

مدل‌سازی تراز آب زیرزمینی آبخوان دشت تبریز با استفاده از مدل ترکیبی SOM-ANN

عطاالله ندیری^{۱*}، مرضیه داداش بابا^۲ و اصغر اصغری مقدم^۳

چکیده

دشت تبریز، در شمال غرب استان آذربایجان شرقی مانند دیگر دشت‌های اطراف دریاچه با بحران کاهش سطح آب زیرزمینی ارومیه روبرو است؛ بنابراین برای مدیریت صحیح و مؤثر این منابع، مطالعه و بررسی تغییرات تراز آب زیرزمینی در دشت‌ها ضروری به نظر می‌رسد. در این پژوهش، از روش ترکیبی مدل شبکه عصبی پیش‌رو (ANN) با دسته‌بندی هوشمند نقشه خودسازمان‌ده (SOM) برای مدل‌سازی تراز آب در ۱۰ چاه مشاهده‌ای آبخوان آزاد دشت تبریز استفاده شده است. ابتدا پنج پارامتر ورودی مؤثر بر تراز آب زیرزمینی شامل بارش (P)، دما (T)، تبخیر (E)، دبی خروجی (Q) و تراز آب زیرزمینی (GWL) در یک زمان قبل (t-1) برای ۱۰ چاه مشاهده‌ای آماده شدند. سپس این چاه‌های مشاهده‌ای، بر اساس تغییرات تراز آب ۱۴ ساله در چهار کلاس دسته‌بندی و با استفاده از مدل ANN، پیش‌بینی تراز آب در تمام چاه‌های مشاهده‌ای برای دسته‌ها انجام شد. طبق نتایج، برای کلاس‌های یک، دو و چهار، میانگین خطای مرحله آموزش و آزمایش به ترتیب ۰/۱۰، ۰/۲۰ و ۰/۲۲ متر و برای کلاس سه که در مرکز دشت موقعیت یافته است، میانگین خطا ۰/۲۳ متر حاصل شد.

واژه‌های کلیدی: آبخوان آزاد دشت تبریز، تراز آب زیرزمینی، چاه‌های مشاهده‌ای، مدل SOM-ANN.

ارجاع: ندیری ع. داداش بابا م. و اصغری مقدم ا. ۱۳۹۷. مدل‌سازی تراز آب زیرزمینی آبخوان دشت تبریز با استفاده از مدل ترکیبی SOM-ANN. مجله پژوهش آب ایران. ۳۱: ۹۵-۱۰۲.

1- دانشیار گروه علوم زمین، دانشکده علوم طبیعی، دانشگاه تبریز.
2- کارشناسی ارشد، گروه علوم زمین، دانشکده علوم طبیعی، دانشگاه تبریز.
3- استاد گروه علوم زمین، دانشکده علوم طبیعی، دانشگاه تبریز.

* نویسنده مسئول: Nadiri@tabrizu.ac.ir

تاریخ دریافت: ۱۳۹۶/۰۱/۳۰ تاریخ پذیرش: ۱۳۹۶/۰۵/۱۶

مقدمه

محدودیت منابع آب سطحی، افزایش تقاضای مصرف آب، توسعه صنعتی و اقتصادی جوامع و افزایش کشاورزی، آب‌های زیرزمینی را به یک منبع طبیعی و ارزشمند برای تأمین نیازهای مربوطه تبدیل کرده است. از طرفی استخراج بی‌رویه آب‌های زیرزمینی به یک مسأله جدی جهانی به‌خصوص در کشورهای درحال توسعه بدل شده است (کونیکو و کندی، ۲۰۰۵)؛ بنابراین برای حفاظت و مدیریت صحیح و مؤثر این منابع ارزشمند، مطالعه و بررسی تغییرات تراز آب زیرزمینی از اهمیت ویژه‌ای برخوردار است. با توجه به وضعیت پیچیده و غیرقابل مشاهده محیط زیرسطحی، مدل‌سازی آب‌های زیرزمینی به عنوان ابزاری قدرتمند برای توسعه برنامه‌ریزی‌های مدیریتی قابل اجرا در مورد آب‌های زیرزمینی و محافظت از این منابع، حیاتی است. با توجه به برخی محدودیت‌های مدل‌های عددی و فیزیکی از جمله وقت‌گیر بودن، پیچیدگی زیاد، پرهزینه بودن و نیاز داشتن به اطلاعات ورودی متنوع، روش‌های هوش مصنوعی از جمله مدل‌های تجربی هستند که می‌توانند در زمانی کوتاه‌تر و با داده‌های در دسترس محدود، نتایج ارزشمندی را ارائه دهند. شبکه‌های عصبی مصنوعی (ANN^۱) برخلاف روش‌های عددی بر اساس یافتن رابطه تابعی^۲ پیش‌بینی را انجام می‌دهد (کاپولا و همکاران، ۲۰۰۳)؛ بنابراین نیاز به توصیف ریاضیاتی دقیق از وضعیت پیچیده فرآیندهای زیرسطحی ندارد (نیاک و همکاران، ۲۰۰۶). شبکه‌های عصبی مصنوعی، می‌تواند مسأله‌های پیچیده از قبیل تشخیص الگو، مدل‌سازی غیرخطی، طبقه‌بندی، ارتباط و کنترل را حل کند (انجمن مهندسان عمران آمریکا، ۲۰۰۰). به‌همین دلیل استفاده از شبکه‌های عصبی مصنوعی به‌عنوان مدل تجربی و کارآمد در علوم مختلف از جمله هیدرولوژی به‌سرعت گسترش یافته است. نشان‌دهنده ضرورت و ارزش بالای مطالعه این مدل‌هاست. این مدل را برای اولین بار در آب‌های زیرزمینی عزیز و وانگ در سال ۱۹۹۲ برای تعیین پارامترهای آبخوان استفاده کردند و در دهه‌های اخیر پژوهشگران بسیاری از مدل‌های هوش مصنوعی از جمله شبکه عصبی به عنوان


مدلی مؤثر و توانا در پیش‌بینی سیستم‌های پیشرفته هیدروژئولوژیکی مانند مدل‌سازی بارش و رواناب، پیش‌بینی جریان رودخانه‌ها، مدل‌سازی تراز آب زیرزمینی، کیفیت آب، مدیریت آب، پیش‌بینی بارش و سری‌های زمانی بهره‌برده‌اند (کولیبالی و همکاران، ۲۰۰۱؛ کاپولا و همکاران، ۲۰۰۳؛ لالاهم و همکاران، ۲۰۰۵؛ دیاکوپولوس و همکاران، ۲۰۰۵؛ یانگ و همکاران، ۲۰۰۹؛ آداموسکی و چان، ۲۰۱۱؛ چیت‌سازان و همکاران، ۲۰۱۳؛ حامد و همکاران، ۲۰۱۵). پژوهش‌های قبلی انجام گرفته در حیطه پیش‌بینی تراز آب زیرزمینی، تنها ارزیابی کارایی مدل‌های هوش مصنوعی و به‌خصوص مدل ANN بوده و لذا تنها به پیش‌بینی تراز آب زیرزمینی در یک چاه مشاهده‌ای اکتفا شده است (چیت‌سازان و همکاران، ۲۰۱۳؛ نورانی و همکاران، ۲۰۱۵). این در حالی است که مدل‌سازی آبخوان نیازمند پیش‌بینی تراز آب زیرزمینی در تمام چاه‌های مشاهده‌ای است تا بتوان راهکارهای مدیریتی مناسبی را برای آبخوان ارائه کرد. از طرفی با توجه به ناهمگنی اکثر آبخوان‌ها عموماً استفاده از مدل‌های هوش مصنوعی مانند شبکه‌های عصبی برای پیش‌بینی تراز آب زیرزمینی در همه چاه‌های مشاهده‌ای نیازمند دسته‌بندی است که از این میان، می‌توان به دسته‌بندی سلسله‌مراتبی که به‌تازگی حبیبی و همکاران (۱۳۹۴) در ترکیب با مدل‌های فازی و نروفازی استفاده کرده‌اند، اشاره کرد. این روش توانست تا حدی از مشکل ناهمگنی و پیچیدگی آبخوان بکاهد و بر تقویت نتایج مدل و تدقیق آن بیفزاید؛ با وجود این به‌دلیل این‌که روش دسته‌بندی مذکور دارای خصوصیات خطی است؛ لذا نمی‌تواند به‌طور دقیق دسته‌بندی محیط ناهمگن را انجام دهد. روش‌های دسته‌بندی هوش مصنوعی برخلاف روش‌های آماری اشاره شده، می‌توانند برای دسته‌بندی داده‌های غیرخطی و پیچیده مانند پیرومترهای آبخوان چندگانه (از جمله LVQ^۳ و SOM^۴) جوابگو باشند.

روش دسته‌بندی نقشه خودسازمان‌ده (SOM) را اولین بار کوهنن (۱۹۸۲) توسعه داد و برای مدل کردن، نقشه‌های بهینه‌سازی توپوگرافیکی سازمان‌یافته، به‌وجود آمد. بی‌نیاز به نظارت حین دسته‌بندی، از برتری‌های این روش است؛

3- Learning Vector Quantization
4- Self - Organization Map

1- Artificial Neural Network
2- Functional relationship

دشت از شمال به دامنه‌های جنوبی کوه‌های میشو، از جنوب به دامنه‌های شمالی سهند، از غرب به اراضی شوره‌زار دریاچه ارومیه و از شرق به شهر تبریز محدود می‌شود (شکل ۱). رودخانه اصلی محدوده مورد مطالعه را تلخه‌رود یا آجی‌چای تشکیل می‌دهد که مهران رود از سرشاخه‌های مهم این رودخانه است. اغلب مواد تشکیل‌دهنده سفره‌های آب زیرزمینی دشت تبریز از سیلت، رس، ماسه و شن هستند که به صورت تناوب تکرار شده و در نقاط مختلف، ضخامت و دانه‌بندی متفاوتی دارند. اقلیم منطقه بر اساس اقلیم نمای آمبرژه (آمبرژه، ۱۹۳۰) از نوع نیمه خشک سرد است. متوسط دمای سالانه ۱۳/۱۹ درجه سلسیوس (بر اساس اطلاعات هواشناسی ایستگاه سینوپتیک تبریز، ۱۳۹۳-۱۳۶۴) و میزان متوسط سالانه بارش ۲۵۰/۶۹ میلی‌متر (بر اساس اطلاعات سازمان آب منطقه‌ای استان آذربایجان شرقی، ۱۳۹۳-۱۳۶۴) است. بر اساس نتایج به‌دست‌آمده از اطلاعات حفاری‌های چاه‌های مشاهده‌ای معلوم شده که آبخوان دشت تبریز از دو نوع آزاد و تحت‌فشار تشکیل شده است (ندیری، ۱۳۸۶). سفره‌های عمقی به‌علت مجاورت با رسوبات میوسن و سفره‌های سطحی به‌علت تأثیر رودخانه آجی‌چای شور بوده؛ ولی سفره‌های میانی (۱۲۰-۵۸ متر) کیفیت بهتری دارند (سبحان‌وردی، ۱۳۸۷). بر اساس نقشه هم‌ضخامت آبخوان آزاد این دشت که بر اساس اطلاعات لاگ‌های حفاری ۲۲ پیزومتر حفر شده در آبخوان آزاد تهیه شده است، مشخص می‌شود قسمت‌های مرکزی دشت دارای ضخامت بیشتری نسبت به نواحی حواشی دشت هستند (شکل ۲). به‌طور کلی آبخوان آزاد این دشت از میان لایه‌های رسی و رسوبات آبرفتی در حد ماسه و سیلت که حضور میان لایه‌های رسی با توزیع تصادفی در آبخوان بر پیچیدگی این آبخوان افزوده است.



شکل ۱- موقعیت دشت تبریز

به‌گونه‌ای که الگوریتم آموزش آن، به‌صورت رقابتی و بدون ناظر است (کوهن، ۱۹۸۲)؛ لذا در چند سال اخیر این روش دسته‌بندی در ترکیب با روش‌های مختلف هوش مصنوعی مانند شبکه عصبی مصنوعی و شبکه ترکیبی موجک- نروفازی^۱ برای پیش‌بینی تراز آب زیرزمینی استفاده شده است. چن و لین (۲۰۱۱) و نورانی و همکاران (۲۰۱۳) به این نتیجه رسیدند که با دسته‌بندی داده‌ها و استفاده از شبکه ترکیبی می‌توان به نتایج بهتری دست یافت. دشت تبریز دارای یک آبخوان آزاد و یک آبخوان تحت‌فشار است. آبخوان آزاد این دشت یک آبخوان چندلایه و پیچیده که در قسمت‌های مختلف دارای ضخامت و کیفیت آب متنوعی است. ضرورت مطالعه آبخوان آزاد این دشت را از سه دیدگاه می‌توان بررسی کرد: الف) تأمین نیاز آبی؛ کیفیت آب آبخوان آزاد در عمق‌های میانی (۱۲۰-۵۸ متر) مناسب است و برای مصارف مختلف کارایی دارد؛ ب) مدیریت پس‌روی دریاچه ارومیه؛ دشت تبریز یکی از ۱۲ دشت احاطه‌کننده دریاچه ارومیه است؛ بنابراین مدیریت و مدل‌سازی تراز آب زیرزمینی در این دشت می‌تواند باعث افزایش تراز آب زیرزمینی و به‌تبع آن کاهش نفوذ و افزایش رواناب سطحی ورودی به دریاچه شود و از پس روی بیشتر دریاچه ارومیه جلوگیری کند و ج) ضرورت مطالعه با روش‌های هوش مصنوعی به دلیل پیچیده و چندلایه بودن آبخوان دشت تبریز؛ پیش‌بینی تراز آب زیرزمینی این منطقه با مدل‌سازی عددی ناموفق بوده است (ندیری، ۱۳۸۶)؛ بنابراین هدف از مطالعه حاضر، کاهش اثر چندلایه‌ای و پیچیدگی آبخوان دشت تبریز در پیش‌بینی تراز آب زیرزمینی این منطقه است. کاهش این اثر با ترکیب مدل شبکه عصبی مصنوعی و دسته‌بندی هوش مصنوعی غیر نظارتی میسر شده و مدل ترکیبی ارائه‌شده (ANN-SOM)، خواهد توانست از حداکثر مزایای مدل شبکه عصبی برای پیش‌بینی دقیق‌تر تراز آب زیرزمینی و مدیریت مناسب استفاده کند.

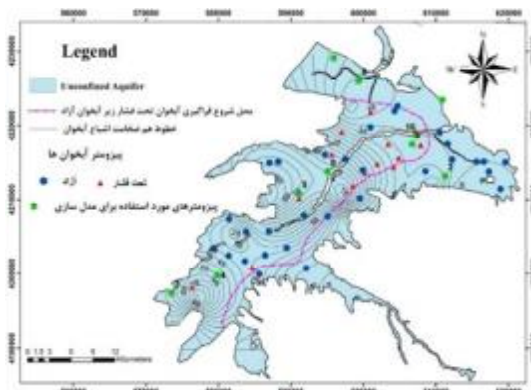
منطقه مطالعاتی

دشت تبریز به وسعت ۱۰۰ هزار هکتار در شمال‌غرب ایران در استان آذربایجان شرقی قرار گرفته است. این

خروجی مدل را معرفی می‌کند و لایه‌های میانی که از گره‌های پردازشگر تشکیل شده‌اند، محل پردازش داده‌ها هستند (ندیری و همکاران، ۲۰۱۳). ساختار یک شبکه عصبی به وسیله الگوی ارتباطی بین گره‌ها، روش تعیین وزن‌های ارتباطی و تابع فعال‌سازی مشخص می‌شود (ندیری و همکاران، ۲۰۱۷). شبکه‌های عصبی مصنوعی، برای جریان و پردازش اطلاعات به دو دسته شبکه‌های پیشرو و شبکه‌های برگشتی طبقه‌بندی می‌شوند. در یک شبکه عصبی پیشرو، گره‌ها در لایه‌ها با شروع از لایه ورودی و با پایان در لایه خروجی نهایی مرتب می‌شوند (انجمن مهندسان عمران آمریکا، ۲۰۰۰). در این پژوهش، از شبکه عصبی پیشرو برای پیش‌بینی استفاده شده است. همچنین الگوریتم مورد استفاده در این تحقیق الگوریتم لونبرگ-مارکوارت^۲ است (ندیری و همکاران، ۲۰۱۷، b)

نقشه خودسازمان‌ده (SOM)

خوشه‌بندی، برای طبقه‌بندی داده‌ها، ساخت داده‌های همگن و یا برای بهینه‌سازی ساختار مدل با انتخاب ورودی‌های غالب و مرتبط انجام می‌شود (نورانی و همکاران، ۲۰۱۳). نقشه خودسازمان‌ده (SOM) به دلیل یادگیری رقابتی، غیرنظارتی و خودسازمانده، نسبت به سایر روش‌های دسته‌بندی برتری دارد. این نوع دسته‌بندی از یک لایه ورودی و یک لایه خروجی تشکیل می‌شود. به ازای هر متغیر ورودی یک نرون در لایه ورودی وجود دارد (شکل ۳ الف). شیوه کار در SOM بدین صورت است که ورودی‌ها با یک وزن تصادفی بین صفر و یک وارد سیستم می‌شوند، سپس فاصله بین هر پارامتر ورودی با مرکز لایه پنهان بر اساس فاز رقابت و تابع کمینه به دست می‌آید. فرآیند آموزش SOM به صورت زیر در سه مرحله رقابت، همکاری و تطبیق تشکیل می‌شود: الف) فاز رقابت: در این فاز با معرفی ورودی به شبکه، کمترین فاصله آن نسبت به نرون‌های لایه خروجی محاسبه می‌شود و هر کدام که فاصله کمتری داشته باشد، به عنوان نرون برنده انتخاب می‌شود. مقدار فاصله اقلیدسی (D_j)، مطابق با معادله (۱) محاسبه می‌شود (کوهن و همکاران، ۱۹۹۷). در این معادله x بردار ورودی نرون i و w_j وزن نرون برنده است.



شکل ۲- هم‌مضامت اشباع و موقعیت پیرومترها

مواد و روش‌ها


پس از بررسی تغییرات سطح آب زیرزمینی و ارتفاع سطح زمین در محل چاه‌های مشاهده‌ای، ۱۰ چاه مشاهده‌ای موجود در آبخوان آزاد دشت به عنوان مناسب‌ترین چاه‌های مشاهده‌ای به دلیل کامل‌ترین سری داده (۱۴ ساله) و توزیع مناسب برای پیش‌بینی مورد استفاده قرار گرفتند (شکل ۲). در این پژوهش انتخاب زمان تأخیر داده‌های ورودی با استفاده از تابع خودهمبستگی جزئی PACF در نرم‌افزار SPSS تعیین شد. با این آنالیز مشخص شد استفاده از داده‌های ورودی یک زمان قبل (t_{0-1})، بالاترین تأثیر را در پیش‌بینی سطح آب زیرزمینی در زمان (t_0) خواهد داشت؛ بنابراین از پنج داده شامل تراز آب زیرزمینی ماهانه یک زمان قبل (t_{0-1})، متوسط بارندگی ماهانه یک زمان قبل (t_{0-1})، متوسط دمای ماهانه یک زمان قبل (t_{0-1})، تبخیر و میزان تخلیه ماهانه از چاه‌های بهره‌برداری در یک زمان قبل (t_{0-1}) که طی دوره ۱۴ ساله در دسترس بودند به عنوان ورودی‌های مدل استفاده شد. تراز آب زیرزمینی در زمان t_0 به عنوان خروجی انتخاب شد. تعداد داده‌های مورد استفاده برای هر متغیر ۱۶۸ بودند که از ۸۰٪ آن‌ها برای مرحله آموزش و ۲۰٪ دیگر؛ برای مرحله آزمایش استفاده شد.

شبکه‌های عصبی مصنوعی^۱

یک شبکه عصبی مصنوعی تیپیک شامل لایه ورودی، لایه میانی و لایه خروجی است. لایه ورودی یک لایه انتقال‌دهنده داده‌ها به شبکه است. آخرین لایه یا لایه خروجی شامل مقادیر پیش‌بینی شده به وسیله شبکه است،


2- Levenberg-Marquardt (LM)

1- Artificial Neural Networks



شکل ۳- شبکه SOM، الف) شکل شماتیک از شبکه SOM، ب) تعداد پیژومترهای موجود در کلاس‌ها

برای ارزیابی کارایی دسته‌بندی، تغییرات تراز آب پیژومترهایی که در یک دسته قرار گرفته‌اند رسم و مقایسه شد. برای نمونه در شکل ۴ تغییرات تراز آب برای دسته چهار آورده شده است. با توجه به این شکل، مشاهده می‌شود تراز آب زیرزمینی چهار چاه مشاهده‌ای مقادیر نزدیک به هم است؛ به‌گونه‌ای که تراز آب در پیژومترها ضریب تغییرات و روند یکسانی مشابهی دارند. این نتیجه برای سایر کلاس‌ها نیز حاصل شد؛ در نتیجه با این دسته‌بندی چهار کلاس با حداقل ناهمگنی به دست آمده است که پیش‌بینی تراز آب زیرزمینی برای هر کدام از آن‌ها با حداقل پیچیدگی انجام خواهد شد. بر اساس نتایج ضریب تغییرات بیشترین تفاوت برای تغییرات تراز آب زیرزمینی در پیژومترها در هر گروه مربوط به گروه سه است.



شکل ۴- تغییرات تراز آب پیژومترهای کلاس

$$D_j = |x - w_j| = \sqrt{\sum_{i=1}^M (x_i - w_{ij})^2} \quad (1)$$

$$j = 1, 2, 3, \dots, M$$

ب) فاز همکاری: نقش این فاز بر اساس معادله (۲) به هنگام‌سازی وزن نرون‌های همسایه و انتخاب آن‌ها برحسب مقدار فاصله با نرون برنده است (کوهنن، ۱۹۹۷).

$$h_{ij}(x) = (fd_{ij}) \quad (2)$$

فاز تطبیق: هدف این فاز افزایش سرعت مدل است. طبق معادله (۳) تغییرات وزن نرون‌ها (W) برابر است با ضریب یادگیری (η) ضربدر ورودی x و خروجی (کوهنن، ۱۹۹۷):

$$W = w(t + 1) - w(t) = \eta xy \Delta \quad (3)$$

جایی که w وزن نرون‌ها نسبت به زمان (t) می‌باشد.

نتایج و بحث

دسته‌بندی SOM

در این بخش دسته‌بندی ۱۰ چاه مشاهده‌ای بر اساس تغییرات تراز آب آن‌ها طی ۱۴ سال (۱۳۸۰-۱۳۹۳) انجام شد. تعداد کلاس‌ها چهار عدد انتخاب شد که این انتخاب بر مبنای رنج تغییرات تراز آب زیرزمینی دشت تبریز به دست آمد. پیژومترها در یک شبکه با ساختار 2×2 دسته‌بندی شدند. نتایج حاصل از دسته‌بندی نشان داد در سه کلاس پیژومترهای دوتایی و در یک کلاس چهار چاه مشاهده‌ای قرار گرفته است (شکل ۳ ب).

مدل برای همه پیژومترها پس از نرمال‌سازی در مدل استفاده شدند. بر اساس مدل‌های ارائه شده برای کلاس‌های یک تا سه تعداد گره‌های لایه میانی و ساختار

مدل شبکه عصبی SOM-ANN


شبکه عصبی پیشرو با الگوریتم لونیبرگ-مارکوارت برای هر کدام از دسته‌های منتخب شبیه‌سازی شد. ورودی‌های

عصبی پیشرو برای پیژومترها در مراحل آزمایش و آموزش در جدول ۱ ارائه شده است.

به ترتیب برابر با دو و ۵-۲ است. مدل ارائه شده برای کلاس چهار با دارا بودن چهار پیژومتر، دارای چهار گره در لایه میانی و ساختار ۴-۴-۷ است. نتایج حاصل از شبکه

جدول ۱- نتایج مدل شبکه عصبی پیشرو برای کلاسها در مراحل آموزش و آزمایش

کلاس	نام پیژومتر	مرحله آموزش		مرحله آزمایش	
		R^2	RMSE(m)	R^2	R_n
۱	آناختون	۰/۳۲	۰/۷۳	۰/۷۲	۰/۸۳
	تبریز کمربند لاله زار	۰/۱۱	۰/۸۳	۰/۸۲	۰/۸۹
۲	حسن آباد	۰/۱۷	۰/۸۲	۰/۸۱	۰/۸۹
	میرجانی	۰/۱۷	۰/۷۶	۰/۷۴	۰/۸۴
۳	نوجه ده - بغل مدرسه	۰/۲۰	۰/۶۹	۰/۶۸	۰/۸۱
	شرق نوجه ده	۰/۲۱	۰/۷۰	۰/۶۸	۰/۸۱
۴	قراملک - کنار راه آهن	۰/۲۰	۰/۸۶	۰/۶۷	۰/۸۰
	قراملک - خرمنگاه	۰/۲۶	۰/۸۸	۰/۷۰	۰/۸۱
	جنب دیوار گمرک سهلان	۰/۲۰	۰/۹۵	۰/۸۲	۰/۸۸
	سهلان - ایستگاه راه آهن	۰/۱۷	۰/۸۷	۰/۸۰	۰/۸۸



شکل ۵- مقایسه میزان $RMSE$ و R^2 مدل ترکیبی برای کلاسها

با توجه به تفاوت در ناهمگنی آبخوانها شاید نتوان مقایسه دقیقی بین نتایج به دست آمده از مدل ترکیبی ارائه شده (SOM-ANN) با مدل های ترکیبی دیگر که از روش خطی مانند دسته بندی سلسله مراتبی برای دسته بندی پیژومترها استفاده کرده اند، انجام داد؛ زیرا زمانی می توان مقایسه دقیقی بین روش ارائه شده و روش ترکیبی دیگر مانند (HCA-ANN) (حبیبی و همکاران، ۱۳۹۴؛ ندیری و همکاران، ۱۳۹۵) انجام داد که این دو مدل در یک آبخوان ارائه شود؛ ولی به طور کلی می توان نتیجه گرفت که کارایی هر دو مدل ترکیبی در آبخوان های هموزن نزدیک به هم است و تفاوت اصلی این دو روش در

در شکل ۵ معیارهای ارزیابی پیش بینی مدل به صورت کردار برای مقایسه آسان آورده شده است. با توجه به این شکل مشخص می شود در هر چهار کلاس پیش بینی تراز آب با بازدهی مناسب و خطای ناچیز انجام شده و برای کلاس های یک تا چهار میانگین خطای مرحله آموزش و آزمایش به ترتیب برابر ۰/۱۰، ۰/۲۰، ۰/۲۳ و ۰/۲۲ متر است. همچنین میانگین مقادیر R^2 در دو مرحله برای کلاسها به ترتیب ۰/۷۷، ۰/۷۹، ۰/۶۸ و ۰/۸۲ به دست آمد. نتایج حاصل از این پژوهش، در مقایسه با نتایج پژوهش های انجام شده توسط مدل های هوش مصنوعی منفرد، نشان داد خطای مدل سازی از $RMSE$ بالای یک متر به طور متوسط به میزان ۰/۱۸ متر کاهش یافته است که توانایی مدل های ترکیبی را در مسائل پیش بینی در وضعیت پیچیده زیرسطحی با داده های در دسترس محدود نشان می دهد. بر اساس نتایج به دست آمده بالاترین خطاها مربوط به پیژومترهای دسته سه است که می تواند به دلیل قرار گرفتن در مرکز دشت باشد که بالاترین ضخامت اشباع را دارد و عموماً از میان لایه های رسی فراوان تشکیل شده است؛ لذا هتروژنیتهی بالای این دشت می تواند دلیل اصلی خطای بالای پیژومترهای این دسته باشد. این موضوع نشان می دهد که شناخت دقیق آبخوان و در دست بودن لاگها و داده های کافی برای دسته بندی آبخوان از اهمیت بالایی برخوردار است.

قسمت همگن و در نتیجه پیش‌بینی با مقدار خطای ناچیز باشد که نتایج این پژوهش نیز به روشنی بیان‌کننده این امر است. برای بررسی دقیق توانایی مدل ارائه شده نیاز است که در دو آبخوان همگن و ناهمگن توانایی این مدل ترکیبی با مدل‌های منفرد و ترکیبی دیگر با هم مقایسه شود تا نقاط قوت و ضعف این مدل بهتر مشخص شود.

سپاس‌گزاری

این تحقیق با حمایت مالی مرکز مطالعات و همکاری‌های علمی بین‌المللی وزارت علوم، تحقیقات و فناوری انجام گرفته و نویسندگان تشکر خود را از این مرکز ابراز می‌دارند.

منابع

- حبیبی م. ح. ندیری ع. و اصغری مقدم الف. ۱۳۹۴. ارائه مدل ترکیبی ژنتیک- کریجینگ برای پیش‌بینی زمانی و مکانی سطح آب زیرزمینی. مجله تحقیقات منابع آب ایران. ۱۱(۳): ۸۵-۹۹.
- سبحان‌وردی ج. ۱۳۸۷. مطالعات ژئوشیمی زیست‌محیطی دشت مایان، جنوب غرب تبریز (مقیاس ۱:۲۵۰۰۰). پایان‌نامه کارشناسی ارشد، گروه زمین‌شناسی، دانشگاه تربیت‌معلم تهران. ۱۲۲ ص.
- ندیری ع. نادری ک. اصغری مقدم الف. و حبیبی م. ح. ۱۳۹۵. پیش‌بینی زمانی و مکانی سطح آب زیرزمینی با استفاده از روش‌های هوش مصنوعی و زمین آمار (مطالعه موردی: آبخوان دشت دوزدوزان). ۲۰(۵۸): ۲۸۱-۳۰۱.
- ندیری عطاالله. ۱۳۸۶. ارزیابی سطح آب‌های زیرزمینی در محدوده متروی شهر تبریز با استفاده از مدل شبکه‌های عصبی مصنوعی. پایان‌نامه کارشناسی ارشد، گروه زمین‌شناسی، دانشکده علوم طبیعی دانشگاه تبریز. ۱۷۸ ص.
- Adamowski J. and Chan F. H. 2011. A wavelet neural network conjunction model for groundwater level forecasting. Journal of Hydrology. 407: 28-40.
- ASCE. Task Committee on Application of Artificial Neural Networks in Hydrology. 2000. Artificial neural network in hydrology part I and II. Journal of Hydrologic Engineering. 5(2): 115-137.

آبخوان‌های ناهمگن بیشتر خواهد شد؛ لذا برای بررسی دقیق توانایی این دو مدل نیاز است که در دو آبخوان همگن و ناهمگن هر دو مدل اجرا تا نقاط قوت و ضعف این دو مدل بهتر مشخص شود.

نتیجه‌گیری

در این پژوهش، تراز آب زیرزمینی آبخوان آزاد دشت تبریز با استفاده از مدل شبکه عصبی ANN در ترکیب با دسته‌بندی هوشمند SOM با داده‌های ورودی بارش، دما، تبخیر، دبی و تراز آب یک زمان قبل پیش‌بینی شد. با توجه به میزان تغییرات تراز آب زیرزمینی، ۱۰ چاه مشاهده‌ای از میان چاه‌های مشاهده‌ای دشت به عنوان نماینده که قسمت‌های مختلف دشت را پوشش می‌دهند، انتخاب شد. این پیرومترها با روش دسته‌بندی غیرنظارتی (SOM) در چهار کلاس دسته‌بندی شدند که نزدیک بودن روند و نوسانات تراز آب پیرومترهای همکلاس نشان از دسته‌بندی ایده‌آل دارد. سپس داده‌های ورودی همگی در یک زمان قبل وارد مدل شدند و پیش‌بینی انجام شد. بر اساس معیارهای ارزیابی، در حالت کلی میانگین خطای پیش‌بینی چهار کلاس برای مرحله آموزش ۰/۱۶۴ متر و برای مرحله آزمایش ۰/۲۱۵ متر به دست آمد که این موضوع، نشان از دقت و کارایی بالای مدل‌های ترکیبی نسبت به مدل‌های منفرد دارد. دلیل آن بهره‌گیری از مزایای دسته‌بندی هوشمند و مدل شبکه عصبی به طور همزمان است. مقایسه بین کلاس‌ها نشان داد برای کلاس‌های یک، دو و چهار، میانگین خطای مرحله آموزش و آزمایش به ترتیب برابر ۰/۱۰، ۰/۲۰ و ۰/۲۲ متر است. همچنین میانگین مقادیر R^2 در دو مرحله برای این کلاس‌ها به ترتیب ۰/۷۷، ۰/۷۹ و ۰/۸۲ به دست آمد. برای کلاس سه که در مرکز دشت قرار گرفته است، میانگین خطای ۰/۲۳ متر و R^2 برابر با ۰/۶۸ حاصل شد. با توجه به نقشه هم‌ضخامت اشباع آبخوان آزاد مشاهده می‌شود پیرومترهای این کلاس دارای ضخامت اشباع بالایی هستند که این مورد می‌تواند با ایجاد پیچیدگی‌های هیدروژئولوژیکی در نوسانات تراز آب زیرزمینی و به دنبال آن در نتیجه پیش‌بینی تراز آب نقش منفی داشته باشد. با توجه به وضعیت پیچیده زیرسطحی در مسائل پیش‌بینی، استفاده از روش دسته‌بندی هوشمند غیرنظارتی می‌تواند روشی مناسب برای تفکیک منطقه مطالعاتی به چند

20. Nadiri A. A. Gharekhani M. Khatibi R. and Asghari Moghaddam A. 2017c. Assessment of groundwater vulnerability using supervised committee to combine fuzzy logic models. *Environmental Science and Pollution Research*, 1-16. 10.1007/s11356-017-8489-4.
21. Nadiri A. A. Gharekhani M. Khatibi R. Sadeghfam S. and Asghari Moghaddam A. 2017b. Groundwater vulnerability indices conditioned by Supervised Intelligence Committee Machine (SICM). *Science of The Total Environment*. 574: 691-706.
22. Nadiri A. A. Sedghi Z. Khatibi R. and Gharekhani M. 2017a. Mapping vulnerability of multiple aquifers using multiple models and fuzzy logic to objectively derive model structures. *Science of The Total Environment*. 593-594: 75-90.
23. 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.
24. Nourani V. Alami M. T. and Vousoughi F. D. 2015. Wavelet-entropy data pre-processing approach for ANN-based groundwater level modeling. *Journal of Hydrology*. 524: 255-269.
25. Nourani V. Baghanam A. H. Adamowski J. and Gebremichael M. 2013. Using self-organizing maps and wavelet transforms for space-time pre-processing of satellite precipitation and runoff data in neural network based rainfall-runoff modeling. *Journal of hydrology*. 476: 228-243.
26. Yang Z. P. Lu. W. X. Long Y. Q. and Li P. 2009. Application and comparison of two prediction models for groundwater levels: A case study in Western Jilin Province, China. *Journal of Arid Environments*. 73: 487-492.
7. Aziz A. Abd R. and Wong K. F. V. 1992. A neural-network approach to the determination of aquifer parameters. *Ground Water*. 30(2): 164-166.
8. Chen L. and Lin D. 2011. Application of Integrated Back-Propagation Network and Self-Organizing Map for Groundwater Level Forecasting. *J. Whater resour. Plann Manage*. 137: 352-365.
9. Chitsazan M. Rahmani G. and Neyamadpour A. 2013. Groundwater level simulation using artificial neural network: a case study from Aghili plain, urban area of Gotvand, south-west Iran. *GEOPEsia*. 3(1): 35-46.
10. Copola E. Szidarovszky F. Poulton M. and Charles E. 2003. Artificial neural network approach for predicting transient water levels in multilayered groundwater system under variable state, pumping, and climate conditions *Journal of Hydrologic Engineering*. 8(6): 348-380.
11. 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.
12. Daliakopoulos I. N. Coulibaly P. and Tsanis I. K. 2005. Groundwater level forecasting using artificial neural networks. *Journal of Hydrology*. 309: 229-240.
13. Emberger L. 1930. La vegetation de la region mediterrannee. *Essai d'une classification des groupements vegetaux. Rev. Gen. Bot (Revue générale de Botanique)*. 42: 641-662.
14. 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.
15. Kohonen T. 1982. Self-organized formation of topologically correct feature maps. *Biological cybernetics*. 43(1): 59-69.
16. Kohonen T. Kaski S. and Lappalainen H. 1997. Self-organized formation of various invariant-feature filters in the adaptive-subspace SOM. *Neural computation*. 9(6): 1321-1344.
17. Konikow L. F. and Kendy E. 2005. Groundwater depletion: A global problem. *Hydrogeology Journal*. 13(1): 317-320.
18. Lallahem S. Mania J. Hani A. and Najjar Y. 2005. On the use of neural networks to evaluate ground water levels in fractured media. *Journal of Hydrology*. 307: 92-111.
19. Nadiri A. A. Fijani E. Tsai FTC. and Asghari Moghaddam A. A. 2013. Supervised Committee Machine with Artificial Intelligence for Prediction of Fluoride Concentration. *Hydroinformatics Journal*. 15: 1474-1490.