ها و N بیانگر تعداد سطوح تجزیه می‌باشد (نورانی و همکاران، 2009).

شبکه عصبی FFNN

شبکه عصبی استفاده شده در مدل ANN به‌منظور پیش‌بینی سطح تراز آب زیرزمینی پیرومترهای مرکزی، شبکه عصبی پیشرو FFNN می‌باشد. شکل بهینه شبکه‌های عصبی به صورت آزمون و خطا به دست می‌آید. هدف از این آزمون و خطا، یافتن تعداد نرون‌های لایه پنهان و تعداد تکرار الگوریتم می‌باشد تا به واسطه آن‌ها مدل تعریف گردد. این روند با استفاده از جعبه ابزار نرم‌افزار متلب یا از طریق کدنویسی‌های مربوطه انجام می‌پذیرد. یک شبکه عصبی مصنوعی ایده‌ای است برای پردازش اطلاعات که از سیستم عصبی زیستی الهام گرفته شده و مانند مغز به پردازش اطلاعات می‌پردازد و برای حل یک مسئله باهم هماهنگ عمل می‌کند. یک ANN برای انجام وظیفه‌های مشخص، مانند شناسایی الگوها و دسته‌بندی اطلاعات، در طول یک پروسه یادگیری، تنظیم می‌شود. در سیستم‌های زیستی یادگیری با تنظیماتی در اتصالات سیناپسی که بین اعصاب قرار دارد، همراه است. شبکه‌های عصبی، با قابلیت قابل توجه آن‌ها در استنتاج معانی از داده‌های پیچیده یا مبهم، می‌تواند برای استخراج الگوها و شناسایی روش‌هایی که آگاهی از آن‌ها برای انسان و دیگر تکنیک‌های کامپیوتری بسیار پیچیده و دشوار است به کار گرفته شود. یک شبکه عصبی تربیت یافته می‌تواند به‌عنوان یک متخصص در مقوله اطلاعاتی که برای تجزیه تحلیل به آن داده شده به حساب آید. شبکه عصبی تخمین گر مورد استفاده برای مدل‌سازی در تحقیق از نوع شبکه عصبی پیشرو می‌باشد. در حالت کلی این شبکه از سه لایه تشکیل می‌شود. لایه اول شامل همه

با استفاده از این تبدیل می‌توان سیگنال اصلی را به سیگنال‌های پایه سازنده‌اش تجزیه کرد. دو نوع تبدیل موجکی وجود دارد: ۱- تبدیل موجکی پیوسته (CWT)^{۱۲}، ۲- تبدیل موجک گسسته (DWT)^{۱۳}، تبدیل موجکی پیوسته با یکی از این روابط بیان می‌شود:

$$CWT(scale, position) = \int_{-\infty}^{+\infty} f(t) \psi(t)(scale, position) dt$$

[6] یا:

$$CWT_s^{\psi} = \frac{1}{\sqrt{S}} \int S(t) \psi_{s,\tau}^*(t) dt$$

رابطه فوق تابعی از دو متغیر s و τ است که τ نشان دهنده انتقال، s بیانگر مقیاس (عکس بسامد) و علامت * نشان دهنده مزدوج مختلط است. S و τ اعداد حقیقی هستند و s همیشه مثبت است که ممکن است مقادیر پیوسته یا گسسته به خود بگیرد. s و τ در تبدیل موجکی پیوسته دارای مقادیر پیوسته و در تبدیل گسسته دارای مقادیر گسسته هستند. $\psi(t)$ تابع موجک مادر است. عبارت مادر به این دلیل به کار رفته که توابع متفاوت به وجود آمده بر اساس پارامترهای مقیاس و انتقال، همگی از توابع پایه (موجک مادر) ناشی می‌شوند. کلیه توابعی که از تابع مادر ساخته می‌شوند، موجک‌های دختر نامیده می‌شوند که از رابطه ۴ به دست می‌آیند. ضریب مقیاس با یکی از حروف α یا s نشان داده می‌شود:

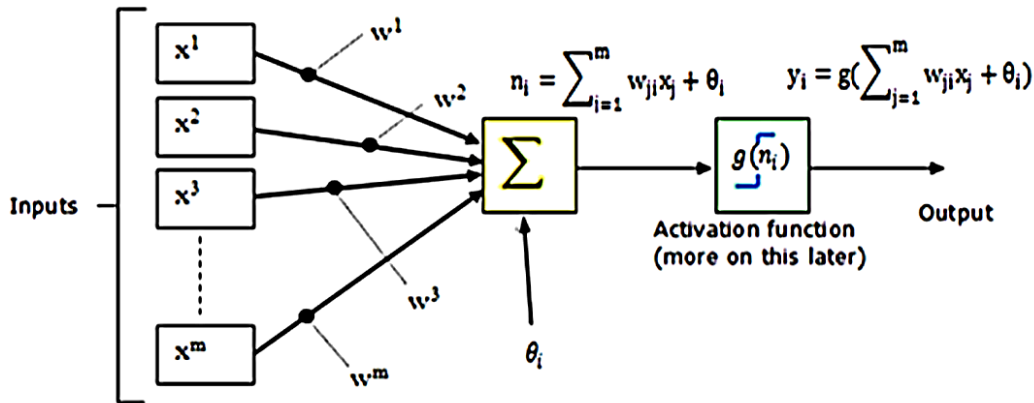
$$\psi_{s,\tau}(t) = \psi\left(\frac{t-\tau}{s}\right) \quad [4]$$

انتقال موجک به‌طور ساده به مفهوم به تأخیر انداختن یا جلو انداختن موجک و بیان‌کننده موقعیت موجک روی محور زمان است. تبدیل گسسته موجکی جهت پردازش و تحلیل سری‌های زمانی، بهتر از تبدیل پیوسته موجکی می‌باشد، زیرا داده‌های تبدیل یافته با DWT اجزای اضافی نداشته و بنابراین تبدیل معکوس را می‌توان برای هر دسته از داده‌های زمان بسامد به کار برد. تحلیل موجک یک روش بسیار جدید در زمینه‌های هیدرولوژی منابع آب است. موجک گسسته به صورت رابطه ۵ بیان می‌شود. در رابطه فوق m و n اعداد

¹² Continues Wavelet Transform

¹³ Discrete Wavelet Transform

متغیرهای ورودی، لایه آخر شامل متغیرهای خروجی و لایه میانی شامل تعدادی از گره‌های مصنوعی می‌باشد. گره‌های لایه‌های مجاور توسط بردارهای وزنی به هم مرتبط‌اند. شکل ۴



شکل ۴- شمای کلی شبکه عصبی مصنوعی با یک نرون (نورانی و همکاران، ۲۰۱۵).

در مرحله پیش‌بینی، دو معیار مختلف ضریب تبیین (R^2) و جذر میانگین مربعات خطا به منظور ارزیابی کارایی هر شبکه و توانایی آن برای پیشگویی دقیق‌تر استفاده شده است.

$$R^2 = 1 - \frac{\sum_{i=1}^N (G_{com_i} - G_{obs_i})^2}{\sum_{i=1}^N (G_{obs_i} - \bar{G}_{obs_i})^2} \quad [8]$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (G_{com_i} - G_{obs_i})^2}{N}} \quad [9]$$

N تعداد داده‌های مشاهده‌ای، G_{com_i} داده‌های محاسباتی (مقدار پیش‌بینی شده)، G_{obs_i} داده‌های مشاهده‌ای و \bar{G}_{obs_i} میانگین داده‌های مشاهده‌ای است. هرچه مقدار $RMSE$ به صفر و R^2 به یک نزدیک شود، جواب بهتری برای مدل حاصل شده است.

نتایج و بحث

نتایج خوشه‌بندی

در این مطالعه، برای دست آوردن تعداد خوشه‌ها از SOM دوبعدی استفاده شده است. به این صورت که برای تمامی دوبعدی‌ها عملیات خوشه‌بندی انجام شد تا بتوان دقیق‌ترین و بهتر خوشه انتخاب شود. بعد از انجام این مراحل به این نتیجه

معیار ارزیابی موفقیت

در مرحله خوشه‌بندی مکانی، از ضریب سیلپوت^{۱۴} می‌توان به‌عنوان معیاری برای اندازه‌گیری اعتبار خوشه استفاده نمود (رابطه ۷). این ضریب برای یک خوشه درجه شباهت ایستگاه‌های داخل یک خوشه را بیان می‌کند که در آن $S(i)$ مقدار سیلپوت پیزومتر i است. مقادیر کوچک $S(i)$ بیانگر کمی شباهت ایستگاه‌ها در همان^{۱۵} خوشه است. کیفیت خوشه‌بندی می‌تواند با استفاده از متوسط سیلپوت برای مجموعه کل داده‌ها اندازه‌گیری شود.

$$s(i) = \frac{b(i) - a(i)}{\max\{a(i), b(i)\}} \quad [7]$$

$a(i)$ فاصله اقلیدسی است که متوسط نامشابهتی خوشه i را از تمام ایستگاه‌های دیگر در خوشه A اندازه می‌گیرد. $b(i)$ فاصله اقلیدسی است که کمینه نامشابهتی متوسط ایستگاه i را از ایستگاه‌های دیگر در غیر از خوشه A بیان می‌کند (هسو و لی، ۲۰۱۰).

¹⁴ Silhouette Coefficient

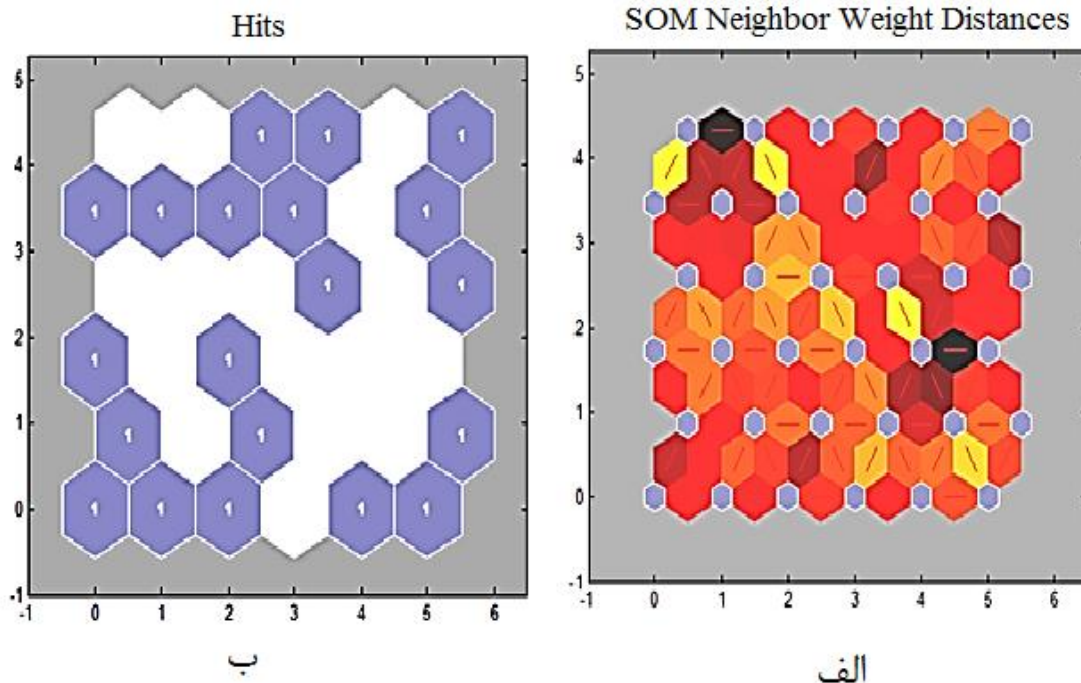
نتایج حاصل از تحلیل خوشه‌بندی *SOM* را برای متغیر تراز آب زیرزمینی دشت آذرشهر نشان می‌دهد.

معیار اعتبار خوشه‌بندی کاربرد وسیعی در تعیین تعداد خوشه‌های بهینه دارند. در این مطالعه، از شاخص سیلهوت برای سنجش اعتبار خوشه‌بندی انجام گرفته استفاده شده است. شاخص سیلهوت برای یک بردار ویژگی، معیاری است از میزان شباهتی که آن بردار ویژگی در خوشه‌ی مربوطه به خود با بردارهای ویژگی در سایر خوشه‌ها دارد. مقادیر شاخص سیلهوت در بازه‌ی بین ۱- تا ۱ بود. ضرایب سیلهوت در ستون سوم جدول ۱ آورده شده است.

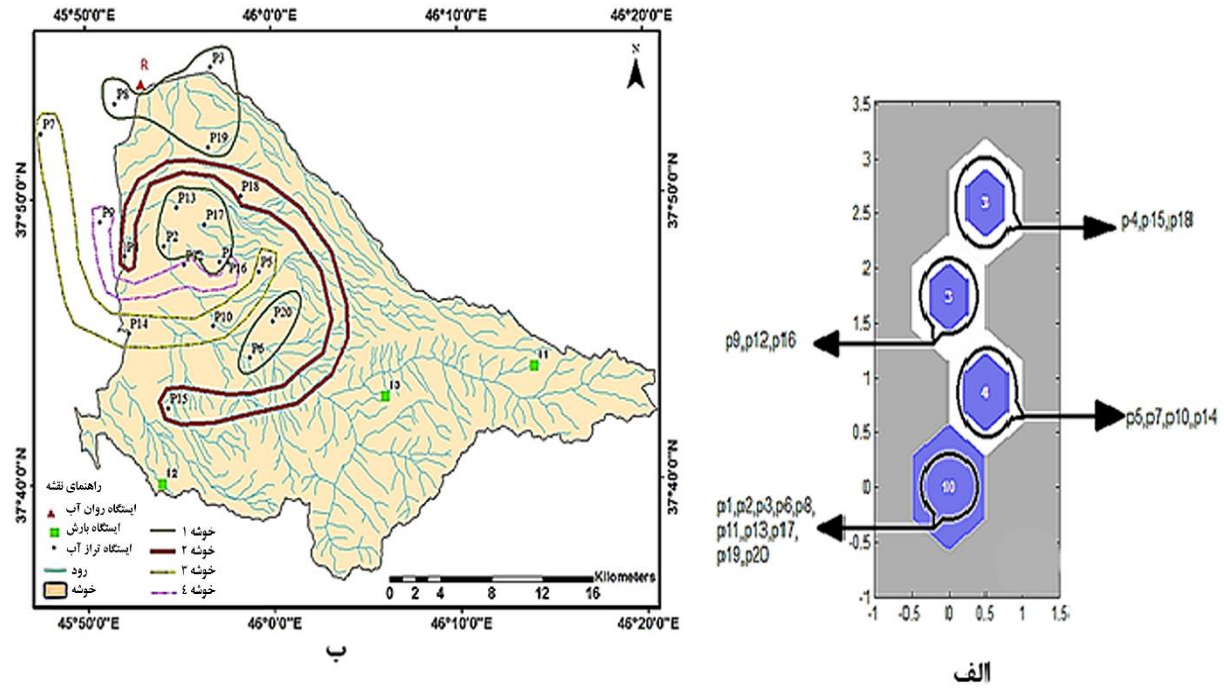
طبق ضرایب سیلهوت در جدول ۱، می‌توان نتیجه گرفت که پیژومترهای خوشه چهارم با داشتن بالاترین مقادیر این ضریب، بیشترین ارتباط را باهم دارند و همچنین خوشه اول کمترین ارتباط را دارند.

پیژومترهای مرکزی در ستون چهارم جدول ۱ آورده شده است که دارای بیشترین مقدار ضرایب سیلهوت می‌باشد. شکل (۶-ب) نتایج خوشه‌بندی را بر روی حوضه مورد مطالعه نشان می‌دهد.

رسیده شد که *SOM* دوبعدی ۶*۶ بهترین نتایج را نسبت به دو بعدی‌های دیگر دارد. این نتایج نشان داد که اگر پیژومترهای مورد مطالعه به چهار خوشه تبدیل شوند، بهترین نتیجه را خواهند داشت. شکل (۵) تحلیل خوشه‌بندی *SOM* دوبعدی ۶*۶ را برای متغیر تراز آب زیرزمینی نشان می‌دهد. شکل (۵-الف) نشان‌گر فاصله وزن‌های همسایگی هستند، رنگ‌های تیره نشان دهنده هم‌بستگی و ارتباط بیشتر پیژومترهای مورد تحلیل قرار گرفته می‌باشد. و رنگ‌های روشن نشانگر هم‌بستگی و ارتباط کمتر بین پیژومترها می‌باشد. شکل (۵-ب) نقشه *Hits* را برای خوشه‌بندی ۶*۶ نشان می‌دهد که *SOM* پیژومترها را به چند خوشه تقسیم کرده است. شکل‌های شش ضلعی که با عدد یک نشان داده شده است، بیانگر یک پیژومتر می‌باشد که شش ضلعی‌های سفید، پیژومترهایی هستند که ارتباط کمتری باهم دارند و در یک خوشه قرار نگرفته‌اند. این شش ضلعی‌های سفید پیژومترهای یک خوشه را از خوشه‌های دیگر جدا می‌کنند که در این شکل پیژومترها به چهار خوشه تقسیم شده‌اند. شکل (۶-الف) که تحلیل خوشه‌بندی *SOM* تک بعدی برای متغیر تراز آب زیرزمینی را نشان می‌دهد، نمایان‌گر این است که چند پیژومتر در یک خوشه قرار گرفته است. جدول ۱



شکل ۵- نتایج خوشه‌بندی *SOM* دوبعدی برای متغیر تراز آب زیرزمینی، (الف) فاصله وزن‌های همسایگی، (ب) نقشه *Hits*.



شکل ۶-الف - پیژومترهای واقع در هر خوشه، ب - خوشه‌بندی مکانی SOM روی نقشه منطقه مطالعاتی.

جدول ۱- نتایج حاصل از خوشه‌بندی نقشه خودسازمان‌ده.

شماره کلاس	پیژومترها	ضریب سیلپوت	پیژومتر مرکزی
کلاس ۱	P1, P2, P3, P6, P8, P11 P13, P17, P19, P20	۰/۳۳۴۸، ۰/۳۱۸۲، ۰/۴۵۶۱، ۰/۱۱۴۱، ۰/۲۰۳۱، ۰/۱۱۰۲ ۰/۲۳۶۸، ۰/۱۰۰۵، ۰/۴۷۹۴، ۰/۰۸۷۶	P19
کلاس ۲	P5, P7, P10, P14	۰/۴۷۷۳، ۰/۴۵۶۰، ۰/۲۵۶۷، ۰/۲۵۸۵	P5
کلاس ۳	P9, P12, P16	۰/۲۲۸۸، ۰/۲۹۱۹، ۰/۳۰۹۷	P16
کلاس ۴	P4, P15, P18	۰/۳۷۱۴، ۰/۷۲۰۷، ۰/۶۳۱۷	P15

در آینده استفاده شود. یکی از مزیت‌های این سناریو این است که اگر داده‌های تراز آب پیژومترهای دیگر در خوشه دارای داده‌های مفقود باشند، مشکلی در فرایند مدل‌سازی رخ نداده و پیش‌بینی تنها با استفاده از داده‌های پیژومتر مرکزی (بارش، رواناب و تراز آب زیرزمینی) صورت می‌پذیرد. انتخاب ورودی برای مدل ANN بر اساس نتایج حاصل از پیش‌پردازش مکانی داده‌ها صورت گرفت. به این صورت که به‌جای اعمال داده‌های مربوط به تمام ایستگاه‌های پیژومتریک، تنها از داده‌های پیژومترهای مرکزی استفاده شد. با توجه به مرکزیت پیژومتر مرکزی در منطقه مطالعاتی، این پیژومتر برای مدل‌سازی در هر

نتایج مدل‌سازی با مدل شبکه عصبی مصنوعی (ANN)

نتایج سناریو اول با مدل ANN

نوسانات تراز آب زیرزمینی پیژومتر مرکزی می‌تواند به‌عنوان نماینده‌ای از الگوی نوسانات یک خوشه در نظر گرفته شود. در سناریوی یک، مدل‌سازی تراز آب زیرزمینی تنها با استفاده از داده‌های پیژومتر مرکزی صورت پذیرفت. از آنجایی که نوسانات تراز آب زیرزمینی پیژومترهای واقع در یک خوشه از الگوی مشابهی تبعیت می‌کنند، تراز آب پیژومتر مرکزی می‌تواند برای پیش‌بینی تراز آب زیرزمینی برای خوشه مربوط

خوشه انتخاب شد. در دشت آذرشهر داده‌های بارش (I)، رواناب (R) و تراز آب زیرزمینی (P) در مقیاس ماهانه (t) اندازه‌گیری می‌شود. ترکیب ورودی برای هر چهار ایستگاه مرکزی در جدول (۲) ارائه شده است.

جدول ۲- نتایج و آماره‌های مدل‌سازی تراز آب زیرزمینی با روش شبکه عصبی مصنوعی برای سناریوی اول.

شماره کلاس	متغیرهای ورودی به شبکه	متغیر خروجی	تعداد تکرار	ساختار شبکه *	R^2	RMSE (بدون بعد)
کلاس ۱	$p19(t), I_2(t-3), R(t)$	$p19(t+1)$	۴۰	۳-۴-۱	۰/۹۴	۰/۰۵۳
کلاس ۲	$p5(t), I_2(t-3), R(t)$	$p5(t+1)$	۳۰	۳-۵-۱	۰/۵۹	۰/۱۱۴
کلاس ۳	$p16(t), I_2(t-1), R(t)$	$p16(t+1)$	۵۰	۳-۴-۱	۰/۹۴	۰/۰۶۰
کلاس ۴	$p15(t), I_2(t), R(t)$	$p15(t+1)$	۲۰	۳-۲-۱	۰/۹۳	۰/۰۵۴

* عدد اول: تعداد ورودی‌ها، عدد دوم: میانی و عدد سوم خروجی مدل شبکه عصبی می‌باشد.

برای صحت‌سنجی و ۷۰ الی ۸۰ درصد آن‌ها برای واسنجی استفاده شده است. همچنین در جدول ۲ نتیجه مدل‌سازی با شبکه عصبی نیز گزارش شده است.

نتایج نشان می‌دهد که مدل‌سازی نسبتاً قابل قبول می‌باشد. طبق این جدول خوشه شماره سوم بهترین جواب و خوشه شماره دوم ضعیف‌ترین جواب را می‌دهد. طبق نتایج به دست آمده می‌توان نتیجه گرفت به علت نزدیک بودن پیرومترهای خوشه سوم از نظر موقعیت مکانی و شرایط یکسان از نظر ارتفاعی در دشت مورد مطالعه ضرایب سیلهوت در این خوشه به هم نزدیک شده و خوشه‌بندی خوبی صورت گرفته و باعث به وجود آمدن مدلی با دقت بهتر شده است. همچنین دقت مدل‌سازی برای خوشه دوم نسبت به سه خوشه دیگر نسبتاً پایین به دست آمد که می‌تواند به دلیل ساختار داده‌های سطح آب زیرزمینی در ایستگاه‌های این خوشه باشد. توجه این موضوع می‌توان گفت، با توجه به نقشه‌های توپوگرافی دشت آذرشهر، چهار ایستگاه $P5, P7, P10, P14$ با توجه به موقعیت مکانی در حوضه و با توجه به این موضوع که هر چهار ایستگاه از نظر موقعیت ارتفاعی، از اختلاف زیادی نسبت به یکدیگر برخوردار هستند که این امر باعث می‌شود که میانگین درجه حرارت سالانه در این چهار ایستگاه متفاوت باشد که منجر به اختلاف میزان بارش باران و برف در چهار ایستگاه می‌شود. همچنین این اختلاف ارتفاع و وجود شیب متفاوت بین پیرومترها و تفاوت در جنس خاک از نظر جذب آب، باعث می‌شود که آب زیرزمینی در این چهار ایستگاه دارای نوسانات بیشتر و ناهمگون نسبت به سه خوشه دیگر و دیگر پیرومترهای این

در سناریوی اول، داده‌های (P)، (R) و (I) و پیرومتر مرکزی را به نمایندگی از پیرومترهای آن خوشه وارد شبکه عصبی مصنوعی می‌شود. قابل ذکر است که در این مرحله از تبدیل موجک استفاده نمی‌شود، داده‌ها قبل از وارد شدن برای مدل‌سازی باید نرمال‌سازی شوند و داده‌های نرمال شده وارد شبکه عصبی شود. به دلیل وجود سه ایستگاه بارش در منطقه مورد مطالعه باید بین ایستگاه‌های بارش و پیرومتر مرکزی، ایستگاه بارشی انتخاب شود که بیشترین همبستگی و بیشترین ارتباط را دارا می‌باشد. این عمل به وسیله همبستگی خطی^{۱۶} صورت پذیرفت. با استفاده از همبستگی خطی مشخص شد که فاصله ایستگاه بارش هر چقدر از پیرومتر مرکزی کمتر باشد، همبستگی و ارتباط بیشتری خواهند داشت (رابطه ۱۰).

$$Correl(X, Y) = \frac{\sum(x - \bar{x})(y - \bar{y})}{\sqrt{\sum(x - \bar{x})^2 \sum(y - \bar{y})^2}} \quad [10]$$

در این رابطه، x و y همان دو سری داده‌های مورد بررسی برای همبستگی و \bar{x}, \bar{y} هم میانگین سری‌های زمانی x, y هستند. در این تحقیق، مقادیر آینده سری زمانی به صورت تابعی از مقادیر گذشته همان سری زمانی پیش‌بینی می‌شوند. بر این اساس سطح تراز آب زیرزمینی در زمان t و بارش و رواناب طبق ارتباط بین پیرومتر مرکزی به‌عنوان ورودی و تراز آب زیرزمینی در زمان $t+1$ به‌عنوان خروجی، طبق جدول ۲ در نظر گرفته می‌شود. در مدل‌سازی ۲۰ الی ۳۰ درصد از داده‌ها

¹⁶ Linear Correlation

آب زیرزمینی) صورت می‌پذیرد. در مدل‌سازی با شبکه عصبی مصنوعی برای سناریوی دوم تمامی مراحل مانند مراحل مدل‌سازی شبکه عصبی مصنوعی برای سناریوی اول انجام گرفته است. تنها تفاوت بین این مدل‌سازی به جای سطح تراز آب زیرزمینی پیژومتر مرکزی در زمان t به عنوان ورودی، سطح تراز آب زیرزمینی دو پیژومتر از همان خوشه که بیشترین ارتباط را با پیژومتر مرکزی دارد، جایگزین شده است. معیار انتخاب این دو پیژومتر داشتن بیشترین ارتباط خطی بین پیژومتر مرکزی و تک تک پیژومترهای واقع در هر خوشه می‌باشد. جدول ۳ ترکیب ورودی‌ها را برای شبکه عصبی در سناریو دوم و نتایج مدل‌سازی با شبکه عصبی را نشان می‌دهد.

خوشه باشد. این نوسانات ناهمگون باعث به وجود آمدن خطا در مدل‌سازی شده و دقت مدل‌سازی را به مقدار قابل توجهی در خوشه دوم کاهش می‌دهد.

نتایج سناریوی دوم با مدل ANN

از آنجایی که نوسانات تراز آب زیرزمینی پیژومترهای واقع در یک خوشه از الگوی مشابهی تبعیت می‌کنند، می‌تواند برای پیش‌بینی تراز آب زیرزمینی برای خوشه از همه پیژومترها استفاده کرد. یکی از مزیت‌های این سناریو این است که اگر داده‌های تراز آب پیژومتر مرکزی دارای داده‌های مفقود باشد، مشکلی در فرایند مدل‌سازی رخ نداده و پیش‌بینی با استفاده از داده‌های پیژومترهای دیگر همان خوشه (بارش، رواناب و تراز

جدول ۳- نتایج و آماره‌های مدل‌سازی تراز آب زیرزمینی با شبکه عصبی مصنوعی برای سناریوی دوم.

شماره کلاس	متغیرهای ورودی به شبکه	متغیر خروجی	تعداد تکرار	ساختار شبکه	R^2	RMSE (بدون بعد)
					واسنجی - صحت سنجی	واسنجی - صحت سنجی
کلاس ۱	$p1(t), p3(t), I_2(t-3), R(t)$	$p19(t+1)$	۱۱۰	۴-۱۰-۱	۰/۸۲۴	۰/۱۴۰
کلاس ۲	$p10(t), p14(t), I_2(t-3), R(t)$	$p5(t+1)$	۳۰	۴-۶-۱	۰/۸۰	۰/۱۹۱
کلاس ۳	$p9(t), p16(t), I_2(t-1), R(t)$	$p12(t+1)$	۱۰	۴-۷-۱	۰/۷۳	۰/۱۳۲
کلاس ۴	$p4(t), p18(t), I_2(t), R(t)$	$p15(t+1)$	۱۲۰	۴-۵-۱	۰/۸۷	۰/۱۵۰

موجود در آن منطقه ممکن است در هر محدوده زمانی متفاوت باشد. اما آنچه در این مورد مشخص است این است که تغییرپذیری طبیعی را نمی‌توان از طریق بهبود ساختار مدل، افزایش تعداد دفعات مدل‌سازی یا واسنجی بهتر پارامترهای مدل و جمع‌آوری اطلاعات بیشتر کاهش داد یا حذف کرد. بنابراین، برای غلبه بر این محدودیت‌ها از ترکیب تبدیل موجک با شبکه عصبی مصنوعی استفاده می‌شود.

نتایج سناریوی اول با مدل WANN

در این مطالعه تعداد داده‌های سری‌های زمانی ۱۲۴ عدد می‌باشد. در این مرحله با استفاده از رابطه ۶ عدد به دست آمده برای سطح تجزیه بالاتر از ۲ می‌باشد و در این صورت عدد ۳ برای سطح تجزیه انتخاب می‌شود. تابع $db4$ به عنوان تابع موجک مادر انتخاب شد.


طبق نتایج جدول ۳ بالاترین دقت مدل‌سازی برای خوشه اول بوده و پایین‌ترین دقت مدل‌سازی همانند سناریوی اول در خوشه دوم مشاهده می‌شود. با توجه به نتایج، مدل‌سازی نسبتاً قابل قبول می‌باشد. مقادیر R^2 به دست آمده برای داده‌های صحت‌سنجی در خوشه دوم در هر دو سناریو نسبت به سه خوشه دیگر نسبتاً پایین مطابق دلایل اعلام شده در سناریو قبل به دست آمد.

نتایج مدل‌سازی با مدل ترکیبی شبکه عصبی و تبدیل موجک (WANN)

مدل‌های ANN در مدل‌سازی‌های غیرخطی مسائل هیدرولوژیکی علی‌رغم قابلیت و توانایی بالا، بعضی اوقات در مدل‌سازی سری‌های زمانی هیدرولوژیکی که دارای تغییرات زمانی زیادی هستند، تغییرپذیری ذاتی و طبیعی در سری داده‌های ورودی باعث تغییرپذیری مقادیر خروجی این مدل می‌شود. تحقیقات نشان داده است که این تغییرپذیری در اثر متغیر بودن شرایط طبیعی هر منطقه و فعالیت‌های انسانی

¹⁷ Daubechies-4 (db4)

زیرا این تابع همخوانی بیشتری از لحاظ شکل ظاهری با سری شکل ۷ زیرسری‌های تجزیه پیزومتر ۱۹ با تبدیل موجک db4 زمانی تراز آب زیرزمینی دارد.



باعث بهبودی قابل توجه مدل‌سازی شده، و دقت مدل‌سازی را افزایش داده و خطای مدل‌سازی را نیز نسبت به زمانی که مدل تنها با شبکه عصبی مصنوعی انجام گرفت است، کاهش داده است. در روش ترکیب تبدیل موجک با شبکه عصبی به‌جای اینکه از داده‌های خام سری زمانی ورودی برای آموزش شبکه استفاده شود، ابتدا سری زمانی ورودی در چند سطح تجزیه می‌شود و سپس به همراه ورودی‌های دیگر (بارش و رواناب) برای آموزش شبکه به کار می‌رود. در این صورت سری زمانی ورودی به شبکه عصبی به‌جای یک مؤلفه، چند مؤلفه دارد. مزیت مهم این روش، قابلیت آن در تشخیص اجزای تشکیل‌دهنده داده‌های غیرایستا به‌وسیله تجزیه چند سطحی موجکی داده‌ها است که باعث افزایش دقت مدل‌سازی شده و خطای مدل‌سازی را کاهش می‌دهد.

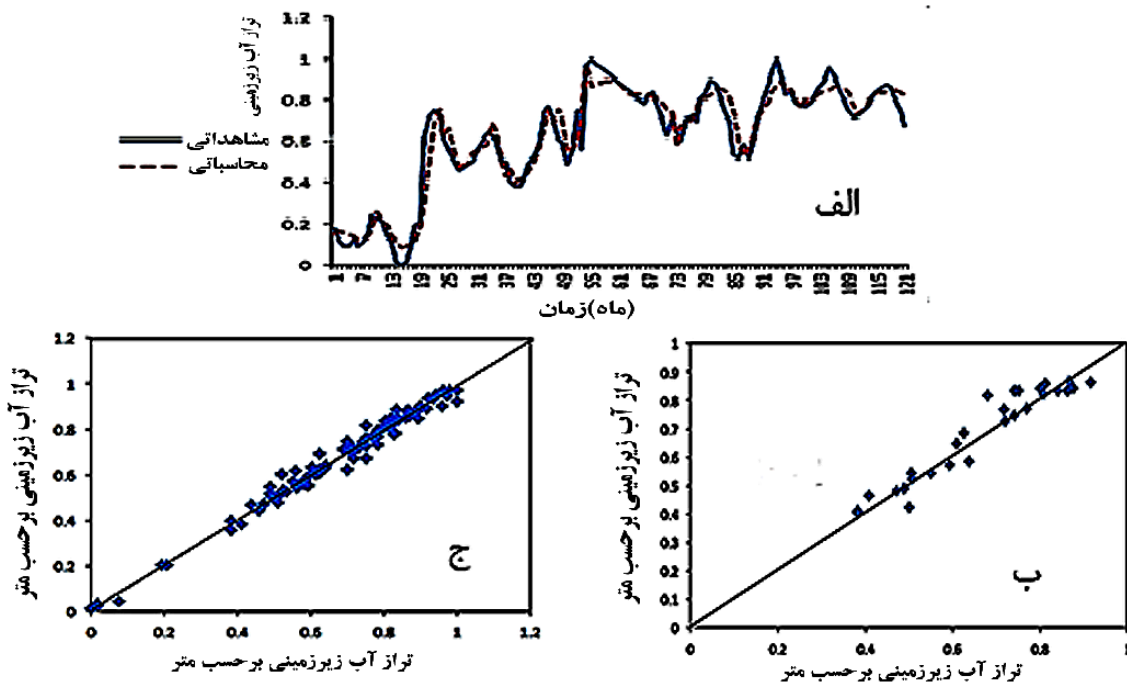
در گام بعدی، داده‌های تراز آب زیرزمینی در زمان (t) برای به دست آوردن زیرسری‌ها، وارد محیط متلب در قسمت تبدیل موجک، می‌شود. با انجام عملیات فوق داده‌ها به‌وسیله تبدیل موجک db4 به زیرسری‌هایی تبدیل می‌شود و سه سطح زیرسری نمایان می‌گردد، حال زیرسری که بیشترین ارتباط را با داده‌های مشاهداتی دارا می‌باشد با استفاده از همبستگی خطی مشخص شده و همراه زیرسری تقریبی به‌عنوان ورودی انتخاب می‌گردد. در مدل WANN، از زیرسری‌های تقریبی و جزئی انتخاب شده تراز آب زیرزمینی حاصل از تحلیل موجکی، هم‌زمان به‌عنوان ورودی به همراه داده‌های بارش و رواناب به مدل شبکه عصبی مصنوعی داده می‌شود نتایج مدل ترکیبی برای سناریوی اول در جدول ۴ نشان داده شده است. بعد از مدل‌سازی و به دست آوردن نتایج، مطابق با جدول ۴، مشخص می‌شود که ترکیب تبدیل موجک با شبکه عصبی مصنوعی

جدول ۴- نتایج و آماره‌های مدل‌سازی تراز آب زیرزمینی با مدل ترکیبی WANN برای سناریوی اول.

شماره کلاس	متغیرهای ورودی به شبکه	متغیر خروجی	تعداد تکرار	ساختار شبکه	R ²	RMSE (بدون بعد)
کلاس ۱	WTp19(t), I ₂ (t-3), R(t)	p19(t+1)	۹۰	۴-۳-۱	۰/۹۳	۰/۰۴
کلاس ۲	WTp5(t), I ₂ (t-3), R(t)	p5(t+1)	۱۴۰	۴-۳-۱	۰/۶۸	۰/۱۳۷
کلاس ۳	WTp16(t), I ₂ (t-1), R(t)	p16(t+1)	۲۰	۴-۳-۱	۰/۹۷	۰/۰۴۵
کلاس ۴	WT p15(t), I ₂ (t), R(t)	p15(t+1)	۹۰	۴-۲-۱	۰/۹۷	۰/۰۴۷

* زیرسری‌های حاصل از تجزیه سری زمانی متغیر تراز آب زیرزمینی توسط تبدیل موجک در ورودی شبکه.

برای ارزیابی مدل در شکل (۸- الف) مقادیر محاسباتی و مقادیر مشاهداتی پیزومتر ۱۹ به‌عنوان نمونه نشان داده شده است. شکل (۸- ب) نمودار مقادیر مشاهداتی در مقابل محاسباتی برای صحت سنجی پیزومتر ۱۹ برای مثال نشان داده شده است. همچنین در شکل (۸- ج) نمودار مقادیر مشاهداتی در مقابل محاسباتی مقادیر کالیبره را برای پیزومتر ۱۹ به‌عنوان نمونه نشان داده شده است. با توجه به شکل ۸ دقت مدل‌سازی قابل قبول می‌باشد.



شکل ۸- الف- مقادیر محاسباتی و مقادیر مشاهداتی پیزومتر ۱۹ در حالت نرمال. (ب) نمودار مقادیر مشاهداتی در مقابل محاسباتی برای مقادیر صحت سنجی پیزومتر ۱۹، (ج) نمودار مقادیر مشاهداتی در مقابل محاسباتی مقادیر کالیبره برای پیزومتر ۱۹.

طبق شکل ۸ مشاهده می‌شود که مقادیر مشاهداتی و محاسباتی از انطباق خوبی نسبت به یکدیگر برخوردار می‌باشند. می‌توان نتیجه گرفت که مدل‌سازی به صورت قابل قبول انجام گرفته و پیش‌بینی سطح تراز آب زیرزمینی می‌تواند مورد قبول باشد. بهترین جواب برای مدلی ترکیبی WANN در خوشه سوم و ضعیف‌ترین جواب برای خوشه دوم رخ داده است. می‌توان گفت که مدل ترکیبی WANN توانسته دقت مدل‌سازی را افزایش دهد. همچنین می‌توان گفت مدل ترکیبی به این دلیل که از سیگنال‌های تجزیه شده به‌عنوان ورودی شبکه عصبی استفاده می‌کند، توانسته است خصوصیات غیرخطی و غیر ایستایی تراز آب زیرزمینی را دقیق‌تر از مدل شبکه عصبی مصنوعی شبیه‌سازی کند.

نتایج سناریوی دوم با مدل WANN

این مرحله همانند قبل سطح تجزیه ۳ در نظر گرفته می‌شود. با اجرای عملیات فوق داده‌های ورودی ما به شش داده، بارش رواناب، و چهار زیرسری از اجرای تبدیل موجک بر روی داده‌های تراز آب پیژومترهای انتخابی ایجاد می‌شود. تجربه نشان داده است که با افزایش یا کاهش مقدار داده‌های ورودی در شبکه عصبی، زمانی جواب دقیق‌تری به دست می‌آید که نسبت به داده‌هایی ورودی نرون‌های میانی نیز تغییر پیدا کند. با افزایش داده‌ها اگر نرون میانی به صورت صحیح افزایش یابد باعث به دست آمدن جواب دقیق‌تری می‌شود. در جدول ۵ نتیجه مدل‌سازی با شبکه ترکیبی WANN برای سناریوی دوم گزارش شده است.

در مدل‌سازی مدل ترکیبی WANN برای سناریوی دوم دو پیژومتر هم خوشه که ارتباط خطی بیشتری با پیژومتر مرکزی دارند، انتخاب می‌شود. سپس داده‌های سطح تراز آب هر دو پیژومتر در زمان (t) ، همراه داده‌های بارش و رواناب برای وارد کردن در شبکه عصبی انتخاب می‌شود، ولی قبل از آن داده‌های تراز آب هر دو پیژومتر انتخابی با تبدیل موجک به زیرسری‌هایی که با اجرای تبدیل موجک به وجود می‌آید، تبدیل می‌شود. همانند مدل‌سازی در سناریوی اول زیرسری ای که بیشترین ارتباط را با داده‌های مشاهداتی دارا است، انتخاب شده و به جای داده‌های تراز آب زیرزمینی در زمان (t) قرار می‌گیرد. در

جدول ۵- نتایج و آماره‌های مدل‌سازی برای تراز آب زیرزمینی با مدل ترکیبی WANN برای سناریوی دوم.

شماره کلاس	متغیرهای ورودی به شبکه	متغیر خروجی	تعداد تکرار	ساختار شبکه	R^2	RMSE (بدون بعد)
کلاس ۱	WTp1(t), WTp3(t), I ₂ (t-3), R(t)	p19(t+1)	۹۰	۶-۸-۱	۰/۹۸	۰/۰۸۵
کلاس ۲	WTp4(t), WTp18(t), I ₂ (t), R(t)	p5(t+1)	۴۰	۶-۲-۱	۰/۷۳	۰/۱۱۶
کلاس ۳	WTp9(t), WTp12(t), I ₂ (t-1), R(t)	p16(t+1)	۱۴۰	۶-۲-۱	۰/۷۶	۰/۱۰۶
کلاس ۴	WTp10(t), WTp15(t), I ₂ (t-3), R(t)	p15(t+1)	۸۰	۶-۱۲-۱	۰/۹۹	۰/۱۳۱

استفاده می‌شود. سناریوی دوم در مقایسه با سناریوی اول به علت استفاده از ورودی‌های زیاد که سبب ورود مقداری خطا به مدل‌سازی شده است، در مرحله مدل‌سازی دقت کمی داشت. همچنین پیژومتر مرکزی در زمان t که به‌عنوان ورودی در سناریوی اول استفاده شده است، از ارتباط بیشتری با خروجی یا همان پیژومتر مرکزی در زمان $t+1$ دارد. در هر دو سناریو دقت مدل‌سازی به غیر از خوشه دوم، برای خوشه‌های دیگر نسبتاً قابل قبول بود. با توجه به نتایج دو سناریو می‌توان فهمید که تعداد ورودی‌ها نقش مهمی در دقت مدل‌سازی دارند و هر چقدر تعداد ورودی‌ها کمتر باشند، دقت مدل‌سازی بیشتر می‌شود. در مطالعات چن و همکاران (۲۰۱۰ و ۲۰۱۱) و چانگ و همکاران (۲۰۱۶) از SOM فقط برای کاهش ورودی‌ها، هان و همکاران (۲۰۱۶) برای کلاس‌بندی مکانی و پیش‌پردازش مکانی بهره گرفتند. حال آنکه در این مطالعه نیز از این ابزار برای خوشه‌بندی یا کلاس‌بندی مکانی استفاده شده است. هم-چنین وانگ و دینگ (2003)، وانگ و زو (2011)، رجایی و زینی‌وند (۱۳۹۳) و رجایی و ابراهیمی (۱۳۹۳) تنها از روش پیش‌پردازش زمانی موجک به همراه مدل شبکه عصبی

طبق نتایج به دست آمده از مدل‌سازی ترکیبی WANN برای سناریوی دوم در جداول ۴ و ۵، بهترین جواب در خوشه اول و ضعیف‌ترین جواب در خوشه دوم به دست آمده است. با توجه به جدول (۵) و جدول ۳ ترکیب تبدیل موجک با شبکه عصبی توانسته ضریب R^2 در مرحله صحت‌سنجی را در ضعیف‌ترین خوشه نسبت به مدل شبکه عصبی مصنوعی تا ۷۵ درصد افزایش دهد و همچنین در بهترین خوشه تا ۱۳ درصد افزایش دهد. قابل ذکر است که افزایش ضریب R^2 صحت‌سنجی به مقدار ۷۵ درصد تأثیر بسیار زیادی در دقت مدل‌سازی می‌گارد و بیان‌گر این است که ترکیب تبدیل موجک با شبکه عصبی چقدر می‌تواند باعث بهبودی دقت مدل‌سازی شود.

مقایسه سناریوها و مدل‌ها

طبق نتایج جداول ۳ و ۲ می‌توان گفت که نتایج به دست آمده از مدل‌سازی توسط شبکه عصبی مصنوعی برای سناریوی دوم، نسبتاً ضعیف‌تر و با دقت کمتر نسبت به نتایج به دست آمده توسط مدل‌سازی برای سناریوی اول می‌باشد. دلیل آن این است که در سناریوی اول، از داده‌های پیژومترهای مرکزی

منابع

- مصنوعی برای پیش‌بینی تراز آب زیرزمینی استفاده کردند. حال آنکه در پژوهش نورانی و همکاران (۲۰۱۵) و مطالعه حاضر که بسیار شبیه هم هستند از ترکیب پیش‌پردازش مکانی SOM و پیش‌پردازش زمانی تبدیل موجک به‌طور توأمان برای دشت اردبیل و دشت آذرشهر استفاده شده است.
- ### نتیجه‌گیری
- در این تحقیق، از دو مدل ANN و WANN جهت پیش‌بینی سطح تراز آب زیرزمینی در دشت آذرشهر استفاده شد. دقت قابل توجه مدل WANN نشان می‌دهد که در صورت استفاده بجا از تبدیل‌های موجک و ترکیب آن با مدل شبکه عصبی، می‌توان سیستم‌های هیدرولوژیکی پیچیده را شبیه‌سازی کرد. با توجه به نتایج این پروژه به‌خوبی می‌توان افزایش دقت مدل‌سازی را توسط مدل WANN مشاهده کرد. استفاده از مدل WANN باعث افزایش مقادیر R^2 برای تمامی حالات و همچنین کاهش مقادیر RMES نسبت به مدل‌سازی توسط مدل ANN شد که این امر نشان دهنده افزایش دقت مدل‌سازی و کاهش خطای مدل‌سازی است. مدل WANN نسبت به مدل ANN باعث بهبودی ۲۴ درصدی در ضعیف‌ترین خوشه در سناریو اول و ۳ درصدی در بهترین خوشه این سناریو در گام صحت‌سنجی شده است. همچنین باعث افزایش دقت مدل‌سازی به صورت ۶۷ درصدی در ضعیف‌ترین خوشه سناریوی دوم و ۱۲ درصدی در بهترین خوشه این سناریو در گام صحت‌سنجی شده است. به‌طور کلی مدل WANN نسبت به مدل ANN باعث بهبودی ۱۱/۶ درصدی در گام صحت‌سنجی برای سناریوی اول و ۲۳/۵ درصدی عملکرد مدل برای سناریوی دوم شد. با رویداشت به این پژوهش، مجال انجام انواع مدل‌های هوش مصنوعی وجود نداشت لذا پیشنهاد می‌شود در مطالعات آتی از مدل‌های دیگر هوش مصنوعی برای پیش‌بینی تراز آب زیرزمینی این دشت به کار گرفته شود. استفاده از ابزارهای دیگر خوشه‌بندی مانند Ward, K-means جهت پیش‌پردازش مکانی داده‌ها گزینه‌ای دیگر جهت بررسی می‌باشد. همچنین، در این راستا پیشنهاد می‌شود از مدل یاد شده در زمینه مدل‌سازی سایر پدیده‌های هیدرولوژیکی همانند خشک‌سالی، رسوب، بارش- رواناب و... استفاده نمود.
- رجایی، ط. و ابراهیمی، ه.، ۱۳۹۳. مدل‌سازی نوسان‌های ماهانه آب زیرزمینی به‌وسیله تبدیل موجک و شبکه عصبی پویا. مدیریت آب و آبیاری، ۴(۱)، ۹۹-۱۱۵.
- رجایی، ط. و زینی‌وند، آ.، ۱۳۹۳. مدل‌سازی تراز آب زیرزمینی با بهره‌گیری از مدل هیبریک موجک- شبکه عصبی مصنوعی. نشریه مهندسی عمران و محیط‌زیست، ۴۴(۴)، ۶۳-۵۱.
- ملکی‌نژاد، ح. پورشریعیانی، ر.، ۱۳۹۲. کاربرد و مقایسه مدل سری زمانی تجمعی و مدل شبکه عصبی مصنوعی در پیش‌بینی تغییرات سطح آب زیرزمینی (مطالعه موردی: دشت مروست). علوم مهندسی آبیاری (مجله کشاورزی)، ۳۶(۳)، ۹۲-۸۱.
- Abrahart, R. J., Anctil, F., Coulibaly, Dawson, Mount, N. J., See, L., Shamseldin, A., Solomatine, D., Toth, E., Wilby, L. R., 2012. Two decades of anarchy? Emerging themes and outstanding challenges for neural network river forecasting, *Progress in Physical Geography*, 36(4), 480-513.
- Adamowski, J., 2008. Development of a short-term river flood forecasting method based on wavelet analysis, *Journal of Hydrology*, 353(3-4), 247-266.
- ASCE Task Committee on application of artificial neural network in hydrology, 2000. Artificial neural network in hydrology 1: Hydrology application, *Journal of Hydrologic Engineering*, 5(2), 124-137.
- Aussem, A., Campbell, J., Murtagh, F., 1998. Wavelet-based feature extraction and decomposition strategies for financial forecasting, *International Journal of Soft Computing and Engineering*, 6(2), 5-12.
- Chae, G. T., Kim, K., Yun, S. T., Kim, K. H., Kim, S. O., Choi, B. Y., Kim, H. S. and Rhee, C. W., 2004. Hydrogeochemistry of alluvial groundwaters in an agricultural area: an implication for groundwater contamination susceptibility, *Chemosphere*, 55, 369-378.
- Chang, F.J., Chang, L.C., Huang, C.W., Kao, I.F., 2016. Prediction of monthly regional groundwater levels through hybrid soft-computing techniques, *Journal of Hydrology*, 541, 965-976.
- Chen, L. H., Chen, C. T and Pan, Y. G., 2010. Groundwater level prediction using SOM-RBFN multisite model. *Journal of Hydrologic Engineering*, 15, 624-631.
- Chen, L.H., Chen, C.T., Li, D.W., 2011. Application of integrated back-propagation network and self-organizing map for groundwater level forecasting, *Water Resources Management*, 137 (4), 352-365.
- Choi, B. Y., Yun, S. T., Kim, K. H., Kim, J. W., Kim, H. M. and Koh, Y. K., 2014. Hydrogeochemical interpretation of South Korean groundwater monitoring data using Self- Organizing Maps, *Journal of Geochemical Exploration*, 137, 73-84.
- Han, J.C., Huang, Y., Li, Z., Zhao, C., Cheng, G., Huang, P., 2016. Groundwater level prediction using a SOM-aided stepwise cluster inference model, *Journal of Environmental Management*, 182, 308-321.

- Hsu, K.C., and Li, S.T., 2010. Clustering spatial-temporal precipitation data using wavelet transform and self-organizing map neural network, *Advances in Water Resources*, 33, 190-200.
- Kisi, O., 2008. Stream flow forecasting using neuro-wavelet technique, *Hydrological processes*, 22(20), 4142- 4152.
- Jain, A.K., 2010. Data clustering: 50 years beyond k-means, *Pattern Recognition Letters*, 31,615-666.
- Kohonen, T., 1998. The Self organizing map, *Neurocomputing*, 21, 1-6.
- Koonce, J. E., Yu, Z., Farnham, I. M. and Stetzenbach, K. J., 2006 Geochemical interpretation of groundwater flow in the southern. *Geosphere*, 2, 88-101.
- Moosavi, V., Vafakhah, M., Shirmohammadi, B. and Ranjbar, M., 2014. Optimization of wavelet- ANFIS and wavelet- ANN hybrid models by Taguchi method for groundwater level forecastion, *Arabian Journal for Science and Engineering*, 39(3), 1785-1796.
- Nayak, P. C., Satyajai rao, Y. P., 2009, Sudheer, P. K. Groundwater Level Forecasting in a Shallow Aquifer Using Artificial Neural Network Approach, *Water Resources Management*, 20, 77-90.
- Nguyen, T. T., Kawamura, A., Tong, T. N., Nakagawa, N., Amaguchi, H. and Jr, R. G., 2015. Clustering spation-seasonal hydrigeochemical data using self-organizing maps for groundwater quality assessment in Red River Delta, Vietnam, *Journal of Hydrology*, 552, 661-673.
- Nourani, V., Alami, M.T., Aminfar, M.H., 2009. Combined neural - wavelet model for prediction of Ligvanchayi watershed precipitation, *Engineering Applications of Artificial Intelligence*, 22, 466 - 472.
- Nourani, V., Hosseini Baghanam, A., Adamowski, J., Gebremichael, M., 2013. Using self-organizing maps and wavelet transforms for space-time pre-processing of satellite precipitation and runoff data in neural network based rainfall-runoff modeling, *Journal of Hydrology*, 476, 228-243.
- Nourani, V., Hosseini Baghanam, A., Daneshvar Vousoughi, F., Alami, M., T., 2012. Classification of Groundwater Level Data Using SOM to Develop ANN-Based Forecasting Model, *International Journal of Soft Computing and Engineering*, 2, 2231-2307.
- Nourani, V., Taghi Alami, M., Daneshvar Vousoughi, F., 2015. Wavelet-entropy data pre-processing approach for ANN-based groundwater level modeling, *Journal of Hydrology*, 524, 255-269.
- Suryanarayana, Ch., Sudheer, Ch., Vazeer Mahammood., Panigrahi, B.K., 2014. An integrated wavelet-support vector machine for groundwater level prediction in Visakhapatnam, India, *Neurocomputing*, 145, 324-335.
- Wang, L. and Zhao, W., 2001. Forecasting groundwater level based on WNM with GA. *Journal of Computational Information Systems*, 7(1), 160-167.
- Wang, W. and Ding, S., 2003. Wavelet network model and its application to the predication of hydrology, *Nature and Science*, 1(1), 67-71.
- Warren Liao, T., 2005. Clustering streamflow time series for regional classification, *Journal of Hydrology*, 407, 73-80.
- Wasserman, P.D., 1989. *Neural computing: Theory and practice*; Van Nostard Rehinold, New York, 230.