

پیش بینی نوسانات سطح آب زیرزمینی در آبخوان باروق با استفاده از مدل SOM-AI

یاسرباقری^۱، اسفندیار عباس نوین پور^۲، عطاءالله ندیری^۳ و کیوان نادری^۴

^۱ کارشناسی ارشد، دانشکده علوم، دانشگاه ارومیه، ارومیه، ایران

^۲ استادیار، دانشکده علوم، دانشگاه ارومیه، ارومیه، ایران

^۳ دانشیار، دانشکده علوم طبیعی، دانشگاه تبریز، تبریز، ایران

^۴ دکترا، دانشکده علوم طبیعی، دانشگاه تبریز، تبریز، ایران

تاریخ دریافت: ۱۳۹۶/۱۰/۲۶ تاریخ پذیرش: ۱۳۹۷/۰۱/۲۶

چکیده

قسمت اعظم مساحت کشور از لحاظ جغرافیایی در کمربند خشک و نیمه خشک با بارندگی کم قرار گرفته است. رشد روزافزون جمعیت و محدودیت منابع آبی و استفاده بیش از قبل از منابع آب زیرزمینی در بیشتر نقاط کشور، پیش بینی دقیق مقدار این منابع را به دلیل اهمیت در برنامه ریزی و مدیریت بهینه می طلبد. در این تحقیق به منظور تخمین نوسانات سطح آب زیرزمینی آبخوان باروق در استان آذربایجان غربی و محدوده مطالعاتی میاندوآب از مدل های هوش مصنوعی شامل مدل فازی و مدل ماشین بردار پشتیبان و شبکه عصبی مصنوعی برگشتی با به کارگیری داده های سطح آب زیرزمینی ۷ پیزومتر انتخابی و همچنین تغییرات دما و بارش طی دوره زمانی ۱۴ ساله (۸۱ تا ۹۴) استفاده شده است. با وجود توانایی های ذاتی هر یک از این مدل های هوش مصنوعی در پیش بینی سطح آب زیرزمینی، ناهمگنی فراوان محدوده مطالعاتی از حصول بازده بالای مدل ها می کاهد. لذا مدل سازی SOM-AI که ترکیب روش دسته بندی نقشه خودسازمانده و مدل های اجرا شده است، با تقسیم بندی منطقه مطالعاتی به مناطق همگن باعث افزایش بازده هر یک از مدل های مرکب در قسمت های مختلف آبخوان شد. نتایج نشان داد که روش ارائه شده می تواند روشی کارا در مدل سازی آبخوان های ناهمگن و حتی چند لایه باشد.

کلیدواژه ها: آبخوان باروق، سطح آب زیرزمینی، شبکه عصبی مصنوعی برگشتی، ماشین بردار پشتیبان، فازی ساگنو.

* نویسنده مسئول: عطاءالله ندیری

E-mail: Nadiri@tabrizu.ac.ir

۱- پیش نوشتار

ماشین بردار پشتیبان یکی دیگر از مدل های هوش مصنوعی و یک سیستم یادگیری کارآمد بر مبنای تئوری بهینه سازی مقید است، که از اصل استقرای کمینه سازی خطای ساختاری استفاده می کند و منجر به یک جواب بهینه کلی می شود (اعلمی و همکاران، ۱۳۹۲). اولین کاربرد مدل ماشین بردار پشتیبان SVM در مسائل آب توسط Dibikey et al. (2001) با مدل سازی بارش - رواناب ارائه شده است. بعد از آن در تحقیقات زیادی از ماشین بردار پشتیبان برای پیش بینی سطح آب و هدایت هیدرولیکی و همچنین بررسی آسیب پذیری آبخوان استفاده شده است (Yoon et al., 2011; Suryanarayana et al., 2014; Park et al., 2015; Mirzavand et al., 2015; Raj et al., 2016; Zhou et al., 2017).

یکی دیگر از مدل های هوش مصنوعی، مدل فازی است. مجموعه های فازی مرزهای مبهم و تدریجی بین مرزهای تعریف شده دارند، که برای مقابله با ماهیت عدم قطعیت در سیستم و خطاهای انسانی مناسب هستند (Tayfur et al., 2014; Calvo and Estrada, 2009). تحقیقات مختلفی در زمینه هیدروژئولوژی با این روش انجام شده است (Kisi, 2013; Nadiri et al., 2014; Asadi et al., 2017; Srinivas et al., 2015; Vadiati et al., 2016; نادیری و همکاران، ۱۳۹۳) و همچنین برای پیش بینی سطح آب زیرزمینی نیز از این روش بهره جسته اند (Alvisi et al., 2006; Jalalkamali et al., 2011; Naderifar et al., 2017; Umamaheswari and Kalamani, 2014).

با توجه به توانایی ذاتی هر یک از مدل های هوش مصنوعی در پیش بینی و تخمین پارامترهای هیدروژئولوژیکی، ناهمگنی محیط های مطالعاتی از دقت و کارایی بالای این مدل ها می کاهد. بدین منظور می توان با ترکیب دسته بندی های مختلف با مدل های هوش مصنوعی (AI) از مشکل ناهمگنی این محیط ها کاست. از روش های دسته بندی استفاده شده در این نوع از ترکیب ها می توان به روش دسته بندی سلسه مراتبی (HCA) اشاره کرد، که در ترکیب با مدل های فازی، نروفازی و ژنتیک بوده و از مشکل ناهمگنی آبخوان کاسته و نتایج مدل را تقویت کرده و بهبود بخشیده است (حبیبی، ۱۳۹۳؛ نادری، ۱۳۹۳؛ ودیعی و همکاران، ۱۳۹۶؛ مصطفی زاده و همکاران، ۱۳۹۵). مزیت روش های دسته بندی هوش مصنوعی نسبت به روش های آماری که نیاز به

امروزه مطالعات هیدروژئولوژیکی با اهدافی چون بررسی وضعیت فعلی منابع آب زیرزمینی، تعیین پتانسیل موجود آب زیرزمینی، پیش بینی و تغییرات تراز آب زیرزمینی و بررسی هدایت هیدرولیکی آبخوان ها در دوره های آبی و امکان برنامه ریزی و مدیریت منابع آب برای بهبود شرایط آبخوان در آینده انجام می گیرد (Ansari Mahabadi et al., 2011). اگر چه مدل های ریاضی و مفهومی ابزار اصلی برای نمایش متغیرهای هیدرولوژیکی و درک فرایندهای فیزیکی در یک سیستم هستند، اما این ابزار محدودیت های علمی دارند و در بسیاری از موارد قابل استفاده نیستند؛ از جمله زمانی که داده ها کافی نیست و پیش بینی دقیق مهم تر از درک فیزیکی است (Nadiri et al., 2013). در این شرایط مدل های هوش مصنوعی می تواند یک گزینه مناسب برای مطالعات هیدروژئولوژیکی باشد (Nadiri et al., 2014). مدل های هوش مصنوعی (AI) شامل شبکه عصبی مصنوعی (ANN; Artificial Neural Network)، منطق فازی (FL; Fuzzy Logic)، ماشین بردار پشتیبان (SVM; Support Vector Machine)، نرو فازی (NF; Neurofuzzy) و غیره است که هر کدام از این مدل ها مزیت ها و خصوصیات منحصر به فردی دارند. در طی سال های اخیر تحقیقات گسترده ای در زمینه پیش بینی و تخمین پارامترهای هیدروژئولوژی و هیدروژئولوژیکی با استفاده از این مدل ها انجام گرفته است. از مدل های کارا در زمینه پیش بینی نوسانات سطح آب زیرزمینی می توان به مدل شبکه عصبی مصنوعی (ANN) اشاره کرد، که دارای خواص ویژه برای سیستم های غیرخطی هستند. توانایی مدل شبکه عصبی مصنوعی در شناسایی یک رابطه از الگوهای داده شده، امکان حل مشکلات پیچیده هیدروژئولوژیکی را فراهم می سازد. از جمله مطالعات انجام شده با شبکه عصبی مصنوعی می توان به ارزیابی نوسانات سطح آب زیرزمینی (Coppola et al., 2003؛ نادیری، ۱۳۸۶؛ Nourani et al., 2008؛ Hamed et al., 2015; Karthikeyan et al., 2013)، تخمین هدایت هیدرولیکی (Coppola et al., 2005؛ Cho et al., 2011؛ Nadiri, 2015؛ Nadiri et al., 2018؛ Nasr and Zahran., 2014؛ Baghapour et al., 2016؛ Nadiri et al., 2018) و پیش بینی مکانی پارامترهای هیدروشیماایی (اصغری مقدم و همکاران، ۱۳۸۸؛ Mair and Dandy, 1996; Nadiri et al., 2014 and 2015) اشاره کرد.

استفاده شده است. همچنین ترکیب این روش‌های مذکور با روش دسته‌بندی SOM به منظور غلبه بر وضعیت ناهمگن محدوده مطالعاتی و مقایسه این مدل‌ها به منظور دست‌یابی به بهینه‌ترین مدل برای پیش‌بینی و مدیریت منابع آب زیرزمینی انجام گرفته است.

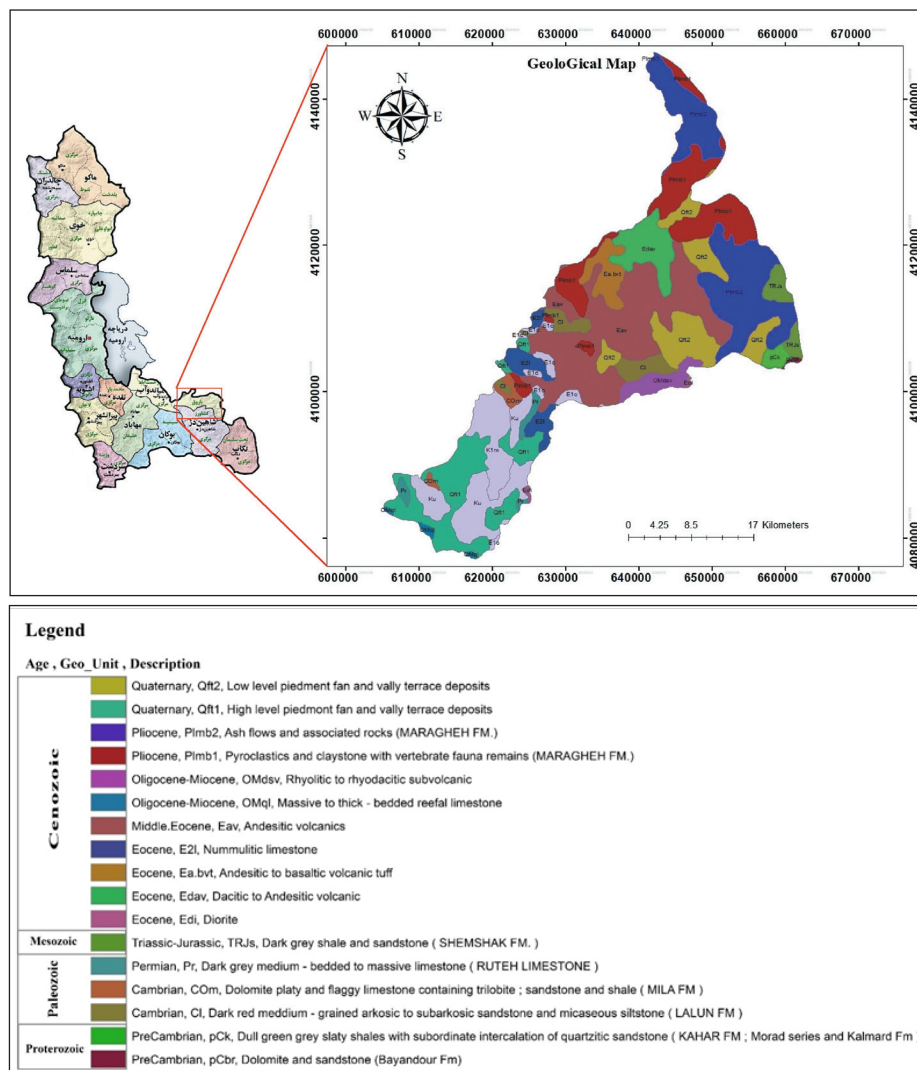
۲- مواد و روش‌ها

۲-۱. موقعیت منطقه مطالعاتی

دشت باروق با وسعت ۵۰ کیلومترمربع در خاور محدوده مطالعاتی میان‌دوآب یکی از ۲۵ محدوده مطالعاتی حوضه آبریز دریاچه ارومیه بوده و در قسمت جنوب دریاچه ارومیه واقع شده است. آبخوان مذکور به فاصله ۲۰ کیلومتر از شهرستان میان‌دوآب قرار دارد. موقعیت بسیار مطلوب جغرافیایی باعث رشد بسیار خوب کشاورزی و در نتیجه رشد صنعتی منطقه میان‌دوآب شده است. از نظر زمین‌شناسی و چینه‌شناسی در این ناحیه رخنمون سنگ‌های مربوط به سازندهای گوناگون از پرکامبرین تا عهد حاضر به استثنای دوره‌های سیلورین تا کربونیفر با رخساره‌های رسوبی دریایی و قاره‌ای، آذرین و دگرگونی گسترش دارد (شکل ۱). ساختارهای زمین‌شناسی ناحیه احتمالاً بر اثر رخدادهای زمین‌ساختی آسیتیک که سنگ‌های پرکامبرین را دگرگون کرده و آلی که موجب نفوذ توده‌های آذرین شده، شکل گرفته است. روند کلی این ساختارها شمال باختری- جنوب خاوری بوده و طرح ساختاری گروه‌های سنگی مختلف با یکدیگر تفاوت قابل ملاحظه دارد. امتداد عمده گسل‌های منطقه شمال باختری- جنوب خاوری است.

داده‌های زیاد و حالت خطی دارند، سازگار بودن این روش‌ها با سیستم‌های پیچیده آبخوان چندگانه و حالت غیرخطی آنهاست. از جمله این مدل‌های دسته‌بندی می‌توان به نقشه خود سازمانده (Self Organizing Map) (SOM) اشاره کرد. در سال‌های اخیر این مدل در ترکیب با مدل‌های مختلف هوش مصنوعی استفاده شده است. از جمله (Nourani et al. 2016) بررسی نوسانات سطح آب دشت تامپا در فلوریدای آمریکا را در سه سناریوی مجزا با ترکیب مدل نروفازی موجکی با روش دسته‌بندی SOM انجام دادند و همچنین در تحقیقی دیگر، داداش‌بابا و همکاران (۱۳۹۶) به ارزیابی توانایی مدل ترکیبی SOM-FL برای پیش‌بینی هدایت هیدرولیکی در محدوده متروی شهر تبریز پرداخته‌اند. در هر دو مطالعه ذکر شده، با دسته‌بندی داده‌ها با روش SOM نتایج بهتری حاصل شده است.

آبخوان باروق در خاور محدوده مطالعاتی میان‌دوآب یکی از حوضه‌های آبریز دریاچه ارومیه است. این دشت در سال اخیر به علت افزایش استفاده از آب‌های سطحی و زیرزمینی و متعاقباً کاهش نزولات جوی با افت شدید سطح آب‌های زیرزمینی مواجه شده است. با توجه به این که عمده درآمد جمعیت این منطقه از طریق کشاورزی سنتی و باغات است و همچنین با توجه به جمعیت رو به رشد، این دشت به مدیریت صحیح و کارآمد در کنترل برداشت‌های بی‌رویه نیاز دارد. از آنجایی که آبخوان باروق جزو دشت‌های ممنوعه است، برداشت از آب‌های زیرزمینی این منطقه به همین منوال مشکلات جبران‌ناپذیری را در پی خواهد داشت. در این پژوهش به منظور ارزیابی و پیش‌بینی نوسانات سطح آب زیرزمینی آبخوان باروق از مدل‌های شبکه عصبی برگشتی، ماشین بردار پشتیبان و فازی ساگنو

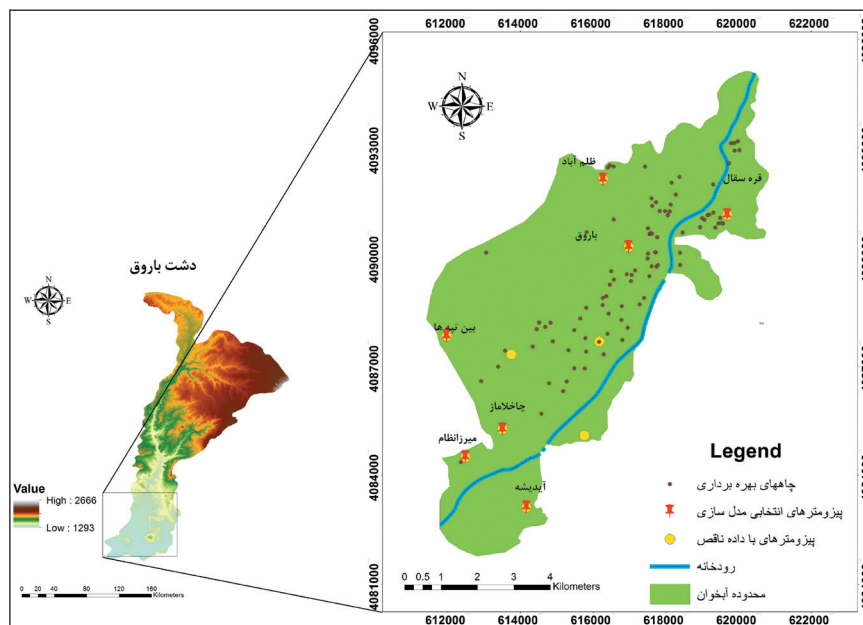


شکل ۱- موقعیت و نقشه زمین‌شناسی منطقه مطالعاتی.

۲-۲. هیدروژئولوژی و هیدروژئولوژی منطقه

مطالعاتی شاهین دژ و میان‌دوآب و حداقل آن در خروجی دشت برابر با ۱۳۰۰ متر از سطح دریاهای آزاد بوده و متوسط ارتفاع دشت ۱۳۴۳ متر برآورد شده است. در دشت باروق با توجه به نقشه مقاومت عرضی (RT; Resistance Transversal) و حفاری‌های اکتشافی صورت گرفته، اندازه رسوبات آبرفتی در حوالی رودخانه دانه‌درشت است و به سمت حواشی از اندازه ذرات کاسته می‌شود. بر اساس اطلاعات حاصل از حفاری، رسوبات آبرفتی در محل چاه مخلوطی از لایه‌های دانه‌ریز رس و سیلتی تا ذرات دانه‌متوسط تا درشت ماسه و شنی است که با افزایش عمق به صورت متناوب تکرار می‌شوند. آبخوان در این دشت از نوع آزاد است. در این محدوده ۱۰ حلقه پیزومتر و ۶۷۶ حلقه چاه کم‌عمق و عمیق وجود دارد (شکل ۲). مطالعه و مدل‌سازی سطح آب زیرزمینی این دشت به علت اهمیت آن در بحث کشاورزی و برداشت بی‌رویه منابع آب زیرزمینی و افت شدید سطح آب آن و متعاقباً ممنوعه اعلام کردن دشت باروق از اهمیت بسزایی در مدیریت منابع آب منطقه برخوردار است.

دشت باروق به همراه ارتفاعات مشرف به دشت (حوضه آبریز قوری‌چای) با وسعت برابر ۱۶۹۵ کیلومتر مربع از میان دشت‌های محدوده مطالعاتی میان‌دوآب به شمار می‌رود (شکل ۲). مساحت دشت باروق در حدود ۵۰ کیلومتر مربع است و بقیه مساحت حوضه را ارتفاعات تشکیل می‌دهد. حوضه آبریز قوری‌چای از زیر حوضه‌های زربینه‌رود، زهکش اصلی این دشت است. در این محدوده مطالعاتی میانگین بارندگی سالانه در دوره درازمدت ۲۰ ساله (۷۴ تا ۹۴) بر اساس گزارش سازمان آب منطقه‌ای استان آذربایجان غربی در ارتفاعات و دشت به ترتیب ۳۱۸/۱ و ۲۷۵/۸ میلی‌متر برآورد شده است و ماه‌های فروردین و اردیبهشت، پرباران‌ترین ماه‌های سال هستند. میانگین دمای ماهانه متفاوت و از ۸- درجه سانتی‌گراد در بهمن ماه تا ۴۰+ درجه سانتی‌گراد در مرداد ماه متغیر است. اقلیم عمومی غالب منطقه باروق بر اساس روش اقلیم‌بندی یونسکو ویژگی‌های نیمه‌خشک دارد. حداکثر ارتفاع آن، قله اربت‌داغ با ارتفاع ۱۶۵۸ متر در خاور منطقه و مرز دو محدوده



شکل ۲-۲ ارتفاع رقمی، آبراهه و موقعیت چاه‌های حفر شده منطقه مورد مطالعه.

۲-۳ روش شناسی

در این تحقیق به منظور بررسی نوسانات سطح آب آبخوان باروق از مدل‌سازی SOM-AL که ترکیب روش دسته‌بندی نقشه خودسازمانده و مدل‌های هوش مصنوعی شامل شبکه عصبی، فازی و ماشین بردار پشتیبان است؛ برای تقسیم‌بندی منطقه مطالعاتی استفاده شده است. دسته‌بندی داده‌ها برای به دست آوردن محیط همگنی از داده‌ها و ایجاد ساختاری بهینه از مدل صورت می‌گیرد.

نقشه خودسازمانده (SOM) یکی از روش‌های هوش مصنوعی است که اولین بار توسط Kohonen (1997) توسعه داده شده است. این مدل یک توزیع منظم ابعاد بزرگ را بر روی یک منظومه کوچک کم حجم نمایش می‌دهد. از این رو، می‌تواند ارتباط پیچیده غیرخطی را در مجموعه داده‌های با ابعاد بزرگ به یک صفحه نمایش ساده تقلیل دهد. در حالی که ساختار توپولوژی اصلی داده‌ها حفظ می‌شود (Kohonen, 1997). بنابراین SOMها ابعاد داده‌ها را کاهش و الگوهای مشابهی نشان می‌دهند. این روش با استفاده از نرم‌افزار متلب انجام شده و یکی از روش‌های هوش مصنوعی است. هر

شبکه SOM معمولاً شامل یک لایه ورودی و یک لایه خروجی است. بردارهای وزن (سیناپس‌ها) لایه ورودی را به لایه خروجی (که نقشه یا لایه رقابتی نامیده می‌شود) متصل می‌کنند. در یک فرایند تکرار، SOM آموزش دیده است. هر بردار ورودی بر اساس بیشترین شباهت، گرهی را فعال می‌کند که در لایه خروجی سلول برنده خوانده می‌شود. شباهت بین دو بردار معمولاً بر اساس فاصله اقلیدسی مطابق رابطه ۱ در نظر گرفته می‌شود که اغلب به عنوان یک تفاوت قابل اندازه‌گیری است (Kohonen, 1997):

$$D_j = \sum_{i=1}^n \|W_{i,j} - X_i\|^2 \quad (1)$$

که در آن، x_i امین بردار ورودی، W_{ij} بردار وزنی متصل کننده ورودی i به نرون خروجی j و D_j حاصل جمع فاصله اقلیدسی بین نمونه ورودی x_i و بردار وزن ارتباطی آن به زمین سلول خروجی است که واحد نقشه نامیده می‌شود.

۲-۴ شبکه عصبی مصنوعی

شبکه‌های عصبی مصنوعی یک سیستم پردازشگر اطلاعات توده‌ای هستند که به صورت موازی قرار گرفته‌اند و عملکردی شبیه شبکه عصبی مغز انسان دارند (Hopfield, 1982).

۲-۶. ماشین بردار پشتیبان

اساس روش ماشین‌های بردار پشتیبان SVM توسط (Cortes and Vapnik (1995 ارائه شد. ماشین بردار پشتیبان یک سیستم یادگیری کارآمد است که از اصل استقرار کمیته‌سازی خطای ساختاری بهره می‌جوید و به یک جواب بهینه کلی منجر می‌شود (Cristianini and Shawe-Taylor, 2000). مهم‌ترین کاربردهای ماشین بردار پشتیبان، طبقه‌بندی داده‌ها است. ویژگی مهم SVM این است که برخلاف الگو ریتیم‌های کلاسیک و رگرسیون خطی که به وسیله حداقل کردن قدرمطلق خطا یا توان دوم خطا عمل می‌کنند، آنها ریسک‌های عملیاتی را به حداقل می‌رسانند. SVM ریسک نبود طبقه‌بندی صحیح را به صورت یک سری عددی بیان و بعد مقدار کمیته آن را حساب می‌کند. اما شبکه عصبی MLP هر موقع خطای تقسیم‌بندی (تفکیک) کم باشد، آن را به عنوان یک راه حل ارائه می‌دهد. ماشین بردار پشتیبان بر خلاف شبکه عصبی با شکل گیر افتادن در مینیمم‌های محلی تابع خطا مواجه نیست. مراحل حل مسئله در الگوریتم شبکه‌های عصبی به دو مرحله آموزش و آزمایش تقسیم می‌شود. انواع مدل‌های ماشین بردار پشتیبان عبارتند از طبقه‌بندی بردار پشتیبان، رگرسیون بردار پشتیبان، حداقل مربعات ماشین‌های بردار پشتیبان، برنامه‌ریزی خطی ماشین‌های بردار پشتیبان و Nu ماشین‌های بردار پشتیبان (Raghavendra and Chandra, 2014).

۲-۷. آنالیز داده‌ها

انتخاب ورودی در مدل‌های هوش مصنوعی از مهم‌ترین مسائلی است که باید برای به‌دست آوردن دقیق‌ترین خروجی به آن توجه کرد. در آبخوان باروق ۱۰ حلقه پیزومتر وجود دارد که از این تعداد، ۷ پیزومتر دارای داده‌های ۱۴ ساله سطح آب زیرزمینی (شکل ۲) و نیز با توزیع مناسب در دشت، برای مدل‌سازی و پیش‌بینی سطح آب زیرزمینی آبخوان مورد استفاده قرار گرفته است. به‌طور کلی در این تحقیق از متوسط بارش ماهانه و دمای ماهانه در گام زمانی t_0 و از سطح آب زیرزمینی در گام زمانی t_{0+1} به علت تأثیر این دو مؤلفه بر سطح آب زیرزمینی در بازه زمانی سال‌های ۸۱ تا ۹۴ به عنوان ورودی و همچنین از سطح آب زیرزمینی در زمان t_0 به عنوان خروجی مدل‌های هوش مصنوعی شامل شبکه عصبی برگشتی، ماشین بردار پشتیبان و منطق فازی استفاده شد. به‌طوری که ۸۰ درصد از داده‌های مذکور به‌صورت نرمال شده به عنوان داده‌های ورودی قسمت آموزش مدل‌های هوش مصنوعی استفاده و ۲۰ درصد مابقی داده‌ها نیز به‌صورت نرمال شده به عنوان ورودی بخش آزمایش مدل‌ها انتخاب شدند. داده‌های دما در طی این دوره با توجه به آمار ایستگاه سد نوروزلو (جدول ۱) تقریباً روند ثابتی نشان می‌دهند، ولی داده‌های بارش و سطح آب زیرزمینی در بیشتر موارد سیر نزولی درازمدت دارند.

اساس کار شبکه‌های عصبی عبارتند از: الف) گره‌ها واحدهایی هستند که وظیفه پردازش داده‌ها را بر عهده دارند؛ ب) بردارهای ارتباطی سیگنال بین گره را انتقال می‌دهند؛ ج) با توجه به اهمیت داده ورودی وزن هر کدام از خطوط ارتباطی تعیین می‌شود؛ د) گره‌ها دارای توابع فعال‌سازی و تبدیل‌گر برای تعیین سیگنال‌های خروجی از داده‌های ورودی شبکه هستند. یک شبکه معمولاً از سه لایه ورودی، میانی، خروجی تشکیل شده که لایه ورودی وسیله‌ای برای ورود داده‌ها بوده و هر گره ممکن است از متغیرهای ورودی یا از خروجی گره‌های دیگر به دست بیاید و لایه میانی به عنوان پردازشگر سیستم عمل می‌کند که شمار گره‌ها به وسیله روش آزمون و خطا تعیین می‌شود. در نهایت لایه خروجی شامل مقادیر پیش‌بینی شده است. از مهم‌ترین کاربردهای شبکه عصبی مصنوعی می‌توان به موارد زیر اشاره کرد: ۱) تقسیم‌بندی الگوها (داده‌ها، اشکال و غیره)؛ ۲) پیش‌بینی در زمینه‌های مختلف؛ ۳) بهینه‌سازی؛ ۴) حافظه در دسترس برای ذخیره‌سازی؛ ۵) کنترل سیستم‌های مختلف. یک شبکه عصبی مصنوعی چند لایه، شامل گره‌های پردازش (شبه نورون مغز) در لایه‌های مختلف و اتصال‌هایی (شبه سیناپس مغز) است که بین گره‌ها ایجاد می‌شود (Coppola et al., 2003). در شبکه عصبی برگشتی اطلاعات بین گره‌ها در دو جهت، از ورودی به سمت خروجی و بالعکس جریان می‌یابد. این نوع از شبکه، از خروجی‌ها به عنوان ورودی‌های جدید استفاده می‌کند، بنابراین به داده‌ها اجازه برگشت به ورودی را می‌دهد (ASCE, 2000).

۲-۵. سیستم استنتاج فازی

تئوری فازی برای اولین بار توسط پروفیسور Zadeh (1965) در مقاله‌ای با عنوان مجموعه‌های فازی معرفی شد و پس از آن بسیاری از مفاهیم بنیادی تئوری فازی شامل الگوریتم‌های فازی، تصمیم‌گیری فازی و تلفیق فازی در دهه ۱۹۷۰ مطرح شد و امروزه سیستم‌های فازی در طیف وسیعی از علوم کاربرد یافته‌اند. در سیستم‌های کلاسیک عضویت در مجموعه‌ها به‌صورت صفر و یک در نظر گرفته می‌شد، اما برخلاف آنها در سیستم فازی مجموعه‌ها دارای مرزهای مبهم و عضوها دارای درجه عضویت در هر یک از مجموعه‌ها هستند، بدین معنا که مقادیر بین صفر و یک عضویت بخشی دارند. اساس سیستم‌های فازی شامل سه بخش اصلی است: الف) فازی کردن داده‌ها که این عمل با تعریف تابع عضویت انجام می‌شود؛ ب) ایجاد ارتباط بین ورودی و خروجی که این کار نیز با یک سری قوانینی مانند اگر-آنگاه if-then انجام می‌شود؛ ج) بررسی سیستم که به‌دوروش ممدانی (Mamdani) یا ساگنو (Sageno) قابل اجرا است. تفاوت این دو روش در خروجی آنهاست که در روش ساگنو بر خلاف روش ممدانی، تابع عضویت خروجی سیستم فازی به‌صورت ثابت یا رابطه خطی است که توسط روش دسته‌بندی به دست می‌آید (ندیری و همکاران، ۱۳۹۳).

جدول ۱- خلاصه آمار دشت باروق (سازمان آب منطقه‌ای).

متوسط تغییرات سطح آب زیرزمینی	کمیته تبخیر (دی) mm	بیشینه تبخیر (مرداد) mm	بارندگی سالانه درازمدت (دشت)	بارندگی سالانه درازمدت (ارتفاعات)	متوسط دمای سالانه (ارتفاعات)	متوسط دمای سالانه (دشت)
۱۳۰۹-۱۳۶۰	۴۹/۸	۲۶۹	۲۷۵/۸	۳۱۸/۱	۱۱/۷	۹/۴


متوسط سطح آب پیزومتر میرزاانظام	متوسط سطح آب پیزومتر بین‌تپه	متوسط سطح آب پیزومتر چاخلاماز	متوسط سطح آب پیزومتر قره‌سقال	متوسط سطح آب پیزومتر ظلم‌آباد	متوسط سطح آب پیزومتر باروق	متوسط سطح آب پیزومتر آیدیشه
۱۳۱۰	۱۳۲۹	۱۳۱۴	۱۳۵۱	۱۳۵۳	۱۳۳۳	۱۳۰۹

۳- بحث

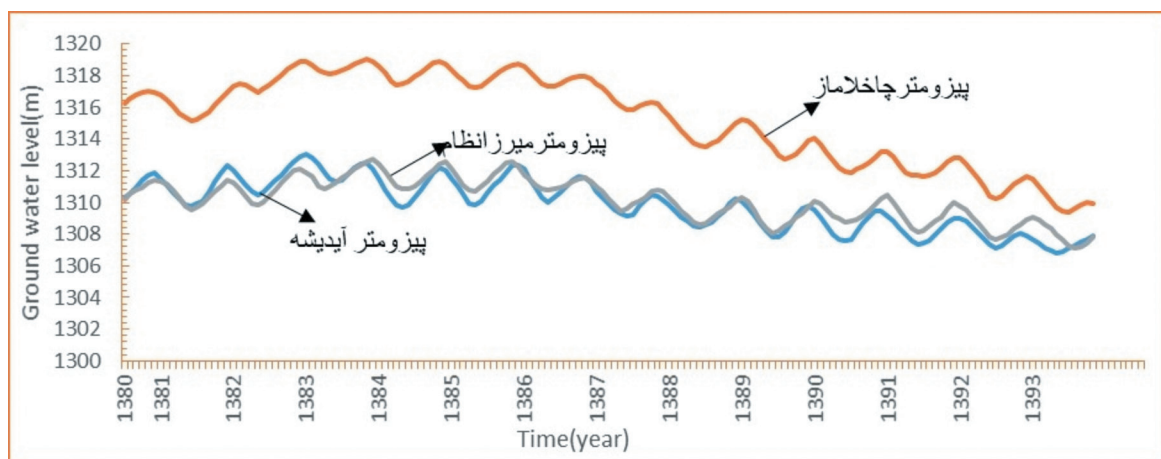
۳-۱. دسته‌بندی منطقه مطالعاتی با روش SOM

برای اجرای این مدل دسته‌بندی ۷ پیزومتر با نام‌های چاخلاماز، آیدیشه، قره‌سقال، ظلم‌آباد، میرزانظام، بین‌تپه‌ها و باروق به عنوان ورودی مدل انتخاب شدند که دارای داده درازمدت سطح آب زیرزمینی ۱۴ ساله (۸۱ تا ۹۴) بودند. خروجی مدل SOM برای این تعداد پیزومتر ۳ دسته، شامل دو دسته هر کدام با ۲ پیزومتر و دسته سوم با ۳ پیزومتر است (شکل ۳). پیزومترهای قره‌سقال و ظلم‌آباد در دسته اول، پیزومترهای میرزانظام، چاخلاماز و آیدیشه در دسته دوم و باروق و بین‌تپه‌ها در دسته سوم قرار گرفتند. در شکل ۴ نمونه‌ای از روند سطح آب زیرزمینی سه پیزومتری که در دسته سه‌تایی قرار گرفته‌اند، نشان داده شده که نشانگر خروجی دقیقی این مدل است.

هدف از این پژوهش ارزیابی تراز آب زیرزمینی آبخوان باروق با استفاده از مدل‌های هوش مصنوعی از جمله شبکه عصبی برگشتی، ماشین بردار پشتیبان و منطق فازی است. اما با توجه به پیچیده و غیرهمگن بودن سیستم منطقه مطالعاتی مذکور و تفاوت قابل ملاحظه تغییرات سطح آب پیزومترها با یکدیگر، هر یک از مدل‌ها به تنهایی قادر به ارائه مدل با دقت بالا در پیش‌بینی سطح آب زیرزمینی نیستند. به همین منظور برای افزایش دقت مدل و غلبه بر محیط نامگن محدوده مطالعاتی، از روش‌های دسته‌بندی پیزومترها استفاده شد. از بین روش‌های دسته‌بندی مختلف از روش دسته‌بندی هوشمند SOM استفاده شده که روشی مبتنی بر هوش مصنوعی است و با توجه به تحقیقات انجام شده، خروجی دقیقی نسبت به سایر روش‌های دسته‌بندی دارد که در بخش روش‌شناسی به صورت کامل مورد بررسی قرار گرفته است.



شکل ۳- میزان تحریک پذیری و حالت نهایی نرون همسایه در مدل SOM.



شکل ۴- روند پیزومترهای انتخابی SOM در یک دسته.

۳-۲. پیش‌بینی زمانی با استفاده از SOM-ANN

در این پژوهش با توجه به تعداد دسته‌های موجود، سه نوع ساختار شبکه عصبی برگشتی ایجاد می‌شود که ساختمان هر یک از این شبکه‌ها وابسته به تعداد پیزومترها، تعداد گره‌های میانی و تعداد خروجی‌هایی است که سطح آب آنها در هر دسته پیش‌بینی می‌شود. در هر سه شبکه اجرا شده برای دسته‌ها از الگوریتم

لونیبرگ-مارکوات 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 به طوری که حالت تخم مرغی شبکه حفظ شود، تعیین شدند. با در نظر گرفتن موارد ذکر شده در هر شبکه، برای دسته اول که دارای دو پیزومتر است، ۴ ورودی شامل بارش، دما و سطح آب دو پیزومتر با تأخیر زمانی (t_{n-1}) در نظر گرفته

خطا و بر حسب به دست آوردن کمترین میزان خطا (RMSE) و بیشترین ضریب تبیین (R^2) انتخاب شد که تعداد ۵ گره بهترین خروجی را ارائه داد. ساختار کلی شبکه با توجه به ۲ خروجی به صورت ۴-۵-۲ است.

در بررسی هر یک از شبکه‌ها به‌طور مجزا (جدول ۲) میزان متوسط کمینه خطا (RMSE) برای دسته اول برابر ۰/۱۶ متر در مرحله آموزش و آزمایش است. همچنین مقدار متوسط این کمینه خطا (RMSE) برای دسته دوم با سه پیرومتر مشخص شده در قسمت دسته‌بندی برابر با ۰/۲ متر در مرحله آموزش و ۰/۲۱ متر در مرحله آزمایش به دست آمد. برای دسته سوم نیز متوسط میزان خطای محاسبه شده (RMSE) در مرحله آموزش برابر ۰/۲۴ متر و برای مرحله آزمایش ۰/۱۹ متر است. با مقایسه نتایج کمینه خطا (RMSE) در هر سه دسته، دسته اول با میزان RMSE کمتر نسبت به دسته دوم و سوم، پاسخ مناسب‌تری با پیرومترهای قره‌سقال و ظلم آباد دارد.

شد. تعداد گره‌های میانی که با روش آزمون و خطا برای این شبکه با کمترین مقدار خطا (RMSE) و بیشترین ضریب تبیین R^2 تعیین شده، ۴ است. بنابراین ساختار کلی شبکه ۴-۴-۲ خواهد بود.

در دسته دوم با توجه به تعداد پیرومترهای این دسته، شبکه دارای ۵ ورودی خواهد بود که از سطح آب سه پیرومتر مذکور و دما و بارش در گام زمانی ($t_{(t-1)}$) تشکیل شده است. تعداد گره‌های میانی که برای این شبکه با توجه به تعداد ورودی‌ها و میزان خطای (RMSE) حاصل از نتایج شبکه به وسیله روش آزمون و خطا به دست آمده است، ۵ گره خواهد بود. بنابراین ساختار شبکه با ۳ خروجی سطح آب زیرزمینی به صورت ۴-۳-۵ است. ساختار شبکه دسته سوم نیز همانند شبکه دسته اول ۴ ورودی دارد. ورودی‌های این شبکه شامل سطح آب دو پیرومتر، بارش و دما خواهد بود. در این شبکه نیز همانند دو شبکه قبلی تعداد گره‌های لایه میانی بر اساس روش آزمون و

جدول ۲- نتایج مدل‌های شبکه عصبی مصنوعی، ماشین بردار پشتیبان و منطق فازی اجرا شده.

نوع مدل		شبکه عصبی مصنوعی				ماشین بردار پشتیبان				منطق فازی	
دسته	نام محل	مرحله آموزش		مرحله آزمایش		مرحله آموزش		مرحله آزمایش		مرحله آموزش	
		RMSE (m)	RMSE (m)	RMSE (m)	RMSE (m)	RMSE (m)	RMSE (m)	RMSE (m)	RMSE (m)	RMSE (m)	RMSE (m)
اول	قره‌سقال (P1)	۰/۹۹	۰/۲۳	۰/۸۳	۰/۲۱	۰/۹۹	۰/۲۶	۰/۸۸	۰/۲۵	۰/۹۹	۰/۱۹
	ظلم آباد (P2)	۰/۹۸	۰/۱۰	۰/۶۲	۰/۱۱	۰/۹۸	۰/۰۹	۰/۶۶	۰/۱۱	۰/۹۸	۰/۰۸
	آیدیشه (P3)	۰/۹۷	۰/۲۲	۰/۸۹	۰/۲۳	۰/۹۶	۰/۲۳	۰/۸۷	۰/۲۳	۰/۹۸	۰/۱۸
دوم	چاخلاماز (P4)	۰/۹۹	۰/۱۸	۰/۹۷	۰/۱۸	۰/۹۹	۰/۲۰	۰/۹۷	۰/۱۵	۰/۹۹	۰/۱۳
	میرزانظام (P5)	۰/۹۶	۰/۲۰	۰/۹۴	۰/۲۳	۰/۹۳	۰/۲۰	۰/۹۵	۰/۱۹	۰/۹۷	۰/۱۵
	باروق (P6)	۰/۹۴	۰/۲۱	۰/۵۹	۰/۱۸	۰/۹۶	۰/۱۷	۰/۶۵	۰/۱۶	۰/۹۷	۰/۱۵
سوم	بین تپه‌ها (P7)	۰/۹۶	۰/۲۸	۰/۹۲	۰/۲۰	۰/۹۷	۰/۲۳	۰/۸۲	۰/۳۶	۰/۹۷	۰/۲۴

پرسپترون چندلایه (MLP-kernel)، سینک (Sinc-kernel) و غیره برای این نوع مدل ماشین بردار پشتیبان وجود دارد (Seifi, 2010). در این تحقیق با توجه به روش آزمون و خطا، برای دسته اول که شامل پیرومترهای قره‌سقال و ظلم آباد است، کرنل تابع پایه شعاعی به عنوان کرنلی دارای کمترین خطا (RMSE) برحسب متر و بیشترین مقدار ضریب تبیین R^2 در مرحله‌های آموزش و آزمایش انتخاب شد. همچنین برای دسته دوم با ۳ پیرومتر میرزانظام، چاخلاماز و آیدیشه و دسته سوم با دو پیرومتر باروق و بین تپه‌ها، کرنل خطی کمترین میزان خطا (RMSE) برحسب متر و بیشترین ضریب تبیین R^2 را نسبت به کرنل‌های اجرا شده بر روی هر دسته نشان داد. در مدل‌های SVM پارامتری به نام گاما وجود دارد که پارامتر تنظیم‌کننده (Regularization parameter) مدل است. با استفاده از آزمون گاما می‌توان متغیرهای با بیشترین و کمترین تأثیرگذاری بر پیش‌بینی را تعیین کرد. مقدار گاما بر اساس روش آزمون و خطا و برای به دست آوردن کمترین میزان RMSE تعیین می‌شود که در تحقیق فوق مقدار آن ۱۰ انتخاب شده است. با توجه به نتایج حاصل از مدل (جدول ۲)، متوسط میزان RMSE در دسته اول برای هر دو پیرومتر در مرحله آموزش ۰/۱۷ متر و در مرحله آزمایش ۰/۱۸ متر بوده که نشانگر نتایج قابل قبول برای این دسته است. در دسته دوم این میزان RMSE برای پیرومترهای آیدیشه، چاخلاماز و میرزانظام در مرحله آموزش ۰/۲۱ متر و در قسمت آزمایش ۰/۱۹ متر و در دسته سوم این متوسط خطا RMSE برای مرحله آموزش ۰/۲۰ متر و برای مرحله آزمایش ۰/۲۶ متر بوده که مقایسه این متوسط‌ها برای هر سه دسته نشانگر خروجی با کمترین

با توجه به خروجی‌های مدل شبکه عصبی برای هر یک از پیرومترها به صورت مجزا، بهترین خروجی برای دسته دوم و پیرومتر چاخلاماز بوده است. روند داده‌های سطح آب و همچنین جهت جریان آب زیرزمینی که از بخش شمال باختری به سمت جنوب خاوری است، نشان می‌دهد که پیرومترهای دسته اول در جهت جریان واقع شده‌اند که از طریق رودخانه قوری چای تغذیه می‌شوند. در نتیجه میزان افت سطح آب به علت تغذیه مناسب کمتر از پیرومترهای دیگر بوده و از شرایط پایدارتری برخوردار است. همچنین بیشترین خطا مربوط به پیرومترهای باروق از دسته سوم و آیدیشه از دسته دوم است. این دو پیرومتر به علت برداشت زیاد آب در فصل‌های مورد نیاز کشاورزی از افت بیشتری نسبت به سایر پیرومترها برخوردارند و نوسانات زیادی دارند.

۳-۳. پیش‌بینی زمانی با استفاده از مدل SOM-SVM

انواع مدل‌های ماشین‌های بردار پشتیبان که عبارتند از ماشین‌های بردار پشتیبان حداقل مربعات (LS-SVM; Least-squares support vector machine)، ماشین‌های بردار پشتیبان برنامه‌ریزی خطی و ماشین‌های بردار پشتیبان Nu (LP-SVM; Linear programming support vector machine) که هر کدام از این مدل‌ها به دو صورت طبقه‌بندی و مسائل رگرسیونی به کار گرفته می‌شوند. در این تحقیق از ماشین بردار پشتیبان حداقل مربعات استفاده شده است (Suyknes et al., 2002) که با توجه به تعداد دسته‌ها مدل SVM خواهیم داشت. کرنل‌های مختلفی همچون کرنل خطی (Lin-kernel)، چندجمله‌ای (Poly-kernel)، تابع پایه شعاعی (RBF-kernel)،

با توجه به جهت جریان آب زیرزمینی دشت و روند نوسانات سطح آب پیژومترها، پیژومتر ظلم‌آباد به طبع تغذیه مناسب و حفظ روند سینوسی افت خیز سطح آب آن خطای (RMSE) کمتری دارد. اما پیژومتر باروق همان‌طور که ذکر شد با افت سطح آب بالایی طی درازمدت به سبب افزایش برداشت‌های مصارف کشاورزی و عدم تغذیه مناسب آن خطای بیشتری نسبت به سایر پیژومترها دارد.

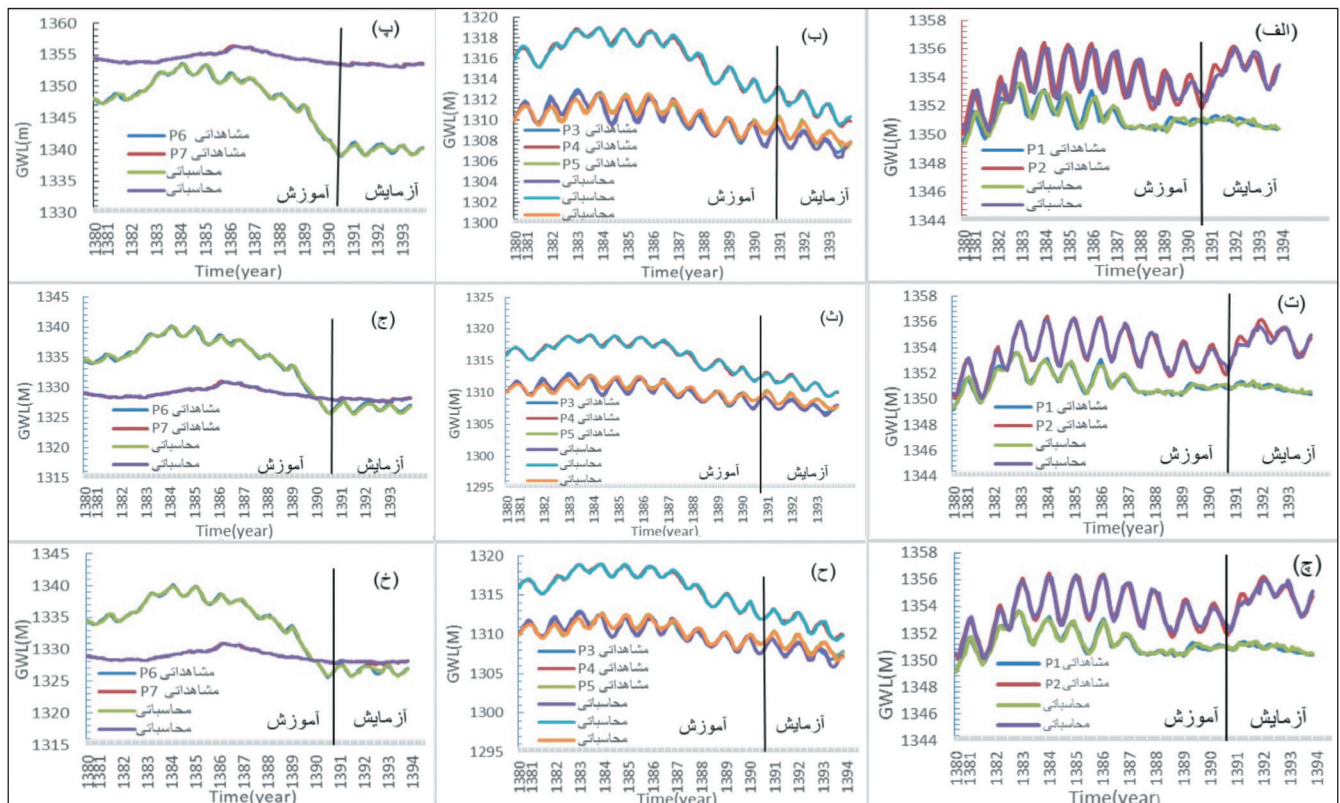
۳-۵. مقایسه مدل‌های اجرا شده

نتایج نشان داد که هر یک از مدل‌های هوش مصنوعی SVM، ANN و SFL به تنهایی قادرند سطح آب زیرزمینی را به خوبی پیش‌بینی کنند که نشانگر این مطلب است که در مدل‌سازی با روش‌های هوش مصنوعی اگر داده‌های صحیح مورد استفاده قرار گیرند و پارامترهای مؤثر در خروجی مدل‌ها به عنوان ورودی انتخاب شوند، این مدل‌ها قابلیت مدل‌سازی و پیش‌بینی خروجی را دارند. همچنین برای غلبه بر محیط ناهمگن محدوده مطالعاتی از ترکیب مدل‌های ذکر شده با مدل دسته‌بندی هوشمند SOM استفاده شده است که بر دقت مدل‌های خروجی می‌افزاید. در بررسی عملکرد هر یک از مدل‌ها همان‌طور که مشهود است در کلیه موارد پیژومتر باروق به علت افت زیاد سطح آب زیرزمینی و دلایل ذکر شده در بررسی مجزای هر یک از مدل‌ها در درازمدت دارای خطای RMSE بیشتری نسبت به سایر پیژومترها در هر سه مدل است. اما در مدل فازی نسبت این خطا در پیژومتر باروق به علت ساختار شبکه فازی کمتر است. با توجه به نتایج، پیژومتر ظلم‌آباد از دسته اول در هر سه مدل اجرایی کمتری نسبت به سایر پیژومترها دارد اما در صورت مقایسه با ضریب تبیین و RMSE به صورت مشترک پیژومتر چاخلاماز خروجی بهتری برای هر سه مدل خواهد داشت (شکل ۵). پیشنهاد می‌شود برای ایجاد مدلی با دقت بیشتر و همچنین تسلط بر کل دشت این مدل‌های اجرا شده به صورت مدلی ترکیبی درآیند و نتایج مدل ترکیبی مورد بحث و بررسی قرار گیرد.

میزان خطای دسته اول نسبت به دو دسته دیگر است. در بررسی پیژومترها به صورت انفرادی پیژومتر ظلم‌آباد از دسته اول با توجه به مقایسه میزان RMSE در دو مرحله آموزش و آزمایش بهترین خروجی را دارد که این امر به سبب افت کم سطح آب زیرزمینی این پیژومتر در درازمدت و تغذیه مداوم آن ایجاد شده است. همچنین پیژومتر باروق از دسته سوم دارای بیشترین خطا (RMSE) به دلیل افت زیاد سطح آن و خروج از روند کلی نوسانات پیژومتر در سال‌های اخیر به سبب برداشت‌های بی‌رویه در این منطقه است.

۳-۴. پیش‌بینی زمانی با استفاده از مدل فازی ساگنو (SFL)

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 بوده که در این پژوهش از روش دسته‌بندی کاهشی (Subtractive clustering) استفاده شده است. اصول شعاع دسته‌بندی در این روش بر اساس کمینه خطای ایجاد شده است. شعاع دسته، پارامتر مهمی در دسته‌بندی کاهشی و کنترل‌کننده تعداد دسته‌ها و تعداد قوانین اگر-آنگاه بوده که مقدار این پارامتر بین صفر و یک است. همچنین تابع عضویت گوسی برای مدل‌سازی فازی مورد استفاده قرار گرفت. ملاک تعیین شعاع بهینه برای هر یک از دسته‌ها، مقایسه میزان کمینه خطا (RMSE) متوسط بین پیژومترهای آن دسته و همچنین مقدار بیشینه ضریب تبیین (R^2) متوسط در هر دو مرحله آموزش و آزمایش، در شعاع‌های متفاوت است. به عبارتی مقایسه بین متوسط‌های RMSE دو پیژومتر در هر دو مرحله آموزش و آزمایش است. بر همین اساس در دسته اول شعاع ۰/۸ به عنوان شعاع بهینه با کمترین میزان RMSE انتخاب و همچنین مقدار ۰/۷ برای دسته دوم با سه پیژومتر آیدیشه، چاخلاماز و میرزانظام تعیین شد. برای دسته سوم با دو پیژومتر مقدار شعاع ۰/۷، کمترین خطا RMSE متوسط و بیشترین ضریب تبیین را داشت (جدول ۲). در بررسی مجزای هر یک از پیژومترها نیز



شکل ۵- مقایسه نتایج مدل‌های اجرا شده با داده‌های مشاهده‌ای: مدل شبکه عصبی (الف: دسته اول، ب: دسته دوم، پ: دسته سوم)، مدل ماشین بردار پشتیبان (ت: دسته اول، ث: دسته دوم، ج: دسته سوم) و مدل فازی (ج: دسته اول، ح: دسته دوم، خ: دسته سوم).

۴- نتیجه‌گیری

اما برای به دست آوردن نتایج دقیق‌تر پیشنهاد می‌شود که در مطالعات آینده ترکیبی از مدل‌های ارائه شده بررسی شود. دشت باروق با توجه به مساحت کم (۵۰ کیلومتر مربع)، کاهش نزولات جوی در سال‌های اخیر و همچنین افزایش استفاده بی‌رویه از منابع آب زیرزمینی برای کشاورزی دچار افت شدید سطح آب‌های زیرسطحی شده است. اگر این امر کنترل و جلوگیری نشود مشکلات زیادی از جمله خشک شدن چاه‌های آب، خشکی رودخانه‌ها و فرونشست دشت را در پی خواهد داشت.

هدف از این تحقیق بررسی سطح آب آبخوان باروق به وسیله سه مدل شبکه عصبی برگشتی، منطق فازی و ماشین بردار پشتیبان و ترکیب با روش دسته‌بندی SOM برای غلبه بر محیط ناهمگن محدوده مطالعاتی و همچنین مقایسه این شبکه‌ها و ارائه ایده‌آل‌ترین مدل برای آبخوان مورد نظر است. نتایج نشان می‌دهد که هر سه مدل SOM-AI پیش‌بینی قابل قبول ارائه می‌دهد، لذا روش ترکیبی ارائه شده می‌تواند راهگشای مشکلات موجود در آبخوان‌های پیچیده باشد. با این وجود انتخاب بهترین مدل از بین مدل‌های SOM-AI به دلیل نتایج نزدیک به هم منطقی به نظر نمی‌رسد.

کتابنگاری

- اصغری مقدم، ا.، ندیری، ع. و فیجانی، ا.، ۱۳۸۸- پیش‌بینی مکانی غلظت فلئورید با استفاده از مدل‌های شبکه‌های عصبی و زمین‌آمار، مجله دانش آب و خاک، ۲(۱۹)، صص. ۱۲۹ تا ۱۴۵.
- اعلمی، م.، صادق‌فام، س.، فاضلی‌فرد، م. و نقی‌پور، ل.، ۱۳۹۲- مدل‌سازی سری داده‌ها، انتشارات دانشگاه تبریز، تبریز، ۲۹۹ ص.
- حبیبی، م. ح.، ۱۳۹۳- پیش‌بینی سطح آب زیرزمینی در دشت هادیشهر با استفاده از روش‌های هوش مصنوعی، پایان‌نامه کارشناسی ارشد، دانشکده علوم طبیعی، دانشگاه تبریز، ۱۵۲ ص.
- داداش‌بابا، م.، ندیری، ع.، اصغری مقدم، ا. و برزگری، ق.، ۱۳۹۶- ارائه روش جدید ترکیبی SOM-GEP برای پیش‌بینی هدایت هیدرولیکی محدوده متروی شهر تبریز، مجله اکوهیدرولوژی، ۴(۴)، صص ۷۵ تا ۸۷.
- مصطفی‌زاده، ر.، مهری، س.، اسمعیلی عوری، ا. و قربانی، ا.، ۱۳۹۵- گروه‌بندی آبخیزها بر اساس خصوصیات فیزیکی و دبی پایه جریان رودخانه با روش‌های مختلف خوشه‌بندی در استان اردبیل، ترویج و توسعه آبخیزداری، ۴(۱۵)، صص. ۳۱ تا ۴۰.
- نادری، ک.، ۱۳۹۳- پیش‌بینی زمانی و مکانی سطح آب زیرزمینی با استفاده از روش‌های هوش مصنوعی و زمین‌آمار (مطالعه موردی: آبخوان دشت دوزدوزان)، پایان‌نامه کارشناسی ارشد، دانشکده علوم طبیعی، دانشگاه تبریز، ۱۳۴ ص.
- ندیری، ع.، ۱۳۸۶- پیش‌بینی سطح آب‌های زیرزمینی با استفاده از مدل‌های شبکه عصبی مصنوعی در محدوده مترو شهر تبریز، پایان‌نامه کارشناسی ارشد، دانشکده علوم طبیعی، دانشگاه تبریز، ۱۷۸ ص.
- ندیری، ع.، اصغری مقدم، ا.، قعیقوری، ه.، کلانتری اسکویی، ع.، حسین‌پور، ع. و حبیب‌زاده، و.، ۱۳۹۳- منطق فازی در تخمین انتقال آبخوان‌ها (مطالعه موردی: دشت تسوج)، نشریه آب و خاک، ۲۴(۱)، صص. ۲۰۹ تا ۲۲۳.
- ودیعتی، م.، اصغری مقدم، ا.، نخعی و م.، ۱۳۹۶- تبیین تحولات رخساره‌های هیدروشمیایی آبخوان سراب با استفاده از روش‌های خوشه‌بندی میانگین فازی و تحلیل خوشه سلسله مراتبی، مجله اکوهیدرولوژی، ۴(۳)، صص. ۷۶۳ تا ۷۷۳.

References

- Alvisi, S., Mascellani, G., Franchini, M. and Bradossy, A., 2006- Water level forecasting through fuzzy logic and artificial neural network approaches. *Hydrology and earth system science*, 10:1- 17.
- Ansari Mahabadi, S., Shamsai, A. and Massah Bavani, A., 2011- Ground water level modeling in Sefiddasht by GMS model Second National Conference on Applied Research in Water Resources, Zanjan, Iran.
- Asadi, P., Hosseini, H., Ataie-Ashtiani, B. and Simmons, C., 2017- Fuzzy vulnerability mapping of urban groundwater systems to nitrate contamination. *Environmental Modelling and Software*, 96: 146- 157.
- ASCE)Task Committee on Application of Artificial Neural Networks in Hydrology(, 2000- Artificial neural network in hydrology, part I and II. *J. Hydrol. Eng.* 5(2): 115- 137.
- Baghapour, M. A., Nobandegani, A. F., Talebbeydokhti, N., Bagherzadeh, S., Nadiri, A. A., Gharekhani, M. and Chitsazan. N., 2016- Optimization of DRASTIC method by artificial neural network, nitrate vulnerability index, and composite DRASTIC models to assess groundwater vulnerability for unconfined aquifer of Shiraz Plain, Iran. *Journal of Environmental Health Science and Engineering* 14 (1), 13.
- Cho, K. H., Sthiannopkao, S., Pachepsky, Y. A. and Kim, K. W., 2011- Prediction of contamination potential of groundwater arsenic in ambodia, Laos, and Thailand using artificial neural network. *Water Research*, 45: 5535- 5544.
- Calvo, P. I. and Estrada, G. J. C., 2009- Improwed irrigation water demand forecasting using a softcomputing hybrid model, *Biosystems Engineering* 102(2): 202- 218.
- Coppola, E. A., McLane, C. F., Pouton, M. M., Szidarovszky, F. and Magelky, R. D., 2005- Predicting Conductance Due to Upconing Using Neural Networks. *Ground Water*, 6: 827- 836.
- Coppola, E., Szidarovszky, F., Poulton, M. and Charles, E., 2003- 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*, 6: 348- 360.
- Cortes, C. and Vapnik, V., 1995- Support-vector networks. *Machine learning*, 20: 3, pp. 273- 297.

- Cristianini, N. and Shawe-Taylor, J., 2000- An Introduction to Support Vector Machines. Cambridge University Press, New York, USA.
- Dibike, Y. B., Velickov, S., Solomatine, D. and Abbot, M. B., 2001- ModelInduction with Support Vector Machines-Introduction and Applications. Journal of Computing Civil Engineering, 15(3):208- 216.
- Hamed, Y., Elkiki, M. and Al Gahtani, O. S., 2015- Prediction of future groundwater level using artificial neural network, Southern Riyadh, KSA(case study). International Water Technology Journal, 5(2): 149- 169.
- Hopfield, J. J., 1982- Neural network and physical systems with emergent collective computational abilities. Proc. Nat. Academy of Scientists, 79: 2554- 2558.
- Jalalkamali, A., Sedghi, H. and manshouri, M., 2011- Monthly ground water level prediction using ANN and neuro-fuzzy models, a case study on Kerman plain. Iran, Journal of Hydroinformatics, 13(4): 867- 876.
- Karthikeyan, L., Kumar, N. D., Graillot, D. and Gaur, S., 2013, Prediction of Ground Water Levels in the Uplands of a Tropical Coastal Riparian Wetland using Artificial Neural Networks, Water Resour Manage, 27, pp. 871- 883.
- Kisi, O., 2013- Applicability of Mamdani and Sugeno fuzzy genetic approaches for modeling reference evapotranspiration. Journal of Hydrology, 504: 160- 170.
- Kohonen, T., 1997- Self-organizing maps, Springer, Berlin.
- Mair, H. R. and Dandy, G. C., 1996- The use of artificial neural network for the prediction of water quality parameters. Water Resour Research, 32(4): 1013- 1022.
- Mirzavand, M., Khoshnevisian, B., Shamshirband, S., Kisi, O., R. and Akib, S., 2015- Evaluating groundwater level fluctuation by support vector regression and neuro-fuzzy methods. a comparative study. Nat Hazards, Published online: 1007 (10): 11069-015-1602-4..
- Naderifar, M., Piri, J. and Kisi, O., 2017- Pre-processing data to predict groundwater levels using the fuzzy standardized evapotranspiration and precipitation index (SEPI). Water Resources Management, 31(14): pp 4433- 4448.
- Nadiri, A. A., 2015- Application of Artificial Intelligence methods in Geosciences and Hydrology. OMICS Publication. 124p.
- Nadiri, A. A., Chitsazan, N., Frank T. C., Tsai, M. and Asghari Moghaddam, A., 2014- Bayesian Artificial Intelligence Model Averaging for Hydraulic Conductivity Estimation. Journal of Hydrologic Engineering, 19:520- 532.
- Nadiri, A. A., Fijani, E., Tsai, F. T.C. and Asghari Moghaddam, A. A., 2013- Supervised Committee Machine with Artificial Intelligence for prediction of Fluoride Concentration . Hydroinformatics Journal, 15(4): 1474- 1490.
- Nadiri, A. A., Hassan, M. M. and Asadi, S., 2015- Supervised intelligence committee machine to evaluate field performance of photocatalytic asphalt pavement for ambient air purification. Transportation Research Record: TRB 2528, 96-105.
- Nadiri, A. A., Sadeghfam, Sina, Gharekhani , M., Khatibi, R. and Akbari, E., 2018- Introducing the risk aggregation problem to aquifers exposed to impacts of anthropogenic and geogenic origins on a modular basis using ‘risk cells’. Journal of Environmental Management 217, 654–667.
- Nasr, M. and Zahran, H. F., 2014- Using of ph as a tool to predict salinity of groundwater for irrigation purpose using artificial neural network. egyptian Journal of Aquatic Research, 40: 111- 115.
- Nourani, V., Asgharimoghaddam, A. A. Nadiri A. O. and Singh, V. P., 2008- Forecasting spatiotemporal water levels of Tabriz aquifer. Trends in Applied Sciences Research 3 (4), 319- 329.
- Nourani, V., Taghi Alami, M. and Daneshvar Vousoughi, F., 2016- Hybrid of SOM-Clustering Method and Wavelet-ANFIS Approach to Model and Infill Missing Groundwater Level Data. Journal of Hydrologic Engineering, 21(9), 05016018.
- Park, Y., Ligaray, M., Kim, Y. M., Kim, J. H., Cho, K. H. and Sthiannopkao, S., 2015- Development of enhanced groundwater arsenic prediction model using machine learning approaches Asian countries. Desalination and water Treatment 1080(10): 1- 10 .
- Raghavendra, S. and Chandra, D. P., 2014- support vector machine applications in the field of hydrology. A review Elsevier , applied soft computing, 19:372- 386.
- Raj, R. J. R., Sasipraba, T., Vasudev, M., Gupta, S., Rizwan, Md. and Srivastava, P., 2016- Predicting the Impact of Climate Change on Tidal Zone Fishes Using SVM Approach. Procedia Computer Science, 92:237- 243.
- Seifi, A., 2010- Developing of expert system to prediction of daily evapotranspiration by support vector machine and compare result to ANN, ANFIS and experimental method. M.Sc. Thesis, Department of Water Engineering, Tarbiat modares University, Tehran, Iran
- Srinivas, R., Bhakar, P. and Singh, A. P., 2015- Groundwater quality assessment in some selected area of Rajasthan, India using fuzzy multi-criteria decision making tool. Aquatic Procedia, 4:1023- 1030.
- Suryanarayana, Ch., Sudheer, C. H., Mahmood, V. and Panigrahi, B. K., 2014- An integrated wavelet-support vector machine for groundwater level prediction in Visakhapatnam, India. Neurocomputing, 145: 324- 335.
- Suykness, G., Van, G., Brabanter, J., De, M. and Vandewalle, J., 2002- Least Squares Support Vector Machine, .World Scientific Publishing, Singapore.
- Tayfur, G., Nadiri, A. A. and Moghaddam, A. A., 2014- supervised intelligent committee machine method for hydraulic conductivity estimation. water resources management, 28: 1173- 1184.

- Umamaheswari, G. R. and Kalamani, D., 2014- Adaptive Neuro Fuzzy inference for monthly groundwater level prediction in Amaravathi river minor basin. *Journal of Theoretical and Applied Information Technology*, 68 (3): 523- 530.
- Vadiati, M., Asghari Moghaddam, A., Nakhaei, M. and Adamowski, J., 2016- A fuzzy- logic based decision-making Approach for identification of ground water quality indices. *Journal of Environmental Management*, 184 (Pt 2): 255- 270.
- Yoon, H., Jun, S. C., Hyun, Y., Bae, G. O. and Lee, K. K., 2011- A comparative study of artificial neural network and support vector machine for prediction ground water level in a coastal aquifer. *Journal of hydrology*, 396: 128- 138.
- Zadeh, L. A., 1965- Fuzzy sets, *Information and Control*, 8 (3): 338- 353.
- Zhou, T., Wang, F. and Yang, Zhi., 2017- Comparative Analysis of ANN and SVM Models Combined with Wavelet Preprocess for Groundwater Depth Prediction. *Water*, 9 (10): 781.

Forecasting of groundwater level fluctuations in Baruq aquifer using the SOM-AI model

Y. Bagjeri¹, E. A. Novinpour², A. A. Nadiri^{3*} and K. Naderi⁴

¹M.Sc., Faculty of Sciences, Urmia University, Urmia, Iran

²Assistant Professor, Faculty of Sciences, Urmia University, Urmia, Iran

³Associated Professor, Faculty of Natural Sciences, Tabriz University, Tabriz, Iran

⁴Ph.D., Faculty of Natural Sciences, Tabriz University, Tabriz, Iran

Received: 2018 January 16

Accepted: 2018 April 15

Abstract

Most of the country's geographically area is located in dry and semi-dry zone with low rainfall. The growing population, the limitation of water resources and the prevalence of groundwater resources in most parts of the country requirement to accurate prediction of the amount of these resources due to the importance of these resources in optimal planning and management. In this research, in order to estimate the fluctuations of groundwater level in the Baruq aquifer, the artificial intelligence models including fuzzy, support vector machine and neural network models were used by the data of depth from 7 piezometers with long-term data of 14 years, as well as changes in temperature and precipitation in this period. Despite the inherent abilities of each models in predicting groundwater level, the heterogeneity of the study area prevented the high efficiency of these models. Therefore, SOM-AI modeling combined the self-organized maps (SOM) classification method and each model that increased the efficiency of each composite model in different parts of the aquifer by dividing the study area into homogeneous regions. The results showed that the proposed method can be an effective method in the modeling of heterogeneous and even multi-layered aquifers.

Keywords: Baruq Aquifer, Groundwater Level, Neural Network, Support Vector Machine, Sageno Fuzzy

For Persian Version see pages 157 to 166

*Corresponding author: A. A. Nadiri; E-mail: Nadiri@tabrizu.ac.ir