

# بررسی کلراید در آب زیرزمینی با استفاده از تلفیق مدل هوش مصنوعی و روش وابستگی تبدیل موجک

شهرام موسوی<sup>۱\*</sup>، وحید نورانی<sup>۲</sup>، محمد تقی اعلمی<sup>۳</sup>

۱- استادیار، باشگاه پژوهشگران جوان و نخبگان، واحد میانه، دانشگاه آزاد اسلامی

۲- استاد، گروه مهندسی آب، دانشکده مهندسی عمران، دانشگاه تبریز

۳- استاد، گروه مهندسی آب، دانشکده مهندسی عمران، دانشگاه تبریز

sh.mousavi@m-iau.ac.ir

تاریخ پذیرش: ۹۶/۰۲/۰۶

تاریخ دریافت: [۹۵/۰۸/۲۵]

## چکیده

در این پژوهش، مدل‌های زمانی جریان آب زیرزمینی و انتقال آلودگی با استفاده از تلفیق تکنیک‌های هوش مصنوعی و وابستگی تبدیل موجک توسعه داده شده است. دشت میاندوآب به عنوان مطالعه موردی برای شبیه‌سازی تراز آب زیرزمینی و غلظت کلراید انتخاب شد. به منظور خوشه‌بندی پیرومترهای دشت، وابستگی تبدیل موجک به عنوان تکنیکی برای بررسی وابستگی و تاخیر فاز بین سری‌های زمانی نایستای تراز آب و غلظت کلراید استفاده شد. همچنین از وابستگی تبدیل موجک به عنوان یک روش جدید برای مشخص کردن ارتباط سفره‌ها و ارتباط بین تراز آب دریاچه و تراز آب پیرومترهای نزدیک ساحل دریاچه که می‌تواند در مدلسازی تراز آب و غلظت کلراید مفید باشد، استفاده شد. در ادامه سری‌های زمانی تراز آب و غلظت کلراید در ۱۴ پیرومتر مختلف با استفاده شبکه عصبی مصنوعی و سیستم عصبی-فازی تطبیقی برای تخمین تراز آب و غلظت کلراید در یک ماه بعد آموزش و اعتبارسنجی شدند. نتایج نشان داد که کارایی مدل عصبی-فازی تطبیقی تا ۱۳ درصد بیشتر از مدل شبکه عصبی مصنوعی است. توانایی مدل عصبی-فازی تطبیقی در هر دو مرحله آموزش و درستی آزمایی به دلیل کارایی منطق فازی برای غلبه بر عدم قطعیت پدیده از شبکه عصبی مصنوعی بیشتر بوده است.

**واژگان کلیدی:** آبهای زیرزمینی، انتقال آلودگی، هوش مصنوعی، وابستگی تبدیل موجک.

## ۱- مقدمه

کمبود آب شود. بنابراین شبیه‌سازی انتقال آلودگی می‌تواند یک ابزار مهم در مطالعات آب و محیط زیست باشد و بر این اساس توسعه مدل قدرتمند که قادر به پیش‌بینی زمانی آلودگی باشد، ضروری است. برای مدلسازی زمانی تراز آب و غلظت آلودگی در محیط‌های متخلخل روش‌های محاسباتی متعددی از قبیل روش تفاضل محدود، روش احجام محدود، روش المان محدود و روش المان مرزی برای حل عددی معادلات دیفرانسیل پاره‌ای حاکم بر مسئله به کار گرفته شده‌اند [1].

آب زیرزمینی یک منبع حیاتی برای تامین آب آشامیدنی، کشاورزی و صنعت محسوب می‌شود. بنابراین یکی از مسائل مهم زیست محیطی، مدیریت و حفاظت منابع آب زیرزمینی از آلاینده‌های مختلف است. زمانی که آب زیرزمینی آلوده می‌شود، فرآیند خارج کردن آلودگی و بازیافت کیفیت ممکن است بسیار کند و در برخی موارد غیر عملی باشد. این مسئله می‌تواند برای سلامتی انسانها و اکوسیستم خطر آفرین و منجر به

ورودی‌های مدل‌های هوش مصنوعی و همچنین ارتباط بین سطح آب دریاچه (دریاچه ارومیه) و پیژومترهای دشت (دشت میان‌دوآب) استفاده شده‌است. این امر می‌تواند حجم مدل‌سازی شبکه عصبی مصنوعی و سیستم عصبی-فازی تطبیقی را تا حد زیادی کاهش دهد. نوع آلودگی مورد مطالعه در این پژوهش به دلیل قرار گرفتن دشت میان‌دوآب در جنوب غرب دریاچه ارومیه، غلظت کلراید انتخاب شده‌است.

## ۲- مواد و روش‌ها

### ۲-۱- مدل پیشنهادی

روش پیشنهادی در این پژوهش برای مدل‌سازی زمانی جریان و انتقال آلودگی در محیط‌های متخلخل شامل ۳ بخش مجزا است. در ابتدا با استفاده از سری‌های زمانی تراز آب زیرزمینی، بارش، رواناب، تراز دریاچه و غلظت کلراید در پیژومترها و رودخانه‌های منطقه مطالعه شده، ارتباط فرکانسی آنها بررسی و بدین ترتیب پیژومترهایی که رفتار مشترک دارند از طریق تکنیک وابستگی تبدیل موجک خوشه‌بندی می‌شود. این روش در تعیین پارامترهای ورودی مدل‌های هوش مصنوعی نیز موثر خواهد بود. در مرحله دوم، پس از مشخص شدن پیژومترهای مرکزی در هر خوشه، تراز آب زیرزمینی با استفاده از مدل‌های هوش مصنوعی (ANN, ANFIS) آموزش و درستی‌آزمایی می‌شود. برای این منظور پارامترهای ورودی مدل که شامل بارش، رواناب، تراز دریاچه و تراز آب در زمان‌های قبل است، لحاظ شده‌اند. آثار سایر پارامترهای موثر در پیش بینی تراز آب زیرزمینی که شامل تبخیر، برداشت، آبیاری و غیره می‌باشد، بطور غیرصریح در تراز آب زیرزمینی در ماه‌های قبل در نظر گرفته می‌شود. در مرحله سوم به منظور پیش بینی زمانی غلظت آلاینده (کلراید) مشابه مرحله قبل از مدل‌های هوش مصنوعی استفاده می‌شود.

پارامترهای ورودی در این مرحله تراز آب زیرزمینی با تاخیر زمانی مناسب، تراز آب دریاچه و غلظت کلراید در رودخانه محدوده منطقه مطالعه شده در نظر گرفته شده‌اند. کلیه ابزارهای استفاد شده در محیط Matlab کد نویسی و توسعه داده شدند. شکل (۱) دیاگرام مدل پیشنهادی را نشان می‌دهد.

اگر چه تکنیک‌های عددی مبتنی بر فیزیک بطور گسترده برای مدل‌سازی زمانی ویا مکانی سیستم‌های آب و محیط زیست بکار برده می‌شوند، در برخی شرایط ساده‌سازی‌های در نظر گرفته شده می‌تواند تاثیر معنی داری بر مدل‌سازی جریان آب و انتقال آلودگی داشته باشد و کاربرد این روش‌ها را محدود سازد. در نتیجه زمانی که داده‌های میدانی کافی نباشند یا دقت خروجی مهمتر از مفهوم فیزیکی مسئله باشد، مدل‌های جعبه سیاه یا داده محور می‌توانند جایگزین این روش‌ها شوند. عدم قطعیت و پیچیدگی فرآیندهای آب زیرزمینی باعث شده‌اند تا مدل‌های داده‌محور از قبیل شبکه‌های عصبی مصنوعی (Artificial Neural Networks (ANNs) و سیستم عصبی-فازی تطبیقی (Adaptive Neuro-Fuzzy Inference System (ANFIS)) بطور گسترده توسط هیدروژئولیس‌ها به کار گرفته شوند. مطالعات متعددی برای ارزیابی مدل‌های هوش مصنوعی در مدل‌سازی جریان آب و انتقال آلودگی در محیط‌های متخلخل انجام شده است [2, 3, 4, 5, 6 و 7]. از طرف دیگر خوشه‌بندی پیژومترهای سفره آب زیرزمینی و پیدا کردن ارتباط بین پیژومترهای منطقه یا ارتباط بین سفره‌های آب زیرزمینی در دشت مورد مطالعه و نیز یافتن ارتباط بین سفره‌های مطالعه شده و دریاچه‌ها یا دریاچه‌های اطراف محدوده مورد مطالعه حائز اهمیت بوده و کمک شایانی در مدل‌سازی جریان آب و انتقال آلودگی خواهد نمود. از این روش وابستگی تبدیل موجک (Wavelet Transform Coherence (WTC)) به عنوان ابزاری برای پیدا کردن ارتباط فرکانسی سری‌های زمانی و تاخیر فاز بین آنها حائز اهمیت است. در حوزه کاربردی، برخلاف تبدیل موجک از وابستگی تبدیل موجک در مطالعات محدودی از قبیل اندرکنش آب سطحی و زیرزمینی [8] و اعتبار سنجی شبیه‌سازهای سه بعدی هیدرولوژیکی [9] استفاده شده‌است. در زمینه آبهای زیرزمینی نیز از تبدیل موجک به عنوان یک روش ترکیبی با روش‌های هوش مصنوعی در فرآیند آموزش و درستی‌آزمایی استفاده شده است [7, 10 و 11]. در این پژوهش، برای مدل‌سازی زمانی جریان آب و انتقال آلودگی در محیط متخلخل، به عنوان یک نوآوری از روش وابستگی تبدیل موجک برای خوشه‌بندی و تعیین پیژومترهای مرکزی، تعیین

شکل ۱. دیاگرام مدل پیشنهادی برای پیش‌بینی تراز آب و غلظت آلودگی (I: بارش، Q: رواناب، h: تراز آب زیرزمینی، CC: غلظت کلراید)

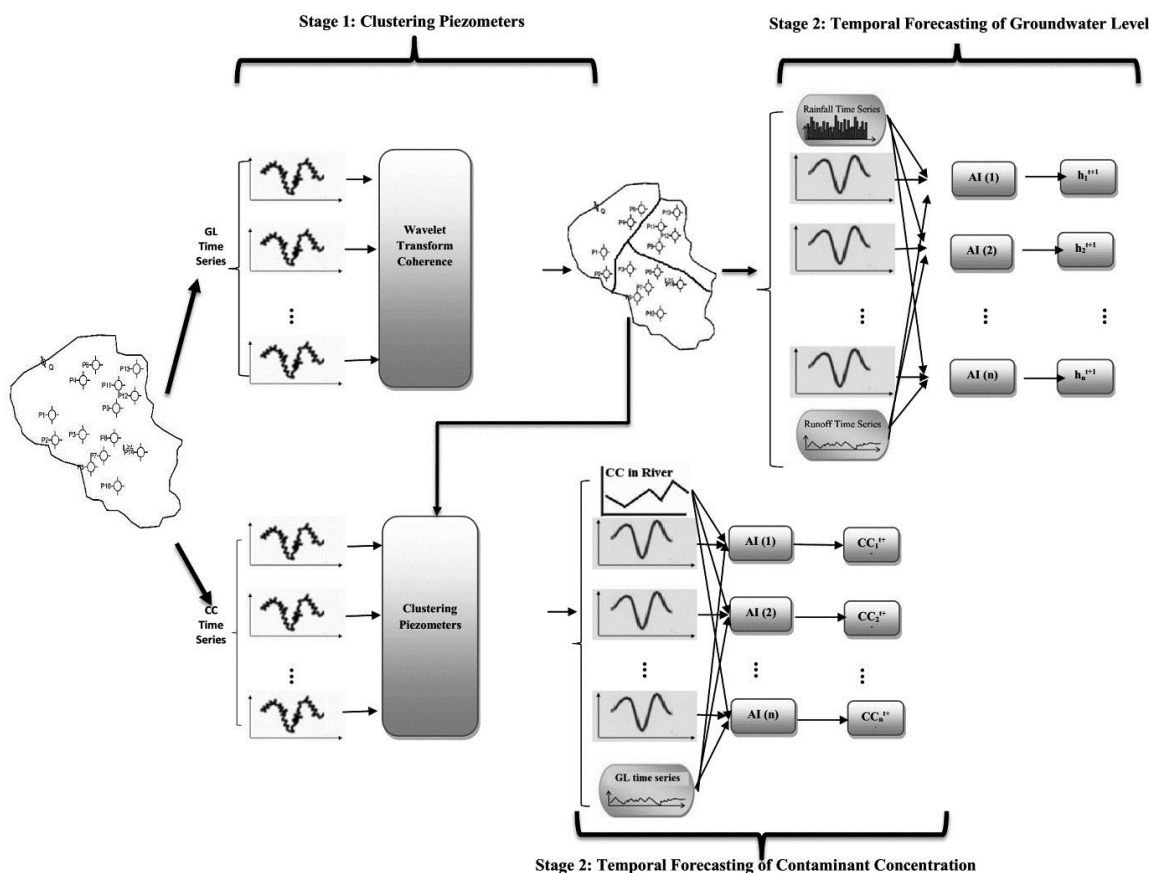


Fig. 1. Schematic of the proposed model for predicting of groundwater level and contaminant concentration (I = rainfall, Q = runoff, h = groundwater level at piezometer, CC = chloride concentration)

تخمین و پیش‌بینی انتخاب شد. کلراید در آب‌های سطحی و زیرزمینی می‌تواند ناشی از منابع طبیعی و انسانی از قبیل رواناب حاصل از ذوب یخچا به وسیله نمک پاشی در جاده‌ها، فاضلاب‌های صنعتی، زهکشی آبیاری، کودهای غیرارگانیک، شیرابه زباله‌ها، فاضلاب سپتیک تانک، خوراک دامی و نفوذ آب شور دریاها به نواحی ساحلی باشد [13]. در منطقه مطالعه شده میزان غلظت کلراید از ۳/۵۵ تا ۱۳۴۹۰ میلی‌گرم بر لیتر در پیژومترهای مشاهده دشت در طول سال‌های ۱۹۹۸ تا ۲۰۱۵ تغییر یافته‌است به گونه‌ای که استفاده از آب زیرزمینی در بخشی از مناطق دشت را با مشکل مواجه ساخته‌است. در سال‌های اخیر کاهش تراز دریاچه ارومیه تاثیر معنی‌داری در کیفیت آبهای نزدیک ساحل دریاچه به ویژه در غلظت کلراید داشته‌است.

## ۲-۲- مطالعه موردی و داده‌ها

به منظور آزمون کارایی مدل پیشنهادی در شرایط واقعی، دشت میان‌دوآب واقع در شمال‌غرب ایران به عنوان مطالعه موردی انتخاب شد. دشت میان‌دوآب در دلتای رودخانه‌های زرينه‌رود و سمينه‌رود واقع شده‌است (شکل ۲). دریاچه ارومیه در شمال دشت که بزرگترین دریاچه نمکی در خاورمیانه است در دو دهه اخیر تحت شرایط تغییرات اقلیمی قرار گرفته‌است. به دلیل کاهش جریان ورودی از حوضه آبریز به دریاچه و افزایش غلظت نمک در دریاچه در دهه‌های اخیر، یک خط ساحلی طولانی نمک تشکیل شده‌است. تغییرات اقلیمی حوضه دریاچه و برداشت‌های غیرکنترل شده از آبهای زیرزمینی منطقه باعث تغییر در مقادیر کمی و کیفی آب در دشت میان‌دوآب شده‌است [12]. در این مطالعه غلظت کلراید به علت وجود داده‌های کافی و آثار دریاچه ارومیه به عنوان ماده آلاینده برای

شکل ۲. محدوده مورد مطالعه و موقعیت پیزومترها




Fig. 2. Study area and position of piezometers.

$$R_n^2(s) = \frac{|S(s^{-1}W_n^{XY}(s))|^2}{S(s^{-1}|S(W_n^X(s))|^2)S(s^{-1}|S(W_n^Y(s))|^2)} \quad (1)$$

که  $S$  بیانگر اپراتور هموار ساز و توسط نوع موجک تعیین می-شود. معادله (۱) شبیه به ضریب همبستگی رایج است و در محدود زمان-فرکانس محلی شده است. اطلاعات بیشتر در مورد وابستگی تبدیل موجکی را می توان در مرجع [15] بدست آورد.

#### ۲-۴- مدل های هوش مصنوعی

روش های هوش مصنوعی به عنوان مدل های جعبه سیاه به صورت گسترده در مسائل مختلف به کار گرفته شده اند. در این پژوهش دو نوع تکنیک هوش مصنوعی برای مدلسازی زمانی جریان آب و انتقال آلودگی در محیط متخلخل، شامل شبکه عصبی و سیستم عصبی-فازی تطبیقی استفاده شده است. توضیح اجمالی درباره مدل های مذکور در بخش بعد ارائه شده است.

#### ۲-۴-۱- شبکه های عصبی مصنوعی

شبکه های عصبی به عنوان یک ابزار جعبه سیاه بسیار متداول و بطور گسترده در مسائل کاربردی استفاده شده است. شبکه عصبی پیشرو به صورت وسیع در مسائل آب و محیط

در این مطالعه داده های حاصل از ۱۴ پیزومتر (P1، P2، ... (P14 از سال ۱۹۹۸ الی ۲۰۱۵ (۱۸ سال) با فواصل زمانی یک ماه و یک فصل به ترتیب برای تراز آب و غلظت کلراید جمع آوری شده است. تغییرات تراز بین ۱۲۷۶/۲۴ تا ۱۲۸۰/۳۷ بوده- است. دبی و غلظت کلراید ماهانه رودخانه زینه رود و نیز بارش ماهانه دشت میاندوآب از سالهای ۱۹۹۸ تا ۲۰۱۵ در مدلسازی به کار رفته است. ۷۰٪ داده های جمع آوری شده برای کالیبراسیون و مابقی برای اعتبار سنجی مدل های هوش مصنوعی (ANN یا ANFIS) به کار رفته است.

#### ۲-۳- روش وابستگی تبدیل موجک

وابستگی تبدیل موجک (WTC) یک تکنیک برای تحلیل ارتباط و تاخیر فاز بین سری های زمانی نایستا به صورت تابعی از فضای فرکانس-زمان است [14]. تبدیل موجک متقابل دو سری زمانی  $X_n$  و  $Y_n$  ( $n$  نشان دهنده مقیاس زمانی است) با تبدیلات موجک مجزای  $W_n^X(s)$  و  $W_n^Y(s)$  بصورت  $W_n^{XX}(s) = W_n^X(s)W_n^{*Y}(s)$  بیان می شود. علاوه بر این اندازه طیف موجک متقابل بصورت  $|W_n^{XY}(s)|$  مشخص می شود. بیشترین قدرت طیف مشترک دو سری زمانی  $X_n$  و  $Y_n$  در فضای زمان-فرکانس بوسیله تبدیل موجک متقابل پیدا می شود. وابستگی تبدیل موجک دو سری زمانی  $X_n$  و  $Y_n$  به شکل تبدیل موجک متقابل به صورت رابطه (۱) بیان می شود [9]:

پارامترهای تابع خروجی است. بنابراین در این حالت فرمول بندی در شبکه عصبی - فازی تطبیقی از یک آرایش شبکه عصبی پنج لایه پیشرو پیروی می‌کند. اطلاعات بیشتر در زمینه مدل ANFIS را می‌توان در منابع جانگ و سان [22] و جانگ و همکاران (۱۹۹۷) [19] ملاحظه نمود.

#### ۲-۴-۲- معیار ارزیابی مدلها

کارایی مدل‌های هوش مصنوعی مبتنی بر برخی معیارهای ارزیابی در هر دو مرحله آموزش و درستی آزمایشی است. برخی از معیارهای ارزیابی متداول در مسائل آب و محیط زیست شامل ضریب تبیین ( $DC$ )، میانگین مربع خطاها ( $MSE$ )، جذر میانگین مربع خطاها ( $RMSE$ )، میانگین مطلق خطاها ( $MAE$ ) و درصد خطاهای استاندارد ( $SEP$ ) است. در این پژوهش دو نوع معیار ارزیابی  $RMSE$  و  $DC$  به کار گرفته شده‌اند. این معیارها برای مقایسه مقادیر واقعی و تخمینی از رابطه‌های (۳ و ۴) بدست می‌آیند.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (X_{obs} - X_{pre})^2}{n}} \quad (۳)$$

$$DC = 1 - \frac{\sum_{i=1}^n (X_{obs} - X_{pre})^2}{\sum_{i=1}^n (X_{obs} - \bar{X}_{obs})^2} \quad (۴)$$

که  $X_{obs}$ ،  $X_{pre}$  و  $\bar{X}_{obs}$  به ترتیب نشان دهنده مقدار واقعی، تخمینی و متوسط داده‌هاست و  $n$  تعداد داده‌هاست. لگاتس و مکیب (۱۹۹۹) نشان دادند که  $RMSE$  و  $DC$  برای ارزیابی مدل‌های آب و محیط زیست کافی است [23].

### ۳- نتایج و بحث

عدم قطعیت پارامترهای مدل‌های انتقال آلودگی در آب‌های زیرزمینی از قبیل هدایت هیدرولیکی، ضریب پخش و تغییرات زمانی آنها و شرایط مرزی نامشخص باعث شده‌اند تا مدل‌سازی جریان آب و انتقال آلودگی در محیط‌های متخلخل، غیرخطی و پیچیده باشد. به دلیل همین پیچیدگی‌ها، در این پژوهش از روش‌های هوش مصنوعی ( $ANN$  و  $ANFIS$ ) به عنوان مدل‌های جعبه سیاه که به اطلاعات فیزیکی پدیده نیاز چندانی ندارند استفاده شده‌اند.

زیست به عنوان یک تکنیک پیش‌بینی زمانی به کار رفته است [16]. شبکه عصبی پیشرو با یک لایه ورودی، یک لایه خروجی و لایه مخفی کالیبره شده با الگوریتم انتشار برگشتی برای مدل‌سازی زمانی غیر خطی آب و محیط زیست مناسب است [17, 18].

#### ۲-۴-۲-۲ مدل شبکه عصبی - فازی تطبیقی

مدل ANFIS به عنوان یک تابع تخمین‌گر عمومی در بسیاری از مسائل کاربردی استفاده شده است. در این پژوهش، به منظور غلبه بر عدم قطعیت پدیده (برای نمونه در نظر گرفتن یک بارش برای کل محدوده مطالعه شده) از مدل شبکه عصبی-فازی تطبیقی برای مدل‌سازی زمان تراز آب و انتقال آلودگی استفاده شده‌است. این مدل در برگیرنده دو مدل فازی و عصبی در یک ساختار است. بخش فازی رابطه‌ای بین متغیرهای ورودی و خروجی برقرار نموده و پارامترهای مربوط به توابع عضویت بخش فازی به وسیله شبکه عصبی تعیین می‌شود. بنابراین ویژگی‌های هر دو مدل فازی و عصبی در شبکه عصبی-فازی تطبیقی نهفته است [19]. ممدانی-آسیلین و تاکاگی-سوگونو دو نوع تکنیک شناخته شده‌ای است که به صورت وسیع به کار برده شده‌اند و در سیستم فازی مطلوب بوده‌اند [20]. در این پژوهش از روش فازی مرتبه اول سوگونو برای مدل‌سازی زمانی جریان آب و انتقال آلودگی استفاده شده‌است.

برای یک مدل فازی مرتبه اول سوگونو با دو ورودی، یک خروجی و دو تابع عضویت برای هر یک از ورودی‌ها، یک مدل شبکه عصبی-فازی تطبیقی معمولی تشکیل می‌شود [21]. در این حالت فرض می‌شود که سیستم فازی دارای ورودی  $x$  و  $y$  و یک خروجی  $f$  است.

برای چنین مدلی قوانین معمولی با در نظر گرفتن دو قانون فازی اگر- سپس ( $If-then$  rules) به صورت زیر تعریف می‌شود.

$$\begin{aligned} \text{Rule 1: If } \mu(x) \text{ is } A_1 \text{ and } \mu(y) \text{ is } B_1; \text{ then } f_1 &= p_1x + q_1y + r_1 \\ \text{Rule 2: If } \mu(x) \text{ is } A_2 \text{ and } \mu(y) \text{ is } B_2; \text{ then } f_2 &= p_2x + q_2y + r_2 \end{aligned}$$

که متغیرهای  $A_1, A_2, B_1$  و  $B_2$  به ترتیب توابع عضویت برای ورودی‌های  $x$  و  $y$  است و  $p_1, q_1, r_1, p_2, q_2, r_2$

مقیاس‌های زمانی کوتاه مدت ملاحظه نمود. همبستگی زیاد در مقیاس زمانی یکساله دیده می‌شود. این موضوع توسط پیکان-های مستقیم به سمت راست تایید می‌شود. به منظور توجیه فیزیکی این مطلب، می‌توان گفت از سمت شمال به طرف مرکز دشت میاندوآب سفره از آبرفت‌های درشت دانه زرینه رود و سمینه رود تشکیل یافته است. این بخش از دشت لایه آبدار آزاد است. اما در بخش‌های خروجی دشت و به طرف سواحل دریاچه ارومیه به دلیل تناوب رسوب گذاری نهشته‌های دانه ریز دریاچه‌ای با نهشته‌های طغیانی رودخانه‌ای، تعداد سفره‌ها به سه لایه افزایش می‌یابد. بنابراین نتایج تکنیک WTC می‌تواند برای شناسایی همبستگی بین پیزومترها یا سفره‌های آب زیرزمینی دشت به کار گرفته شود. این موضوع می‌تواند در خوشه‌بندی سفره‌ها یا پیزومترهای منطقه به عنوان یک فرآیند پیش‌پردازش اطلاعات مکانی برای افزایش کارایی مدلسازی جریان آب و انتقال آلودگی استفاده شود.

با روش مشابه پیزومترهای P3, P5, P7, P8, P10 و P14 در یک خوشه و مابقی پیزومترها (P9, P11, P12 و P13) در خوشه دیگر قرار می‌گیرند. بر اساس انحراف از میانگین، ترازهای متوسط آب زیرزمینی در پیزومترهای هر خوشه، پیزومترهای مرکزی تعیین شدند. بر این اساس پیزومترهای P1, P7 و P11 به ترتیب برای خوشه ۱، ۲ و ۳ به عنوان پیزومترهای مرکزی انتخاب شدند.

به منظور تعیین لایه ورودی مدل‌های هوش مصنوعی، وابستگی تبدیل موجک (WTC) برای خوشه‌بندی پیزومترها و مشخص کردن همبستگی بین پارامترهای هیدروژئولوژیکی به کار گرفته شد. در روش WTC، مجذور مقدار هماهنگی (معادله ۱) به همراه اختلاف فاز هماهنگی در قالب یک مقیاس نما ارائه می‌شود. با به کارگیری رنگ‌بندی آب تیره (مجذور تطابق مساوی با صفر) تا قرمز تیره (مجذور تطابق مساوی با یک) مقدار تابع تطابق به کمک پیکانهای جهت‌دار اختلاف زاویه فازی هماهنگی در قالب یک تجزیه طیفی زمانی-فرکانسی به نمایش در آمده‌است. پیکان‌ها با نوک معطوف به سمت راست بیانگر فاز مثبت (همفاز) و پیکان‌های با نوک معطوف به چپ بیانگر زاویه فازی منفی (آنتی فاز) بین دو سری زمانی هستند. همفاز بودن بدین معنا است که با افزایش در مقدار سری اول، سری دوم نیز رو به افزایش می‌گذارد. به منظور مقایسه و آزمون الگوی تراز آب زیرزمینی در مقیاس‌های زمانی مختلف، WTC بر روی سری‌های زمانی کلیه پیزومترها اعمال شد. بر اساس آنالیز WTC، پیزومترهای P1, P2, P4 و P6 رفتار مشابهی در مقیاس‌های مختلف برای تراز آب زیرزمینی نشان دادند. برای نمونه شکل (۳) سری‌های زمانی و نمودار WTC برای ترازهای آب زیرزمینی پیزومترهای P1 و P2 را نشان می‌دهد. بر اساس نمودار WTC ارتباط خوبی بین پیزومترهای P1 و P2 دیده می‌شود. برخی از همبستگی‌های ضعیف را می‌توان به ویژه در

شکل ۳. تحلیل وابستگی موجک متقابل برای ارتباط سری‌های تراز آب زیرزمینی پیزومترهای P1 و P2.

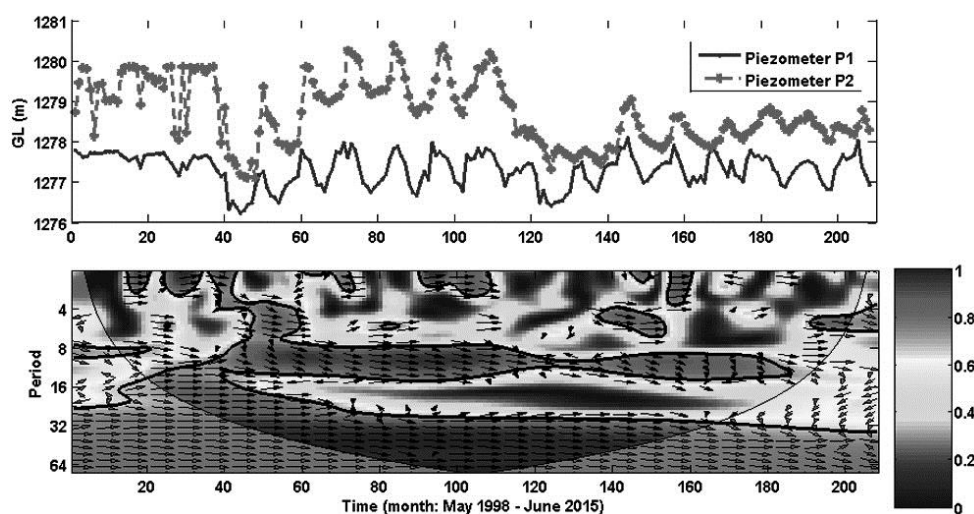


Fig. 3. Cross wavelet coherence analysis for correlation of time series of GL between piezometers P1 and P2

شکل ۴. اسکالوگرام سری زمانی برای تراز آب زیرزمینی پیزومتر P1.




Fig. 4. Scalogram of GL time series for piezometer P1.

به منظور تخمین لایه ورودی در مدل‌سازی زمانی غلظت کلراید به وسیله ANN، تراز آب زیرزمینی، غلظت کلراید در رودخانه و تراز آب دریاچه ارومیه به عنوان پارامترهای غالب ورودی انتخاب شدند. دبی رودخانه به دلیل دیده شدن اثر آن در تراز آب زیرزمینی در این مرحله در نظر گرفته نشد. بر اساس WTC تراز آب زیرزمینی در ماه‌های قبل و غلظت کلراید برای هر خوشه مشخص شد. ورودی‌های مختلف برای خوشه-ها برای مدل‌سازی زمانی غلظت کلراید در آب زیرزمینی دشت میاندوآب به شرح زیر در نظر گرفته شد:

ترکیب (۱-۲):  $ht-3, ht-1, ht$  و  $Wt$  برای خوشه ۱

ترکیب (۲-۲):  $ht-3, ht-1, ht$  و  $Wt$  برای خوشه ۲

ترکیب (۳-۲):  $ht-1, ht$  و  $Crt-1$  برای خوشه ۳

که  $Crt$  و  $Ct$  به ترتیب نشان دهنده غلظت کلراید در پیزومتر و رودخانه در گام زمانی  $t$  است. لایه خروجی شامل یک نرون غلظت کلراید پیزومتر در گام زمانی  $t+1$  در نظر گرفته شد.

بر اساس ترکیب ورودی (۱-۲ تا ۳-۲) تخمین مقادیر غلظت کلراید ماهانه در منطقه مورد مطالعه برای کلیه پیزومترها که فقط دارای آمار غلظت فصلی هستند، مقدور خواهد بود. بنابراین علاوه بر تخمین غلظت کلراید در ماه‌های مختلف، تخمین مقدار غلظت کلراید برای یک ماه بعد نیز مشخص خواهد شد. نتایج مدل‌های ANN برای تخمین غلظت کلراید در جدول (۲) برای هر پیزومتر مرکزی نشان داده شده است.

با روش مشابه، مدل ANFIS برای پیش‌بینی تراز آب زیرزمینی و غلظت کلراید در کلیه پیزومترها با ترکیب‌های مختلف ورودی به کار بسته شد. در مدل ANFIS تعداد و نوع توابع عضویت و انتخاب تعداد تکرار پارامترهای اساسی است

بارش و رواناب و مقادیر تراز آب زیرزمینی به عنوان لایه ورودی در مدل‌سازی هوش مصنوعی استفاده شدند. علاوه بر این، اثر آب‌های سطحی مانند آبیاری در تراز آب زیرزمینی در ماه‌های قبل لحاظ شده است. به منظور تعیین اثر فصلی فرآیند تراز در ۱۱ ماه قبل نیز در مدل‌سازی اعمال شده است. برای نمونه در شکل (۴) اسکالوگرام سری زمانی برای پیزومتر P1 نشان داده شده است.

در این پژوهش از الگوریتم لونیگ-مارکارت برای آموزش ANN استفاده شد [24]. بر اساس معیارهای ارزیابی (DC و RMSE)، ساختار مناسب برای ANN از طریق آزمون و خطا برای کلیه پیزومترهای مرکزی مشخص شد.

برای هر خوشه یک مدل مجزای ANN با ورودی‌های مختلف برای مدل‌سازی تراز آب زیرزمینی به شرح زیر تعیین شد:

ترکیب (۱-۱):  $ht, ht-1, ht-11, Qt, Wt$  برای خوشه ۱

ترکیب (۲-۱):  $It, ht, ht-1, ht-11, Qt$  برای خوشه ۲

ترکیب (۳-۱):  $ht, ht-1, ht-11, Qt$  برای خوشه ۳

که  $ht, Qt, It$  و  $Wt$  به ترتیب بیانگر تراز آب زیرزمینی، بارش، رواناب و تراز دریاچه ارومیه در گام زمانی  $t$  است. لایه خروجی شامل یک نرون تراز آب زیر زمینی در یک گام زمانی بعد ( $ht+1$ ) است.

نتایج نشان داد که بارش تاثیر کمی در مدل‌سازی زمانی تراز آب زیرزمینی بوسیله ANN در خوشه‌های ۱ و ۳ دارد. این مطلب از نظر فیزیکی با نفوذ پذیری کم خاک‌های سطحی خوشه ۱ و ۳ هماهنگی دارد. جدول (۱) نتایج ANN با ساختارهای مختلف برای تخمین تراز آب در پیزومترهای مرکزی را نشان می‌دهد.

مقایسه بین مقادیر مشاهده و شبیه‌سازی شده تراز آب زیرزمینی و غلظت کلراید به وسیله مدل‌های ANN و ANFIS در شکل-های (۵ و ۶) برای پیزومتر P1 نشان داده شده‌است.

در سال‌های اخیر کاهش تراز آب و افزایش شوری دریاچه ارومیه بحران‌های زیست محیطی را موجب شده‌است. این آثار در پیزومترهای نزدیک ساحل دریاچه بیشتر مشهود است. تغییرات زیاد سری‌های زمانی غلظت کلر در طول سال‌های ۱۹۹۹ تا ۲۰۰۸ در پیزومترهای نزدیک دریاچه مشاهده می‌شود. اما در دوره زمانی بین ۲۰۰۸ تا ۲۰۱۵ نوسان کمی در غلظت کلر ملاحظه می‌شود که این اثر می‌تواند مربوط به کاهش تراز آب دریاچه و پیشروی آب سفره به طرف دریاچه باشد و کارایی مدل‌های هوش مصنوعی را همان گونه که در شکل (۶) نیز دیده می‌شود، تحت تاثیر قرار دهد

که کارایی مدل را تحت تاثیر قرار می‌دهند. استفاده از تعداد زیاد توابع عضویت منجر به نتایج نامطلوب در کارایی مدل می‌شود. توابع عضویت استفاده شده در این پژوهش تابع گوسی، تابع ترکیبی گوسی، تابع دوزنقه‌ای، تابع مثلثی شکل، تابع زنگوله‌ای، تابع پی شکل، تفاضل دو تابع حلقوی و حاصل ضرب دو تابع حلقوی بوده‌اند. برای نمونه جداول (۱ و ۲) نتایج مدل ANFIS را با ساختارهای مختلف برای پیزومترهای مرکزی نشان می‌دهد. ترکیب‌های ۱-۱ و ۲-۱ با تابع عضویت trimf و ترکیب ۳-۱ با تابع عضویت dsigmf و تعداد دو قانون (rule) مقادیر مناسبی را در مدلسازی ANFIS در پی داشتند. همچنین ترکیب‌های ۱-۲ و ۲-۲ با تابع عضویت gussmf و ترکیب ۳-۲ با تابع عضویت psigmf بهترین نتیجه را برای پیش‌بینی غلظت کلراید با استفاده از مدل ANFIS نشان دادند.

جدول ۱. مقایسه نتایج مدلسازی زمانی تراز آب زیرزمینی با استفاده از مدل‌های ANN و ANFIS

Model	Piezometer	Network structure	RMSE (normalized)		R <sup>2</sup>	
			Calibration	Verification	Calibration	Verification
ANN	P1	5-6-1	0.079	0.104	0.854	0.846
	P7	5-4-1	0.082	0.107	0.880	0.833
	P11	4-6-1	0.081	0.101	0.893	0.831
ANFIS	P1	trimf	0.065	0.087	0.903	0.893
	P7	trimf	0.079	0.091	0.890	0.880
	P11	dsigmf	0.059	0.086	0.935	0.877

Table 1. Comparison of ANN and ANFIS results in temporal modeling of GL

جدول ۲. مقایسه نتایج مدلسازی زمانی غلظت کلراید با استفاده از مدل‌های ANN و ANFIS

Model	Piezometer	Network structure	RMSE (normalized)		R <sup>2</sup>	
			Calibration	Verification	Calibration	Verification
ANN	P1	3-4-1	0.047	0.015	0.954	0.855
	P7	4-6-1	0.098	0.022	0.804	0.694
	P11	3-4-1	0.066	0.019	0.910	0.871
ANFIS	P1	gaussmf	0.047	0.013	0.955	0.903
	P7	gaussmf	0.089	0.020	0.838	0.757
	P11	psigmf	0.047	0.013	0.955	0.903

Table 2. Comparison of ANN and ANFIS results in temporal modeling of chloride concentration

شکل ۵. نمودار مشاهده در مقابل محاسبات تراز آب زیرزمینی برای پیزومتر P1 با استفاده از مدل‌های ANN و ANFIS

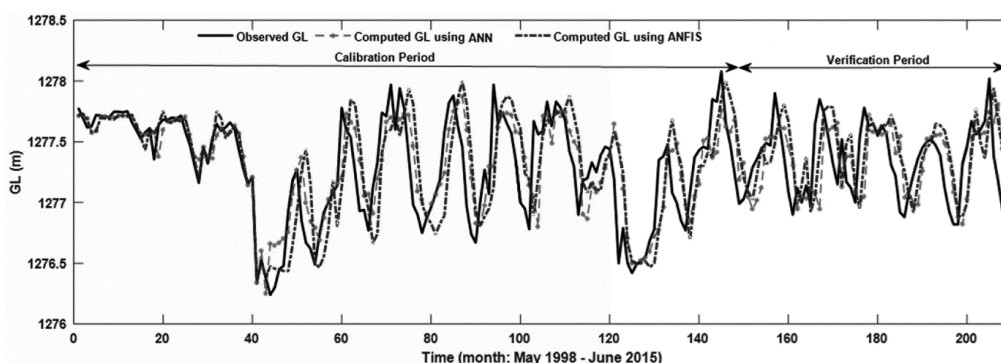


Fig. 5. Observed versus computed GLs of piezometer P1 using ANN and ANFIS models.



شکل ۶. نمودار مشاهده در مقابل محاسبات غلظت کلراید برای پیزومتر P1 با استفاده از مدل‌های ANN و ANFIS

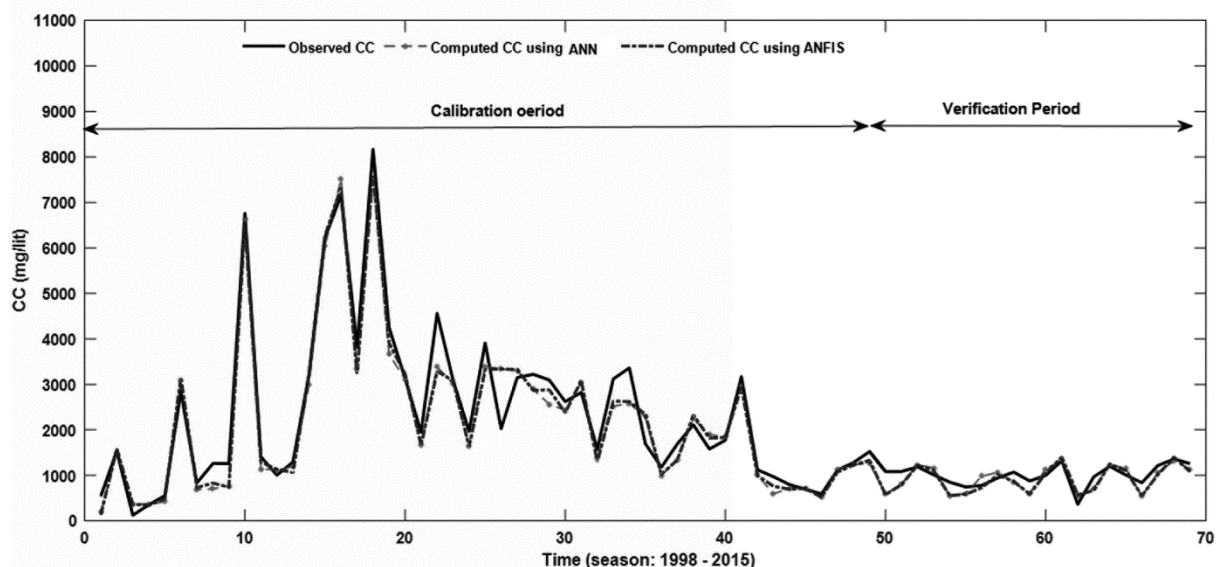


Fig. 6. Observed versus computed CCs of piezometer P1 using ANN and ANFIS models.

درون‌یاب خوبی به شمار می‌روند اما در برون‌یابی دارای مشکل اساسی است، پس در انتخاب داده‌های آموزش باید بخشی از سری‌های زمانی استفاده شوند که شامل تغییرات کم و زیاد باشد.

نتایج این پژوهش نشان می‌دهد که استفاده از مدل ANFIS در پیش‌بینی زمانی تراز آب زیرزمینی و غلظت آلودگی از دقت بیشتری نسبت به روش ANN برخوردار است که می‌تواند ناشی از غلبه تئوری فازی بر عدم قطعیت پارامترهای ورودی مدل باشد. خوشه‌بندی پیزومترهای دشت با استفاده از روش وابستگی تبدیل موجک حجم محاسبات را تا حد زیادی کاهش می‌دهد به گونه‌ای که به جای تعیین ورودی‌های مختلف برای ۱۴ پیزومتر مختلف در این پژوهش فقط از ۳ پیزومتر مرکزی استفاده شده‌است. همچنین در شرایط نامشخص سفره‌ها تکنیک وابستگی موجک می‌تواند در تشخیص ارتباط بین پیزومترها، دریاچه‌ها و سفره‌های دشت موثر باشد.

#### ۴- نتیجه‌گیری

عدم قطعیت پارامترهای فیزیکی فرآیند از قبیل ضریب هدایت هیدرولیکی و پارامتر پخش، شرایط نامعلوم مرزی و ناقص بودن داده‌های مورد نیاز، عوامل مهمی پیش‌بینی زمانی تراز آب زیرزمینی و انتقال آلودگی هستند که نتایج مدل‌سازی را

بر اساس نتایج بدست آمده از وابستگی تبدیل موجک، سری‌های زمانی تراز دریاچه ارومیه و پیزومترهای خوشه ۱ دشت میاندوآب هم فاز هستند و در نتیجه بیشتر تحت تاثیر دریاچه است. با تغییرات تراز دریاچه نوسانات غلظت کلر در بخش‌های شمال و شمال‌غرب دشت به وضوح قابل ملاحظه است. خشک شدن دریاچه و انباشت نمک در سواحل دریاچه باعث خواهد شد تا در صورت بالا آمدن سطح آب دریاچه نمک‌های محلول بیشتری وارد دشت شده و عملاً چاه‌های نزدیک ساحل را بیشتر در معرض شوری قرار خواهد داد. این در حالی است که پیزومترهای مرکزی دشت که بیشتر از رودخانه زرينه‌رود و سمینه‌رود تغذیه می‌شوند و کمتر تحت تاثیر دریاچه هستند و در بازه زمانی این مطالعه هیچ رابطه فازی بین پیزومترهای مرکزی دشت و تراز دریاچه مشاهده نشد و بیشتر به نظر می‌رسد غلظت کلراید بیشتر در اثر مصرف کودها، سم‌های شیمیایی، تصفیه‌خانه، نمک پاشی جاده‌ها در زمستان در بخش‌های مرکزی دشت و محل دفن زباله‌ها در بخش‌های جنوبی دشت باشد.

روش‌های هوش مصنوعی که داده محور است به شدت به کمیت و کیفیت داده‌ها بستگی دارد. وجود خطا و نویز در این داده‌ها تاثیر زیادی در نتایج خروجی این مدل‌ها دارد و کارایی آنها را محدود می‌کند. همچنین روش‌های هوش مصنوعی

Informed Particle Swarm Optimization, *Journal of Hydroinformatics*, 17(1), 99-113.

[6] Foddis, M. L., Ackerer, P., Montisci, A. & Uras, G. (2015), Ann-Based Approach for the Estimation Aquifer Pollutant Source Behaviour, *Water Science and Technology: Water Supply*, 15(6), 1285-1294.

[7] Nourani, V., Alami, M. T. & Vousoughi, F. D. (2015), Wavelet-Entropy Data Pre-Processing Approach for Ann-Based Groundwater Level Modeling, 524, 255-269

[8] Rahman, M., M. Sulis, and S. J. Kollet (2014), The concept of dual-boundary forcing in land surface-subsurface interactions of the terrestrial hydrologic and energy cycles, *Water Resource Reseach*, 50(11), 8531-8548.

[9] Fang, Z., Bogena, H., Kollet, S., Koch, J. and Vereecken, H. (2015), Spatio-temporal validation of long-term 3D hydrological simulations of a forested catchment using empirical orthogonal functions and wavelet coherence analysis, *Journal of hydrology*, 529, 1754-1767.

[10] Rajaei, T. and Zeinivand, A. (2015), Modeling of groundwater level using ANN-Wavelet hybrid model (case study: Sharif Abad plain), *Journal of Civil and Environmental Engineering University of Tabriz*, 77, 51-63. (In Persian)

[11] Rajaei, T. and Ebrahimi, H. (2014), Monthly simulation of groundwater fluctuations using wavelet and dynamic neural network, *Journal of Water and Irrigation Management*, 1, 73-87. (In Persian)

[12] WHO., 1996. Guidelines for drinking-water quality. World Health Organization, Geneva. 2.

[13] Hemmaty, A., 2003. Hydrogeochemical study of groundwater of Miyandoab plain. M.S. thesis, geology department of Tabriz University. (In Persian)

[14] Chang, C. & Glover, G. H. (2010), Time-Frequency Dynamics of Resting-State Brain Connectivity Measured with Fmri, *Neuroimage*, 50, 81-98.

[15] Grinsted, A., Moore, J. C. & Jevrejeva, S. (2004), Application of the Cross Wavelet Transform and Wavelet Coherence to Geophysical Time Series, *Nonlinear Processes in Geophysics*, 11, 561-566.

[16] Nourani, V. & Andalib, G. (2015), Daily and Monthly Suspended Sediment Load Predictions Using Wavelet Based Artificial Intelligence Approaches, *Journal of Mountain Science*, 12(1), 85-100.

[17] Hornik, K., Stinchcombe, M. & White, H. (1989), Multilayer Feedforward Networks Are Universal Approximators, *Neural Networks*, 2, 359-366.

تحت تاثیر قرار می دهند. در این تحقیق از توانایی های مدل های هوش مصنوعی و وابستگی تبدیل موجک برای مدل سازی زمانی تراز آب زیرزمینی و غلظت کلر استفاده شده است. بیشتر پژوهش های قبلی از مدل های هوش مصنوعی یا روش های عددی مبتنی بر فیزیک مسئله برای مناطق فرضی استفاده نموده اند [2]. در این پژوهش برای تخمین تراز آب زیرزمینی و غلظت کلراید برای یک ماه بعد از روش های غیرخطی هوش مصنوعی (ANN یا ANFIS) به عنوان یک مدل جعبه سیاه در پیرومترهای مشاهده شده استفاده شود.

تکنیک همبستگی متقابل موجک استفاده شده در این پژوهش می تواند یک روش جدید در خوشه بندی مکانی پیرومترهای منطقه مطالعه شده، تعیین اثر متقابل دریاچه با پیرومترهای ساحلی و ارتباط بین لایه های آب زیرزمینی دشت مطرح باشد که می تواند در فرآیند مدل سازی جریان آب زیرزمینی و انتقال آلودگی حجم محاسبات را تا حد زیادی کاهش دهد.

مدل ANFIS نسبت به مدل ANN تا ۱۳ درصد در هر دو مرحله کالیبراسیون و درستی آزمایی، قابلیت اطمینان بیشتری دارد که این امر می تواند به دلیل توانایی تئوری فازی در غلبه بر نامعینی فرایند جریان آب زیرزمینی و انتقال آلودگی باشد.

## References

## ۵- مراجع

[1] Bear, J. & Cheng, A. H.-D. (2010), *Modeling Groundwater Flow and Contaminant Transport*, Springer Science & Business Media.

[2] Singh, R. M. & Datta, B. (2007), *Artificial Neural Network Modeling for Identification of Unknown Pollution Sources in Groundwater with Partially Missing Concentration Observation Data*, *Water Resources Management*, 21, 557-572.

[3] Nourani, V., Mogaddam, A. A. & Nadiri, A. O. (2008), *An Ann-Based Model for Spatiotemporal Groundwater Level Forecasting*, *Hydrological Processes*, 22, 5054-5066.

[4] Li, X. & Tsai, F. T.-C. (2009), *Bayesian Model Averaging for Groundwater Head Prediction and Uncertainty Analysis Using Multimodel and Multimethod*, *Water resources research*, 45(9).

[5] Taormina, R. & Chau, K.-W. (2014), *Neural Network River Forecasting with Multi-Objective Fully*

daily and hourly behaviour of runoff. *Journal of Hydrology*, 337, 22-34.

[22] Jang, J.-S. R. & Sun, C.-T. (1995), Neuro-Fuzzy Modeling and Control, *Proceedings of the IEEE*, 83, 378-406.

[23] Legates, D. R. & McCabe, G. J. (1999), Evaluating the Use of 'Goodness-of-Fit' Measures in Hydrologic and Hydroclimatic Model Validation, *Water Resources Research*, 35, 233-241.

[24] Haykin, S. & Lippmann, R. (1994), *Neural Networks, a Comprehensive Foundation*, International Journal of Neural Systems, 5, 363-364.

[18] Govindaraju, R. S. (2000), *Artificial Neural Networks in Hydrology. II: Hydrologic Applications*, *Journal of Hydrologic Engineering*, 5, 124-137.

[19] Jang, J.-S. R., Sun, C.-T. & Mizutani, E. (1997), *Neuro-Fuzzy and Soft Computing; a Computational Approach to Learning and Machine Intelligence*, Prentice-Hall.

[20] Kacprzyk, J. & Pedrycz, W. (2015), *Springer Handbook of Computational Intelligence*, Springer.

[21] Aqil, M., Kita, I., Yano, A. & Nishiyama, S. (2007), A comparative study of artificial neural networks and neuro-fuzzy in continuous modeling of the

## Assessment of Chloride Concentration in Groundwater by Conjugation of Artificial Intelligence and Wavelet Transform Coherence Approaches

Shahram Mousavi<sup>\*1</sup>, Vahid Nourani<sup>2</sup>, Mohammad Taghi Alami<sup>3</sup>

1- Assistant professor, Young Researchers and Elite Club, Miyaneh Branch, Islamic Azad University, Miyaneh, Iran

2- Professor, Dept. of Water Resources Engineering, Faculty of Civil Engineering., University of Tabriz, Iran

3- Professor, Dept. of Water Resources Engineering, Faculty of Civil Engineering., University of Tabriz, Iran

sh.mousavi@m-iau.ac.ir

### Abstract

When groundwater is contaminated, removal of contaminants and the restoration of quality may be slow and sometimes, impractical. It can be harmful for human health, the ecosystem and can result in water shortage. Thus, simulation of contaminant transport can be an important task in hydro-environmental studies and consequently, it is necessary to develop the robust models which can determine the temporal forecast of pollution. For temporal modeling groundwater level and contaminant concentration (GLCC), several computational methods, namely, finite difference method, finite volume method, finite element method and boundary element method have been applied for numerical solution of governing physical-based partial differential equation (PDE). Although the physical-based numerical technique are widely used for temporal and/or spatial modeling of systems, some real-world conditions such as anisotropy and heterogeneity can have meaningful impacts on GLCC and restrict the usefulness of such methods. As a result, these method may be replaced by other techniques. In situation where there is no sufficient field data and output accuracy is preferred over perception of phenomena, a data-driven or black box model can be proper subsided. The uncertainty and complexity of the groundwater process have caused data-driven models such as artificial neural networks (ANNs) and adaptive neuro-fuzzy inference system (ANFIS) are widely used by hydrogeologists. Several studies have been performed to examine the susceptibility of artificial intelligence (AI) models for GFCT modeling. Wavelet transform coherence (WTC) is a technique for examination the localized correlation coefficient and their phase lag between non-stationary time series as a function of both time-frequency spaces. Furthermore, the cross-wavelet power is indicated as high common power of two time series and is found in time-frequency space by cross wavelet transform (XWT). Specifically, XWT investigates the regions in time-frequency space with large common power about a consistent phase relationship, and accordingly suggestion for causality between and time series. On the other hand, the WTC explores the regions in time-frequency apace in which and time series co-vary, but not essentially with high power. So, while analyzing two time series for evaluating both causality and local co-variance, the WTC is more suitable.

In order to examine the applicability of the proposed AI-meshless model in real world conditions, the contaminant transport problem in Miandoab plain located in the northwest of Iran was considered as the case study. Miandoab plain, is located in a delta region of Zarrineh and Simineh Rivers. Urmia Lake in north of Miandoab plain, the largest salt-water lake in the Middle East, has been experienced climate change in early 2 decades. The wavelet transform coherence used in this study can be considered as a novel method for spatial clustering of piezometers, for detecting the interaction of aquifers in the plain and relationship between water level of the lake and GLs and CCs of piezometers located near the lake shore witch can present helpful information in GL and CC modeling. The results showed that the efficiency of ANFIS model was more than ANN model up to 30%. Reliability of ANFIS model is more than ANN model in both calibration and verification stages duo to the efficiency of fuzzy concept to overcome the uncertainties of the phenomenon.

Keywords: Groundwater, Contaminant Transport, Artificial Intelligence, Wavelet Transform.