

## بررسی نوسانات تراز آب زیرزمینی با روش محاسبات نرم (مطالعه موردی: دشتهای ارومیه و میاندوآب)

فرناز محمدی<sup>۱</sup>، میرعلی محمدی<sup>۲\*</sup>، جواد بهمنش<sup>۳</sup> و سعید جلیلی<sup>۴</sup>

تاریخ ارسال: ۱۳۹۹/۰۵/۲۱

تاریخ پذیرش: ۱۳۹۹/۱۰/۲۴

مقاله پژوهشی

### چکیده

مطالعه رفتار نوسانات تراز آبها به دلیل توزیع نامتوازن در چرخه هیدرولوژیک برای بیلان آب حائز اهمیت است. در تحقیق حاضر، نوسانات تراز آب زیرزمینی دشتهای ارومیه و میاندوآب در دو مدل SVM و Wavelet از گروه محاسبات نرم، بررسی شده است. برای این منظور، اطلاعات مربوط به بازه زمانی سالهای ۱۳۸۱-۱۳۹۶ برای هر دو دشتهای ارومیه و میاندوآب با در نظر گرفتن چهار سناریو: (۱) تراز آب زیرزمینی - تراز آب زیرزمینی با یک ماه تأخیر، (۲) تراز آب زیرزمینی - تراز آب زیرزمینی با دو ماه تأخیر، (۳) تراز آب زیرزمینی - بارش و (۴) تراز آب زیرزمینی - دما صورت گرفت. نتایج حاصل از شبیه سازی مورد مقایسه قرار گرفت و بهترین مدل معرفی گردید. نتایج تحلیل رگرسیون حاصل نشان داد  $R^2=0/90$  و  $MSE=0/4$  به ترتیب متعلق به چاه پیژومتر دوم دشت ارومیه و چاه پیژومتر سوم دشت میاندوآب در هر دو مدل SVM و Wavelet برای سه سناریوی تراز آب زیرزمینی - تراز آب زیرزمینی با یک ماه تأخیر، تراز آب زیرزمینی - بارش و تراز آب زیرزمینی - دما بوده است. داده های متغیرهای اقلیمی دما، بارش و تراز آب زیرزمینی با یک ماه تأخیر به عنوان متغیر مستقل و داده های تراز آب زیرزمینی به عنوان متغیر وابسته سناریوهای مذکور با ۸۰٪ داده های آموزشی و ۲۰٪ داده های آزمون را تشکیل دادند؛ و نتایج این بررسی نشان داد که متغیر اقلیمی بارش در نوسانات تراز آب زیرزمینی تأثیر بسزایی دارد. در حالت کلی، نتایج پیش بینی مدل Wavelet بهتر از مدل SVM در بررسی نوسانات تراز آب زیرزمینی در دشتهای ارومیه و میاندوآب بدست آمدند. در تحقیق حاضر، بررسی مستقل مدل های مذکور به منظور شبیه سازی نوسانات تراز آب زیرزمینی و مقایسه یکایک آن دو مدل در کاربرد آنها می باشد.

واژه های کلیدی: تراز آب زیرزمینی، تحلیل رگرسیون، SVM، Wavelet.

<sup>۱</sup> ارشد مهندسی مدیریت منابع آب، دانشکده علوم آب و خاک، دانشگاه زابل، ۰۹۳۵۱۴۶۳۲۰۲، Farnazmohammadi7172@gmail.com

<sup>۲</sup> دانشیار گروه مهندسی عمران - هیدرولیک و مکانیک مهندسی رودخانه، دانشکده فنی و مهندسی دانشگاه ارومیه، صندوق پستی ۱۶۵، ارومیه، ۰۹۱۴۱۴۱۰۶۵۰، m.mohammadi@urmia.ac.ir

<sup>۳</sup> استاد گروه مهندسی آب، دانشکده کشاورزی، دانشگاه ارومیه، ۰۹۱۴۱۴۶۰۲۷۲، j.behmanesh@urmia.ac.ir

<sup>۴</sup> دانشجوی دکتری آبیاری زهکشی، گروه آبیاری و آبادانی، پردیس کشاورزی و منابع طبیعی تهران، دانشگاه تهران، ۰۹۳۸۸۵۳۶۳۵۰، jalili\_saeid@yahoo.com

## مقدمه

(Coulibaly et al., 2001; Coppola et al., 2005; Daliakopoulos et al., 2005; Nayak et al., 2006; Affandi & Watanabe 2007; Dash et al., 2010). یکی از موانع اصلی در استفاده گسترده از مدل‌های تصمیم‌گیری در دنیای واقعی، حجم بالای فرایندهای محاسبات آنها می‌باشد. از مطالعات هیدروژئولوژیک انجام شده در این زمینه به پیش‌بینی سطح ایستابی در زهکشی زیر سطحی مزارع در دشت اتاوا<sup>۲</sup> واقع در کانادا با استفاده از شبکه عصبی مصنوعی<sup>۳</sup> توسط Yang et al. (1997) می‌توان اشاره نمود. نتایج این مطالعه حاکی از آن است که با بکارگیری بارش روزانه، تبخیر و تراز آب زیرزمینی در گام زمانی قبل به عنوان ورودی‌های مدل، روش شبکه عصبی مصنوعی از توانایی بالایی در پیش‌بینی تراز آب زیرزمینی در گام زمانی آینده برخوردار بوده است. (Nayak et al. (2006) با بررسی آبخوان ساحلی واقع در کشور کره دریافتند که با بکارگیری مدل‌های تلفیقی شبکه عصبی می‌توان تراز آب زیرزمینی را تا ۴ ماه بعد پیش‌بینی کرد. (Yoon et al. (2011) با استفاده از مدل‌های غیرخطی سری زمانی شبکه عصبی مصنوعی (ANN) و ماشین بردار پشتیبان<sup>۴</sup> (SVM) نوسانات تراز آب زیرزمینی را بررسی کردند که نتایج آنها نشان داد مقادیر ریشه خطای میانگین مربعات (RMSE) در ANN کم‌تر از SVM بوده است. با این حال، معیارهای عملکرد کلی مدل SVM مشابه یا حتی بهتر از ANN در مرحله پیش‌بینی مدل است. ندیری و همکاران (۱۳۹۲) به مدل‌سازی آب زیرزمینی آبخوان دشت تسوج در حاشیه دریاچه ارومیه با مدل هوش مصنوعی مرکب و با در نظر گرفتن افت تراز آب زیرزمینی پرداختند. در این

آب زیرزمینی یک منبع آبی تجدیدپذیر ارزشمند (Todd & Mays, 2005) با تقاضای بالقوه در سراسر جهان با توجه به اهمیت و گستردگی استفاده روزمره از آن روبرو است (Naghbi et al., 2016; Sandoval & Tiburan, 2019). آب زیرزمینی در حدود ۹۶ درصد از کل منابع آب شیرین قابل دسترس را شامل می‌شود (Sandoval & Tiburan, 2019) و احتمالاً آب زیرزمینی عمده‌ترین منبع آب شیرین در مناطق خشک جهان مانند ایران، که میزان منابع آب سطحی ناچیز است، به شمار می‌رود (Masoud et al., 2018). با توجه به اینکه کشور ایران در مقایسه با اکثر مناطق دنیا دارای کمبود بارندگی سالانه بوده، جایگزینی منابع آبی تخلیه شده از آبخوان‌ها ممکن است دهه‌ها یا هزاران سال طول بکشد و به دلیل وجود تغییرات آب و هوایی، امکان بدتر شدن شرایط منابع آبی نیز وجود دارد (Baghvand et al., 2010; Gleeson et al., 2010). از این رو درک صحیح و بهره‌برداری اصولی از منابع آب زیرزمینی در مناطق خشک و نیمه‌خشک نظیر ایران می‌تواند در توسعه پایدار فعالیت‌های مختلفی نظیر کشاورزی، اقتصادی و اجتماعی مؤثر واقع گردد.

در مدیریت منابع آب بررسی نوسانات تراز آب زیرزمینی از اهمیت بسزایی در تخمین مقادیر آبی حجم آب زیرزمینی برخوردار است. بهره‌برداری از منابع آب زیرزمینی به عنوان جایگزین کمبود آب در مصارف مختلف صورت می‌گیرد. لذا نیاز به مدیریت یکپارچه این منابع بیش از پیش احساس می‌شود و پیش‌بینی تراز سطح آب زیرزمینی جهت برنامه‌ریزی مدیریت یکپارچه منابع آب امری ضروری است. مدل‌های عددی و هوش مصنوعی گوناگونی در سیستم تحلیل محاسبات نرم<sup>۱</sup> برای شبیه‌سازی این فرایند پیچیده توسط محققین پیشنهاد شده است

<sup>2</sup> Ottawa Plain

<sup>3</sup> Artificial Neural Network

<sup>4</sup> Support Vector Machine

<sup>1</sup> Soft Computing



غیرخطی در دشت بستان آباد استفاده کردند. نتایج آنها نشانگر کاهش متوسط خطای هر دسته در مدل هوش مصنوعی مرکب نسبت به مدل‌های منفرد به مقدار میانگین ۱۷٪ در مقادیر RMSE بود. قبادی و همکاران (۱۳۹۶) به بررسی روند تراز آب زیرزمینی و تأثیر بارندگی و حجم جریان بر روی آن در دشت ارومیه پرداختند. طول دوره آماری سال‌های ۱۳۶۰-۱۳۹۲ در نظر گرفته شد که متوسط سالیانه افت تراز آب زیرزمینی ۵/۹ سانتی‌متر بود و متوسط سالیانه افت تراز از سال ۱۳۸۲ به بعد برابر با ۲۴ سانتی‌متر بگزارش شد. با بکارگیری روش هیبرید ANN-Wavelet، Jeihouni et al. (2019) به بررسی رابطه تغییر تراز آب زیرزمینی با پارامترهای اقلیمی در دشت شبستر پرداختند. نتایج آنان نشان داد که متغیرهای اقلیمی به تنهایی موجب تغییر تراز آب زیرزمینی نمی‌شوند و عوامل انسانی نیز تأثیر بسزایی در نوسانات تراز آب زیرزمینی دارند.

در سال‌های اخیر مدل‌های پیش‌بینی اقلیمی و هیدرولوژیکی برای انجام پیش‌بینی‌های بلندمدت توسط محققین مختلف توصیه شده است. در تحقیق حاضر نیز با توجه به اهمیت تراز آب زیرزمینی و نوسانات آن طی سال‌ها موجب بررسی مدل‌سازی تراز آب زیرزمینی و مقایسه مدل‌ها در مدیریت منابع آب شده است. از این‌رو در این تحقیق برای مدل‌سازی دشت‌ها از چاه‌های پیژومتری دو دشت ارومیه و میان‌دوآب بعنوان نمونه استفاده شده است. در این تحقیق از مدل‌های هوش مصنوعی SVM و شبکه عصبی Wavelet جهت بررسی تغییرات تراز آب زیرزمینی دشت‌های ارومیه و میان‌دوآب استفاده شده است. دلیل انتخاب این دو دشت، قرارگیری هر دو دشت در حوضه دریاچه ارومیه و امکان مقایسه نتایج آنها بوده است. وجود چاه‌های غیرمجاز فراوان در این دشت‌ها افت تراز آب‌های زیرزمینی را در این منطقه در پی داشته است. هدف تحقیق حاضر بررسی تفاوت مدل‌های هوش مصنوعی و انتخاب برترین مدل در

مطالعه شرایط کمی و کیفی آبخوان منطقه نیز با استفاده از مدل‌های فازی<sup>۱</sup>، ANN و نرو فازی (NF)<sup>۲</sup> شبیه‌سازی شد. نتایج نشان داد ترکیب این مدل‌ها در مقایسه با کاربرد مدل‌ها به صورت مجزا، نتایج بهتری را ارائه می‌نماید. (Imani et al. (2014) تغییرات سطح آب دریای خزر را با مدل‌های هوش مصنوعی، SVM<sup>۳</sup> و GEP<sup>۴</sup> بررسی کردند. نتایج حاصل نشان داد که مدل SVM نسبت به مدل‌های دیگر از برتری بالایی با  $R^2=0/96$  و  $RMSE=0/035$  (m) برخوردار است. (Ahmadi et al. (2015) با کمک برنامه‌ریزی ژن<sup>۵</sup> (GP) و SVM به تخمین دبی روزانه در رودخانه باراندوزچای پرداختند. آنها دریافتند که مدل GP با  $R=0/978$  و  $RMSE=1/66$  (m<sup>3</sup>/sec) از مدل SVM با  $R=0/976$  و  $RMSE=1/80$  (m<sup>3</sup>/sec) از دقت بالایی برخوردار بوده اما مدل SVM نسبت به GP کاربر پسند است. (Nourani et al. (2016) مطالعه‌ای نشان دادند که مدل مکانی-زمانی ANN (STANN) از مدل‌های دو هیبریدی عصبی-ژئواستاتیکی<sup>۶</sup> (NG) و چند متغیره سری زمانی-ژئواستاتیکی<sup>۷</sup> (TSG) عملکرد بهتری در خصوص شبیه‌سازی تراز آب زیرزمینی داشته است. ندیری و همکاران (۱۳۹۶) جهت بررسی کارایی سه مدل شبکه‌های عصبی پیش‌رو<sup>۸</sup> (FNN) شبکه‌های عصبی برگشتی<sup>۹</sup> (RNN) و برنامه‌ریزی بیان ژن (GEP) و دستیابی به نتیجه بهتر، از روش ترکیبی مدل‌های هوش مصنوعی با کمک ANN به عنوان ترکیب کننده

<sup>1</sup> Fuzzy Models

<sup>2</sup> Neuro-Fuzzy

<sup>3</sup> Genetic Express Programming

<sup>4</sup> Genetic Programming

<sup>5</sup> Neural-Geostatic Models

<sup>6</sup> Multivariate Time Series-Geostatic Model

<sup>7</sup> Forward Neural Network Model

<sup>8</sup> Return Neural Network Model

داده‌های آزمون (مشاهداتی)، مدیریت منابع آب زیرزمینی را بصورت کاربردی با کمک ۲۰٪ داده‌های آزمون محاسباتی انجام داد.

برای مدل‌سازی در محیط نرم‌افزار MATLAB با استفاده از ماشین بردار پشتیبان SVM و شبکه عصبی موجک WAVELET آماده شوند. همانطور که در شکل ۱ مشاهده می‌شود، سه حلقه چاه پیرومتری از دشت ارومیه با دایره‌های توپر و سه حلقه چاه پیرومتری از دشت میان‌دوآب با مثلث‌های توپر نشان داده شده است. در شکل ۱ موقعیت جغرافیایی منطقه مورد مطالعه شامل دشت‌های ارومیه و میان‌دوآب و چاه‌های پیرومتری آنها نشان داده شده است. از بین چاه‌های پیرومتری مشاهداتی دشت‌ها، سه حلقه چاه پیرومتری دشت ارومیه با تراز آب ۱۳۲۰/۳۷، ۱۲۹۵/۶۰ و ۱۲۹۳/۶۳ و سه حلقه چاه پیرومتری دشت میان‌دوآب با تراز آب ۱۲۸۶/۱۳، ۱۳۲۶/۷۳ و ۱۳۰۵/۲۱ با توجه به هم‌پوشانی منطقه انتخاب شدند تا با استفاده از پارامترهای تراز آب زیرزمینی، بارش و دما، نوسانات تراز آب زیرزمینی مورد بررسی قرار گیرند.

در این تحقیق ۴ سناریو در هر دو دشت ارومیه و میان‌دوآب شامل: تراز آب زیرزمینی - تراز آب زیرزمینی با یک ماه تأخیر، تراز آب زیرزمینی - تراز آب زیرزمینی با دو ماه تأخیر، تراز آب زیرزمینی - دما و تراز آب زیرزمینی - بارش در نظر گرفته شد. هم‌چنین متغیرهای بارش، دما و سطح آب زیرزمینی در یک ماه قبل و حال به عنوان ورودی مدل‌ها با در نظر گرفتن سناریوهای مختلف برای شش حلقه چاه پیرومتری دشت‌های ارومیه و میان‌دوآب مورد استفاده قرار گرفتند. هدف از انتخاب تأخیرها در پیش‌بینی نوسانات تراز آب زیرزمینی چاه‌های پیرومتری برای مقایسه تأثیرپذیری متغیرهای دما و بارش بر روی تغییرات تراز آب زیرزمینی و مقایسه مدل‌های SVM و WAVELET با یکدیگر بوده است. تأخیرها صرفاً تا

منطقه مورد نظر با اعمال متغیر دما و بارش در تأثیر روی نوسانات تراز آب زیرزمینی می‌باشد تا بتوان با استفاده از ۸۰٪ داده‌های آموزش (مشاهداتی) و ۲۰٪

## روش تحقیق

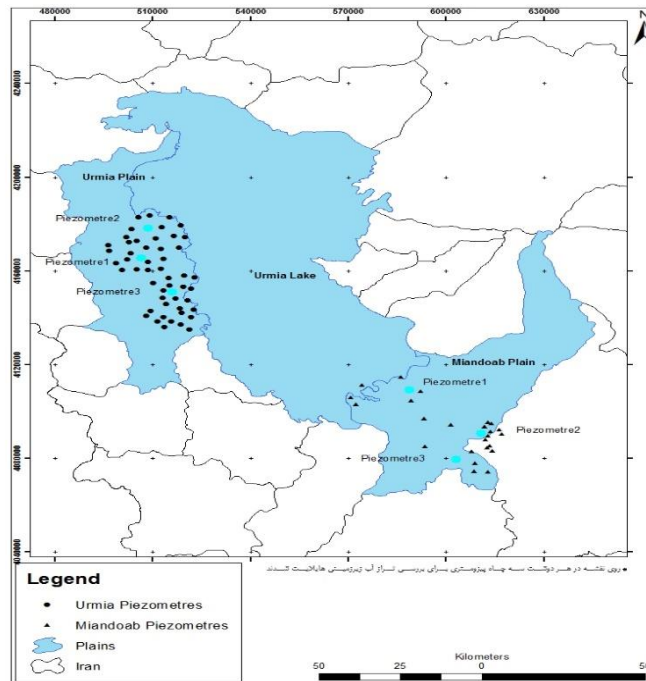
### منطقه مورد مطالعه

در تحقیق حاضر نوسانات تراز آب زیرزمینی دشت‌های ارومیه و میان‌دوآب به‌منظور مقایسه و انتخاب روش‌های واسنجی بهتر برای شبیه‌سازی شرایط آبی و جلوگیری از خسارات تخمینی مورد بررسی قرار گرفتند. دشت‌های ارومیه و میان‌دوآب جزء زیرحوضه‌های دریاچه ارومیه به شمار می‌روند. دشت ارومیه با طول جغرافیایی ۴۶ درجه و ۱۳ دقیقه و ۳۹ ثانیه و عرض جغرافیایی ۳۶ درجه و ۲ دقیقه و ۱۷ ثانیه و دشت میان‌دوآب با موقعیت جغرافیایی ۳۶ درجه و ۵۰ دقیقه تا ۳۷ درجه و ۱۵ دقیقه طول شرقی و ۴۵ درجه و ۵۰ دقیقه تا ۴۶ درجه و ۱۵ دقیقه عرض شمالی واقع شده‌اند. دشت ارومیه با مساحت ۹۸۱۰۰ هکتار در اراضی ساحلی و کم شیب ضلع غربی دریاچه ارومیه و دشت میان‌دوآب با مساحتی بالغ بر ۱۲۱۷۰۰ هکتار در بخش جنوبی و جنوب‌شرقی دریاچه ارومیه واقع شده‌اند (شکل ۱). متوسط بارندگی بلندمدت منطقه ۳۰۴ میلی‌متر بوده و از نظر آب و هوایی دارای اقلیم سرد و خشک می‌باشد. در مرحله اولیه داده‌های ماهانه هیدروژئولوژیک تراز آب زیرزمینی مربوط به دشت‌های ارومیه و میان‌دوآب در بازه زمانی ۱۳۸۱ - ۱۳۹۶ سال آبی و داده‌های ماهانه دما و بارش مناطق مورد مطالعه از شرکت سهامی آب منطقه‌ای استان آذربایجان غربی اخذ گردید. هدف، دستیابی به نتیجه کمی برای پیش‌گیری قبل از وقوع کاهش شدید تراز آب زیرزمینی است. با توجه به ناهمگنی آبخوان‌ها، گستردگی پیرومترها و برای جلوگیری از زمان‌بر بودن مدل‌سازی، سه حلقه چاه پیرومتری در هر یک از دشت‌های ارومیه و میان‌دوآب مورد بررسی قرار گرفتند تا با اعمال سناریوهای مورد نظر، داده‌های ورودی



دو ماه برای کاهش حجم نتایج حاصل بوده است و تمرکز اصلی بر روی متغیرهای تراز آب زیرزمینی - ارومیه و میاندوآب می‌باشد.

دما- بارش در ۶ حلقه چاه پیزومتری در دشت‌های



شکل (۱): موقعیت جغرافیایی منطقه مورد مطالعه

## مدل SVM

باشد، ولی در SVM، به دنبال خط یا ابر صفحه‌ای برای محاسبه میزان فاصله آن از نزدیک‌ترین عنصر هر دو دسته، بیشینه می‌باشد.

با فرض مقادیر ورودی و خروجی  $x_i$  و  $y_i$  در این الگوریتم، هدف تابعی است که کمینه انحراف  $\epsilon$  را از  $y_i$ ها داشته باشد.

$$f(x) = (w \cdot x) + b \quad (1)$$

$$(w \cdot x) \in \mathbb{R}^N, b \in \mathbb{R} \quad (2)$$

مقادیر خروجی بایستی طوری تعریف گردند که تابع  $f(x)$  کمترین انحراف تعیین شده و مقدار مناسب  $w$  را انتخاب کند. برای این منظور حل رابطه زیر پیشنهاد شده است (۳۰).

الگوریتم‌های ماشین بردار پشتیبان SVM از دقیق‌ترین و نیرومندترین الگوریتم‌های داده‌کاوی به شمار می‌روند که اولین بار توسط Vapnik (1998) به عنوان روشی برای طبقه‌بندی و رگرسیون پیشنهاد شد. رگرسیون داده‌ها به وسیله الگوریتم خطی‌سازی  $\epsilon$ -SVR و با تعریف تابع  $\epsilon$ -sensitive صورت می‌پذیرد. الگوریتم SVM که بر اساس کاهش ریسک ساختاری استوار است، از توانایی تعمیم خوبی برخوردار است (Vapnik, 1998) محاسبات الگوریتم SVM به قدری پیچیده است که سریع‌ترین آن‌ها هم به کندی عمل می‌کند. هدف کلی، جداسازی داده‌ها و دسته‌بندی آن‌ها در دو کلاس مختلف توسط منحنی‌ها یا ابرصفحه‌هاست. با وجود این که ممکن است جواب‌های متفاوتی برای این جداسازی وجود داشته

### واسنجی مدل‌ها

استفاده از رگرسیون و مدل‌های مبتنی بر آن از قدمت زیادی در حل و مدل‌سازی مسائل هیدرولوژیکی برخوردار است. به‌وسیله یک رابطه رگرسیونی با معلوم بودن مقادیر متغیرهای مستقل، مقدار متغیر وابسته را می‌توان تخمین زد. روش تحلیلی محاسبه ضرایب مدل رگرسیون روش موسوم به حداقل مربعات خطا می‌باشد و هر چه مقدار آن کم‌تر باشد آنگاه مدل دارای خطای کم‌تری خواهد بود.

$$MSE = \sum_{i=0}^n (y_i - \hat{y}_i)^2 \quad (5)$$

در رابطه فوق  $\hat{y}$  تخمینی از متغیر وابسته  $y$  و  $n$  تعداد داده‌های مشاهداتی می‌باشد. میزان ارتباط بین متغیرهای مستقل و وابسته به‌وسیله ضریب همبستگی بدست می‌آید.

$$R = \frac{\sum x_i y_i - N \bar{x} \bar{y}}{\sqrt{\sum x_i^2 - N \bar{x}^2} \sqrt{\sum y_i^2 - N \bar{y}^2}} \quad (6)$$

### نتایج و بحث

در تحقیق حاضر، نوسانات تراز آب زیرزمینی دشت‌های ارومیه و میاندوآب به‌منظور مقایسه و انتخاب بهترین روش محاسبات نرم برای شبیه‌سازی شرایط آبی و جلوگیری از خسارات تخمینی مورد بررسی قرار گرفتند. هدف، دست‌یابی به نتیجه کمی برای پیش‌گیری قبل از وقوع کاهش شدید تراز آب زیرزمینی است. همان‌طور که پیش‌تر ذکر شد برای همگنی داده‌ها از بین چاه‌های پیژومتری موجود در دشت‌های ارومیه و میاندوآب صرفاً سه حلقه چاه از هر دشت که هم‌پوشانی لازم را در منطقه ایجاد می‌کردند به‌عنوان داده‌های ورودی انتخاب شدند. بدین‌گونه داده‌های تراز آب زیرزمینی - دما - بارش به‌عنوان عوامل تأثیرپذیر در سناریوهای مورد نظر در کل برای ۶ حلقه

$$\min \frac{1}{2} w^2 + C \sum_{i=1}^n (\xi_i - \xi_i^*) \quad (3)$$

$$\left\{ \begin{array}{l} y_i - (w \cdot x_i) - b \leq \varepsilon + \xi_i \\ (w \cdot x_i) + b - y_i \leq \varepsilon + \xi_i \\ \xi_i, \xi_i^* \geq 0 \text{ - for all } i=1,2,\dots,k \end{array} \right. \quad (4)$$

در روابط فوق  $C$  خطای تولید بوده و برای مشخص نمودن رابطه جایگزین تابع  $f(x)$  مورد استفاده قرار می‌گیرد.

### مدل WAVELET

شبکه عصبی موجک (Wavelet) دسته‌ای از توابع ریاضی هستند که برای تجزیه سیگنال پیوسته به مؤلفه‌های فرکانسی آن بکار می‌رود که وضوح هر مؤلفه برابر مقیاس آن است. تبدیل موجک، تجزیه یک تابع بر مبنای توابع موجک است. تفاوت اصلی مدل‌های مفهومی (هوش مصنوعی) در مقایسه با مدل‌های آماری این است که به‌جای استفاده از معادلات فیزیکی و آماری از تجربیات و مشاهدات قبلی اطلاعات مورد نظر بعنوان خروجی استخراج می‌شود. هدف استفاده از مدل‌های شبکه عصبی شبیه‌سازی روابط درونی تراز آب زیرزمینی بعنوان متغیر وابسته و متغیرهای اقلیمی بارش و دما بعنوان متغیر مستقل برای واسنجی مدل‌هاست. مقادیر محاسباتی تراز آب زیرزمینی ماهانه با معیار واسنجی مدل از طریق محاسبه خطای میانگین مربعات (MSE) و رگرسیون ( $R^2$ ) بعنوان خروجی مدل برای مقایسه و تحلیل رگرسیون در نظر گرفته شدند. مقادیر تراز آب زیرزمینی چاه‌های پیژومتری، دما و بارش در گام زمانی فعلی و قبلی (ماه جاری، یک ماه قبل و دو ماه قبل) به‌عنوان متغیرهای مستقل  $T_{i-1}$ ،  $T_{i-2}$  و  $T_{i-3}$  و مقادیر تراز آب زیرزمینی چاه‌های پیژومتری در گام زمانی آینده (یک ماه و دو ماه بعد) بعنوان متغیر وابسته  $T_{i+1}$  و  $T_{i+2}$  در سناریوها در نظر گرفته شد.



میانگین مربعات دشت میاندوآب،  $MSE_U$  (خطای میانگین مربعات دشت ارومیه)،  $R^2_M$  (رگرسیون دشت میاندوآب) و  $R^2_U$  (رگرسیون دشت ارومیه) برای سه سناریو ارائه شده است. بهترین سناریو برای هر دو دشت نتایج مربوط به تراز آب زیرزمینی-دما جهت بررسی است چون هدف دستیابی به یک نتیجه واحد در بررسی تغییرات آب زیرزمینی در هر دو دشت است. همانطور که در جدول ۱ ملاحظه می‌شود هرچه مقدار  $R^2$  نزدیک به یک باشد و  $MSE$  مقدار کم‌تری را داشته باشد آنگاه سناریو مورد نظر قابل قبول خواهد بود. در نتایج دیده می‌شود که در دو چاه مورد بررسی هر دو دشت ارومیه و میاندوآب در تحلیل نرم-افزاری SVM، مقدار  $R^2$  حدود ۰/۸ و  $MSE$  حدود ۰/۴ می‌باشد از اینرو تحلیل سناریوها در مدل SVM نتایج قابل قبولی را ارائه داده است. نتایج به دست آمده با نتایج مطالعات اسمی‌خانی و همکاران (۱۳۸۹)، کماسی و همکاران (۱۳۹۶) و Shiri et al. (2013) مطابقت دارد.

هم‌چنین در شکل‌های ۲ و ۳ داده‌های مشاهداتی تراز آب زیرزمینی در مرحله آزمون در مقابل داده‌های محاسباتی تراز آب زیرزمینی در مرحله آزمون قرار داده شده‌اند و به ترتیب مربوط به چاه دوم پیرومتری دشت ارومیه و چاه سوم پیرومتری دشت میاندوآب می‌باشند. تحلیل رگرسیون در هر دو دشت حاکی از آن است، مدل SVM برای دشت ارومیه مناسب‌تر می‌باشد همان‌طور که نتایج کماسی و همکاران (۱۳۹۶)، Natarajan & Sudheer (2020) و Pourghasemi et al. (2020) نشان داد که SVM عملکرد بهتری در پیش‌بینی تراز آب زیرزمینی چاه‌های مذکور داشته است.

چاه پیرومتری دشت‌های ارومیه و میاندوآب بعنوان ورودی در مدل‌سازی مورد استفاده قرار گرفتند.

هدف از انتخاب تأخیرهای زمانی در پیش‌بینی نوسانات تراز آب زیرزمینی چاه‌های پیرومتری برای مقایسه تأثیرپذیری متغیرهای مستقل دما و بارش بر روی تغییرات تراز آب زیرزمینی و مقایسه مدل‌های SVM و WAVELET با یکدیگر بوده است که بعنوان مثال داده‌های مربوط به دومین پیرومتر منتخب دشت ارومیه نیز به دو قسمت شامل ۸۰٪/ داده‌های آموزش و ۲۰٪/ داده‌های آزمون تقسیم‌بندی شدند. هم‌چنین تأخیرها صرفاً تا دو ماه برای کاهش حجم نتایج حاصل بوده است و مانور اصلی بر روی متغیرهای تراز آب زیرزمینی-دما- بارش در ۶ حلقه چاه پیرومتری در دشت‌های ارومیه و میاندوآب می‌باشد. با توجه به نتایج حاصل از مدل‌ها نیز تأخیر یک ماهه دارای نتایج قابل قبول در سناریوها بوده است.


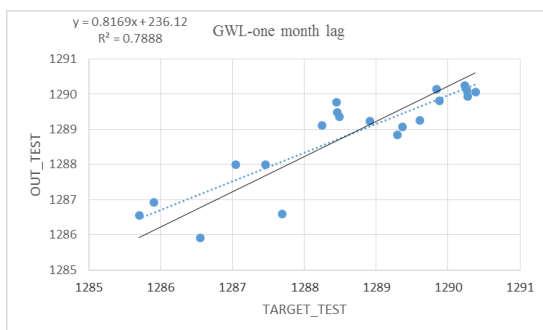
## مدل SVM

### دشت ارومیه


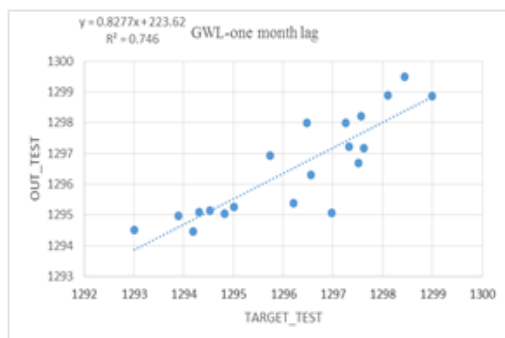
با بررسی خطاها و تحلیل رگرسیون، چاه پیرومتری دوم دشت ارومیه بعنوان مناسب‌ترین و چاه پیرومتری سوم دشت میاندوآب در مدل SVM دارای نتایج بهتری بودند. در نتایج مربوط به تراز آب زیرزمینی با دو ماه تأخیر،  $R^2$  دارای مقدار غیرقابل قبولی بود از این‌رو در تحقیق قابل استفاده نمی‌باشد. پس از بین ۴ سناریوی پیشتر ذکر شده، سناریوی تراز آب زیرزمینی-تراز آب زیرزمینی با دو ماه تأخیر حذف شد. در جدول ۱ مقادیر  $MSE_M$  (خطای

جدول (۱): چاه پیزومتري دوم دشت اروميه و چاه پیزومتري سوم دشت مياندوآب در تحليل مدل SVM

توصيف	رگرسيون دشت اروميه ( $R^2$ )	خطای میانگین مربعات دشت اروميه ( $MSE_U$ )	رگرسيون دشت مياندوآب ( $R^2$ )	خطای میانگین مربعات دشت مياندوآب ( $MSE_M$ )
آب زیرزمینی با یک ماه تأخیر	۰/۷۸	۰/۴۸۷۲	۰/۷۴	۰/۸۱۲۴
تراز آب زیرزمینی - بارندگی	۰/۷۷	۰/۵۱۱۹	۰/۷۱	۰/۹۴۰۲
تراز آب زیرزمینی - دما	۰/۸۸	۰/۴۰۰۶	۰/۷۱	۰/۸۶۵۳



شکل (۲): سناریوهای اعمال شده در چاه دوم پیزومتري در دشت اروميه



شکل (۳): سناریوهای اعمال شده در چاه سوم پیزومتري در دشت مياندوآب

نرم افزار SVM، در مدل Wavelet نیز ۳ سناریوهای تراز آب زیرزمینی با یک ماه تأخیر، تراز آب زیرزمینی - بارش و تراز آب زیرزمینی - دما مورد بررسی قرار گرفتند. معیار ارزیابی سناریوهای مد نظر در تحقیق حاضر تحلیل رگرسيون و تعیین مقادیر  $R^2$  و  $MSE$  می باشد. در جدول ۲،  $MSE_M$  (خطای

### مدل Wavelet دشت اروميه

در تحلیل مدل Wavelet مربوط به دشت های اروميه و مياندوآب از بين سه حلقه چاه پیزومتري منتخب، چاه دوم دشت اروميه و چاه سوم دشت مياندوآب نتایج بهتری را ارائه دادند. به مانند تحلیل

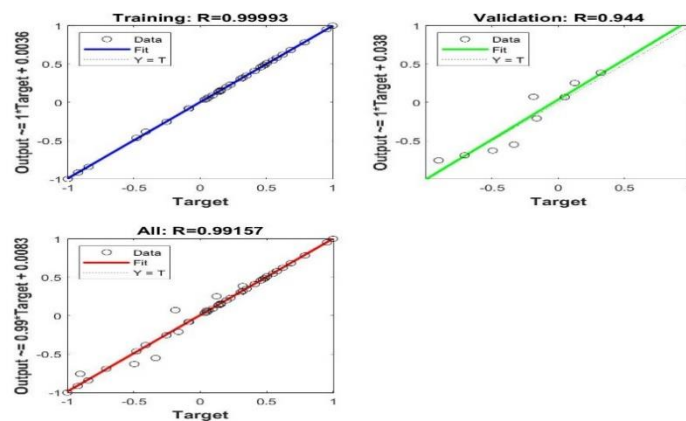


ملاحظه می‌شود که در کل مدل Wavelet نیز در هر دو دشت‌های ارومیه و میاندوآب عملکرد بهتری داشته است و هم‌چنین در این مدل، سناریوی تراز آب زیرزمینی-دما دارای رگرسیون پایین‌تری در هر دو دشت بوده است و مدل Wavelet برای دشت ارومیه بمانند مدل SVM دارای نتایج بهتری می‌باشد. همان‌طور که (Suryanarayana et al. (2014) و (Yadav & Eliza (2017) در نتایج خود نشان دادند مدل Wavelet به‌تنهایی واجد شرایط و دقت کافی برای پیش‌بینی تغییرات تراز آب زیرزمینی و ترکیب آن با مدل SVM و سایر مدل‌های هوش مصنوعی است. به این دلیل از داده‌های خروجی از مدل Wavelet در بیش‌تر موارد بعنوان داده‌های ورودی در ترکیب با سایر مدل‌ها مثل مدل SVM است.

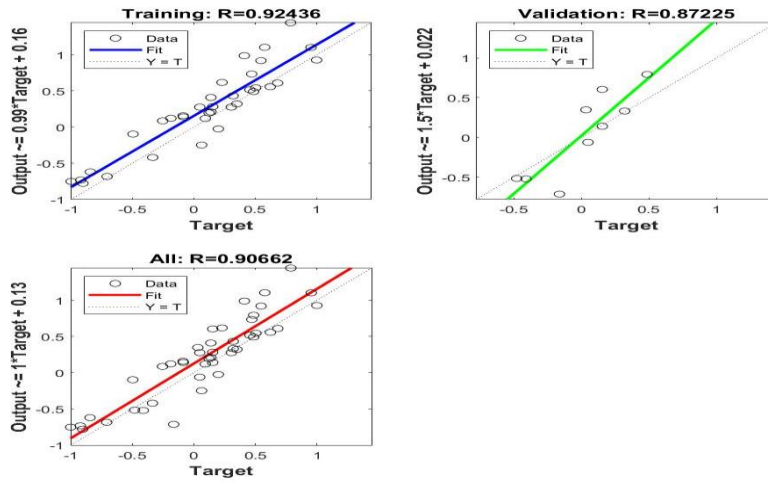
میانگین مربعات دشت میاندوآب،  $MSE_U$  (خطای میانگین مربعات دشت ارومیه)،  $R^2_M$  (رگرسیون دشت میاندوآب) و  $R^2_U$  (رگرسیون دشت ارومیه) مربوط به سه سناریوی مرتبط برای ارزیابی هر دو دشت ارائه شدند. نتایج نشان داد بهترین سناریو با  $R^2$  حدود ۰/۹ برای هر دو دشت و  $MSE$  با مقدار (حدود ۰/۵ برای دشت میاندوآب و حدود ۱ برای دشت ارومیه) برای تراز آب زیرزمینی با یک ماه تأخیر می‌باشد. اشکال ۴ تا ۹ نیز خروجی تحلیل رگرسیونی داده‌های محاسباتی تراز آب زیرزمینی آموزش و آزمون را در مقابل داده‌های مشاهداتی تراز آب زیرزمینی آموزش و آزمون دو چاه منتخب در دشت‌های ارومیه و میاندوآب انجام گرفته در مدل Wavelet را نشان می‌دهند. از بررسی نتایج  $R^2$  و  $MSE$  در جدول ۲

جدول (۲): چاه پیزومتری دوم دشت ارومیه و چاه پیزومتری سوم در تحلیل مدل Wavelet

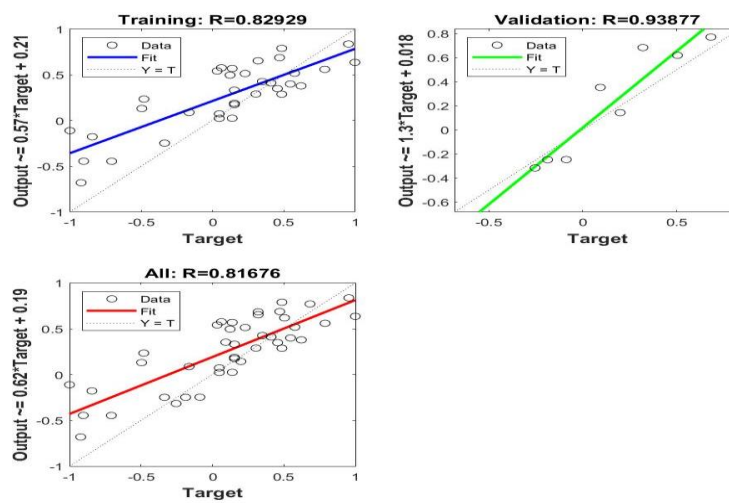
توصیف	رگرسیون دشت ارومیه ( $R^2$ )	خطای میانگین مربعات دشت ارومیه ( $MSE_U$ )	رگرسیون دشت میاندوآب ( $R^2$ )	خطای میانگین مربعات دشت میاندوآب ( $MSE_M$ )
آب زیرزمینی با یک ماه تأخیر	۰/۹۸	۰/۵۸۱۷	۰/۹۴	۱/۰۲۴۲
تراز آب زیرزمینی- بارش	۰/۸۱	۱/۴۰۰۵	۰/۸۳	۱/۱۰۶۲
تراز آب زیرزمینی- دما	۰/۶۶	۱/۴۳۲۲	۰/۶۰	۰/۹۳۹۸



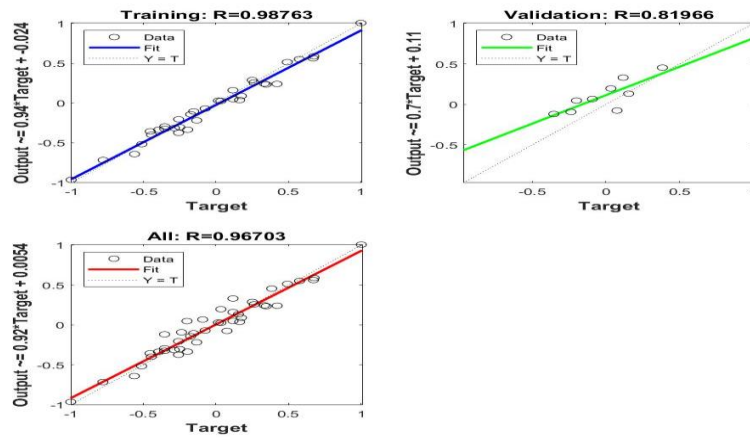
شکل (۴): چاه پیزومتر دوم دشت ارومیه: تحلیل رگرسیون تراز آب زیرزمینی با یک ماه تأخیر



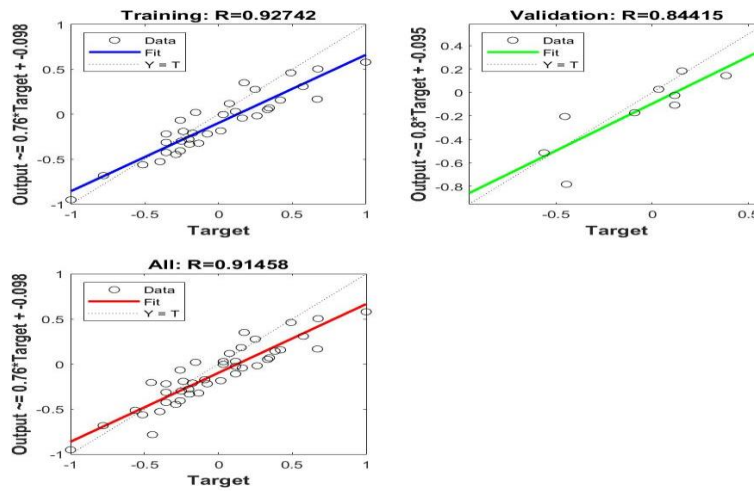
شکل (۵): چاه پیزومتر دوم دشت ارومیه: تحلیل رگرسیون تراز آب زیرزمینی - بارش



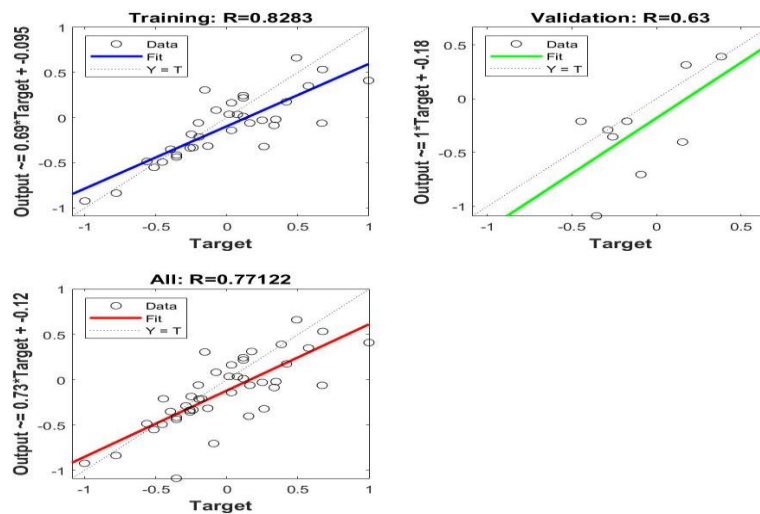
شکل (۶): چاه پیزومتر دوم دشت ارومیه: تحلیل رگرسیون تراز آب زیرزمینی - دما



شکل (۷): چاه پیزومتر سوم دشت میاندوآب: تحلیل رگرسیون تراز آب زیرزمینی با یک ماه تأخیر



شکل (۸): چاه پیزومتر سوم دشت میاندوآب: تحلیل رگرسیون تراز آب زیرزمینی - بارش



شکل (۹): چاه پیزومتر سوم دشت میاندوآب: تحلیل رگرسیون تراز آب زیرزمینی - دما

## نتیجه گیری

نوآوری و هدف در تحقیق حاضر، بررسی نوسانات تراز آب زیرزمینی در دشت‌های ارومیه و میاندوآب در دو مدل متفاوت محاسبات نرم با تحلیل هوش مصنوعی SVM و شبکه عصبی Wavelet و همچنین مقایسه نتایج آنها با یکدیگر بوده است تا عملکرد بهتر این مدل‌ها بررسی گردد. در ابتدا به منظور رعایت همگنی اطلاعات تراز آب زیرزمینی دشت‌ها، سه حلقه چاه پیزومتری از میان کل پیزومترهای منطقه با توجه به هم‌پوشانی و تأمین داده‌های دقیق شده، انتخاب شدند که ۸۰٪ داده‌های برای آموزش و ۲۰٪ داده‌ها برای آزمون استفاده شدند. چاه پیزومتری دوم دشت ارومیه با تراز ۱۲۹۵/۶۰ متر و چاه پیزومتری سوم دشت میاندوآب با تراز ۱۳۰۵/۲۱ متر انتخاب شدند. معیار انتخاب بهترین مدل نیز با تحلیل رگرسیون و تعیین مقادیر خطاهای MSE و  $R^2$  بوده است، زیرا به‌وسیله یک رابطه رگرسیونی با معلوم بودن مقادیر متغیرهای مستقل، مقدار متغیر وابسته را می‌توان تخمین زد. با استفاده از داده‌های تراز آب زیرزمینی، و پارامترهای اقلیمی دما و بارش در بازه زمانی ۱۳۸۱-

۱۳۹۶ هر دو دشت با ۴ سناریو مورد بررسی قرار گرفتند. هدف از انتخاب یک ماه تأخیر و دو ماه تأخیر به جهت صرفاً مقایسه نتایج بوده و برای جلوگیری از حجم بالای تحلیل نتایج از این دو تأخیر استفاده شده است. نتایج حاصل نشان داد که در تحلیل رگرسیون هر دو دشت، تأخیر یک ماهه تراز آب زیرزمینی در دو مدل نتیجه مقبولی را نسبت به تأخیر دو ماهه تراز آب زیرزمینی دشت‌ها داشته است. از این رو در جداول تحلیل رگرسیون نتایج هر دو دشت صرف‌نظر از تأخیر دو ماهه تراز آب زیرزمینی، ۳ سناریو مورد بررسی قرار گرفتند. چاه‌های پیزومتری دوم در دشت ارومیه و سوم در دشت میاندوآب در مدل SVM با مقدار  $R^2$  حدود ۰/۸ و MSE حدود ۰/۴ می‌باشد در سناریوهای مذکور و در مدل Wavelet مناسب‌ترین خروجی‌های مدل برای سناریوی تراز آب زیرزمینی با یک ماه تأخیر دارای  $R^2$  حدود ۰/۹ و MSE با مقدار (حدود ۰/۵ برای دشت میاندوآب و حدود ۱ برای دشت ارومیه) است. در حالت کلی، در تمام چاه‌ها یک ماه تأخیر در تراز آب زیرزمینی به نسبت دو ماه تأخیر در تراز آب زیرزمینی، مدل‌های مذکور بهترین نتیجه را ارائه می‌دهند و مشاهده می‌شود که داده‌های اقلیمی



مدل برای دشت ارومیه نتایج قابل قبولی را ارائه کرده است. هم‌چنین سناریوهای تراز آب زیرزمینی با تأخیر یک ماهه و تراز آب زیرزمینی-بارش دارای تأثیر بالاتری در بررسی تراز آب زیرزمینی دو دشت ارومیه و میاندوآب بوده است. در بسیاری از تحقیقاتی که توسط محقق بررسی نوسانات تراز آب زیرزمینی انجام شده است، همگی متمرکز بر ترکیب مدل‌ها از ابتدای کار بوده است ولی در تحقیق حاضر هدف بررسی یکایک مدل‌ها و مقایسه صلاحیت استفاده از آنها بصورت منفرد در کارهای پژوهشی می‌باشد.

بارش تأثیر بسزایی در نوسانات تراز آب زیرزمینی داشته است. نتایج نشان دادند که از بین چاه‌های منتخب دشت‌های ارومیه و میاندوآب هر کدام به-ترتیب چاه دوم و سوم دارای  $R^2$  بیش‌تر و MSE کم‌تر بوده است و از بین سناریوها، بجز سناریوی تراز آب زیرزمینی-دما در مدل SVM و Wavelet بهترین نتیجه را ارائه دادند. در هر دو دشت، بهترین خروجی مربوط به مدل Wavelet در مقایسه با مدل SVM بدلیل دقت بالاتر در مقدار  $R^2$  بوده است از این رو است که در بیش‌تر موارد از داده‌های خروجی مدل wavelet بعنوان ورودی در سایر مدل‌های هوش مصنوعی استفاده می‌گردد. در حالت کلی نیز هر دو

- ✓ دشت ارومیه در مقایسه با دشت میاندوآب دارای نتایج با دقت بالاتری در بررسی نوسانات تراز آب زیرزمینی در شبیه‌سازی مدل SVM و WAVELET بوده است.
- ✓ مدل WAVELET در مقایسه با مدل SVM عملکرد بهتری در تغییرات سطح آب زیرزمینی با توجه به مقدار  $R^2$  بالاتر داشته است.
- ✓ سناریوی تراز آب زیرزمینی با تأخیر یک ماهه و تراز آب زیرزمینی-بارش دارای تأثیر بالاتری در نوسانات سطح آب زیرزمینی نسبت به سناریوی تراز آب زیرزمینی-دما بوده است.
- ✓ به‌ترتیب سناریوهای تأخیر یک ماهه در تراز آب زیرزمینی، تراز آب زیرزمینی-بارش و تراز آب زیرزمینی-دما تأثیر زیادی در مقایسه تغییرات تراز آب زیرزمینی هر دو دشت ارومیه و میاندوآب داشته‌اند.

## منابع

- اسمی‌خانی م.، صفوی ح.ر. و یزدانی‌پور م. (۱۳۸۹). مدیریت تلفیقی منابع آب سطحی و زیرزمینی با کاربرد روش‌های ماشین‌های بردار پشتیبان و الگوریتم ژنتیک. پنجمین کنگره ملی مهندسی عمران. دانشگاه فردوسی، مشهد، ایران.
- قبادی، س.، عبقری، ه. و عرفانیان، م. (۱۳۹۶). تحلیل نوسانات هیدروگراف تراز آب زیرزمینی و معرفی مناسب‌ترین معادله در غرب دریاچه ارومیه. مدیریت سامانه‌های منابع آب. جلد ۱(۲): ۲۵-۳۶.
- کماسی، م.، گودرزی، ح. و بهنیا، ا. (۱۳۹۶). بررسی نوسانات مکانی-زمانی سطح ایستابی آب‌های زیرزمینی به روش ماشین‌بردار پشتیبان (SVM) و کریجینگ (Kriging) (مطالعه موردی: دشت سیلاخور). پژوهش‌های حفاظت آب و خاک. ۲۴ (۴): ۱۹۵-۲۰۹.

ندیری، ع. ا.، اصغری مقدم، ا.، عبقری، ه. و فیجانی، ا. (۱۳۹۲). توسعه مدل هوش مصنوعی مرکب در برآورد قابلیت انتقال آبخوان، مطالعه موردی: دشت تسوج. تحقیقات منابع آب ایران. ۹(۱): ۱-۱۴.

ندیری، ع.، طاهرخانی، ز. و صادقی اقدم، ف. (۱۳۹۶). پیشبینی سطح آب زیرزمینی دشت بستان آباد با استفاده از ترکیب نظارت شده مدل‌های هوش مصنوعی. تحقیقات منابع آب ایران. ۱۳(۳): ۴۳-۵۵.

Affandi, A. and Watanabe, K. 2007. Daily groundwater level fluctuation forecasting using soft computing technique. *Natural science*, 5:1-10

Ahmadi, F., Radmanesh, F. and Mirabbasi Najaf Abadi, R. 2015. Comparison between Genetic Programming and Support Vector Machine methods for daily river flow forecasting (case study: Baranduzchay river). *Water and Soil (Agricultural Sciences and Technology)*, 28(6):1162:1171.

Baghvand, A., Nasrabadi, T., Bidhendi, G.N., Vosoogh, A., Karbassi, A. and Mehrdadi, N. 2010. Groundwater quality degradation of an aquifer in Iran central desert. *Desalination*, 260 (1-3): 264-275.

Chang, F.J., Chang, L.C., Huang, C.W. and Kao, I.O. 2016. Prediction of monthly regional groundwater levels through hybridsoft-computing techniques. *Hydrology*, 541: 965-976.

Coppola, E., Rana, A., Poulton, M., Szidarovszky, F. and Uhl, V. 2005. A neural network model for predicting water table elevations. *Ground Water*, 43: 231-241.

Coulibaly, P., Anctil, F., Aravena, R. and Bobee, B. 2001. Artificial neural network modeling of water table depth fluctuations. *Water Resources Research*, 37 (4): 885-896.

Daliakopoulos, L., Coulibaly, P. and Tsanis, I. 2005. Ground water level forecasting using artificial neural networks. *Hydrology*, 309: 229-240.

Dash, N.B., Panda, S.N., Ramesan, R. and Sahoo, N. 2010. Hybrid neural modeling for groundwater level prediction. *Neural Computing and Applications*, 19: 1253-1261.

Gleeson, T., VanderSteen, J., Sophocleous, M.A., Taniguchi, M., Alley, W.M., Allen, D.M. and Zhou, Y. 2010. Groundwater sustainability strategies. *Nature Geoscience*, 3(6): 378-379.

Imani, M., You, R.J. and Kuo, C.Y. 2014. Forecasting Caspian Sea level changes using satellite altimetry data (June 1992-December 2013) based on evolutionary support vector regression algorithms and gene expression programming. *Global and Planetary Change*, 121:53-63.

Jeihouni, E., Eslamian, M.S., Mohammadi, M. and Zareian, M.J. 2019. Simulation of Groundwater Level Fluctuations in Response to Main Climate Parameters using a Wavelet-ANN Hybrid Technique for the Shabestar Plain, Iran. *Proceedings Journal of Environmental Earth Sciences*, 78: 1-9.

Jianhua, P., Yu, Q. and Ma, X. 2013. A combination model of chaos, Wavelet and Support Vector Machine predicting groundwater levels and its evaluation using three comprehensive quantifying techniques. *Information Technology*, 12: 3158-3163.

Masoud, M.H.Z., Basahi, J.M. and Zaidi, F.K. 2018. Assessment of artificial groundwater recharge potential through estimation of permeability values from infiltration and aquifer tests in unconsolidated alluvial formations in coastal areas. *Environmental Monitoring Assessment*, 191(1): 2-16.

Nadiri, A., Gharekhani, M., Khatibi, R., Sadeghfam, S. and Asghari Moghaddam, A. 2017. Groundwater vulnerability indices conditioned by supervised intelligence committee machine (SICM). *Science of the Total Environment*, 574: 691-706.

Naghibi, S.A., Pourghasemi, H.R., & Dixon, B. 2016. GIS-based groundwater potential mapping using boosted regression tree, classification and regression tree, and random forest machine learning models in Iran. *Environmental Monitoring Assessment*, 188 (1): 44.

Natarajan, N., & Sudheer, C.h. 2020. Groundwater level forecasting using soft computing techniques. *Neural Computing and Applications*, 32: 7691- 7708.

Nayak, P.C., Rao, Y.R.S. and Sudheer, K.P. 2006. Groundwater level forecasting in a shallow aquifer using artificial neural network approach. *Water Resources Management*, 20:77-90.

Nourani, V., Kisi, Ö. and Komasi, M. 2011. Two hybrid artificial intelligence approaches for modeling rainfall-runoff process. *Hydrology*, 402(3): 41-59.

Nourani, V., & Mousavi, S. 2016. Spatio-temporal groundwater level modeling using hybrid artificial intelligence-meshless method. *Hydrology*, 536:10-25.

Pourghasemi, H.R., Sadhasivam, N., Yousefi, S., Tavangar, S., Ghaffari Nazarlou, H., and Santosh, M. 2020. Using machine learning algorithms to map the groundwater recharge potential zones. *Environmental Management*, 265: 1-17.

Sandoval, J.A. and Tiburan, C. L. 2019. Identification of potential artificial groundwater recharge sites in mount makiling forest reserve, Philippines using GIS and analytical hierarchy process. *Applied Geography*, 105: 73-85.

Shiri, J., Kisi, O., Yoon, H., Lee, K. K. and Nazemi, A.H. 2013. Predicting groundwater level fluctuations with meteorological effect implications — A comparative study among soft computing techniques. *Computers & Geosciences*, 56: 32-44.

Suryanarayana, C.h., Sudheer, C.h., Mahammood, V. and Panigrahi, B.K. 2014. An integrated wavelet-support vector machine for groundwater level prediction in Visakhapatnam, India. *Neuro-computing*, 145: 324-335.

Todd, D.K. and Mays, L.W. 2005. *Groundwater Hydrology*. Wiley, Retrieved from. <https://www.wiley.com/en-us/Groundwater+Hydrology%2C3rd+Edition-p-9780471059370>.

Vapnik, V. 1998. *Statistical learning theory*. New York, NY: Wiley, Vol. 1.

Yadav, B., and Eliza, K.h. 2017. A hybrid wavelet-support vector machine model for prediction of Lake water level fluctuations using hydro-meteorological data. *Measurement*, 103: 294-301.

Yang, C.C., Prasher, S.O., Lacroix, R., Sreekanth, S., Patni, N.K and Masse, L. 1997. Artificial neural network model for subsurface drained farmland. *Structural Engineering*, 123: 285-292.

Yoon, H., Jun, S.C., Hyun, Y., Bae, G.O. and Lee, K.K. 2011. A comparative study of artificial neural networks and support vector machines for predicting groundwater levels in a coastal aquifer. *Hydrology*, 396(4):128-138.

## Survey of Groundwater Level Fluctuations by Soft Computing Techniques (Case Study: Urmia and Miandoab Plains)

Farnaz Mohammadi<sup>1</sup>, Mirali Mohammadi<sup>2\*</sup>, Javad Behmanesh<sup>3</sup>, Saeid Jalili<sup>4</sup>

### Abstract

The study of behavior of water level fluctuations is important for water balance due to the unbalanced distribution in the hydrological cycle. In present study, the groundwater level fluctuations of Urmia and Miandoab plains in two models SVM and Wavelet from the group of soft calculations have been investigated. For this purpose, information about the period years of 1381-1386 for both plains of Urmia and Miandoab by considering four scenarios of groundwater level -groundwater level with a delay of one month, groundwater level -groundwater level with a delay of two months, Groundwater level -precipitation and groundwater level -temperature. The simulation results were compared and the best model was introduced. The results of regression analysis showed that  $R^2=0.9$  and  $MSE=0.4$  belong to the second piezometer well of Urmia plain and the third piezometer well of Miandoab plain in both SVM and Wavelet models for 3 scenarios of groundwater level -groundwater level with a delay of one month, Groundwater level was precipitation and groundwater level was temperature. Data on climatic variables of temperature, precipitation and groundwater level with a delay of one month as an independent variable and groundwater level data as a dependent variable formed the mentioned scenarios with 80% of educational data and 20% of test data. The results showed that the climatic variable of precipitation has a significant effect on groundwater level fluctuations. In general, the prediction results of Wavelet model were better than SVM model in investigating groundwater level fluctuations in Urmia and Miandoab plains. In the present study, an independent study of the mentioned models in order to simulate groundwater level fluctuations and compare each of the two models in their application.

**Keywords:** Groundwater Fluctuation, Regression Analysis, SVM, Wavelet

<sup>1</sup> MSc in Water Resources Management Engineering, Faculty of Water and Soil Sciences, Zabol University. Farnazmohammadi7172@gmail.com

<sup>2\*</sup> Associate Professor in Department of Civil Engineering (Hydraulics & River Eng. Mechanics), Faculty of Engineering, Urmia University, P O Box 165, Urmia, Iran. m.mohammadi@urmia.ac.ir

<sup>3</sup> Professor in Department of Water Engineering, Faculty of Agriculture, Urmia University. j.behmanesh@urmia.ac.ir

<sup>4</sup> PhD student in Drainage Irrigation, Department of Irrigation and Development, Campus of Agriculture and Natural Resources, Tehran University. Jalili\_saeid@yahoo.com



## Research Paper

**Survey of Groundwater Level Fluctuations by Soft Computing Techniques  
(Case Study: Urmia and Miandoab Plains)**Farnaz Mohammadi<sup>1</sup>,Mirali Mohammadi<sup>2\*</sup>,Javad Behmanesh<sup>3</sup>Saeid Jalili<sup>4</sup>

1. MSc in Water Resources Management Engineering, Department of Soil and Water, Faculty of Water and Soil Sciences, Zabol University, Iran
2. Associate Professor, Department of Civil Engineering, Faculty of Engineering, Urmia University, P o Box 165, Urmia, Iran
3. Professor, Department of Water Engineering, Faculty of Agriculture, Urmia University, Iran.
4. Phd student, Department of Irrigation and Development, Faculty of Agriculture and Natural Resources, Tehran University, Tehran, Iran



10.22125/IWE.2021.243488.1403

Received:

**August.11.2020**

Accepted:

**January.13.2021**

Available online:

**March.13.2022****Keywords:****Groundwater  
Fluctuation,  
Regression Analysis,  
SVM, Wavelet****Abstract**

The study of behavior of water level fluctuations is important for water balance due to the unbalanced distribution in the hydrological cycle. In present research, the groundwater level fluctuations of Urmia and Miandoab plains in two models SVM and Wavelet from the group of soft calculations have been investigated. For this purpose, information about the period years of 1381-1386 for both plains of Urmia and Miandoab by considering four scenarios of groundwater level -groundwater level with a delay of one month, groundwater level -groundwater level with a delay of two months, Groundwater level -precipitation and groundwater level -temperature. The simulation results were compared and the best model was introduced. The results of regression analysis showed that  $R^2=0.9$  and  $MSE=0.4$  belong to the second piezometer well of Urmia plain and the third piezometer well of Miandoab plain in both SVM and Wavelet models for 3 scenarios of groundwater level -groundwater level with a delay of one month, Groundwater level was precipitation and groundwater level was temperature. Data on climatic variables of temperature, precipitation and groundwater level with a delay of one month as an independent variable and groundwater level data as a dependent variable formed the mentioned scenarios with 80% of educational data and 20% of test data. The results showed that the climatic variable of precipitation has a significant effect on groundwater level fluctuations. In general, the prediction results of Wavelet model were better than SVM model in investigating groundwater level fluctuations in Urmia and Miandoab plains. In the present research, an independent study of the mentioned models in order to simulate groundwater level fluctuations and compare each of the two models in their application.

**\* Corresponding Author:** Mirali Mohammadi**Address:** Department Civil Eng., Faculty of Eng.,  
Urmia University, Urmia., Iran.**Email:** m.mohammadi@urmia.ac.ir**Cell:** +98 9141410650

## 1. Introduction

Soft computing is a beneficial tool while compel observance of water resources management. Groundwater level is such an important and needful scientific debate which is aimed at improving the present related conditions in all societies. As it is apparent, the Groundwater Level Fluctuation (GLF) is necessary to rectify and by using the meteorological and hydrological data will give the chance to cope with. Whilst the data is in hands, in order to simulate the GLF, the initial stride is done and have to be modeled. In this regard, Supported Vector Machine (SVM), Wavelet and MARS are applied and compared to opt the much better method in this paper. Accurate groundwater level forecasting models entails considerable discussion. Daliakopoulos et al (2005) wanted to provide such a vigorous tool of modeling and forecasting groundwater resources fluctuation. They studied Messara Valley in Greece and applied seven different neural network training algorithms which the results show both standard feedforward neural network and Levenberg–Marquardt algorithm performed the best prediction. Affandi and Watanabe (2007) have investigated forecasting the daily groundwater fluctuation level from two observation wells in Saitama City, Japan. The predictions were conducted by ANFIS and ANN then compared with Levenberg–Marquardt algorithms (LM) and radial basis function (RBF). Mohanty et al. (2010) studied groundwater resources behavior in a river island of tropical humid region, eastern India. Three different algorithms of ANN model were carried out to predict one week ahead GWL over the case study area. Adamowski and Chan (2011) at two sites in the Chateauguay watershed in Quebec, Canada investigated monthly groundwater level forecasting by coupling Wavelet-neural network models and comparing regular Artificial Neural Network models also Autoregressive Integrated Moving Average (ARIMA). Obuobie et al. (2012) at the White Volta River basin of Ghana applied the water table fluctuation method where recharge to groundwater represented 2.5% to 16.5% of the mean annual rainfall variation. Shiri et al. (2013) investigated multiple soft computing techniques compose of Gene Expressing Programming (GEP), (Artificial Neural Network) ANN, (Adaptive Neuro-Fuzzy Inference System) ANFIS and Support Vector Machine (SVM) for 7 days ahead groundwater level fluctuations which also rainfall and evapotranspiration data applied through Hongcheon Well station (South Korea) as a case study. The results showed that GEP is superior to the other mentioned techniques. Shiri et al. (2013) investigated multiple soft computing techniques compose of Gene Expressing Programming (GEP), (Artificial Neural Network) ANN, (Adaptive Neuro-Fuzzy Inference System) ANFIS and Support Vector Machine (SVM) for 7 days ahead groundwater level fluctuations which also rainfall and evapotranspiration data applied through Hongcheon Well station (South Korea) as a case study. The results showed that GEP is superior to the other mentioned techniques.

Although data approachability is a confined factor through simulating by the case study, however, the centralization of data will assist the modeling. Input variables are such as groundwater level, precipitation and temperature for the considered models in the research. Thus, as more as data be used, then, the accuracy and comparing results would be more prolific.

## 2. Materials and Methods

In this research, groundwater level fluctuations in Urmia and Miandoab plains were investigated in order to compare and select better calibration methods to simulate future conditions and prevent estimated damages. Urmia and Miandoab plains are considered as sub-basins of Urmia Lake. Due to the heterogeneity of aquifers, the extent of piezometers and to avoid modeling time, three piezometric wells in each of the plains of Urmia and Miandoab were studied to apply the desired scenarios, data Inputs for modeling in MATLAB software environment using SVM support vector machine and Wavelet neural network. As can be seen in Figure 1, three piezometric wells from the Urmia plain with solid circles and three piezometric wells from the Miandoab plain with solid triangles are shown. Figure 1 shows the geographical location of the study area, including the plains of Urmia and Miandoab and their piezometric wells. Among the observable piezometric wells of the plains, three piezometric wells of Urmia plain with water level of 1320.37, 1295.60 and 1293.63 and three piezometric wells of Miandoab plain with water level of 1313.12, 1326.73 and 1305.21 Due to the overlap of the region were selected to use the parameters of groundwater level, rainfall and

temperature, groundwater level fluctuations to be investigated. In this study, 4 scenarios in both Urmia and Miandoab plains include: Groundwater level -groundwater level with one month delay, groundwater level -groundwater level with two months delay, groundwater level -temperature and groundwater level -precipitation in was considered.

### 3. Results

Innovation and purpose of the present research is to investigate groundwater level fluctuations in Urmia and Miandoab plains in two different models of soft computing by analyzing artificial intelligence SVM and Wavelet neural network and also comparing their results with each other to evaluate the better performance of these models. To observe the homogeneity of groundwater level information in the plains, three piezometric wells were selected from among all piezometers in the area due to the overlap and provision of verified data, which is 80% of the data for training and 20% were used for the test. The second piezometric well of Urmia plain with a level of 1295.60 meters and the third piezometric well of Miandoab plain with a level of 1305.21 meters were selected. The criterion for selecting the best model was also by regression analysis and determining the values of MSE and R2 errors, because by a regression relationship with the known values of independent variables, the value of the dependent variable can be estimated. In both plains, the best output of the Wavelet model compared to the SVM model was due to the higher accuracy of R2 value, so in most cases the output data of Wavelet model is used as input in other AI models. In general, both models have provided acceptable results for the Urmia plain. Also, groundwater level scenarios with a delay of one month and groundwater-precipitation level have a higher impact on the study of groundwater level in Urmia and Miandoab plains.

### 4. Discussion and Conclusion

In this research work, groundwater level fluctuations in Urmia and Miandoab plains were investigated in order to compare and select the best soft calculation method to simulate future conditions and prevent estimated losses. The goal is to achieve a small result for prevention before a sharp drop in groundwater level occurs. As mentioned earlier, for the homogeneity of data from the piezometric wells in the plains of Urmia and Miandoab, only three wells from each plain that provided the necessary overlap in the region as Input data selected. Thus, groundwater level-temperature-precipitation data were used as influential factors in the scenarios in total for 6 piezometric wells in Urmia and Miandoab plains as inputs in modeling.

The purpose of selecting time delays in predicting groundwater level fluctuations of piezometric wells was to compare the effect of temperature and precipitation independent variables on groundwater level changes and to compare SVM and Wavelet models with each other, for example, related data. The second selected piezometer of Urmia plain was divided into two parts including 80% of training data and 20% of test data. Also, the delays have been only for two months to reduce the volume of results and the main maneuver is on the variables of groundwater level -temperature -precipitation in 6 piezometric wells in the plains of Urmia and Miandoab. According to the results of the models, the one-month delay has had acceptable results in the scenarios. By examining the errors and regression analysis, the second piezometric well of Urmia plain as the most suitable and the third piezometric well of Miandoab plain in SVM model had better results. In the results of groundwater level with a delay of two months, R2 had an unacceptable value, so it could not be used in research. After the 4 above mentioned scenarios, the groundwater level-groundwater level scenario was removed with a delay of two months.

### 5. Six important references

1. Daliakopoulos, I. N. Coulibaly, P. Tsanis, I. N. 2005. Groundwater level forecasting using artificial neural networks. *Journal of Hydrology*. 309 (2005) 229–240.

2. Affandi, A. k. and Watanabe, K. 2007. Daily groundwater level fluctuation forecasting using soft computing technique. Geosphere Research Institute Saitama University. Nature and Science, 5(2), 2007.
3. Mohanty, S. Jha, M. K. Kumar, A. Sudheer, K. P. 2010. Artificial Neural Network Modeling for Groundwater Level Forecasting in a River Island of Eastern India. Water Resour. Manag. (2010) 24:1845–1865.
4. Adamoeski, J. Chan, Hiu Fung. 2011. A wavelet neural network conjunction model for groundwater level forecasting. Journal of Hydrology 407 (2011) 28–40.
5. Obuobie, E. Diekkruieger, B. Agyekum. W. Agodzo. A. 2012. Groundwater level monitoring and recharge estimation in the White Volta River basin of Ghana. Journal of African Earth Sciences. 71–72 (2012) 80–86.
6. Shiri, J. Kisi, O. Yoon, H. Lee, K. K. Nazemi, A. H. 2013. Predicting groundwater level fluctuations with meteorological effect implications –A comparative study among soft co

### **Conflict of Interest**

1. Authors declared no conflict of interest mputing techniques. Computers & Geosciences 56 (2013) 32–44.