

استفاده از مدل هوش مصنوعی مرکب نظارت شده برای پیش‌بینی سطح آب زیرزمینی

عطاالله ندیری^{۱*}، فاطمه واحدی^۲، اصغر اصغری مقدم^۳ و علی کدخدایی^۴

^۱ استادیار دانشکده علوم طبیعی، دانشگاه تبریز

^۲ دانشجوی کارشناسی ارشد دانشکده علوم طبیعی، دانشگاه تبریز

^۳ استاد دانشکده علوم طبیعی، دانشگاه تبریز

^۴ استادیار دانشکده علوم طبیعی، دانشگاه تبریز

* نویسنده مسئول

دریافت ۹۴/۱۰/۲۶ پذیرش ۹۵/۴/۹

چکیده

منابع آب زیرزمینی از مهم‌ترین منابع تأمین آب هستند، لذا مدل‌سازی آن‌ها حائز اهمیت می‌باشد. در این میان مطالعه و بررسی نوسانات سطح آب زیرزمینی از نظر مطالعات مدیریتی، ایجاد سازه‌های مهندسی، مصارف کشاورزی و حصول آب‌های زیرزمینی با کیفیت بالا از اهمیت بالایی برخوردار است. عمده تقاضا برای آب شرب و کشاورزی در دشت مشگین‌شهر نیز از طریق آب زیرزمینی تأمین می‌شود. در این تحقیق چهار مدل هوش مصنوعی که عبارتند از شبکه عصبی پیشرو، شبکه عصبی برگشتی، منطق فازی ساگو و ماشین بردار پشتیبان برای پیش‌بینی سطح آب زیرزمینی استفاده شدند. با توجه به نزدیکی بودن نتایج به دست آمده و با توجه به این مسئله که مدل‌های مختلف در مراحل مختلف مدل‌سازی نتایج متفاوتی ارائه دادند، انتخاب یکی از مدل‌ها به عنوان مدل منتخب معقول به نظر نمی‌رسید. لذا از ترکیب غیر خطی این چهار مدل که مدل هوش مصنوعی مرکب نظارت شده نامیده می‌شود، برای ترکیب نتایج این مدل‌ها استفاده شد تا نتایج به دست آمده تقویت شده و از توانایی مدل‌های مختلف به طور هم‌زمان استفاده شود. به منظور ارزیابی کارایی و دقت مدل‌ها در پیش‌بینی، از دو معیار مختلف RMSE و R^2 استفاده شد. نتایج نشان دادند که مدل SCMAI با مقادیر R^2 برابر ۰/۸۵ و ۰/۹۰ به ترتیب برای پیرومترهای شماره ۱ و ۲ در مرحله آموزش بهترین پیش‌بینی را نسبت به هر کدام از چهار مدل منفرد هوش مصنوعی ارائه کرده است. همچنین مدل SCMAI توانست RMSE پیش‌بینی را تا ۹٪ درصد برای پیرومتر شماره یک و ۱۷٪ درصد برای پیرومتر شماره دو کاهش دهد.

واژگان کلیدی: سطح آب زیرزمینی، شبکه عصبی مصنوعی، فازی، ماشین بردار پشتیبان، مدل هوش مصنوعی مرکب.

۱- مقدمه

پیشرفته به کار گرفته شده‌اند، از آن جمله می‌توان به کاربرد شبکه‌های عصبی مصنوعی [۵، ۶]، منطق فازی [۸، ۹]، ماشین‌های بردار پشتیبان [۱۰-۱۲] و استفاده ترکیبی از روش‌های هوش مصنوعی [۱۳-۱۵] اشاره کرد.

در این میان مدل‌سازی آبخوان‌ها به منظور پیش‌بینی سطح آب زیرزمینی از اساسی‌ترین موارد در شناخت صحیح منابع آب زیرزمینی و مدیریت کمی آن در مصارف کشاورزی، صنعتی و خانگی، و ایجاد سازه‌های مهندسی می‌باشد. در سال‌های گذشته به علت افزایش نگرانی‌ها در مورد آب زیرزمینی و مورد نیاز بودن پیش‌بینی‌های دقیق، از شبکه عصبی مصنوعی برای پیش‌بینی سطح آب زیرزمینی مطالعات گسترده‌ای انجام شده است [۱۶].

Coppola و همکاران [۱۷، ۱۸] از شبکه عصبی مصنوعی برای پیش‌بینی سطح آب در حالت غیر ماندگار و تحت شرایط

شناخت صحیح و بهره‌برداری اصولی از منابع آب زیرزمینی می‌تواند در توسعه پایدار فعالیت‌های اجتماعی و اقتصادی آن منطقه نقش بسزایی داشته باشد. عدم شناخت صحیح و بهره‌برداری بی‌رویه از این منابع خسارات جبران‌ناپذیری مانند افت شدید سطح آب زیرزمینی [۱] و در نتیجه آن کاهش کیفیت آب [۲]، فرونشست زمین در اثر برداشت‌های بی‌رویه آب زیرزمینی [۳] و پیشروی جبهه‌های آب شور و تداخل آب‌های شور و شیرین [۴] را به دنبال خواهد داشت. مدل‌سازی آب زیرزمینی ابزاری برای توسعه برنامه‌ریزی‌های مدیریتی قابل اجرا در مورد آب‌های زیرزمینی و محافظت از این منبع حیاتی می‌باشد. در دهه‌های اخیر مدل‌های هوش مصنوعی به طور گسترده به عنوان مدلی مؤثر و توانا در پیش‌بینی سیستم‌های هیدرولوژی

Behzad و همکاران [۲۷] در تحقیقی روش‌های مدل‌سازی SVM و ANN را برای پیش‌بینی سطح آب زیرزمینی در حالت غیر ماندگار در یک سیستم پیچیده آب زیرزمینی تحت شرایط متغیر از نظر پمپاژ و آب و هوایی مقایسه کردند. پیش‌بینی‌ها در پنج دوره مختلف روزانه، هفته‌ای، دو هفته‌ای، ماهانه، و دو ماهه، در مدت زمان ۵ ماه انجام گرفته و نتایج نشان دادند که روش SVM با توانایی بالا در عمومی‌سازی و قابلیت مدل‌سازی با داده‌های پراکنده و همچنین در پیش‌بینی‌های با دوره بلند مدت، می‌تواند جایگزین خوبی برای ANN باشد. همچنین در تحقیقی دیگر ترکیبی از مدل‌های ماشین بردار پشتیبان و موجکی برای پیش‌بینی ماهانه سطح آب زیرزمینی به کار برده شد. سپس مدل ترکیبی WA-SVR با مدل‌های انفرادی شبکه عصبی مصنوعی، رگرسیون بردار پشتیبان، و مدل میانگین متحرک تجمعی خود همبسته مقایسه شده و نتایج نشان دادند که مدل ترکیبی دقت بیشتری نسبت به مدل‌های انفرادی دارد [۲۸]. Yoon و همکاران [۲۹] از ماشین‌های بردار پشتیبان و شبکه عصبی مصنوعی به عنوان مدل‌های سری زمانی غیر خطی برای پیش‌بینی سطح آب زیرزمینی در یک سفره ساحلی در کره مورد استفاده قرار دادند. سطح آب زیرزمینی زمان گذشته، بارش و تراز موج-جزر و مد ورودی‌های مدل‌ها انتخاب شدند. در یک تحقیق مقایسه‌ای از شیری و همکاران [۳۰] مدل‌های مختلف هوش مصنوعی مثل برنامه‌ریزی بیان ژن (GEP)، نرو فازی (ANFIS)، شبکه عصبی مصنوعی (ANN) و ماشین بردار پشتیبان (SVM) مورد ارزیابی قرار گرفت. مقادیر سطح آب، بارش و تبخیر از ایستگاه چاه هونگچئون در جنوب کره به عنوان ورودی‌های مدل‌ها انتخاب شدند. نتایج حاصل از مقایسه نشان دادند که مدل GEP عملکرد بهتری نسبت به مدل‌های ANN، ANFIS و SVM دارد.

هر کدام از روش‌های هوش مصنوعی مزیت‌های خاص خود را دارد. یک شبکه عصبی مصنوعی در طول آموزش رفتار سیستم را یاد گرفته و بدون نیاز به قوانین فیزیکی حاکم بر سیستم و بر اساس یافتن رابطه تابعی برای ورودی‌های خاص، خروجی مناسب را ارائه می‌دهد [۱۷]. از این رو شبکه عصبی مصنوعی ابزاری قدرتمند برای اجرای غیر خطی ورودی-خروجی می‌باشد. منطق فازی روشی است بر مبنای قوانین فازی که شامل عبارات ریاضیاتی می‌شود. این قوانین توانایی کار با عدم قطعیت را سبب می‌شود و همچنین به دلیل استفاده از جملات زبانی این روش مورد پسند می‌باشد [۱۵]. ماشین‌های بردار پشتیبان نیز به

متغیر از نظر پمپاژ و وضعیت آب و هوایی استفاده کردند. در تحقیقی نیز ۷ نوع مختلف شبکه‌های عصبی مصنوعی و الگوریتم‌های آموزش بر حسب دقت و میزان کارایی برای پیش-بینی سطح آب زیرزمینی آزموده شدند تا مطلوب‌ترین شبکه عصبی مصنوعی شناسایی شود تا بتواند روند کاهشی سطح آب زیرزمینی را شبیه‌سازی کرده و پیش‌بینی‌های قابل قبولی را تا ۱۸ ماه آینده تهیه کند. در این مطالعه مناسب‌ترین روش شبکه عصبی پیشرو^۱ بوده که با الگوریتم لونبرگ-مارکوات آموزش دیده شده بود و پیش‌بینی‌های دقیقی را از سطح آب نشان می‌داد [۱۹]. مدل شبکه عصبی BP^۲ بر اساس رابطه بین سطح آب و فاکتورهای حساسی مثل بارش، نشت رودخانه‌ای، زهکش معدن، برداشت آب زیرزمینی و تخلیه‌های جانبی آبخوان ایجاد شده سپس همه فاکتورهای حساس آنالیز شده و مشخص گردید که زهکش معدن زغال موجود در منطقه بیشترین تأثیر را بر سطح آب زیرزمینی آن منطقه دارد [۶]. در تحقیقی دیگر با استفاده از داده‌های ۳۰ ساله چهار چاه در جنوب شهر ریاض در عربستان سعودی، سطح آب را به وسیله شبکه عصبی مصنوعی برای ۲۰ سال آینده پیش‌بینی انجام گرفت. نتایج حاصل از این تحقیق نشان داد که افت سطح آب در آینده از ۳۰٪ افت ایجاد شده در ۳۰ سال قبل تجاوز نخواهد کرد [۲۰]. با توجه به این که پیش‌بینی‌های نوسانات آب زیرزمینی با عدم قطعیت همراه می‌باشد، منطق فازی به عنوان ابزاری مناسب برای مقابله با عدم قطعیت‌های موجود از اهمیت خاصی برخوردار است [۲۱، ۲۲]. برای پیش‌بینی سطح آب زیرزمینی شبکه عصبی مصنوعی به صورت مقایسه‌ای با منطق فازی [۲۳] و نروفازی [۲۴، ۲۵] به کار رفته است. در تحقیقی مدل‌های منطق فازی و نروفازی برای پیش‌بینی سطح آب زیرزمینی به کار رفتند. تغذیه و تخلیه آب زیرزمینی، سطح آب زیرزمینی در زمان گذشته و حال به عنوان ورودی‌های مدل‌ها مورد استفاده قرار گرفتند. در این مطالعه مدل‌های نرو فازی نتایج بهتری نسبت به منطق فازی ارائه دادند [۲۶].

ماشین‌های بردار پشتیبان^۳ بر اساس تئوری یادگیری آماری و اصول کمینه‌سازی ریسک ساختاری توسعه یافته‌اند و این اصول SVM را قادر می‌سازد تا داده‌های غیر قابل مشاهده را عمومی‌سازی کنند و دارای سازگاری خوبی با داده‌های پراکنده و کم باشند [۱۲].

- 1- Feedforward neural network
- 2- Back-propagation
- 3- Support Vector Machine (SVM)

ارتفاع ۴۸۱۴ متر از سطح دریا مرتفع‌ترین نقطه منطقه می‌باشد که در قسمت جنوب شرقی مشگین‌شهر واقع شده است و پست‌ترین نقطه مربوط به خروجی دشت که در روستای صاحب‌دیوان قرار دارد و ارتفاع آن ۷۱۴ متر از سطح دریا می‌باشد. سراسر شمال این شهرستان را دنباله کوه‌های ارسباران که از غرب به شرق کشیده شده، پوشانده است. در فاصله بین اهر و مشگین‌شهر کوه‌های دوسرداغ و ایلان‌داغ قرار دارند. علاوه بر اینها ارتفاعات دیگری با جهت شمال‌شرقی - جنوب‌غربی به نام صلوات داغ در شمال مشگین‌شهر وجود دارد. این دشت در حد فاصل بین طول‌های جغرافیایی $38^{\circ} 20'$ و $47^{\circ} 58'$ و عرض‌های جغرافیایی $38^{\circ} 18'$ تا $38^{\circ} 35'$ واقع شده است و دارای وسعتی در حدود ۷۰۵ کیلومتر مربع است (شکل ۱). مسیر مشگین‌شهر - اهر به طول ۶۲ کیلومتر و راه مشگین‌شهر - اردبیل به طول ۸۵ کیلومتر از مسیرهای دسترسی این منطقه به شمار می‌روند. آبخوان دشت مشگین‌شهر از نوع آزاد است. اقلیم منطقه بر اساس اقلیم نمای آمبرژه [۳۳] از نوع نیمه خشک سرد می‌باشد. متوسط دمای سالیانه $11/66$ درجه سانتیگراد (بر اساس داده‌های ایستگاه‌های آبیاری مشگین، صاحب‌دیوان و سد سبلان، ۱۳۸۸-۱۳۹۱) و میزان متوسط سالانه بارش ۲۹۲ میلی‌متر (بر اساس داده‌های ایستگاه آبیاری مشگین، ۱۳۸۰-۱۳۹۱) در سال می‌باشد.

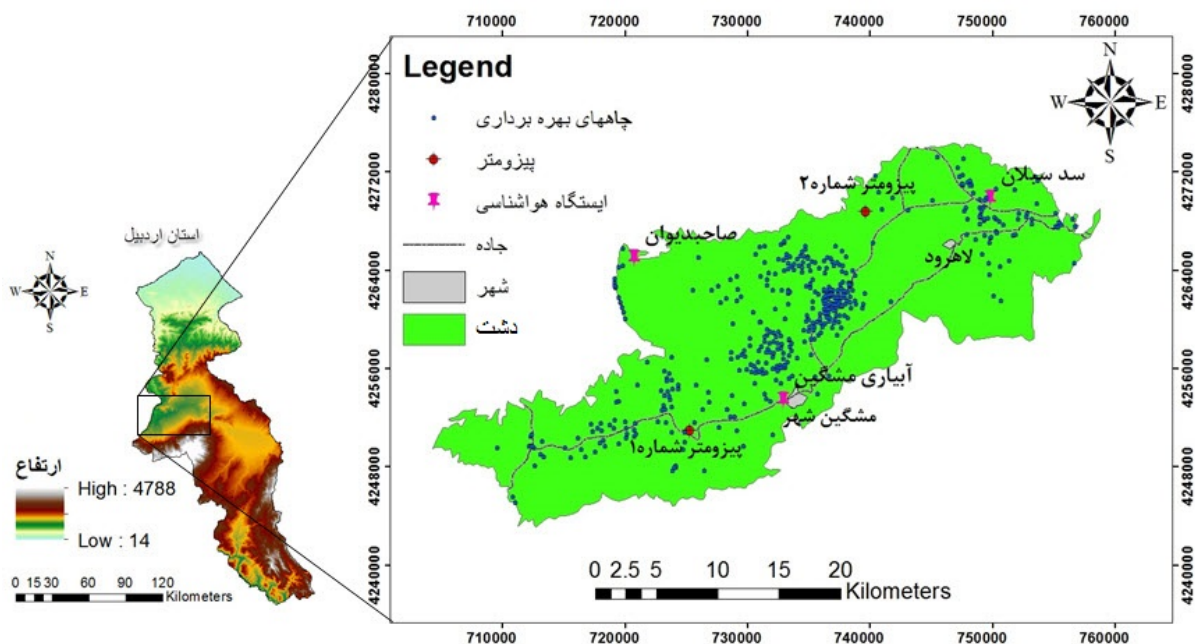
موجب دو مشخصه که شامل قابلیت عمومیت‌سازی و کار با داده‌های پراکنده می‌باشد به عنوان روشی امید بخش در پیش‌بینی به شمار می‌رود [۲۷]. بنابر این استفاده از مدل‌های ترکیبی مزایای بیشتری خواهد داشت. مدل ترکیبی هوش مصنوعی در زمینه‌های مختلف توسط محققانی به کار گرفته شده است [۱۳-۱۵، ۳۱، ۳۲].

منطقه مطالعاتی در این تحقیق، دشت مشگین‌شهر می‌باشد که فعالیت اقتصادی مهم در این دشت کشاورزی است و همچنین عمده تقاضا برای آب از طریق آب زیرزمینی تأمین می‌شود. بنابر این به منظور مدیریت هرچه مؤثرتر این منابع، مطالعه و بررسی سطح آب زیرزمینی در این دشت ضرورت دارد. در این تحقیق از مدل هوش مصنوعی مرکب نظارت شده برای پیش‌بینی سطح آب زیرزمینی استفاده شده است. هدف از بکارگیری این روش در این تحقیق دستیابی به مزایای همه مدل‌های هوش مصنوعی منفرد به صورت همزمان می‌باشد. روش استفاده شده ترکیب جدیدی از مدل‌های هوش مصنوعی در زمینه پیش‌بینی تغییرات سطح آب زیرزمینی می‌باشد که با تحقیقات قبلی متفاوت بوده و تا حال به کار گرفته نشده است.

۲- مواد و روش‌ها

۲-۱- منطقه مورد مطالعه

محدوده مطالعاتی دشت مشگین‌شهر می‌باشد که در شمال غرب ایران در استان اردبیل قرار دارد. کوه سبلان با قله‌ای به



شکل ۱- موقعیت منطقه مورد مطالعه

۲-۲- بررسی داده‌ها

پس از بررسی تغییرات سطح آب زیرزمینی و ارتفاع سطح زمین در محل پیژومترهای موجود در دشت مشکین شهر، پیژومترهای شماره ۱ و ۲ به عنوان نماینده پیژومترهای دشت انتخاب شدند که تغییرات سطح آب در آن‌ها شبیه اکثر پیژومترها بود و هر کدام از آن‌ها نمایانگر بخشی از دشت می‌باشد که از نظر ارتفاعی با ای دیگر متفاوت هستند، و همین‌طور از نظر توزیع در بخش شرقی و غربی دشت قرار گرفته‌اند. شکل (۱) موقعیت چاه‌های مشاهده‌ای، بهره‌برداری و ایستگاه‌های هواشناسی منطقه نشان داده است. در این تحقیق از داده‌های سطح آب زیرزمینی ماهانه در زمان t_0-1 (GWL*) در پیژومترهای مربوطه، میزان متوسط بارندگی در هر ماه (P)، متوسط دمای ماهانه (T) و میزان تخلیه از چاه‌های بهره‌برداری در هر ماه (D) که طی دوره ۹ ساله (۱۳۸۳ تا ۱۳۹۱) در دسترس بودند به عنوان ورودی و سطح آب زیرزمینی در زمان t_0 به عنوان خروجی در هر دو مدل انتخاب شدند. داده‌های سطح آب زیرزمینی و میزان تخلیه از چاه‌های بهره‌برداری برای پیژومترهای مذکور به ترتیب روند نزولی و صعودی را نشان می‌دهند. داده‌های دما و بارش روند تقریباً ثابتی را در دوره ۹ ساله داشته‌اند. همچنین بررسی نوسانات سطح آب زیرزمینی در پیژومترها در طول دوره آماری ذکر شده تغییرات ۱/۲ و ۰/۴۵ متری را به ترتیب برای پیژومترهای شماره ۱ و ۲ نشان دادند. ۸۰ درصد این داده‌ها برای مرحله ی آموزش و ۲۰ درصد بقیه برای مرحله تست مدل‌ها استفاده شدند.


۲-۳- شبکه‌های عصبی مصنوعی (ANNs)

شبکه‌های عصبی مصنوعی یک سیستم پردازشگر اطلاعات توده‌ای هستند که به صورت موازی قرار گرفته‌اند و عملکردی شبیه شبکه عصبی مغز انسان دارند [۳۴]. اصول زیر نشانگر اساس شبکه‌های عصبی مصنوعی می‌باشند:

- ۱- پردازش داده‌ها در واحدهای منفردی به نام گره صورت می‌گیرد.
- ۲- سیگنال بین گره‌ها از طریق خطوط ارتباطی انتقال می‌یابند.
- ۳- وزن نسبت داده شده به هر خط ارتباطی نشانگر قدرت ارتباطی آن خط است.
- ۴- هر گره به طور معمول دارای توابع فعال‌سازی و تبدیل‌گر برای تعیین سیگنال‌های خروجی از داده‌های ورودی شبکه می‌-

باشد [۳۵]. ساختار یک شبکه عصبی به وسیله الگوی ارتباطی بین گره‌ها، روش تعیین وزن‌های ارتباطی و تابع فعال‌سازی مشخص می‌شود [۳۶]. یک شبکه عصبی مصنوعی تیپیک شامل تعدادی از گره‌ها است که بر حسب نظم خاصی سازمان یافته‌اند. یکی از راه‌های طبقه بندی شبکه‌های عصبی توسط تعداد لایه‌ها انجام می‌شود:

- ۱- شبکه‌های تک لایه‌ای (شبکه‌های هاپفیلد)؛
 - ۲- شبکه‌های دو لایه‌ای (شبکه‌های رزونانس تطبیقی)؛
 - ۳- شبکه‌های چند لایه‌ای (اغلب شبکه‌های پس‌انتشار).
- شبکه‌های عصبی مصنوعی بر اساس جهت جریان و پردازش اطلاعات نیز به دو دسته شبکه‌های پیشرو و شبکه‌های برگشتی طبقه‌بندی می‌شوند.
- در یک شبکه عصبی پیشرو (FNN)، گره‌ها در لایه‌ها با شروع از لایه ورودی و با پایان در لایه خروجی نهایی مرتب می‌شوند. هر شبکه می‌تواند از چند لایه پنهان، با داشتن یک گره یا گره‌های بیشتر در هر لایه، وجود داشته باشد. اطلاعات از ورودی به سمت خروجی عبور می‌کنند. گره‌ها در یک لایه به گره‌های دیگر در لایه بعدی متصل هستند، اما به گره‌های موجود در همان لایه متصل نیستند. بنابر این خروجی یک گره در یک لایه فقط به ورودی‌های دریافتی آن از لایه‌های قبلی و وزن مربوطه بستگی دارد. از طرف دیگر در شبکه عصبی برگشتی (RNN) اطلاعات از طریق گره‌ها در هر دو جهت، از ورودی به سمت خروجی و بالعکس جریان دارند. این امر از طریق بازیافت خروجی‌های شبکه قبلی به عنوان ورودی‌های جدید حاصل می‌شود [۳۷]. ساختار کلی یک شبکه عصبی مصنوعی (شکل (۲)) از لایه ورودی، لایه‌های میانی و لایه خروجی تشکیل شده است.



شکل ۲- ساختار شبکه عصبی مصنوعی

تئوری یادگیری آماری توسعه یافته‌اند و مهم‌ترین جنبه این ماشین‌های یادگیری، به کار گرفتن اصول کمینه‌سازی ریسک ساختاری است که SVM را قادر می‌سازد تا داده‌های غیر قابل مشاهده را عمومی‌سازی کند. یعنی به جای کمینه‌سازی خطای مدل یا طبقه‌بندی، ریسک ساختاری را به عنوان تابع هدف در نظر می‌گیرد و مقدار بهینه آن را محاسبه می‌کند. بر اساس این اصول SVM دو ویژگی برجسته دارد که سبب پیش‌بینی‌های ثمربخش این روش می‌شود، که شامل قابلیت عمومی‌سازی عالی آن و سازگاری با داده‌های پراکنده و کم می‌باشد [۲۷]. ماشین‌های بردار پشتیبانی بیشتر برای حل مسائل رگرسیونی و طبقه‌بندی توسعه یافته‌اند [۱۱].

انتخاب بردارهای پشتیبانی که ساختار مدل را پشتیبانی می‌کند و تعیین وزن آن‌ها فرآیندی اصلی در مدل SVM می‌باشد. با در نظر گرفتن مجموعه‌ای با N نمونه $\{x_k, y_k\}_{k=1}^N$ ، $x \in R^m$ ، $y \in R$ که در آن x بردار ورودی m جزئی و y به عنوان بردار خروجی می‌باشند، تخمین‌گر SVM (f) در رگرسیون صورت زیر نشان داده می‌شود [۳۰].

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

که w بردار وزن، b بایاس و φ یک تابع تبدیلگر غیر خطی (بنام کرنل) می‌باشد که بردارهای ورودی را به شکل فضای بالاتر ترسیم می‌کند. Vapnik تابع هدف بهینه‌سازی محدب با تابع تلفات غیر حساس را برای حل رابطه (۱) معرفی کرد [۴۱].

$$\begin{aligned} & \text{Minimize}_{w, b, \xi, \xi^*} \frac{1}{2} \|w\|^2 + C \sum_{k=1}^N (\xi_k + \xi_k^*) \\ & \text{Subject to} \left\{ \begin{array}{l} y_k - w^T \varphi(x_k) - b \leq \varepsilon + \xi_k \\ w^T \varphi(x_k) + b - y_k \leq \varepsilon + \xi_k^* \\ \xi_k, \xi_k^* \geq 0 \\ k = 1, 2, \dots, N \end{array} \right. \quad (2) \end{aligned}$$

در این رابطه ξ و ξ^* متغیرهای کمبود هستند که خطای آموزش را به وسیله تابع تلفات غیر حساس^۲ جریمه می‌کنند و پارامتر مثبت C ضریب موازنه برای تعیین درجه خطای تجربی در مسئله بهینه‌سازی می‌باشد.

لایه ورودی یک لایه انتقال دهنده و وسیله‌ای برای تهیه کردن داده‌هاست. آخرین لایه یا لایه خروجی شامل مقادیر پیش‌بینی شده به وسیله شبکه می‌باشد و خروجی مدل را معرفی می‌کند. لایه‌های میانی که از گره‌های پردازشگر تشکیل شده‌اند، محل پردازش داده‌ها می‌باشند. تعداد لایه‌های میانی و تعداد گره‌ها در هر لایه میانی معمولاً به طریق روش آزمون و خطا تعیین می‌شوند [۳۸].

۲-۴- منطق فازی

برای اولین بار زاده [۳۹] روش فازی را برای رشته‌های مختلف علوم معرفی کرد. فازی به معنای ابهام می‌باشد. مجموعه‌های فازی مرزهای مبهم و تدریجی بین مرزهای تعریف شده دارند، که برای مقابله با ماهیت عدم قطعیت در سیستم و خطاهای انسانی مناسب هستند [۱۵، ۲۲]. تفاوت مجموعه‌های فازی با مجموعه‌های معمولی در عضویت بخشی موجود در آن است. دما می‌تواند مثالی از یک مجموعه فازی باشد. در کلاس-های موجود در دما، به عنوان مثال کلاس "خیلی پایین" یک ناحیه انتقالی وجود دارد که عضویت در ای نواحی دارای درجه می‌باشد. $1^\circ C$ به احتمال زیاد دارای درجه عضویت بیشتری نسبت به $4^\circ C$ ، در کلاس "خیلی پایین" می‌باشد [۸]. سیستم فازی شامل سه بخش اصلی است:

۱- تعریف تابع عضویت یا فازی سازی داده‌ها: درجه عضویت در یک مجموعه فازی از طریق تابع عضویت تعریف می‌شود که مقدار آن بین ۰ و ۱ است که ۰ بدون عضویت و ۱ دارای عضویت کامل می‌باشد و مقادیر بین این دو عضویت بخشی دارند.

۲- قوانین فازی: ایجاد ارتباط بین ورودی و خروجی با استفاده از یک سری قوانین مثل اگر آنگاه^۱ می‌باشد که اگر مربوط به متغیرهای ورودی و آنگاه مربوط به نتایج می‌باشد [۴۰].

۳- غیر فازی سازی: که توسط عملگرهای فازی or، not and انجام می‌گیرد. غیر فازی سازی فرآیندی است که مقادیر ورودی را از طریق مجموعه قوانین فازی ایجاد شده می‌گذراند تا پیش‌بینی‌های مدل را استخراج کند [۸].

۲-۵- ماشین بردار پشتیبانی (SVM)

ماشین بردار پشتیبانی نوعی روش یادگیری است که در سال ۱۹۹۵ توسط Vapnik معرفی شد [۴۱]. SVM بر اساس

۲-۶- مدل هوش مصنوعی مرکب نظارت شده (SCMAI)

یک مدل هوش مصنوعی مرکب نتایج چند مدل هوش مصنوعی منفرد را ترکیب می‌کند تا از مزایای همه مدل‌های منفرد برای تولید خروجی نهایی استفاده کند [۱۳]. روش‌های مختلفی برای ترکیب مدل‌های هوش مصنوعی وجود دارد که روش متوسط‌گیری تجمعی ساده و متوسط‌گیری وزنی از معروف‌ترین آن‌ها می‌باشند [۳۱]. در این مطالعه، به جای روش متوسط‌گیری ساده و وزنی از یک شبکه عصبی مصنوعی به عنوان یک ترکیب کننده نظارت شده استفاده شده است [۱۵]. در این تحقیق از مدل هوش مصنوعی مرکب نظارت شده برای ترکیب مدل‌های شبکه عصبی پیشرو، شبکه عصبی برگشتی، فازی ساگنو و ماشین‌های بردار پشتیبان استفاده شده است. شکل (۴) تصویر شماتیکی از مدل هوش مصنوعی ارائه شده در این تحقیق را نشان می‌دهد. بر اساس مطالعات انجام گرفته در زمینه مدل‌های هوش مصنوعی مرکب [۳۲، ۳۳، ۳۴] می‌توان اصول کلی آن را به صورت زیر توضیح داد:

$$E_i = \varphi \left[\left(T_i^{\wedge} - T \right)^2 \right] = \varphi \left[e_i^2 \right] \quad (6)$$

با فرض وجود i سیستم پیش‌بینی $i=1, \dots, N$ بردار هدف و T_i^{\wedge} خروجی هر سیستم خواهد بود و در رابطه فوق $\varphi[\cdot]$ امید ریاضی است و متوسط خطا برای هر یک از سیستم‌های هوش مصنوعی به صورت رابطه (۷) حساب می‌شود:

$$E_{avg} = \frac{1}{k} \sum_{i=1}^k E_i = \left(\frac{1}{k} \right) \sum_{i=1}^k [e_i^2] \quad (7)$$

لذا با اعمال روش متوسط‌گیری بردار خروجی به صورت رابطه (۸) خواهد بود:

$$T_{CM}^{\wedge} = \frac{1}{k} \sum_{i=1}^k T_i^{\wedge} \quad (8)$$

بنابر این برای مربع خطای مدل هوش مصنوعی مرکب خواهیم داشت:

$$E_{CM} = \varphi \left[\left(T_{CM}^{\wedge} - T \right)^2 \right] = \varphi \left[\left(\frac{1}{k} \sum_{i=1}^k T_i^{\wedge} - T \right)^2 \right] \\ = \varphi \left[\left(\frac{1}{k} \sum_{i=1}^k e_i \right)^2 \right] \quad (9)$$

الگوریتم‌های مختلفی برای حل مسئله بهینه‌ساز دوتایی SVM پیشنهاد شده است. تعدادی از این الگوریتم‌ها را می‌توان در مطالعات [۴۲] جستجو کرد.

تابع هدف در رابطه (۲) می‌تواند به صورت ضرایب لاگرانژ (α و α^*) دوباره فرمول‌بندی شود (رابطه (۳)).

$$\text{Maximize}_{\alpha, \alpha^*} = \begin{cases} -\frac{1}{2} \sum_{k,l=1}^N (\alpha_k - \alpha_k^*)(\alpha_l - \alpha_l^*) K(x_k, x_l) \\ -\varepsilon \sum_{k=1}^N (\alpha_k - \alpha_k^*) + \sum_{k=1}^N y_k (\alpha_k - \alpha_k^*) \end{cases} \quad (3)$$

$$\text{Subject to } \begin{cases} \sum_{k=1}^N (\alpha_k - \alpha_k^*) = 0 \\ 0 \leq \alpha_k, \alpha_k^* \leq C \end{cases}$$

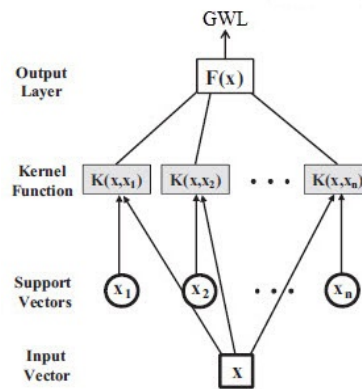
آنگاه تابع تخمین‌گر به صورت زیر به دست می‌آید:

$$f(x) = \sum_{k=1}^n (\alpha_k - \alpha_k^*) K(x, x_k) + b \quad (4)$$

که K تابع کرنل و تعداد بردارهای پشتیبان می‌باشد. در این تحقیق از کرنل RBF^۱ استفاده شده است. رابطه کرنل RBF در زیر آمده است (رابطه (۵)) که در آن پارامتر σ مربوط به تابع کرنل پایه ای شعاعی (RBF) می‌باشد.

$$K(x_k, x_l) = \exp \left(-\frac{\|x_k - x_l\|^2}{2\sigma^2} \right) \quad (5)$$

شکل (۳) ساختار کلی یک ماشین بردار پشتیبان را به صورت شماتیک نشان می‌دهد.



شکل ۳- ساختار مدل SVM [۵۲]

۷-۲- ارزیابی دقت مدل‌ها

در این تحقیق به منظور ارزیابی کارایی مدل‌ها و توانایی آن‌ها در پیش‌بینی دقیق از دو معیار جذر میانگین مربع خطا (RMSE)، ضریب تبیین (R^2) استفاده شده است. از دو معیار مختلف برای ارزیابی دقت مدل‌ها استفاده شده است که به صورت زیر تعریف می‌شوند:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (X_i - \hat{X}_i)^2}{n}} \quad (12)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (X_i - \hat{X}_i)^2}{\sum_{i=1}^n (X_i - \bar{X}_i)^2} \quad (13)$$


در روابط فوق X_i و \hat{X}_i به ترتیب مقادیر مشاهداتی و محاسباتی، \bar{X}_i میانگین مقادیر مشاهداتی و n تعداد کل داده‌ها می‌باشد. $RMSE$ میزان خطای بین مقادیر مشاهداتی و محاسباتی را نشان می‌دهد و R^2 نشانگر میزان بازده مدل است. هر چقدر $RMSE$ به سمت صفر و R^2 به یک میل کنند بهترین جواب برای مدل ایجاد خواهد شد.

۳- بحث و نتایج

۳-۱- نتایج حاصل از مدل شبکه عصبی پیشرو

در این پژوهش از شبکه عصبی پیشرو با الگوریتم لونیگ-مارکوارت استفاده شده است. بدین منظور ابتدا نرمال‌سازی برای کل داده‌های مورد استفاده انجام گرفت سپس به روش آزمون و خطا تعداد بهینه گره‌های لایه میانی تعیین شدند. این کار برای هر دو پیرومتر انجام شد و با توجه به کمترین خطای بازده مدل، تعداد سه گره برای لایه میانی پیرومترها به دست آمد (شکل (۲)). تابع تبدیلگر در لایه میانی از نوع سیگموئید تانژانتی و در لایه خروجی خطی می‌باشد. مدل‌سازی با این تعداد گره‌ها برای هر دو پیرومتر انجام شد.

برای پیرومتر شماره ۱ با ۵۳ دوره آموزشی با کمترین خطای ممکن آموزش پایان یافت. مقادیر ضریب تعیینی (R^2) و $RMSE$ برای پیرومتر شماره ۱ در مرحله آموزش به ترتیب ۰/۸۲ و ۰/۱۷ بوده است. این مقادیر برای پیرومتر شماره ۲ با ۴۹ دوره آموزشی به ترتیب برابر ۰/۸۵ و ۰/۰۵ به دست آمد. پس از آن شبیه‌سازی برای مرحله آزمایش نیز اجرا شد. نتایج مدل شبکه عصبی در جدول (۱) و شکل‌های (۵) و (۶) آمده است.



شکل ۴- تصویر شماتیکی از مدل SCMAI

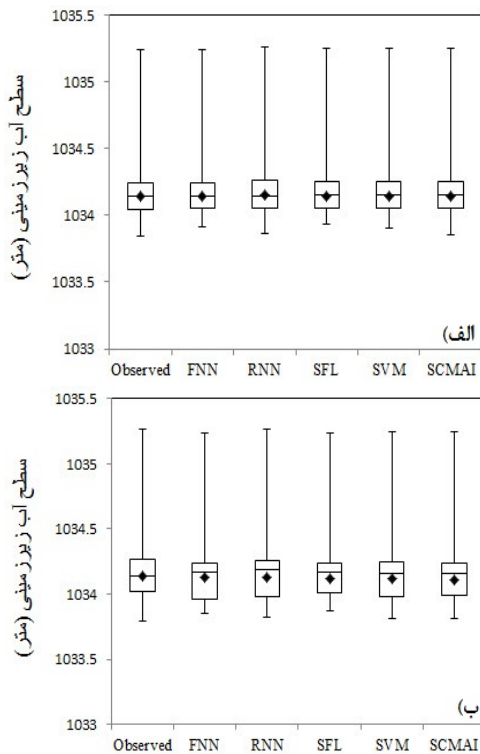
با در نظر گرفتن معادله کاپچی در رابطه (۱۰) می‌توان نشان داد بر اساس رابطه (۱۱) مدل هوش مصنوعی مرکب کمترین خطا را نسبت به هر یک از مدل‌های استفاده شده خواهد شد.

$$(a_1 b_1 + a_2 b_2 + \dots + a_n b_n)^2 \leq (a_1^2 + a_2^2 + \dots + a_n^2) \times (b_1^2 + b_2^2 + \dots + b_n^2) \quad (10)$$

$$E_{CM} = e \left[\left(\frac{1}{k} \sum_{i=1}^k T_i^{\wedge} - T \right)^2 \right] \leq \left(\frac{1}{k} \sum_{i=1}^k [e_i^2] \right) = E_{avg} \quad (11)$$

مدل هوش مصنوعی مرکب نظارت شده در این تحقیق طی دو مرحله اصلی انجام گرفته است. در مرحله اول سطح آب زیرزمینی (GWL) با داده‌های دما (T)، بارش (P)، مقدار حجم تخلیه از چاه‌های بهره برداری (D) و سطح آب زیرزمینی ماه قبلی (GWL^*) به وسیله روش‌های هوش مصنوعی مختلف ANN، RNN، SFL و SVM پیش‌بینی شده و در مرحله بعدی خروجی‌های مدل‌های منفرد به عنوان ورودی‌های مدل SCMAI برای پیش‌بینی سطح آب زیرزمینی استفاده شده است. در این مطالعه از یک شبکه عصبی مصنوعی به عنوان یک ترکیب کننده غیر خطی نظارت شده برای ترکیب مدل‌های مختلف هوش مصنوعی استفاده شده است. برای آموزش این شبکه عصبی، الگوریتم لونیگ-مارکوارت (LM) به عنوان یک الگوریتم یادگیری برای تخمین وزن‌ها و بایاس‌ها انتخاب شد [۳۷].

با توجه به این‌که در روش مرکب هوش مصنوعی از کارایی مدل‌های مختلف بهره گرفته می‌شود، این روش یک روش توسعه یافته در پیش‌بینی سطح آب زیرزمینی می‌باشد که نتایج بهتری نسبت به مدل‌های منفرد بکار رفته در این مطالعه به دست می‌دهد.



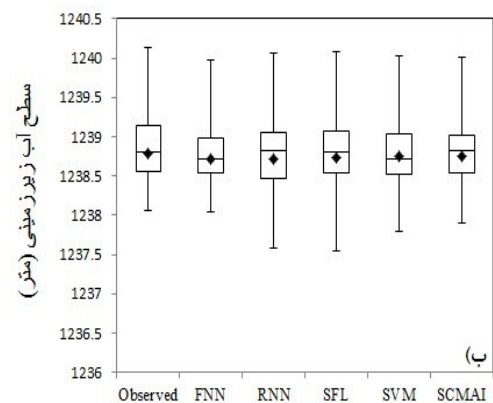
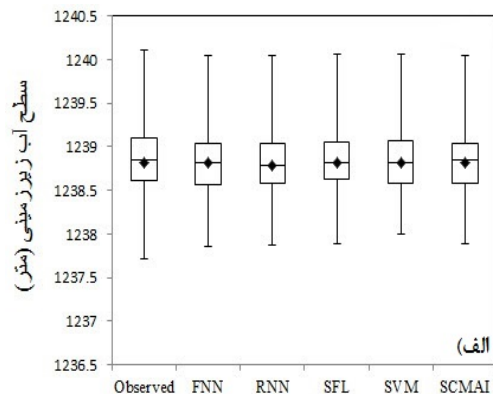
شکل ۶- پلات جعبه‌ای سطح آب زیرزمینی مشاهده‌ای (Observed) و سطح آب پیش‌بینی شده توسط مدل‌های FNN، RNN، SFL، SVM و SCMAI برای پیرومتر شماره ۲: الف) مرحله آموزش و ب) مرحله آزمایش

۳-۳- نتایج حاصل از مدل فازی

در این مطالعه از مدل فازی ساگنو برای پیش‌بینی سطح آب زیرزمینی استفاده شده است. اولین مرحله در این نوع روش دسته‌بندی داده‌ها و تعیین توابع عضویت می‌باشد که در این پژوهش از روش خوشه‌بندی کاهشی^۱ استفاده شده است. اصول شعاع دسته‌بندی در این روش بر اساس کمینه خطای ایجاد شده می‌باشد. شعاع دسته، پارامتر مهمی در خوشه‌بندی کاهشی می‌باشد که کنترل کننده تعداد دسته‌ها و تعداد قوانین اگر آنگاه است که مقدار این پارامتر بین صفر و یک می‌باشد. کاهش این پارامتر باعث افزایش دسته‌ها و تعداد قوانین و افزایش آن به سمت یک باعث کاهش دسته‌ها و قوانین خواهد بود [۴۴]. بنابر این انتخاب شعاع بهینه امر مهمی می‌باشد. در این مطالعه بهینه‌ترین شعاع دسته‌بندی بر اساس کمترین خطای ایجاد شده برای هر دو پیرومتر ۰/۸ به دست آمد که این شعاع دسته‌بندی ۳ قانون و ۳ دسته فازی را برای داده‌های ورودی و خروجی ایجاد می‌کند. تابع عضویت استفاده شده برای

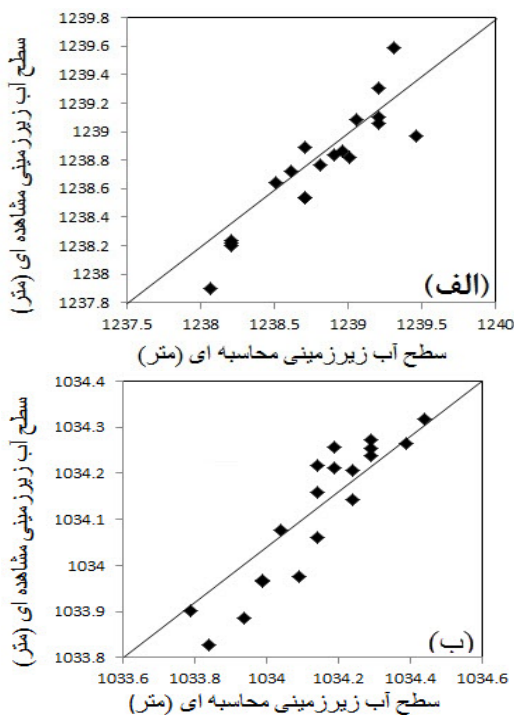
۳-۲- نتایج حاصل از مدل شبکه عصبی برگشتی

پس از نرمال‌سازی کل داده‌های مورد استفاده، شبکه عصبی برگشتی نیز با الگوریتم لوببرگ-مارکوارت استفاده شده است. تابع تبدیلگر برای هر دو پیرومتر در لایه میانی از نوع سیگموئید تانژانتی و در لایه خروجی خطی می‌باشد. به منظور تعیین تعداد بهینه گره‌های لایه میانی روش آزمون و خطا انجام شده و بر اساس کمترین خطای بازده مدل تعداد ۳ گره برای لایه میانی به دست آمد. آموزش شبکه عصبی برگشتی برای پیرومتر شماره ۱ با ۲۰ دوره آموزشی و با مقادیر R^2 و RMSE به ترتیب ۰/۷۸ و ۰/۱۹ و برای پیرومتر شماره ۲ با ۲۶ دوره آموزشی با مقادیر R^2 و RMSE به ترتیب ۰/۸۴ و ۰/۰۵ انجام شد. در نهایت مدل سازی برای مرحله آزمایش نیز انجام شد. نتایج حاصل در جدول (۱) آورده شده است.



شکل ۵- پلات جعبه‌ای سطح آب زیرزمینی مشاهده‌ای (Observed) و سطح آب پیش‌بینی شده توسط مدل‌های FNN، RNN، SFL، SVM و SCMAI برای پیرومتر شماره ۱: الف) مرحله آموزش و ب) مرحله آزمایش

پیش‌بینی دوباره سطح آب پیش‌بینی شده توسط مدل‌های شبکه عصبی پیشرو، برگشتی، منطق فازی ساگنو و ماشین بردار پشتیبان استفاده شد. شبکه عصبی مورد استفاده برای ترکیب مدل‌های منفرد شامل ۴ گره در لایه اول که همان خروجی‌های مدل‌های منفرد می‌باشند که در این‌جا به ورودی مدل مورد استفاده قرار می‌گیرند، ۳ گره برای لایه میانی که از طریق آزمون و خطا به دست آمد و یک گره برای لایه خروجی است که سطح آب پیش‌بینی شده توسط مدل هوش مصنوعی مرکب می‌باشد. تابع تبدیل‌گر برای لایه پنهان از نوع سیگموئید تانژانتی و برای لایه خروجی از نوع خطی است. برای پیژومتر شماره ۱ مقادیر R^2 و RMSE به ترتیب ۰/۸۵ و ۰/۱۵ به دست آمد. این مقادیر برای پیژومتر شماره ۲ به ترتیب برابر ۰/۹۰ و ۰/۰۴ شدند. پس از آن مدل‌سازی برای مرحله آزمایش نیز اجرا شد. نتایج حاصل از مدل هوش مصنوعی مرکب در جدول (۱) و شکل-های (۵) و (۶) آمده است. نمودار حاصل از رسم مقادیر مشاهداتی سطح آب زیرزمینی در مقابل مقادیر پیش‌بینی شده توسط مدل هوش مصنوعی مرکب نظارت شده برای مرحله آزمایش در شکل (۷) برای پیژومتر شماره ۱ و ۲ آورده شده است.



شکل ۷- نمودار حاصل از رسم مقادیر مشاهداتی در مقابل مقادیر محاسباتی مرحله آزمایش حاصل از مدل SCMAI برای (الف) پیژومتر شماره ۱، (ب) پیژومتر شماره ۲

داده‌های ورودی تابع گوسی بود و تابع عضویت خروجی مدل از نوع خطی می‌باشد که بر اساس داده‌های ورودی ساخته می‌شود. مقادیر R^2 و RMSE مربوط به مراحل آموزش و آزمایش پیژومترها با استفاده از روش فازی در جدول (۱) ارائه شده است.

۴-۲- نتایج حاصل از مدل ماشین بردار پشتیبان

مهم‌ترین مزیت SVM استفاده از حقه کرنل^۱ برای ایجاد دانش کارشناسی درباره مسئله می‌باشد که باعث می‌شود پیچیدگی مدل و خطای پیش‌بینی به طور هم‌زمان کمینه شود [۴۵]. در این پژوهش SVM نوع LS-SVM^۲ به کار گرفته شده که توسط Suykens و همکارانش پیشنهاد شده است [۴۶]. برای اجرای SVM انتخاب بهترین تابع کرنل و مقادیر مناسب برای پارامترهای بهینه آن که شامل پارامتر عمومیت‌سازی (C) و پارامتر کرنل (γ) است بر اساس کمینه خطای ایجاد شده ضروری می‌باشد (جدول (۲)). در این تحقیق از کرنل RBF استفاده شده. بر اساس مطالعات انجام گرفته توسط [۴۷، ۱۰] کارایی بهتر تابع کرنل RBF نسبت به تابع کرنل-های دیگر به اثبات رسیده است. نتایج حاصل از این مدل نیز برای مراحل آموزش و آزمایش در جدول (۱) ارائه شده است.

نتایج حاصل از چهار مدل مختلف شبکه عصبی پیشرو، شبکه عصبی برگشتی، منطق فازی ساگنو و ماشین بردار پشتیبان که در جدول (۱) ارائه شده است نشان می‌دهد که هر چهار مدل توانایی خوبی در پیش‌بینی سطح آب زیرزمینی دارند، اما نتایجی که مدل‌ها در پیژومترها و مراحل مختلف نشان می‌دهند متفاوت می‌باشند. مثلاً در پیژومتر شماره ۱ بهترین نتیجه مربوط به مدل‌های SVM و FNN در مرحله آموزش و مدل FNN در مرحله آزمایش می‌باشد و در پیژومتر شماره ۲ مدل SVM در مرحله آموزش و مدل FNN در مرحله آزمایش بهترین نتایج را نسبت به بقیه مدل‌ها ارائه داده‌اند. به همین دلیل انتخاب یک مدل به عنوان بهترین روش برای پیش‌بینی تغییرات سطح آب زیرزمینی در منطقه معقول نمی‌باشد. بنابر این به منظور بهره‌گیری از کارایی و مزایای همه مدل‌ها در یک پیژومتر مدل‌های هوش مصنوعی به کار رفته به صورت غیر خطی از طریق یک شبکه عصبی مصنوعی ترکیب شدند.

۴-۵- نتایج حاصل از مدل هوش مصنوعی مرکب (SCMAI)

برای اجرای مدل مرکب هوش مصنوعی نشان داده شده در شکل (۴) از یک شبکه عصبی سه لایه پرسپترون با الگوریتم LM برای

1- Kernel trick

2- Least-squares support vector machine

جدول ۱- نتایج به دست آمده از مدل‌های مختلف هوش مصنوعی در مراحل آموزش و آزمایش

نوع مدل					معیار ارزیابی	مراحل	پیرومترها
SCMAI	SVM	FL	RNN	FNN			
۰/۱۵	۰/۱۷	۰/۱۷	۰/۱۹	۰/۱۷	RMSE	آموزش	شماره ۱
۰/۸۵	۰/۸۲	۰/۸۱	۰/۷۸	۰/۸۲	R ²		
۰/۱۷	۰/۱۹	۰/۱۹	۰/۲۳	۰/۱۸	RMSE	آزمایش	
۰/۸۱	۰/۷۸	۰/۷۷	۰/۶۶	۰/۷۹	R ²		
۰/۰۴	۰/۰۵	۰/۰۵	۰/۰۵	۰/۰۵	RMSE	آموزش	شماره ۲
۰/۹۰	۰/۸۷	۰/۸۴	۰/۸۴	۰/۸۵	R ²		
۰/۰۶	۰/۰۹	۰/۰۹	۰/۰۸	۰/۰۷	RMSE	آزمایش	
۰/۸۴	۰/۷۴	۰/۷۱	۰/۸۰	۰/۸۳	R ²		

جدول ۲- مقادیر بهینه پارامترهای SVM

تایع کرنل	γ	C	پیرومتر
RBF	۸/۵۷	۲/۶۱	شماره ۱
RBF	۶/۷۷	۲/۳۰	شماره ۲

۴- نتیجه‌گیری

در این تحقیق، پیش‌بینی سطح آب زیرزمینی با استفاده از مدل‌های مختلف هوش مصنوعی با داده‌های بارش، میزان حجم برداشتی از آب زیرزمینی، دما و سطح آب زیرزمینی در یک زمان قبل می‌باشد که در دو مرحله انجام گرفته است. در مرحله اول سطح آب زیرزمینی با استفاده از مدل‌های هوش مصنوعی FNN، RNN، SFL و SVM پیش‌بینی شده و در مرحله دوم خروجی‌های حاصل از مدل‌های منفرد هوش مصنوعی به عنوان ورودی‌های مدل هوش مصنوعی مرکب (SCMAI) بکار رفته و پیش‌بینی دوباره سطح آب زیرزمینی انجام گرفت. نتایج نشان داد که هر یک از مدل‌های هوش مصنوعی به تنهایی سطح آب زیرزمینی را به خوبی پیش‌بینی کردند که نشانگر این مطلب می‌باشد که اگر در مدل‌سازی با روش‌های هوش مصنوعی داده‌های صحیح مورد استفاده قرار گیرد و پارامترهای مؤثر در خروجی مدل‌ها به عنوان ورودی انتخاب شوند، این مدل‌ها قابلیت مدل‌سازی و پیش‌بینی خروجی را دارا می‌باشند.

در این تحقیق، برای بکارگیری توانایی ذاتی و متفاوت هر کدام از مدل‌های هوش مصنوعی و متعاقباً برای دستیابی به نتایج بهتر در زمینه پیش‌بینی سطح آب زیرزمینی اقدام به ترکیب غیر خطی این مدل‌ها گردید. نتایج حاصل از هر دو پیرومتر حاکی از آن هستند که تمام مدل‌ها از دقت خوبی برخوردار بوده و توانسته‌اند سطح آب زیرزمینی را با دقت قابل

قبولی پیش‌بینی کنند. در این میان مدل هوش مصنوعی مرکب کارایی و دقت بالایی نسبت به مدل‌های منفرد هوش مصنوعی داشته و نتایج بهتری در مراحل آموزش و آزمایش نسبت به دیگر مدل‌ها نشان می‌دهد. مدل هوش مصنوعی مرکب با کاهش ۹٪ و ۱۷٪ خطای پیش‌بینی به ترتیب برای پیرومترهای شماره ۱ و ۲ نتایج بهتری را نسبت به مدل‌های منفرد ارائه داده که دلیل آن بهره‌گیری این مدل از مزایای همه مدل‌ها به طور همزمان می‌باشد. توانایی بالای مدل‌های مرکب غیر خطی در مسائل پیش‌بینی در این تحقیق نیز مؤید تحقیقات اخیر [۱۳-۱۵، ۳۲] می‌باشد. همچنین با مقایسه مقادیر R² برای پیرومترها مشخص شد که پیرومتر شماره ۲ که دارای نوسانات سطح آب کمتری (۰/۴۶ متر) نسبت به پیرومتر شماره ۱ (۱/۲ متر) می‌باشد، نتایج بهتری را در پیش‌بینی‌ها ارائه می‌دهد. افزایش تقریباً دو برابری کارایی مدل هوش مصنوعی مرکب در پیرومتر شماره ۲ نسبت به پیرومتر شماره ۱ نیز بیانگر این مسئله می‌باشد.

۵- مراجع

- [۱] اکبری، م.، جرگه، م.، مدنی سادات، ح.، "بررسی افت سطح آب‌های زیرزمینی با استفاده از سیستم اطلاعات جغرافیایی (GIS) (مطالعه موردی: آبخوان دشت مشهد)"، مجله پژوهش‌های حفاظت آب و خاک، ۱۳۸۸، ۱۶ (۴)، ۶۳-۷۸.
- [۲] مرتضوی، س. م.، سلیمانی، ک.، غفاری موفق، ف.، "مدیریت منابع آب و توسعه پایدار، مطالعه موردی: دشت رفسنجان"، آب و فاضلاب، ۱۳۹۰، ۲، ۱۲۶-۱۳۱.
- [3] Zhu, L., Gong, H., Li, X., Wang, R., Chen, B., Dai, Z., Teatini, P., "Land Subsidence due to Groundwater Withdrawal in the Northern

- Conductivity Estimation", *Journal of Hydrologic Engineering*, 2014, 19, 520-532.
- [15] Tayfur, G., Nadiri, A. A., Moghaddam, A. A., "Supervised Intelligent Committee Machine Method for Hydraulic Conductivity Estimation", *Water Resources Management*, 2014, 28, 1173-1184.
- [16] Sreekanth, P. D., Geethanjali, N., Sreedevi, P. D., Ahmed, S., Kumar, N. R., Jayanthi, P. D. K., "Forecasting Groundwater Level Using Artificial Neural Networks", *Research Articles*, 2009, 96 (7), 933-939.
- [17] Coppola, E. A., Szidarovszky, F., Poulton, M., and Charles, E., "Artificial Neural Network Approach for Predicting Transient Water Levels in a Multilayered Groundwater System under Variable State, Pumping, and Climate Conditions", *Journal of Hydrologic Engineering*, 2003, 6, 348-360.
- [18] Coppola, E. A., Rana, A. J., Poulton, M. M., Szidarovszky, F., Uhl, V. W., "A Neural Network Model for Predicting Aquifer Water Level Elevations", *Ground Water*, 2005, 2, 231-241.
- [19] Daliakopoulos, I. N., Coulibaly, P., Tsanis, I. K., "Groundwater Level Forecasting Using Artificial Neural Networks", *Journal of Hydrology*, 2005, 309, 229-240.
- [20] Hamed, Y., Elkiki, M., Gahtani, O. S. A., "Prediction of Future Groundwater Level Using Artificial Neural Network, Southern Riyadh, KSA (Case Study)", *International Water Technology Journal*, 2015, 5 (2), 149-169.
- [21] Kadkhodaie-Ilkhchi, A., Amini, A., "A Fuzzy Logic Approach to Estimating Hydraulic Flow Units from Well Log Data: A Case Study from the Ahwaz oilfield, South Iran", *Journal of Petroleum Geology*, 2009, 32 (1), 67-78.
- [22] Calvo, P. I., Estrada, G. J. C., "Improved Irrigation Water Demand Forecasting using a Soft-Computing Hybrid Model", *Biosystems Engineering*, 2009, 102 (2), 202-218.
- [23] Mayilvaganan, M. K., Naidu, K. B., "ANN and Fuzzy Logic Models for the Prediction of Groundwater Level of A Watershed", *International Journal on Computer Science and Engineering*, 2011, 3 (6), 2523-2530.
- [24] Emamgholizadeh, S., Moslemi, K., Karami, G., "Prediction the Groundwater Level of Bastam Plain (Iran) by Artificial Neural Network (ANN) and Adaptive Neuro-Fuzzy Inference System (ANFIS)", *Water Resources Management*, 2014, 28, 5433-5446.
- Beijing Iain, China", *Engineering Geology*, 2015, 193, 243-255.
- [۴] جعفری، ف.، افتخاری، م.، "بررسی تبادلات آبی و نفوذ جبهه آب شور دریاچه ارومیه به آبخوان‌های همجوار"، *مدیریت آب و آبیاری*، ۱۳۹۲، ۳ (۱)، ۲۹-۴۷.
- [۵] اصغری مقدم، ا.، نورانی، و.، ندیری، ع.، "مدل‌سازی بارش دشت تبریز با استفاده از شبکه‌های عصبی مصنوعی"، *مجله دانش کشاورزی*، ۱۳۸۷، ۱۸ (۱)، ۱-۱۵.
- [6] Li, X., Shu, L., Liu, L., Yin, D., Wen, J., "Sensitivity Analysis of Groundwater Level in Jinci Spring Basin (China) Based on Artificial Neural Network Modeling", *Hydrogeology Journal*, 2012, 20, 727-738.
- [7] Nadiri, A. A., Moghaddam, A. A., Shokri, S., "Efficiency Assessment of Wastewater Treatment Plant of Tabriz Using Artificial Intelligence Models", *Journal of Environmental Studies*, 2015, 40 (4), 827-844.
- [8] Coppola, E. A., Duckstein, L., Davis, D., "Fuzzy Rule-based Methodology for Estimating Monthly Groundwater Recharge in a Temperate Watershed", *Journal of Hydrologic Engineering*, 2002, 4, 326-335.
- [۹] ندیری، ع.، اصغری‌مقدم، ا.، عبقری، ه.، کلانتری اسکویی، ع.، حسین‌پور، ع.، و حبیب‌زاده، و.، "منطق فازی در تخمین قابلیت انتقال آبخوان‌ها مطالعه موردی: دشت تسوج"، *نشریه دانش آب و خاک*، ۱۳۹۳، ۲۴ (۱)، ۲۰۹-۲۲۳.
- [10] Asefa, T., Kemblowski, M., McKee, M., Khalil, A., "Multi-time Scale Stream Flow Predictions: The Support Vector Machines Approach", *Journal of Hydrology*, 2006, 318, 7-16.
- [11] Hong, W. C., Pai, P. F., "Potential Assessment of the Support Vector Regression Technique in Rainfall Forecasting", *Water Resources Management*, 2007, 21, 495-513.
- [12] Behzad, M., Asghari, K., Eazi, M., Palhang, M., "Generalization Performance of Support Vector Machines and Neural Networks in Runoff Modeling", *Expert Systems with Applications*, 2009, 36, 7624-7629.
- [13] Nadiri, A. A., Fijani, E., Tsai, F. T.-C., Moghaddam, A. A., "Supervised Committee Machine with Artificial Intelligence for Prediction of Fluoride Concentration", *Journal of Hydroinformatics*, 2013, 15, 1474-1490.
- [14] Nadiri, A. A., Chitsazan, N., Tsai, F. T. C., Moghaddam, A. A., "Bayesian Artificial Intelligence Model Averaging for Hydraulic

- [۳۵] ندیری، ع.، "مقایسه کارایی مدل‌های عددی و هوش مصنوعی در مدیریت آبخوان‌ها (مطالعه موردی: دشت تسوج)", پایان‌نامه دکتری، دانشگاه تبریز، ایران، ۱۳۹۲.
- [36] Fausett, L., "Fundamentals of Neural Network", Prentice Hall, Englewood Cliffs, 1994.
- [37] ASCE Task Committee on Application of Artificial Neural Networks in Hydrology, "Artificial Neural Network in Hydrology, Part I and II", Journal of Hydrologic Engineering, 2000, 5 (2), 115-137.
- [۳۸] ندیری، ع.، "پیش‌بینی سطح آب‌های زیرزمینی با استفاده از مدل شبکه‌های عصبی مصنوعی در محدوده مترو شهر تبریز"، پایان‌نامه کارشناسی ارشد، دانشگاه تبریز، ایران، ۱۳۸۶.
- [39] Zadeh, L. A., "Fuzzy Sets", Information and Control, 1965, 8 (3), 338-353.
- [40] Bardossy, A., Duckstein, L., "Fuzzy rule-based Modeling with Applications to Geophysical, Biological and Engineering Systems", CRC Press, Florida, 1995.
- [41] Vapnik, V. N., "The Nature of Statistical Learning Theory", Springer, New York, 1995.
- [42] Schölkopf, B., Smola, A. J., "Learning with Kernels: Support Vector Machines, Regularization, Optimization, and Beyond", MIT Press, Cambridge, Massachusetts, 2002.
- [43] Huang, Y., Gedeon, T. D., Wong, P. M., "An Integrated Neural-Fuzzy-Genetic-Algorithm Using Hyper-Surface Membership Functions To Predict Permeability In Petroleum Reservoirs", Engineering Applications of Artificial Intelligence, 2001, 14, 15-21.
- [44] Chiu, S. L., "Fuzzy Model Identification Based on Cluster Estimation", Journal of Intelligent and Fuzzy Systems, 1994, 2 (3), 267-278.
- [45] Raghavendra, S. N., Deka, P. C., "Support Vector Machine Applications in the Field of Hydrology: A Review", Applied Soft Computing, 2014, 19, 372-386.
- [46] Suykens, J. A., Gestel, K. V., Brabanter, T. D., Moor, J. D., Vandewalle, B. J., "Least Squares Support Vector Machines", World Scientific Publishing, Singapore, 2002.
- [47] Asefa, T., Kemblowski, M. W., Urroz, G., McKee, M., "Support Vector Machines SVMs for Monitoring Networks Design", Ground Water, 2005, 43 (3), 413-422.
- [25] Rashidi, S., Mohammadan, M., Azizi, K., "Predicting of Groundwater Level Fluctuation Using ANN and ANFIS in Lailakh plain", Journal of Renewable Natural Resources Bhutan, 2015, 3 (1), 77-84.
- [26] Bisht, D. C. S., Raju, M. M., Joshi, M. C., "Simulation of Water Table Elevation Fluctuation Using Fuzzy-Logic and ANFIS", Computer Modelling and New Technologies, 2009, 13 (2), 16-23.
- [27] Behzad, M., Asghari, K., Coppola, E. A., "Comparative Study of SVMs and ANNs in Aquifer Water Level Prediction", Journal of Computing in Civil Engineering, 2010, 5, 408-413.
- [28] Suryanarayana, Ch., Sudheer, Ch., Mahammood, V., Panigrahi, B. K., "An Integrated Wavelet-Support Vector Machine for Groundwater Level Prediction in Visakhapatnam, India", Neurocomputing, 2014, 145, 324-335.
- [29] Yoon, H., Jun, S. C., Hyun, Y., Bae, G. O., Lee, K. K., "A Comparative Study Of Artificial Neural Networks and Support Vector Machines for Predicting Groundwater Levels In A Coastal Aquifer", Journal of Hydrology, 2011, 396, 128-138.
- [30] Shiri, J., Kisi, O., Yoon, H., Lee, K. K., Nazemi, A. H., "Predicting Groundwater Level Fluctuations with Meteorological Effect Implications-A Comparative Study among Soft Computing Techniques", Computers & Geosciences, 2013, 56, 32-44.
- [31] Chen, C. H., Lin, Z. S., "A Committee Machine with Empirical Formulas for Permeability Prediction", Computers & Geosciences, 2006, 32, 485-496.
- [32] Kadkhodaie-Ilkhchi, A., Rahimpour-Bonab, H., Rezaee, M., "A Committee Machine with Intelligent Systems for Estimation of Total Organic Carbon Content from Petrophysical Data: An Example from Kangan and Dalan reservoirs in South Pars Gas Field, Iran", Computers & Geosciences, 2009, 35, 459-474.
- [33] Emberger, L., "La Vegetation De La Region Mediterranee. Essai D'une Classification Des Groupements Vegetaux", Revue générale de Botanique, 1930, 42, 641-662.
- [34] Hopfield, J. J., "Neural Network and Physical Ayatems with Emergent Collective Computational Abilities", Proceeding of the National Academy of Sciences of the United States of America, 1982, 79, 2554-2558.

EXTENDED ABSTRACT

Supervised Intelligent Committee Machine Method for Groundwater Level Prediction

Ata Allah Nadiri*, Fatemeh Vahedi, Asghar Asghari Moghaddam, Ali Kadkhodaie

Faculty of Natural Science, University of Tabriz, Tabriz, Iran

Received: 16 January 2016; Accepted: 29 July 2016

Keywords:

Groundwater level, Artificial neural network, Fuzzy, Support vector machine, Supervised intelligence committee machine

1. Introduction

Groundwater is an important water resource supplying agricultural, domestic, and industrial needs. Hence, studying and investigation of this vital source is necessary. Over extraction of groundwater cause adverse effects, such as major water level declines [1], consequently water-quality degradation, land subsidence [2], and saltwater intrusion. Therefore, accurate prediction of groundwater level will help planer and managers of water resources and prevent the mentioned effects. The literature shows the success of using artificial intelligence (AI) models in the field of groundwater level such as artificial neural network (ANN) [3], fuzzy logic (FL) [4], and support vector machine (SVM) [5]. Although several studies are reported in the literature that use Supervised committee machine artificial intelligence (SCMAI) as a modeling technique in the field of hydrology e.g. [6] to combine the results of different models to reap the advantages of all AI. This study applied a supervised committee machine with an artificial intelligent (SCMAI) method that replaces linear combination with an artificial neural network. In the SCMAI the ANN receives individual model estimations as input variables and re-predicts the groundwater level. The Meshginshahr plain is located in Northwest Iran in the Province of Ardabil (Fig. 1). The aquifer of this plain is unconfined. The prevailing climate in this plain is semiarid-cold. The average annual temperature and rainfall are 11.66 °C and 292 mm respectively. Sabalan Mount with the height of 4814 meters asml, is the highest point in the study area

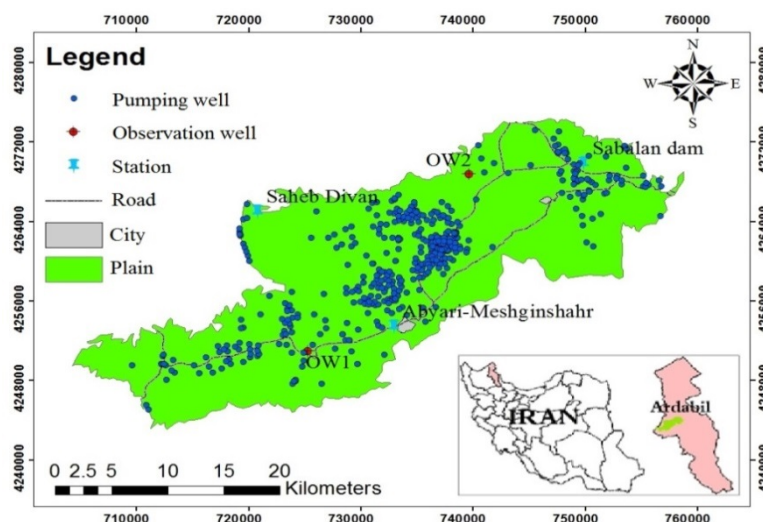


Fig. 1. Study area

* Corresponding Author

E-mail addresses: nadiri@tabrizu.ac.ir (Ata Allah Nadiri), f_vahedi92@ms.tabrizu.ac.ir (Fatemeh Vahedi), moghaddam@tabrizu.ac.ir (Asghar Asghari Moghaddam), Kadkhodai_ali@tabrizu.ac.ir (Ali Kadkhodaie).

2. Methodology

2.1. Data analysis

Based on availability of data, two observation wells in the study area were selected for predicting groundwater level (GWL). The data of temperature (T), precipitation (P), discharge of extraction wells (D), and groundwater level at previous month (GWL*) were used as inputs of models. It should mention that all data are monthly data of 9 years (2004-2012). 80% of data were used for training step and the rest 20% for test step.

2.2. Artificial Neural Networks (ANNs)

The ANN is predicated on finding a functional relationship that maps some specified input vector to a desired output vector [5]. A typical ANN consists of a number of nodes that are organized according to a particular arrangement. ANNs can be classified based on the direction of information flow and processing. In a FNN, information passes from the input layer to the output side. On the other hand, in a RNN, information flows through the nodes in both directions, from the input to the output side and vice versa. This is generally achieved by recycling previous network outputs as current inputs, thus allowing for feedback [7].

2.3. Fuzzy Logic (FL)

Zadeh [8] introduced the fuzzy sets. They are distinguished from ordinary sets in terms of partial membership. Fuzzy set theory is an excellent mathematical tool to handle the uncertainty arising due to vagueness [4]. A fuzzy system includes 3 parts: 1. Fuzzification: The degree of membership in a fuzzy set is defined through a membership function. 2. Fuzzy rules: A fuzzy rule-based model operates on an if→then principle [9] 3. Defuzzification.

2.4. Support Vector Machines (SVMs)

The basic concept and theory of SVM have been introduced by Vapnik [10]. The SVM implements the structural risk minimization principle (SRM). The most important concept of SRM is minimizing an upper bound to the generalization error instead of minimizing the training error. Based on SRM principles, SVM has two outstanding of excellent generalization capability, and sparse representation.

2.5. Supervised Committee Machine with an Artificial Intelligent (SCMAI)

The SCMAI combines the results of artificial intelligence models to reap advantages of all AI models to produce the final output [6]. In this study, we used a SCMAI model that employs an ANN as a supervised combiner of all AI models. The SCMAI model consists of four individual AI models, shown in Fig. 2, to re-predict groundwater level.




Fig. 2. The Schematic structure of SCMAI model

To evaluate the accuracy of the models Root Mean Square Errors (RMSE) and coefficient of determination (R^2) between measured and predicted values were calculated based on the following equations.

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^n (X_i - \hat{X}_i)^2}{n}} \quad (1)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (X_i - \hat{X}_i)^2}{\sum_{i=1}^n (X_i - \bar{X})^2} \quad (2)$$

Where X_i and \hat{X}_i are the measured and predicted value respectively. \bar{X} and n is the mean and number of data.

3. Results and discussion

3.1. Results of FNN and RNN

FNN with Levenberg-Marquardt (LM) training algorithm was used to predict groundwater level. First data were normalized then number of nodes for hidden layer were determined by trial and error. It was 3 nodes for both observation wells based on lowest RMSE. This value was 3 nodes for RNN too. Transfer function of hidden and output layer was tansig and purlin respectively for both FNN and RNN methods. The results are shown in Table 1.

Table 1. Results of models in training and test step

Observation well	Step	Criteria	Models				
			FNN	RNN	FL	SVM	SCMAI
OW1	Training	RMSE	0.17	0.19	0.17	0.17	0.15
		R ²	0.82	0.78	0.81	0.82	0.85
	Test	RMSE	0.18	0.23	0.19	0.19	0.17
		R ²	0.79	0.66	0.77	0.78	0.81
OW2	Training	RMSE	0.05	0.05	0.05	0.05	0.04
		R ²	0.85	0.84	0.84	0.87	0.90
	Test	RMSE	0.07	0.08	0.09	0.09	0.06
		R ²	0.83	0.80	0.71	0.74	0.84

3.2. Results of FL

The Sugeno fuzzy logic model is constructed by subtractive clustering method. The optimal cluster radius of 0.8, 3 clusters and 3 If-Then rules were determined based on the lowest RMSE. The results are shown in table 1.

3.3. Results of SVM

Least-squares SVM type was applied to predict GWL. Selecting suitable kernel function and optimized value of kernel (γ) and regularization (C) parameters is important step in implementing SVM. The optimized value of γ and C were determined based on minimizing RMSE (Table 2). Table 1 shows the results of SVM.

Table 2. Optimized value of SVM parameters

Observation well	γ	C	Kernel function
OW1	8.57	2.61	RBF
OW2	6.77	2.30	RBF

3.4. Results of SCMAI

The aforementioned review of literature reveals that a FNN, trained with the L-M training algorithm, is more efficient than other types of ANN, which was used in this study for SCMAI model to combine the results of four RNN, FNN, FL, and SVM models nonlinearly. The structure of ANN for SCMAI model is 4-3-1. The high R², and the lowest RMSE obtained from SCMAI confirmed the high ability of it in predicting GWL (Table 1).

4. Conclusions

In this paper, first groundwater level prediction was carried out using RNN, FNN, FL, and SVM. Then to obtain the best results, the groundwater level was re-predicted by SCMAI model. Comparing results showed that SCMAI outperforms individual models by decreasing 9% and 17% of RMSE values in OW1 and OW2 respectively. This priority of SCMAI is because of using the advantages of all RNN, FNN, FL, and SVM models simultaneously.

5. References

- [1] Akbari, M., Jarge, M. R., Sadat, H. M., "Assessment of Decreasing of groundwater-table Using Geographic Information System (GIS) (Case study: Mashhad Plain Aquifer)", *Journal of Water and Soil Conservation*, 2009, 16 (4), 63-78 (In Persian).
- [2] Teatini, P., Ferronato, M., Gambolati, G., "Groundwater pumping and Land Subsidence in the Emilia-Romagna Coastland, Italy: Modeling the Past Occurrence and the Future Trend", *Water Resources Research*, 2006, 42, 1-19.
- [3] Coppola, E. A., Szidarovszky, F., Poulton, M., Charles, E., "Artificial Neural Network Approach for Predicting Transient Water Levels in a Multilayered Groundwater System under Variable State, Pumping, and Climate Conditions", *Journal of Hydrologic Engineering*, 2003, 6, 348-360.
- [4] Bisht, D., Jain, Sh., Raju, M. M., "Prediction of Water Table Elevation Fluctuation through Fuzzy Logic & Artificial Neural Networks", *International Journal of Advanced Science and Technology*, 2013, 51, 107-120.
- [5] Behzad, M., Asghari, K., Coppola, E. A., "Comparative Study of SVMs and ANNs in Aquifer Water Level Prediction", *Journal of Computing in Civil Engineering*, 2010, 5, 408-413.
- [6] Nadiri, A. A., Fijani, E., Tsai, F. T. C., Moghaddam, A. A., "Supervised committee machine with artificial intelligence for prediction of fluoride concentration", *Journal of Hydroinformatics*, 2013, 15, 1474-1490.
- [7] ASCE Task Committee on Application of Artificial Neural Networks in Hydrology, "Artificial Neural Network in Hydrology, Part I and II", *Journal of Hydrologic Engineering*, 2000, 5 (2), 115-137.
- [8] Zadeh, L. A., "Fuzzy Sets", *Information and Control*, 1965, 8 (3), 338-353.
- [9] Bardossy, A., Duckstein, L., "Fuzzy Rule-based Modeling with Applications to Geophysical, Biological and Engineering systems", CRC Press, Florida, 1995.
- [10] Vapnik, V. N., "The Nature of Statistical Learning Theory", Springer, New York, 1995.