



"مقاله پژوهشی"

مدل سازی زمانی و مکانی سطح آب زیرزمینی دشتستان بوشهر با استفاده از هوش مصنوعی و زمین آمار

حلیمه پیری^۱، مجتبی مبارکی^۲ و صالح سیاسر^۳

۱- استادیار، گروه مهندسی آب، دانشکده آب و خاک، دانشگاه زابل، (نویسنده مسوول: H_piri2880@uoz.ac.ir)

۲- دانش‌آموخته کارشناسی ارشد، گروه مهندسی آب، دانشکده آب و خاک، دانشگاه زابل

۳- دانشجوی کارشناسی، گروه مهندسی آب، دانشکده آب و خاک، دانشگاه زابل

تاریخ دریافت: ۱۴۰۰/۲/۲۷ تاریخ پذیرش: ۱۴۰۰/۴/۱۴

صفحه: ۵۸ تا ۶۸

چکیده مبسوط

مقدمه و هدف: یکی از اقدامات اساسی برای رسیدن به مدیریت بهینه منابع آب، مدل سازی و پیش بینی سطح ایستابی چاه‌ها است. کنترل سطح ایستابی با استفاده از چاه‌های مشاهده‌ای، منبع اصلی اطلاعات جهت بررسی تنش‌های هیدرولوژیکی محسوب می‌شود. با استفاده از داده‌های روزانه و ماهانه چاه‌ها می‌توان نوسانات سطح آب را بررسی نمود و این بررسی‌ها به منظور درک رفتار منابع آب زیرزمینی در دراز مدت و اخذ هر گونه تصمیم مدیریتی لازم می‌باشد. با توجه به اهمیت پیش‌بینی تراز آب زیرزمینی، یافتن روشی مناسب در این خصوص دارای اهمیت می‌باشد. در سال‌های اخیر کاربرد سامانه‌های هوشمند برای پیش‌بینی تراز آب زیرزمینی به سرعت رو به افزایش است که دلیل این امر به آسانی کاربرد و دقت بالای این مدل‌ها در تقریب معادله‌های غیرخطی و پیچیده ریاضی می‌باشد. هدف از این پژوهش پیش‌بینی سطح ایستابی آب زیرزمینی دشتستان بوشهر به کمک مدل‌های شبکه عصبی مصنوعی، مدل ماشین بردار پشتیبان و درخت تصمیم می‌باشد.

مواد و روش‌ها: در این تحقیق از مدل‌های شبکه عصبی مصنوعی، مدل ماشین بردار پشتیبان و درخت تصمیم برای تخمین تراز آب زیرزمینی دشت دشتستان استفاده شد. همچنین از روش زمین‌آمار برای بررسی تغییرات مکانی آب زیرزمینی استفاده شد. داده‌های مورد استفاده شامل تراز ماهانه سطح ایستابی ۵۰ حلقه چاه موجود در آبخیز دشت طی یک دوره آماری ده ساله از سال ۱۳۸۸ تا ۱۳۹۷ بود. برای بررسی نتایج مدل‌های مذکور از معیارهای ارزیابی مجذور میانگین مربعات خطا، میانگین مطلق خطا و ضریب تبیین R^2 استفاده شد.

یافته‌ها: نتایج نشان داد هر سه روش دقت بالایی در شبیه‌سازی تراز سطح ایستابی داشتند. روش شبکه عصبی مصنوعی با داشتن R^2 بالاتری (۰/۹۹۳)، کمترین مجذور میانگین خطا (۰/۲۹) و کمترین میانگین مطلق خطا (۰/۰۲۴) به عنوان روش برتر برای پیش‌بینی سطح ایستابی انتخاب شد. پهنه‌بندی با روش کریجینگ نشان داد که سطح آب زیرزمینی در بیشتر نقاط دشت در دوره مطالعه افت داشته است. حداکثر این افت معادل ۱۰ متر بود.

نتیجه‌گیری: نتایج مدل‌سازی روش‌ها و نتایج آمارهای ارزیابی مدل، نشان دهنده عملکرد خوب مدل‌ها در برآورد سطح ایستابی آب زیرزمینی است اما با توجه به مقایسه ضریب تبیین مدل‌ها در این تحقیق نشان داده شد که روش شبکه عصبی مصنوعی دقت بالاتری در پراکنش داده‌های موجود دارد و مقادیر محاسبه شده نسبت به مقادیر مشاهداتی مدل شبکه عصبی مصنوعی نسبت به دو مدل دیگر، اختلاف کمتری داشتند. در مجموع نتایج تحقیق نشان داد که روش شبکه عصبی مصنوعی دارای دقت بالاتری در تخمین میزان تراز آب زیرزمینی می‌باشد.

واژه‌های کلیدی: درخت تصمیم، دشتستان، شبکه عصبی مصنوعی، ماشین بردار پشتیبان

مقدمه

آموزش دیده و در پایان مرحله آموزش، شبکه توسط بخش دیگری از داده‌ها مورد آزمایش قرار می‌گیرد (۱۷). قربانی و همکاران (۱۱) پیش‌بینی نوسانات تراز آب زیرزمینی در استرالیا را مورد بررسی قرار دادند و نتیجه گرفتند که ساختار درختی و برنامه‌ریزی بیان ژن برای تمام مقیاس‌های زمانی نسبت به شبکه عصبی از دقت بالاتری برخوردار است. گرچی و همکاران (۱۲) پیش‌بینی نوسانات آب زیرزمینی دشت آذرشهر در آذربایجان شرقی را با استفاده از بیان ژن و شبکه عصبی موجکی انجام دادند. نتایج مدل‌سازی آن‌ها کاهش نوسانات آب زیرزمینی را نشان داد. جبالبارزی و ملکیان (۱۴) سطح ایستابی مناطق خشک و نیمه‌خشک را با استفاده از برنامه‌ریزی بیان ژن و شبکه عصبی مصنوعی پیش‌بینی کردند. نتایج تحقیق آن‌ها نشان داد روش شبکه عصبی مصنوعی دقت بالاتری در پیش‌بینی تراز سطح ایستابی دشت جبرفت داشت. حسینی‌صومعه و همکاران (۱۳) مدل‌سازی تغییرات سطح آب زیرزمینی بر اساس روش‌های مبتنی بر هوش مصنوعی را برای دشت زاوه انجام دادند. نتایج این تحقیق نشان داد که شبکه عصبی مصنوعی با دقت بالایی ($R^2=0.99$) قادر به پیش‌بینی تراز سطح ایستابی می‌باشد. مختاری و همکاران (۱۹) تراز آب زیرزمینی دشت شبستر را با


برای استفاده بهینه از منابع آب‌های زیرزمینی موجود، برنامه‌ریزی همه جانبه و آگاهانه لازم است. این مهم جزء با شناخت دقیق و صحیح کمیت و کیفیت آب میسر نخواهد شد. در سال‌های اخیر به دلیل افزایش تقاضای آب و کاهش سرانه منابع آب تجدید شونده، نگرانی‌های زیادی ایجاد شده است و چگونگی استفاده از این منابع به شکل مطلوب و موثر و کارآمد برای تضمین توسعه پایدار، یکی از مهم‌ترین موضوعات مطرح در محافل بین‌المللی شده است (۹). کنترل سطح ایستابی با استفاده از چاه‌های مشاهده‌ای، منبع اصلی اطلاعات جهت بررسی تنش‌های هیدرولوژیکی محسوب می‌شود. با استفاده از داده‌های روزانه و ماهانه چاه‌ها می‌توان نوسانات سطح آب را بررسی نمود و این بررسی‌ها به منظور درک رفتار منابع آب زیرزمینی در دراز مدت و اخذ هر گونه تصمیم مدیریتی لازم می‌باشد (۲۵). پایش منطقه‌ای سطح سفره‌ها و منظور کردن تراز آبی، از بنیادی‌ترین شاخصه‌ها به منظور تأمین توسعه پایدار به‌شمار می‌آید. در سال‌های اخیر استفاده از تکنیک‌های هوش مصنوعی کمک زیادی به مدل‌سازی آب زیرزمینی نموده است. این شبکه‌ها توسط داده‌های مناسبی که دربرگیرنده ورودی و خروجی می‌باشد،

محاسبه سطح آب زیرزمینی مناسب‌تر از روش زمین آمار و مدل عددی می‌باشد. همچنین نتایج پهنه‌بندی سطح آب زیرزمینی آبخوان نیز گویای روند کاهش سطح آب زیرزمینی از بخش غرب به شرق آبخوان بود که همسو با گرادیان هیدرولیکی می‌باشد.

مواد و روش‌ها منطقه مورد مطالعه

منطقه مورد مطالعه دشتستان می‌باشد که در فاصله ۸۵ کیلومتری شرق شهر بوشهر (مرکز استان بوشهر) قرار دارد و با مرکزیت شهر برازجان، وسیع‌ترین و پرجمعیت‌ترین شهرستان استان بوشهر است که در طول جغرافیایی ۵۰ درجه و ۲۵ دقیقه تا ۵۱ درجه و ۵۹ دقیقه شرقی و عرض جغرافیایی ۲۸ درجه و ۳۰ دقیقه تا ۲۸ درجه و ۵۵ دقیقه شمالی در مرکز استان بوشهر قرار دارد. این شهرستان از شمال به شهرستان گناوه، از غرب به بوشهر، از جنوب به تنگستان و از شرق به استان فارس محدود شده است و وسعتی حدود ۶۳۷۱ کیلومتر مربع دارد. ارتفاع این منطقه از سطح دریا ۶۸۰ متر، بارندگی سالیانه آن ۴۰۰ تا ۷۰۰ میلی‌متر و درجه حرارت بین ۲/۵ تا ۴۸ درجه سانتی‌گراد متغیر می‌باشد. به‌طور کلی اقلیم منطقه براساس طبقه‌بندی آمبرژه بیابانی گرم خفیف و بر اساس روش دومارتن در اقلیم نیمه‌خشک قرار دارد. از نظر زمین‌شناسی بر روی آبرفت‌های دوران چهارم زمین‌شناسی (کوارترنری) قرار گرفته است. این شهرستان دارای شش بخش، دوازده دهستان و نه شهر است. شهرستان دشتستان به‌عنوان قطب کشاورزی استان بوشهر محسوب می‌شود و اقلیم خاص این شهرستان که ناشی از همجواری آن با رشته کوه‌های زاگرس و رودخانه‌های بزرگی همچون دالکی و شاپور است، موجب پیدایش و تنوع گسترده گیاهان سازگار با محیط در این منطقه شده است (۸). برای انجام این پژوهش از داده‌های ماهانه سطح ایستابی ۵۰ چاه موجود در منطقه در دوره مطالعاتی ۱۰ ساله (۱۳۹۷-۱۳۸۸) استفاده شد. شکل ۱ منطقه مورد مطالعه را نمایش می‌دهد.

استفاده از شبکه عصبی مصنوعی انجام دادند و بیان داشتند شبکه عصبی مصنوعی توانایی بالایی در شبیه‌سازی تراز آب زیرزمینی دارد. لالاهم و همکاران (۱۶) از شبکه عصبی مصنوعی در تشخیص داده‌های زمانی لازم برای برآورد سطح آب زیرزمینی یک پیرومتر استفاده کردند. نتایج نشان داد که شبکه عصبی پرسپترون^۱ چند لایه با حداقل تأخیر و لایه پنهان مناسب‌ترین شبیه‌سازی را انجام داد. بنرجی و همکاران (۲) در تحقیقی از شبکه عصبی پیشخور به‌عنوان روشی برای پیش‌بینی سطح آب زیرزمینی استفاده کردند که این شبکه عصبی نتایج مطلوبی را ارائه داد. با توجه به اهمیت پیش‌بینی تراز آب زیرزمینی، یافتن روشی مناسب در این خصوص دارای اهمیت می‌باشد. در سال‌های اخیر کاربرد سامانه‌های هوشمند برای پیش‌بینی تراز آب زیرزمینی به سرعت رو به افزایش است که دلیل این امر به آسانی کاربرد و دقت بالای این مدل‌ها در تقریب معادله‌های غیرخطی و پیچیده ریاضی می‌باشد (۱۸). هدف از این پژوهش پیش‌بینی سطح ایستابی آب زیرزمینی دشتستان بوشهر به کمک مدل‌های شبکه عصبی مصنوعی، مدل ماشین بردار پشتیبان و درخت تصمیم می‌باشد. دشتستان در جنوب ایران و در استان هرمزگان قرار دارد. برداشت بی‌رویه از آب‌های زیرزمینی آبخوان دشتستان موجب افت سطح ایستابی این آبخوان گردیده است. این امر اقتصاد منطقه را که بر پایه کشاورزی استوار است، مورد تهدید جدی قرار می‌دهد. لذا هدف دیگر تحقیق بررسی افت سطح آب زیرزمینی دشت در دوره آماری مورد مطالعه با استفاده از روش زمین‌آمار کربجینگ می‌باشد. پیری و بامری (۲۳) روند تغییرات آب زیرزمینی دشت سیرجان را با استفاده از زمین‌آمار مورد بررسی قرار دادند. نتایج مطالعه آن‌ها نشان داد روش کربجینگ معمولی روش مناسبی برای برآورد سطح آب زیرزمینی می‌باشد. نتایج به‌دست آمده از این روش حاکی از افت شدید سطح آب زیرزمینی در دوره آماری مورد مطالعه در منطقه بود. بیات‌ورکشی و فصیحی (۳) از روش عصبی مصنوعی و زمین‌آمار برای پیش‌بینی سطح ایستابی آبخوان همدان- بهار استفاده کردند. نتیجه تحقیق آن‌ها نشان داد روش‌های ترکیبی هوشمند عصبی به‌ویژه نظریه موجک در



شکل ۱- منطقه مورد مطالعه
Figure1. Location of study area

استانداردسازی داده‌ها

معمولا وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و دقت شبکه می‌شود. برای اجتناب از چنین شرایطی و همچنین به منظور یکسان نمودن ارزش داده‌ها، قبل از آموزش شبکه عصبی، داده‌های ورودی به آن بایستی استاندارد شوند. این کار مانع کوچک شدن بیش از حد وزن‌ها می‌گردد (۲۷) و در عین حال با تنظیم داده‌های ورودی در یک محدوده خاص می‌توان نرون‌ها را در محدوده مطلوب قرار داده و از اشباع زود هنگام نرون‌ها جلوگیری نمود. همچنین این کار به این علت صورت می‌گیرد که داده‌ها به اعدادی بین ۰ و ۱ تبدیل گردند، زیرا خروجی اکثر توابع آستانه اعدادی ما بین ۰ و ۱ می‌باشند و شکل داده‌های ورودی به آن نقش مهمی در یادگیری شبکه ایفا می‌کند. برای استاندارد کردن داده‌ها از رابطه زیر استفاده شد (۴).

$$X_n = \frac{X - X_{\text{mean}}}{X_{\text{max}} - X_{\text{min}}} \quad (۱)$$

X_n معرف داده نرمال شده، X معرف داده مشاهده‌ای، X_{max} و X_{min} به ترتیب معرف داده‌های مشاهده‌ای میانگین، حداکثر و حداقل می‌باشند.

تقسیم‌بندی داده‌ها

مدل‌های شبکه عصبی مصنوعی جهت طراحی نیازمند سه دسته داده آموزشی، اعتبارسنجی و آزمون می‌باشند. از داده‌های آموزشی به منظور پیدا کردن رابطه بین ورودی‌ها و خروجی‌های مشاهده‌ای، استفاده می‌گردد. از داده‌های صحت‌سنجی به منظور کنترل و نظارت بر یادگیری صحیح شبکه استفاده می‌شود و از داده‌های آزمون برای ارزیابی عملکرد شبکه پیشنهادی استفاده می‌شود. در این پژوهش برای مدل شبکه عصبی (ANN) و مدل درخت تصمیم (M5) ۷۰، ۱۵ و ۱۵ درصد کل داده‌ها، به ترتیب برای آموزش، اعتبارسنجی و آزمون مدل و برای مدل ماشین بردار پشتیبان (SVM) ۶۰ و ۴۰ درصد کل داده‌ها به ترتیب برای آموزش و آزمون مدل اختصاص یافت (۱۹).

شبکه عصبی مصنوعی (ANN)

از اوایل دهه ۱۹۹۰ تاکنون، این شبکه‌های عصبی مصنوعی در زمینه هیدرولوژی نیز به طور موفقیت‌آمیز به کار گرفته شده که از آن جمله می‌توان به مدل کردن فرآیندهای بارش-رواناب، پیش بینی جریان رودخانه، مدل کردن آب زیرزمینی، کیفیت آب، پیش‌بینی بارندگی و ... اشاره کرد (۷). حدود ۹۰٪ شبکه‌هایی که در مسائل هیدرولوژی کاربرد دارد شبکه‌های پیشرو هستند. معماری معمول این شبکه متشکل از سه لایه ورودی، پنهانی و خروجی است. تعداد نرون‌های موجود در لایه ورودی و خروجی بستگی به نوع مسئله دارد. ولی تعداد گره‌های لایه پنهان با سعی و خطا به دست می‌آید. به منظور آموزش شبکه عصبی، شبکه پرسپترون چند لایه مورد استفاده قرار گرفت. فرایند آموزش که شامل تغییر وزن‌ها بین لایه‌های مختلف در طول زمان آموزش است، انجام گردید تا جایی که تفاوت بین داده‌های واقعی (برای داده‌های آزمون) و داده‌های پیش‌بینی شده به حداقل برسد. الگوریتم آموزشی لونبرگ-مارکوات^۱ و تابع سیگموئید تانژانتی هیپربولیک^۲ در لایه پنهان و تابع خطی^۳ در لایه خروجی برای

فرایند آموزش به کار گرفته شدند. تعداد نرون‌ها در لایه پنهان به روش سعی و خطا تعیین شد و در نهایت بهترین ساختارهای شبکه برای برآورد سطح آب زیرزمینی بر اساس بیشترین R^2 و کمترین RMSE انتخاب شد.

ماشین بردار پشتیبان

مفهوم اولیه ماشین‌های بردار پشتیبان (SVM) اولین بار توسط محقق روسی به نام واپنیک در سال ۱۹۹۵ مطرح شد. این مفهوم روش جدیدی را بر مبنای طبقه‌بندی ارائه می‌دهد و یکی از ویژگی‌های آن طراحی دسته بندی کننده با حداکثر تعمیم است (۵). هدف ماشین‌های بردار پشتیبان، یافتن یک تابع پیوسته با مقدار حقیقی است که بتواند به‌ازای مقادیر ورودی، پیش‌بینی دقیقی از مقدار خروجی داشته باشد (۲۰). به‌طور کلی ماشین بردار پشتیبان نوعی سیستم یادگیری کارآمد بر مبنای تئوری بهینه‌سازی مقید است که توسط واپنیک ارائه شده است (۲۱). ماشین بردار پشتیبان روشی است که هم برای گروه‌بندی و هم برای تخمین و برآورد تابع برازش داده‌ها در مسائل رگرسیون به کار می‌رود. به‌طوری‌که کمترین خطا در گروه‌بندی داده‌ها با تابع برازش رخ می‌دهد. SVM الگوریتمی است که نوع خاصی از مدل‌های خطی را می‌یابد که حداکثر حاشیه ابر صفحه را حاصل می‌کند، به نزدیک‌ترین نقاط آموزشی به حداکثر حاشیه ابر صفحه، بردارهای پشتیبان گفته می‌شود و تنها از این بردارها برای مشخص کردن مرز بین طبقات استفاده می‌شود. در یک مدل رگرسیونی SVM لازم است وابستگی تابع متغیر وابسته (y) به مجموعه‌ای از متغیرهای مستقل (x) تخمین زده شود. فرض بر این است که مانند دیگر مسائل رگرسیونی، رابطه بین متغیرهای وابسته و مستقل توسط یک تابع معین f به‌علاوه یک مقدار اضافی نویز مشخص می‌شود:

$$y = f(x) + \text{noise} \quad (۲)$$

بنابراین موضوع اصلی پیدا کردن فرم اصلی تابع f است که بتواند به‌صورت صحیح، موارد جدیدی را که SVM تاکنون تجربه نکرده است، پیش‌بینی کند. در روش SVM - ε از توابع هسته‌ای (کرنل) به منظور جداسازی صفحات و بهینه‌سازی فواصل موجود بین داده‌های مشاهداتی و تخمینی استفاده می‌شود اما در مدل V-SVM از روش برنامه‌ریزی غیرخطی برای کاهش خطای پیش‌بینی استفاده می‌شود. در این مطالعه مدل SVM - ε به دلیل کاربرد گسترده آن در مسائل رگرسیونی استفاده گردید. برای این مدل، تابع خطا به‌صورت زیر تعریف می‌شود:

$$C \sum_{i=1}^n \varepsilon_i^* + C \sum_{i=1}^n \varepsilon_i + \frac{1}{2} W^T W \quad (۳)$$

تابع خطای مذکور لازم است که با توجه به محدودیت‌های زیر حداقل گردد:

$$W^T \phi(x_i) + b - y_i \leq \varepsilon + \varepsilon_i \quad (۴)$$

$$y_i - W^T \phi(x_i) + b \leq \varepsilon + \varepsilon_i \quad (۵)$$

$$\varepsilon_i \times \varepsilon_i^* \geq 0$$

در این روابط C : ثابت گنجایش، W : بردار ضریب، W^T : ترانزاده بردار ضریب، ε^* و ε_i : ضرایب کمبود، b : ضریب ثابت، n : الگوی آموزش مدل و ϕ : تابع کرنل است.

تصمیم به منظور سادگی در رسم معمولاً از چپ به راست و یا از بالا به پایین کشیده می‌شود، به‌طوری که ریشه (گره اول) در بالا قرار می‌گیرد. انتهای یک زنجیره را برگ می‌نامند. هر گره مربوط به یک خصوصیت معین است و شاخه‌ها به معنای بازه‌ای از مقادیر هستند. عمل انشعاب توسط یکی از متغیرهای پیش‌بینی‌کننده انجام می‌پذیرد، بازه‌های انشعاب طوری انتخاب می‌شوند که مجموع مجذور انحراف از میانگین داده‌های هر گره را حداقل کنند (۱۰). اولین مرحله برای ایجاد یک مدل درختی، استفاده از یک معیار انشعاب است. معیار انشعاب برای الگوریتم M5 بر اساس عملکرد انحراف استاندارد مقادیر هر کلاس و یا طبقه است که در هر گره به دست آمده است. این روش اساس روش‌های طبقه‌بندی است که آنتروپی نامیده می‌شود. آنتروپی می‌تواند به‌عنوان معیار میزان آشفتگی و بی‌نظمی یک سیستم تفسیر شود. معیار انشعاب بیان‌گر میزان خطا در آن گره می‌باشد و مدل حداقل خطای مورد انتظار را به‌عنوان نتیجه آزمایش هر صفت در آن گره محاسبه می‌کند. خطای مدل عموماً با اندازه‌گیری دقت پیش‌بینی مقادیر هدف موارد دیده نشده سنجش می‌شود. فرمول محاسبه کاهش انحراف استاندارد (SDR) به‌صورت روابط ۶ و ۷ می‌باشد.

$$SDR = Sd(T) - \sum_{i=1}^N \left| \frac{T_i}{T} \right| Sd(T_i) \quad (6)$$

$$Sd = \sqrt{\frac{1}{N} \left(\sum_{i=1}^N y_i^2 - \frac{1}{N} \left(\sum_{i=1}^N y_i \right)^2 \right)} \quad (7)$$

در این رابطه T: مجموعه‌ای از نمونه‌هاست که به هر گره وارد می‌شود، T_i: نشان‌دهنده زیر مجموعه‌ای از نمونه‌هاست که i امین نتیجه تست پتانسیلی را دارند، Sd: بیانگر انحراف معیار، y_i: مقدار عددی ویژگی هدف نمونه i و N: شماره داده‌ها را نشان می‌دهد (۱).

محاسبات مربوط به شبکه عصبی مصنوعی، درخت تصمیم و ماشین بردار پشتیبان با استفاده از نرم‌افزار Matlab 7.9 انجام شد.

معیارهای ارزیابی

برای ارزیابی صحت و اعتبار مدل‌های مورد استفاده از شاخص‌های آماری ریشه میانگین مربعات خطا (RMSE)، ضریب تبیین (R²)، و میانگین مطلق خطا (MAE) استفاده شد (روابط ۸ تا ۱۰).

$$R^2 = 1 - \frac{\sum_{i=1}^n \frac{(x_i - x_i^*)}{(x_i - \bar{x}_i)^2}}{\quad} \quad (8)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - x_i^*)^2} \quad (9)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |x_i - x_i^*| \quad (10)$$

در این روابط x_i مقدار اندازه‌گیری شده، x_i^{*} مقادیر برآورد شده و n تعداد نمونه می‌باشد (۲۳).

زمین‌آمار

بعد از تعیین روش مناسب برای پیش‌بینی تراز سطح ایستابی، جهت تعیین بررسی افت سطح آب از روش زمین‌آمار (کریجینگ) استفاده شد. پهنه‌بندی مکانی در ابتدا و انتهای دوره آماری مورد مطالعه با استفاده از نرم‌افزار ARC GIS 9.1 ترسیم شد. در نهایت از تفاضل این دو نقشه، نقشه کمی افت سطح ایستابی دشت دشتستان بوشهر به‌دست آمد.

ماشین‌های بردار پشتیبان برای حل مسائل غیرخطی، ابعاد مسئله را از طریق توابع کرنل تغییر می‌دهند. انتخاب کرنل برای SVM به حجم داده‌های آموزشی و ابعاد بردار ویژگی بستگی دارد. به عبارت دیگر، باید با توجه به این پارامترها تابع کرنلی را انتخاب نمود که توانایی آموزش برای ورودی‌های مسئله را داشته باشد. در عمل کرنل خطی به کار برده می‌شود (۲۸).

مدل درختی M5

مدل درختی M5 که توسط کوئیزنل (۶) کشف شده و تئوری او به صورت یک روش توسعه یافت و مدل وی در سال ۱۹۹۷ توسط ونگ و ویتن به نام M5 نامیده شد (۲۷). این مدل زیر مجموعه‌ای از روش‌های یادگیری ماشینی و داده‌کاوی است. داده‌کاوی به فرآیند جست‌وجو و کشف مدل‌های گوناگون، مختصرسازی‌ها و اخذ مقادیر از مجموعه‌ای از مقادیر معلوم اطلاق می‌گردد. روش‌های داده‌کاوی برای مجموعه داده‌های بزرگ با متغیرهای زیاد ساخته شده‌اند، بنابراین متفاوت از روش‌های آماری قدیمی هستند که برای مجموعه داده‌های کوچک با متغیرهای اندک طراحی شده‌اند. روش‌های بر مبنای درخت^۱ یکی از تکنیک‌های داده‌کاوی است که در این روش‌ها خروجی به‌صورت یک مدل با سازه درختی با استفاده از داده‌های ورودی و خروجی می‌باشد. الگوریتم M5 رایج‌ترین طبقه‌بندی استفاده شده در خانواده مدل تصمیم‌گیری درختی است. اساساً یک مدل درخت به شکل درخت تصمیم‌گیر با توابع رگرسیون خطی جایگزین مقادیر کلاس ترمینال در برگ‌های درخت ستانده می‌شود. مدل درختی M5 یک الگوریتم پیش‌بینی عددی است و گره‌های درخت با خواص پیشینه خطاهای مورد انتظاری که به عنوان تابعی از انحراف استاندارد پارامترهای خروجی می‌باشد انتخاب می‌شوند. مدل M5 یک مدل درختی برای پیش‌بینی صفات عددی پیوسته است که در آن توابع رگرسیونی خطی در برگ‌های این درخت متظاهر می‌شوند (۲۲) و در سال‌های اخیر تحول قابل توجهی در مسایل طبقه‌بندی و پیش‌بینی ایجاد نموده است. مدل‌های درختی چندین مزیت دارند که آن‌ها را به یک روش رگرسیون مناسب برای تجزیه و تحلیل عملکرد تبدیل کرده است. دقت پیش‌بینی مدل درختی با تکنیک‌هایی نظیر شبکه‌های عصبی شناخته شده که می‌تواند بزرگ‌تر از مدل پیش‌بینی رگرسیون خطی نظیر روش کارت باشد لیکن نتایج ساختار درختی و مدل رگرسیون برگ‌ها برای پیشبرد آگاهی از ماهیت و میزان مشکل در عملکرد می‌تواند مورد استفاده قرار گیرد. نتایج مدل درختی برای فهم و شبیه‌سازی آسان هستند و خروجی مدل از دقت بالایی برخوردار است که می‌توان آن را با سایر مدل‌ها مقایسه کرد، مدل درختی می‌تواند در مسایل گوناگون مورد استفاده محققین قرار گیرد (۱۰). مدل‌های درختی همچنین برای اداره کارآمد مجموعه داده‌های بزرگ با تعداد زیادی از ویژگی‌ها و ابعاد بالا شناخته شده‌اند. یک درخت تصمیم معمولاً از چهار بخش ریشه^۲، شاخه^۳، گره‌ها^۴ و برگ‌ها^۵ تشکیل شده است که گره‌ها با دایره نشان داده می‌شوند و شاخه‌ها نشان‌دهنده اتصال بین گره‌ها می‌باشند. درخت

نتایج و بحث

نتایج مدل سازی شبکه عصبی (ANN)

در این تحقیق از شبکه پرسپترون چندلایه به منظور پیش بینی سطح آب زیرزمینی استفاده گردید و توابع انتقال، تعداد لایه پنهان، تعداد نرون در لایه پنهان و تعداد بهینه ترین تکرار برای هر شبکه مورد آزمایش قرار گرفت و بهترین ساختار شبکه ها با روش سعی و خطا بدست آمد. همان طور که گفته شد ۷۰ درصد داده ها برای آموزش، ۱۵ درصد داده ها



جدول ۱- نتایج معیارها برای مرحله آموزش، صحت سنجی و آزمون

Table 1. Results of criteria for training, validation and testing

آماره خطا	R ²	RMSE	MAE
آموزش	۰/۸۹	۰/۰۲۶	۰/۰۱۵
صحت سنجی	۰/۸۵	۰/۰۳۴	۰/۰۲۱
آزمون	۰/۸۱	۰/۰۴۲	۰/۰۳۲

مرجع قرار گرفته اند، نشان دهنده این هستند که مدل مقدار آن ها را کمتر از مقدار واقعی تخمین زده است و نقاط بالاتر از این خط نشان می دهند که مدل مقدار آن ها را بیش تر تخمین زده است. معیار R² به تنهایی برای برآورد دقت مدل نمی تواند مناسب باشد. بنابراین از آماره خطای RMSE و MAE نیز استفاده شد. این دو آماره معیار ارزیابی کیفیت مدل بر اساس بررسی میزان خطای پیش بینی هستند. هرچه مقدار این دو آماره کمتر و نزدیک به صفر باشد، نشان دهنده برآورد خوب مدل می باشد. همان طور که از جدول ۱ مشاهده می شود در هر سه مرحله آموزش، صحت سنجی و آزمون مقادیر این دو آماره کم و نزدیک به صفر می باشد.

ضریب تبیین مهم ترین معیاری است که به کمک آن می توان رابطه بین دو متغیر را توضیح داد و مقدار آن بین صفر و یک می باشد. هر چه این معیار به یک نزدیک تر باشد، نشان دهنده برآورد خوب می باشد. مقدار این آماره برای مرحله آزمون ۰/۸۱ به دست آمد که نشان می دهد شبکه عصبی به خوبی توانسته است سطح آب زیرزمینی را برآورد کند. برای دستیابی به اطلاعات بیش تر، نمودار پراکنش نقاط و بهترین خط برازنده به این نقاط رسم شد (شکل ۲). با توجه به نمودار پراکنش ارتباط مستقیم خطی بین داده های اندازه گیری شده و پیش بینی شده مشاهده می شود. بیش تر نقاط حول خط رگرسیونی و نزدیک به آن هستند. نقاطی که زیر این خط



شکل ۲- مقادیر پیش بینی و مشاهده ای سطح آب زیرزمینی با مدل شبکه عصبی (ANN)

Figure 2. Predictive and observational values of groundwater level with neural network model

نشان می دهد. تقریباً نتایج ارزیابی مشابهی و با کمترین اختلاف در هر دو مرحله به دست آمد و این بدین معنی است که ماشین بردار پشتیبان در برآورد سطح ایستابی از دقت پیش بینی خوبی برخوردار است. همچنین نتایج حاکی از کمترین مجذور میانگین مربعات خطا (RMSE) به ترتیب برابر با مرحله آزمون، آموزش و صحت سنجی می باشد.

نتایج مدل ماشین بردار پشتیبان (SVR)

در این مدل بر خلاف مدل شبکه عصبی (ANN) که از سه مرحله آموزش، صحت سنجی و آزمون استفاده شد، از دو مرحله آموزش و آزمون استفاده می شود. از ۶۰ درصد داده ها برای مرحله آموزش و ۴۰ درصد داده ها برای مرحله آزمون استفاده شد. جدول ۲ نتایج ارزیابی مرحله آموزش و آزمون را



جدول ۲- نتایج معیارها برای مرحله آموزش و آزمون

Table 2. Results of criteria for the training and test phase

آماره خطا	R ²	RMSE	MAE
آموزش	۰/۸۹	۰/۳۱	۰/۲۴
آزمون	۰/۸۵	۰/۳۶	۰/۲۹

خط نیم‌ساز پراکنده شده و این امر دلالت بر برابری مقادیر مشاهداتی و محاسباتی بر اساس خط $(y=x)$ می‌کند.

در شکل (۳) پراکنش بین مقادیر مشاهده‌ای و برآوردی سطح ایستابی را نشان می‌دهد. همان‌طور که از این نمودار مشخص است مقادیر برآورد شده و مشاهداتی به‌غیر از چند نقطه روی



شکل ۳- مقادیر پیش‌بینی و مشاهده‌ای سطح آب زیرزمینی با مدل ماشین بردار پشتیبان (SVM)

Figure 3. Predictive and observational values of groundwater level with support vector machine model

کردن برای مدل‌سازی استفاده شدند. معیارهای ارزیابی عملکرد مدل در هر سه مرحله در جدول ۳ آورده شده است. مقادیر معیارهای ارزیابی مرحله آموزش مدل (R^2 بالا و $RMSE$ و MAE پایین) نشان‌دهنده عملکرد بسیار خوب مدل بود. در مرحله آزمون و صحت‌سنجی مقادیر R^2 نسبتاً پایین بود که نشان می‌دهد مدل عملکرد ضعیف‌تری نسبت به مرحله آموزش داشته است.


نتایج مدل درخت تصمیم (M5)

نتایج مدل‌سازی با درخت تصمیم همانند مدل شبکه عصبی (ANN) از سه مرحله آموزش، صحت‌سنجی و آزمون برای مدل‌سازی تشکیل شده است. از ۷۰ درصد داده‌ها برای مرحله آموزش و ۱۵ درصد داده‌ها برای مرحله صحت‌سنجی و ۱۵ درصد داده‌ها برای مرحله آزمون قرار داده شد. الگوریتم مورد استفاده M5 بود و فرایندهای هموارسازی و هرس

جدول ۳- نتایج معیارها برای مرحله آموزش، صحت‌سنجی و آزمون

Table 3. Results of criteria for training, validation and testing

آماره خطا	R ²	RMSE	MAE
آموزش	۰/۸۱	۰/۵۸	۰/۲۴
صحت‌سنجی	۰/۷۸	۰/۸۴	۰/۴۶
آزمون	۰/۷۵	۰/۸۱	۰/۳۲



شکل ۴- مقادیر پیش‌بینی و مشاهده‌ای سطح آب زیرزمینی با مدل درخت تصمیم (M5)

Figure 4. Predictive and observational values of ground water level with decision tree model

شبکه عصبی مصنوعی، مدل ماشین بردار پشتیبان و درخت تصمیم به ترتیب با داده های واقعی ۰/۹۹۳، ۰/۹۹۲، ۰/۹۷۱ می باشد. مجذور میانگین مربعات خطا در سه مدل شبکه عصبی مصنوعی، مدل ماشین بردار پشتیبان و درخت تصمیم به ترتیب ۰/۲۹، ۰/۳۱، ۰/۴۶ به دست آمد. همچنین میانگین مطلق خطا برای سه مدل شبکه عصبی مصنوعی، مدل ماشین بردار پشتیبان و درخت تصمیم به ترتیب ۰/۰۲۴، ۰/۰۲۷ و ۰/۰۵۶ محاسبه شد. بنابراین با توجه به ضریب تبیین بالا و آماره های خطای پایین، مدل شبکه عصبی مصنوعی به عنوان مدل برتر برای پیش بینی سطح ایستابی آب زیرزمینی دشتستان انتخاب شد.

شکل ۴ پراکنش میان مقادیر مشاهده ای و برآوردی سطح ایستابی را نشان می دهد. همان طور که از این نمودار مشخص است مقادیر برآورد شده و مشاهده ای به غیر از چند نقطه روی خط نیم سازه پراکنده شده و این امر دلالت بر برابری مقادیر مشاهده ای و محاسباتی بر اساس خط $(Y=X)$ می کند.

مقایسه کارایی سه مدل

در جدول ۴ کارایی سه مدل شبکه عصبی مصنوعی، مدل ماشین بردار پشتیبان و درخت تصمیم در پیش بینی سطح ایستابی آب زیرزمینی با استفاده از آماره های مجذور میانگین مربعات خطا و ضریب تبیین مقایسه شده است. با توجه به جدول ۴، همبستگی داده های شبیه سازی شده با مدل های


جدول ۴- نتایج معیارهای ارزیابی در حالت کلی برای هر سه مدل

Table 4. Results of evaluation criteria in general for all three models

MAE	RMSE	R ²	آماره خطا
۰/۰۲۴	۰/۲۹	۰/۹۹۳	شبکه عصبی ANN
۰/۰۲۷	۰/۳۱	۰/۹۹۲	ماشین بردار پشتیبان SVR
۰/۰۵۶	۰/۴۶	۰/۹۷۱	درخت تصمیم M5

مدل ماشین بردار پشتیبان و درخت تصمیم دارای روند کاملاً منطبق و مشابهی برای پیش بینی سطح آب زیرزمینی بودند.

شکل ۵ مقادیر سطح ایستابی پیش بینی شده توسط سه مدل در قیاس با داده های واقعی سطح ایستابی چاه ها را نشان می دهد. با توجه به شکل سه مدل شبکه عصبی مصنوعی،



شکل ۵- مقادیر سطح ایستابی پیش بینی شده توسط سه مدل شبکه عصبی مصنوعی (ANN)، مدل ماشین بردار پشتیبان (SVM) و درخت تصمیم (M5) در قیاس با داده های واقعی

Figure 5. Predictive values of groundwater level with neural network model (ANN), support vector machine (SVM) and decision tree model (M5)

پیش بینی سطح های آب زیرزمینی با استفاده از آماره های میانگین مربع خطا و همبستگی برتری دارد. نکته ای که باید در این جا به آن توجه نمود برتری های استفاده از شبکه عصبی نسبت به دو مدل دیگر می باشد.


پهنه بندی مکانی سطح آب زیرزمینی

شکل ۶ تغییرات مکانی آب زیرزمینی در سال ۱۳۸۸ و ۱۳۹۷ و شکل ۷ تغییرات افت آب زیرزمینی را نشان می دهد. نتایج به دست آمده از بررسی نقشه های پهنه بندی مکانی سطح آب زیرزمینی به روش کریجینگ نشان داد که در بخش غرب و شمال غرب سطح آب زیرزمینی بالا می باشد و


این مقایسه و بررسی کارایی سه روش نیز در نتایج پژوهش دیگران نیز مشهود می باشد. جاتیپراکش و ساکر (۱۵) و سریکنت و همکاران (۲۶) در پژوهش هایی جداگانه دریافتند که شبکه عصبی کارایی مناسبی برای پیش بینی سطح ایستابی چاه ها دارد. از نتایج دیگر این پژوهش می توان به همبستگی بهتر و خطای کمتر شبکه عصبی در پیش بینی سطح ایستابی در قیاس با دو مدل، مدل ماشین بردار پشتیبان و درخت تصمیم اشاره نمود. در همین راستا یانگ و همکاران (۲۹) در پژوهشی دیگر نشان دادند که دقت پیش بینی شبکه مصنوعی نسبت به دو مدل دیگر در

سطحی شده و از سوی دیگر باعث هجوم انسان به بهره‌برداری از منابع آب زیرزمینی شده است. آسیب‌پذیر بودن اکوسیستم‌های مناطق خشک و نیمه‌خشک را به فعالیت‌های انسانی و سایر عوامل تنش‌زا از جمله خشکسالی می‌توان مرتبط دانست. در زمینه خشکسالی پوتا‌پ و موزنی (۲۴) اظهار می‌دارند، بررسی تکامل خشکسالی در طول پنج دهه اخیر نشان می‌دهد که فراوانی وقوع خشکسالی‌ها افزایش یافته است و دوره‌های خشک به واسطه افزایش میزان تبخیر و تعرق در طول تابستان تقویت می‌شوند و در دسترس بودن منابع آب را تحت تأثیر قرار می‌دهند.

به تدریج به سمت مرکز، شمال و جنوب دشت، سطح آب زیرزمینی کاهش می‌یابد. مقایسه نقشه‌های پهنه‌بندی ابتدا (سال ۱۳۸۸) و انتهای دوره آماری (سال ۱۳۹۷) نشان داد سطح آب زیرزمینی در منطقه افت داشته است. سهم عمده کاهش سطح آب زیرزمینی دشتستان به عوامل انسانی و اضافه برداشت بستگی دارد که روند رو به رشد تعداد چاه‌های بهره‌برداری و به دنبال آن افزایش برداشت و تخلیه از سفره آب زیرزمینی سبب افت مستمر سطح آب زیرزمینی در دوره آماری مورد مطالعه شده است. البته خشکسالی‌های اخیر نیز باعث کاهش میزان تغذیه منابع آب زیرزمینی از منابع آب



شکل ۶- پهنه‌بندی مکانی سطح آب زیرزمینی دشتستان سال ۱۳۸۸ و ۱۳۹۷
Figure 6. Spatial zoning of Dashtestan groundwater level in 2009-2018



شکل ۷- تغییرات کمی افت سطح آب زیرزمینی دشتستان (۱۳۸۸-۱۳۹۷)
Figure 7. Quantitative changes in groundwater level drop in Dashtestan (2009-2018)

میزان تراز آب زیرزمینی مشاهداتی با میزان تراز آب زیرزمینی برآورد شده با مدل‌های مذکور با استفاده از معیارهای ارزیابی مورد مقایسه قرار گرفت. نتایج مدل‌سازی روش‌ها و نتایج آماره‌های ارزیابی مدل، نشان دهنده عملکرد خوب مدل‌ها در برآورد سطح ایستابی آب زیرزمینی است اما با توجه به مقایسه ضریب تبیین مدل‌ها در این تحقیق نشان داده شد که روش

نتیجه‌گیری کلی

از آنجایی که پیش‌بینی تراز سطح آب زیرزمینی در مناطق خشک و نیمه‌خشک کشور از اهمیت زیادی برخوردار است، در این تحقیق عملکرد مدل‌های شبکه عصبی مصنوعی، ماشین بردار پشتیبان و درخت تصمیم برای پیش‌بینی تراز سطح آب زیرزمینی دشتستان بوشهر مورد بررسی قرار گرفت. مقادیر

زیرزمینی صورت نگیرد، علاوه بر تشدید این پیامدها، شاهد اختلال در روند فعالیت‌های کشاورزی و دامپروری، کاهش فراورده‌های زراعی و دامی، تهدید امنیت زراعی و دامی، تهدید امنیت غذایی و عدم تأمین آب شرب کافی در منطقه خواهیم بود. بنابراین با حفاظت آب در کشاورزی از طریق بهبود روش‌های آبیاری همراه با انجام اقداماتی نظیر بیان مشکلات و افزایش سطح دانش بهره‌برداران، تهیه الگوی کشت بهینه، جلوگیری از برداشت‌های غیرمجاز و عدم صدور مجوزهای جدید، حفاظت از سفره‌ها و تغذیه مصنوعی آن‌ها، می‌توان میزان افت سطح آب‌های زیرزمینی و پیامدهای ناشی از آن را به حداقل رساند. همچنین پیشنهاد می‌شود با توجه به روش‌های فراوان هوش مصنوعی از سایر روش‌ها و مدل‌ها (برنامه ریزی بیان ژن، انفیس و ...) نیز برای برآورد سطح آب زیرزمینی استفاده شود.

تشکر و قدردانی

این پژوهش با حمایت مالی دانشگاه زابل انجام شده است. کد پژوهانه IR-UOZ-GR-1837.

شبکه عصبی مصنوعی دقت بالاتری در پراکنش داده‌های موجود دارد و مقادیر محاسبه شده نسبت به مقادیر مشاهداتی مدل شبکه عصبی مصنوعی نسبت به دو مدل دیگر، اختلاف کمتری داشتند. در مجموع نتایج تحقیق نشان داد که روش شبکه عصبی مصنوعی دارای دقت بالاتری در تخمین میزان تراز آب زیرزمینی می‌باشد. شبکه عصبی مصنوعی به دلیل برخورداری از توانایی تشخیص الگو، کشف رابطه بین ورودی و خروجی، حساسیت کمتر نسبت به نویز در اطلاعات ورودی، فرآیند پردازش به‌طور کامل موازی نیاز به تعداد داده‌های کمتر و روند صحت‌سنجی و واسنجی سریع‌تر، قادر به پیش‌بینی و دسته‌بندی با دقت مطلوب است.

نتایج تحقیق نشان داد به دلیل برداشت بیش از اندازه از سفره آب زیرزمینی، سطح ایستابی دشت دشتستان افت نموده است و شدت این افت در مناطق مختلف با توجه به میزان تغذیه و تخلیه آبخوان متفاوت است. اضافه برداشت از منابع آبی طی سال‌های گذشته پیامدهای محیطی و اقتصادی نامطلوبی را به دنبال داشته است و چنانچه اقدامات جدی و عملی جهت کاهش برداشت‌های بی‌رویه و به تعادل رساندن سفره‌های آب

منابع

- Alberg, D., M. Last and A. Kandel. 2012. Knowledge Discovery in Data Streams with Regression Tree Methods. Wiley Interdisciplinary Reviews: Data Mining Knowledge Discovery, 2(1): 69-78.
- Banerjee, P., R.K. Prasad and V.S. Singh. 2009. Forecasting of groundwater level in hard rock region using artificial neural network. Environmental Geology, 58(6): 1239-1246.
- BayatVarkeshi, M. and R. Fasihi. 2017. Comparison of numerical model, intelligent neural methods and geostatistics in estimating groundwater level. Applied Research in Geographical Sciences, 18(48): 165-182 (In Persian).
- Bouma, J. 1989. Using soil survey data for quantitative land evaluation. Advances Soil Science, 9: 177-213.
- Burges, C.J. 1998. A tutorial on support vector machines for pattern recognition. Data mining and knowledge discovery, 2: 121-167.
- Choisnel, E. and P. Gavilan. 1992. Une approche uniformisee du calcul l'evapotranspiration potentialle pour l'ensemble des pays de la communaut'es europ'eene. Publication EUR 14223, Office des publications officielles des communaut'e europ'eene: Luxembourg.
- Dawson C.W., R.J. Abrahart, A.Y. Shamseldin and R.L. Wibly. 2006. Flood estimation at ungauged sites using artificial neural networks. Journal of Hydrology, 319(14): 391-409.
- Dolatkhahi, M. and V. Ghorbani Nehooji. 2013. Introduction of high consumption medicinal plants in Dashtestan city in Bushehr province with emphasis on traditional application. Journal of Medicinal Plants, 12(2): 85-105 (In Persian).
- DvodAbadi Farahani, M. 2013. Mapping Groundwater Potential in Karstic Area- West of Shahrood, M.S.Thesis, Shahrood University of Technology, Shahrood, Iran, 130 pp (In Persian).
- Fallahi, M., H. Varvani and S. Golian. 2011. Rainfall Forecasting Using Regression Tree Model for Flood Control, 5th National Conference on Watershed Management and Soil and Water Resource Management, Kerman, 248-256 pp (In Persian).
- Ghorbani, M.A., R. Khatibi, M. Hasanpour kashani and O. Kisi. 2010. Comparison of three artificial intelligence techniques for discharge routing. Journal of Hydrology, 403(3-4): 201-212 (In Persian).
- Gorgij, A.D., O. Kisi and A. Moghaddam. 2016. Groundwater budget forecasting using hybrid wavelet-ANN-GP modelling: a case study of Azarshahr plain, East Azerbaijan, Iran. Journal of Hydrology Research (In Persian).
- Hoseini Someh, M., A. Roshani and A. Zebah. 2021. Modeling of groundwater level changes based on methods based on artificial intelligence (Case study of Zaveh Torbat Heydariyeh plain). Watershed Management, 11(21): 223-235 (In Persian).
- Jabalbarezi, B. and A. Malekian. 2020. Comparison of the efficiency of artificial neural network methods and gene expression planning for predicting water table in arid and semi-arid regions (Case study: Jiroft plain). Iranian Range and Desert Research, 26(2): 292-301 (In Persian).
- Jothiprakash, V. and S. Sakhare. 2008. Ground Water Level Fluctuations using Artificial Neural Network, The 12th International Conference of International Association for Computer Methods and Advances in Geomechanics (IACMAG), Goa, India.

16. Lallahem, S., J. Mania A. Hani and Y. Najjar. 2005. On the use of neural networks to evaluate ground water levels in fractured media. *Journal of Hydrology*, 307: 92-111.
17. Menhaj, M.B. 2005. Fundamentals of neural networks, computational intelligence. Publishing Center of Amir Kabir University of Technology, Iran, 718 p.
18. Mohtasham, M., A. Dehghani, A. Akbarpour, M. Meftah and M. Eatebari. 2010. Estimation of the level of the station using the Artificial Neural Network of Shabestar Plain, *Journal of Irrigation and Drainage*, 11(1):1-10 (In Persian).
19. Mokhtari, Z., A. Nazemi and A. Nadiri. 2012. The prediction of ground watear leveling using Shistar plain artificial neural network model, *Geotechnical Geology (Applied Geology)*, 8(4): 345-353
20. Norouzi Ghoshbalagh, H., A. Nadiri, A. Asghari Moghaddam and M. Qarahkhani. 2018. Comparison of the efficiency of artificial neural networks, fuzzy logic and random forest in estimating the aquifer transfer capability of Malekan plain. *Echo Hydrology*, 5(3): 739-751 (In Persian).
21. Nosrati Karizak, F., S.A. Movahedi Naeni and A. Hezarjaribi, 2012. Using Artificial Neural Networks to estimate saturated hydraulic conductivity from easily available soil properties. *Journal of Soil Management and Sustainable Production*, 2(1): 95-110 (In Persian).
22. Pal, M. 2006. M5 model tree for land cover classification. *Remote Sensing*. 27(4):825-831.
23. Piri, H. and A. Bameri. 2013. Investigation of the trend of quantitative changes in the water table of groundwater resources using statistics and geographic information system (Case study: Sirjan plain). *Application of Remote Sensing and GIS in Natural Resources Science*, 5(1): 29-43 (In Persian).
24. Potop, V. and M. Možný. 2011. The application a new drought index–Standardized precipitation evapotranspiration index in the Czech Republic. *Mikroklima a mezoklima krajinných struktur a antropogenních prostředí*, 2(4): 1-12.
25. Reghunath, R., T.R. Murthy and B.R. Raghavan. 2005. Time series analysis to monitor and assess water resources: A moving average approach. *Environmental Monitoring and Assessment*, 109: 65-72.
26. Sreekanth, D., N. Geethanjali, P. Sreedevi, Sh. Ahmed, N. Ravi Kumar and P.D. Kamala Jayanthi. 2009. Forecasting groundwater level using artificial neural networks, *Current Science*, 96: 1-7.
27. Wang, Y. and I.H. Witten. 1997. Inducing model trees for continuous classes. In *Proceedings of the Ninth European Conference on Machine Learning*, 128-137.
28. Wosten, J.H.M., Y.A. Pachepsky and W.J. Rawls. 2001. Pedotransfer functions: bridging the gap between available basic soil data and missing soil hydraulic characteristics. *Journal of Hydrology*, 251: 123-150.
29. Yang, Z.P., W.X. Lu, Y.Q. Long and P. Li. 2009. Application and comparison of two prediction models for groundwater levels: A case study in Western Jilin Province. China. *Journal Arid Environ*. 73: 487-492.

Temporal and Spatial Modeling of Groundwater Level in Bushehr Plain using Artificial Intelligence and Geostatistics

Halimeh Piri¹, Mojtaba Mobaraki² and Saleh Siasar³

1- Assistant Professor, Department of Water Engineering, Faculty of Water and Soil, University of Zabol,
(Corresponding author: H_piri2880@uoz.ac.ir)

2- Graduated from the Department of Water Engineering, Faculty of Water and Soil, University of Zabol

3- Undergraduate student, Department of Water Engineering, Faculty of Water and Soil, University of Zabol

Received: 17 May, 2021

Accepted: 5 July, 2021

Extended Abstract

Introduction and Objective: One of the basic measures to reach the optimal management of water resources is modeling and predicting the level of stagnation of wells. Controlling the level of stability using observation wells is considered as the main source of information to investigate hydrological stresses. By using the daily and monthly data of the wells, it is possible to check the fluctuations of the water level, and these checks are necessary for understanding the behavior of underground water resources in the long term and making any kind of management decisions. Considering the importance of predicting the groundwater level, it is important to find an appropriate method in this regard. In recent years, the use of intelligent systems for predicting the level of underground water is rapidly increasing, which is due to the ease of use and the high accuracy of these models in approximating nonlinear and complex mathematical equations. The aim of this research is to predict the level of groundwater stagnation in Bushehr plain with the help of artificial neural network models, support vector machine model and decision tree.

Material and Methods: In the first half of the year, all the support vector machines and the decision tree were made from the hot water of Dashtestan. Also, statistical method was used to study the spatial changes of groundwater. The data of month of 50 wells in the plain aquifer was a ten-year period from 2009-2018. To evaluate the results of the mentioned models were used of RMSE, MBE and R^2 .

Result: The results showed that all three methods had high accuracy in simulating water level. The artificial neural network method with a higher R^2 (0.993), the lowest squared mean error (0.29) and the lowest absolute mean error (0.024) was selected as the superior method for predicting the water table. Kriging zoning showed that the groundwater level in most parts of the plain during the study period has decreased. The maximum drop is equal to 10 meters.

Conclusion: The results of the modeling methods and the results of the model evaluation statistics show the good performance of the models in estimating the groundwater stagnation level, but according to the comparison of the explanation coefficient of the models in this research, it was shown that the neural network method Artificial has a higher accuracy in the distribution of available data and the calculated values were less different than the observed values of the artificial neural network model compared to the other two models. In total, the results of the research showed that the artificial neural network method has a higher accuracy in estimating the level of underground water.

Keywords: Artificial Neural Network, Decision Tree, Dashtestan, Support Vector Machine