



"مقاله پژوهشی"

مقایسه و ارزیابی مدل‌های هوشمند و زمین‌آمار به منظور تحلیل تغییرات مکانی کیفیت آب زیرزمینی (دشت کميجان)

مه‌نوش مقدسی^۱، مهدی مردیان^۲ و محسن پارسا^۳

۱- دانشیار گروه مهندسی آب دانشگاه اراک، (نویسنده مسوول: m-moghaddasi@araku.ac.ir)

۲- دانش‌آموخته دکتری آبخیزداری دانشگاه علوم کشاورزی و منابع طبیعی ساری

۳- دانش‌آموخته کارشناسی ارشد مهندسی آب دانشگاه اراک

تاریخ دریافت: ۱۳۹۸/۸/۵ تاریخ پذیرش: ۱۳۹۹/۵/۱۲

صفحه: ۵۴ تا ۶۴

چکیده مبسوط

مقدمه و هدف: امروزه با توسعه بخش شهری، صنعتی و کشاورزی استفاده از آب‌های زیرزمینی اهمیت بیشتری یافته است. بنابراین پایداری و توسعه بهره برداری از آب‌های زیرزمینی برای انواع مشتریان و اهداف مختلف، امری ضروری است که ویژگی‌های کمی و کیفی آن مورد بررسی و ارزیابی قرار گیرد. **مواد و روش‌ها:** شبکه عصبی تطبیقی فازی (FANN) و روش زمین آماری مبتنی بر سیستم اطلاعات جغرافیایی برای دشت کميجان، استان مرکزی، ایران استفاده شده است. ابتدا داده‌های ۳۶ حلقه چاه از شرکت آب و فاضلاب روستایی جمع‌آوری شد. سپس با استفاده از انواع نیمه واریوگرام مانند: گوسی، خطی، کروی و همچنین کریجینگ و کوکریجینگ، مدل زمین آماری با استفاده از شاخص‌های R² و RMSE مورد ارزیابی قرار گرفت. سپس برای مدل شبکه عصبی تطبیقی فازی توابع عضویت مانند: مثلثی، زنگ تعمیم یافته و گاوسی بررسی شد و بهترین مدل با استفاده از شاخص‌های R² و RMSE تعیین شد.

یافته‌ها: با توجه به نتایج R² و RMSE در مدل‌های زمین آماری، کروی، خطی و نمایی به ترتیب برای متغیرهای EC، TDS و pH بهترین انتخاب شدند. همچنین بر اساس نیمه واریوگرام، روش کریجینگ عملکرد بهتری نسبت به روش کوکریجینگ برای تمامی متغیرهای مورد مطالعه با ضریب تعیین بالا به ترتیب ۰/۷۳، ۰/۶۶ و ۰/۸۵ برای EC، TDS و pH و کمتر در RMSE دارد. نتایج نشان داد که در شبکه عصبی تطبیقی فازی، متغیر EC، تابع زنگ تعمیم یافته فازی با ضریب همبستگی ۰/۹۸ و میانگین مربعات خطای ۱۴۴/۵۹ در مرحله آزمون، خوب است. برای متغیر TDS، تابع گاوسی با ضریب همبستگی ۰/۹۸ و میانگین مربعات خطای ۰/۳۳ در مرحله آزمون بهترین است. همچنین برای متغیر pH، تابع زنگ تعمیم یافته با ضریب همبستگی ۰/۹۹ و میانگین مربعات خطای ۱۰۳/۱۰ در مرحله آزمون عملکرد بهتری نسبت به سایر توابع فازی در مدل سازی دارد. با مقایسه نتایج شبکه عصبی تطبیقی زمین آماری و فازی می‌توان دریافت که مدل FANN نسبت به مدل زمین آماری کارایی بالاتری دارد.

نتیجه‌گیری: نتایج نقشه‌های پهنه‌بندی نشان داد که در قسمت شمالی دشت EC کم و در مرکز و غرب EC بالای ۲۰۰۰ $\mu\text{Siemens/cm}$ است. همچنین برای متغیر TDS، در قسمت شمالی دشت کم و در جنوب و جنوب غربی بالای ۱۰۰۰ میلی‌گرم در لیتر است. همچنین تغییرات مقدار pH نشان داد که تغییرات این متغیر کم بوده و بیشترین میزان pH در قسمت شمالی و کمترین آن در قسمت جنوبی است.

واژه‌های کلیدی: شبکه عصبی مصنوعی، مدل کریجینگ، مدل کوکریجینگ، هدایت الکتریکی، ANFIS

مقدمه

کمکی برای تخمین متغیرهای مکانی در علوم آب و خاک بسیار مورد توجه متخصصان قرار گرفته است (۲۸،۵). همچنین با رشد روزافزون محاسبات نرم از جمله هوش مصنوعی، استفاده از مدل‌های شبکه عصبی به‌طور گسترده‌ای در مطالعات منابع آب مورد استفاده قرار گرفته است و محققان بر دقت بالای این مدل‌ها در مقایسه با روش‌های تجربی و رگرسیونی تأکید نموده‌اند. شبکه‌های عصبی از سیستم عصبی بیولوژیکی الهام گرفته‌اند و توانایی یادگیری و تشخیص ارتباط الگوهای مختلف را از طریق یادگیری دارند. هدف اصلی این روش‌ها، پیدا کردن راه‌حل الگوریتمی برای مسائل پیچیده، مانند پیش‌بینی، تشخیص الگو و طبقه‌بندی است (۸،۶). تعداد نرون‌های ورودی و خروجی در شبکه به تعداد ورودی و خروجی‌های مسئله وابسته است؛ در حالی که تعداد لایه‌های مخفی و نرون‌های آن در هر لایه با روش سعی و خطا تعیین می‌شود. مقادیر وزن‌ها و ارباب‌ها در هر نرون می‌تواند کارایی شبکه را تعیین کند (۲۵). تابع ورودی شبکه توسط ضرب مقادیر وزن‌ها در ورودی و جمع آنها با بایاس‌ها به‌دست می‌آید. خروجی شبکه با تعیین علامت تابع ورودی از طریق توابع انتقال تولید می‌شود. در میان تمام ساختارهای شبکه‌های عصبی، پرسپترون چند لایه پیشرونده (FF-MLP)

آب زیرزمینی منبع اصلی آب شیرین برای مصارف خانگی و تولید مواد غذایی در بخش کشاورزی ضروری است (۷). برداشت بی‌رویه آب‌های زیرزمینی و افزایش آلودگی‌های زیست‌محیطی در نتیجه رشد روزافزون جمعیت منجر به افزایش املاح و کاهش کیفیت آب‌های زیرزمینی شده است (۲۳). علاوه بر این، خشکسالی یکی از مهمترین پدیده‌های طبیعی است که بر کیفیت منابع آب زیرزمینی تأثیر منفی گذاشته است (۳). بنابراین، آگاهی از میزان تغییرات شیمیایی آب‌های زیرزمینی و پهنه‌بندی آنها نقش مهمی در مدیریت برداشت آب‌های زیرزمینی ایفا می‌کند. روش‌های مختلفی مانند زمین‌آمار و مدل‌های هوشمند برای مطالعه و پهنه‌بندی ویژگی‌های کیفی آب زیرزمینی وجود دارد که انتخاب روش مناسب بسته به هدف، شرایط منطقه و وجود آمار و اطلاعات دارد (۳۰،۸). برای دستیابی به اطلاعات مورد نظر، میان‌یابی و پهنه‌بندی صحیح بر اساس تعداد مشخصی داده معلوم لازم است. در سال‌های اخیر استفاده از روش‌های زمین‌آمار به‌دلیل دقت قابل قبولی که دارند رو به گسترش است (۲۷،۲۶). در این بین استفاده از مدل‌های زمین‌آمار کریجینگ با استفاده از داده‌های همان متغیر و کوکریجینگ با استفاده از متغیرهای

همکاران (۱۴) نیز از روش کریجینگ برای تخمین پارامترهای هیدروشیمیایی آب زیرزمینی و همچنین درجه‌بندی قابلیت انتقال مزرعه و ظرفیت پمپاژ سفره استفاده کردند. تافورمینا و همکاران (۳۲) با استفاده از شبکه عصبی با الگوریتم پس‌انتشار خطا، سطح آب زیرزمینی آبخوان آزاد ساحلی منطقه لاگون ایتالیا را برای ساعات آینده پیش‌بینی کردند. تاپوعلو و همکاران (۳۳) با مقایسه مدل هیبرید شبکه عصبی و روش کریجینگ برای شبیه‌سازی سطح آب زیرزمینی نشان دادند که بر اساس ارزیابی متقابل، مدل شبکه عصبی با دو لایه پنهان از کارایی بهتری برخوردار است. لوهانی و کریشان (۲۰) به کارایی قابل قبول استفاده از مدل شبکه عصبی مصنوعی برای پیش‌بینی سطح آب‌های زیرزمینی در جنوب شرقی پنجاب هند اشاره داشتند. واق و همکاران (۳۴) با استفاده از مدل شبکه عصبی مصنوعی به منظور بررسی پارامترهای فیزیکی و شیمیایی نشان دادند شبکه عصبی یک ابزار کاربردی برای پیش‌بینی سطح آب‌های زیرزمینی برای اهداف آبیاری است.

ساختار مدل به همراه صحت و ساختار داده‌ها می‌تواند تاثیر مناسبی در نتایج مدل داشته باشد (۷). با توجه به پژوهش‌های انجام شده در زمینه مدل‌سازی کمی و کیفی آب زیرزمینی و با توجه اهمیت برنامه‌ریزی پایدار منابع آب زیرزمینی، در این تحقیق برای پهنه‌بندی و بررسی پارامترهای کیفی آب‌های زیرزمینی از روش‌های زمین‌آمار و شبکه عصبی و ANFIS استفاده شده است تا ضمن ارزیابی کارایی مدل‌ها، نمایش قابل قبولی از تغییرات مکانی پارامترهای کیفی در دشت کمپجان که با افت شدید منابع آب و کاهش کیفیت روبروست، بدست آورد.

مواد و روش‌ها

معرفی منطقه مطالعاتی


دشت کمپجان با کد ۴۱۱۸ تماب بین طول‌های جغرافیایی ۴۹° ۶' ۱۹" و ۴۹° ۳۸' ۴۰" شرقی و عرض‌های جغرافیایی ۳۴° ۳۱' ۲۹" و ۳۴° ۵۷' ۴۳" شمالی قرار گرفته است (شکل ۱). مساحت این محدوده مطالعاتی در حدود ۱۶۸۶ کیلومتر مربع است که ۵/۷ درصد مساحت استان مرکزی را به خود اختصاص داده است. بر اساس برنامه اجرای طرح احیاء و تعادل بخشی منابع آب زیرزمینی در این دشت، سالانه در حدود ۳۳۰ میلیون مترمکعب از منابع آب زیرزمینی برداشت می‌شود که با توجه به افت متوسط سالانه ۰/۹ متر سطح آب زیرزمینی، لازم است ضمن پر و مسلوب المنفعه نمودن چاه‌های غیرمجاز، درصد برداشت فعلی چاه‌های کشاورزی حدود ۴۰ درصد نیز کاهش یابد (۱۳). همچنین با توجه به پتانسیل بالای کشاورزی در این دشت، لازم است مدیریت کیفی منابع آب نیز مدنظر قرار گیرد. فاکتورهای مرتبط با شوری از جمله هدایت الکتریکی با فاکتورهای مهم تنظیم کننده عملکرد محصول (یعنی بافت خاک، تبادل کاتیونی، شرایط زهکشی، سطح ماده آلی) ارتباط دارند که به نوبه خود می‌توانند عمل سلامت محصول را کنترل کنند (۹).

به‌طور مرسوم به عنوان یک تخمین‌گر سراسری شناخته می‌شود (۱۸). قوانین یادگیری متفاوت زیادی برای شبکه‌های عصبی پیش‌رونده وجود دارد؛ اما اغلب از قوانین دلتا یا قوانین پس‌انتشار (BP) استفاده می‌شود (۱۷).

از طرفی استفاده از تئوری فازی به‌عنوان یک روش جدید در این زمینه به‌منظور بهینه‌سازی نتایج و کاهش عدم قطعیت‌ها در نتایج مطرح بوده است. با توجه به اهمیت اطلاع از وضعیت کیفیت آب‌های زیرزمینی برای مصارف کشاورزی و نیز هزینه‌بر و وقت‌گیر بودن اندازه‌گیری پارامترهایی مهم و معمول نظیر pH، EC، TDS، یافتن راهکاری برای تخمین آن‌ها با استفاده از پارامترهایی که اندازه‌گیری آن‌ها راحت‌تر است، امری ضروری به‌نظر می‌رسد (۷).

تحقیقات متعددی در رابطه با استفاده از مدل‌های زمین‌آمار و شبکه عصبی مصنوعی انجام شده است که اشاره به کارآمدی آنها برای تخمین متغیرهای مختلف کمی و کیفی هیدرولوژیکی دارند. خالدیان و همکاران (۱۵) با پهنه‌بندی هدایت هیدرولیکی در حوضه آبخیز ناورود اسالم استان گیلان، به کارایی قابل قبول روش زمین‌آمار اشاره نمودند. سعدی‌پور و همکاران (۲۸) نیز همین نتیجه را در دشت لاغر اعلام کردند. کوهی چله‌کران و همکاران (۱۹) در بررسی مدل‌های زمین‌آمار نشان دادند که کوکریجینگ به‌همراه متغیر کمی TDS نسبت به سایر روش‌ها از دقت بالایی در پیش‌بینی کیفیت منابع آب زیرزمینی دارد. اما هاشمی جزی و همکاران (۱۰) با برآورد مکانی مولفه‌های کیفی آب‌های زیرزمینی با استفاده از روش‌های زمین‌آمار در دشت گلپایگان نشان دادند که مدل کوکریجینگ نسبت به کریجینگ برتری ندارد. متکان و همکاران (۲۲) با استفاده از تلفیق تکنیک شبکه‌های عصبی مصنوعی و زمین‌آمار نشان دادند که دقت شبکه عصبی برای تخمین مقادیر میانگین بارندگی ماهانه و فصلی و سالانه در سطح منطقه بالاتر از زمین‌آمار است. خاشعی سیوکی و همکاران (۱۶) مدل‌های شبکه عصبی مصنوعی، سیستم استنتاج فازی و رگرسیونی در برآورد سطح ایستابی آبخوان دشت نیشابور را مورد ارزیابی قرار دادند که مدل شبکه عصبی مصنوعی و فازی بهترین کارایی را داشتند. صفوی گردینی و همکاران (۲۹) در بررسی تغییرات مکانی متغیرهای کیفی آب زیرزمینی جنوب دشت قروه و دهگلان نشان دادند که روش‌های کریجینگ معمولی و ساده در تخمین اکثر متغیرهای کیفی خطای کمتری داشته‌اند. معروفی‌پور و همکاران (۲۱) با ارزیابی مدل‌های هوشمند و ترکیبی GIS برای تحلیل و پیش‌بینی تغییرات مکانی پارامترهای کیفی EC نشان دادند مدل‌های هوشمند با کمترین مجموع مربعات خطا برای پیش‌بینی پارامترهای کیفی کارایی دارند. عظیمی و همکاران (۳) با استفاده از مدل‌های هوشمند و GIS نشان دادند مناطق دارای تنش خشکی شدید و وضعیت کلاس بی کیفیت در مناطق مرکزی ایران رخ داده است.

بالوشا (۴) با ارزیابی شبکه‌های پایش کیفیت آب زیرزمینی با استفاده از نقشه‌برداری‌های آسیب‌پذیری و زمین‌آمار در حوضه هراتانگا در نیوزلند نتیجه گرفتند روش کریجینگ برای درون‌یابی از دقت قابل قبولی برخوردار است. جانگ و



شکل ۱- موقعیت منطقه مورد مطالعه در بین استان‌های مرکزی و همدان
Figure 1. Location of the study area between Markazi and Hamedan provinces

$$2\gamma(h) = \frac{1}{N(h)} \sum_{i=1}^{N(h)} [Z(x+h) - Z(x)]^2 \quad (1)$$

$\gamma(h)$ موسوم به نیم‌تغییرنما، $N(h)$ تعداد جفت نقاطی است که فاصله آنها از یکدیگر برابر h است. $Z(x+h)$ و $Z(x)$ متغیرهای ناحیه‌ای با فاصله h از یکدیگر می‌باشند (۲۸، ۲۶، ۱۳). در این پژوهش انواع نیم‌تغییرنما شامل خطی، نمایی، گوسی و کروی و نیز مدل‌های زمین‌آمار شامل کریجینگ و کوکریجینگ با متغیر ارتفاع از سطح دریا برآزش شدند. همچنین به‌منظور نمایش گرافیکی تغییرات مکانی پارامترهای EC، TDS و pH بر اساس بهترین روش و مدل، از شاخص‌های ارزیابی R^2 و R^2 و RMSE استفاده شد.

مدلسازی با شبکه‌های هوشمند

در این تحقیق از دو روش آموزش Levenberg-Marquardt (MLPLM) و Quasi-Newton (MLPBF) برای مدل‌سازی با شبکه عصبی استفاده شد (۳۴، ۱۲). جزئیات ساختاری شبکه‌های مصنوعی استفاده شده از دو مدل در جدول‌های ۱ و ۲ نشان داده شده است.

مدلسازی زمین‌آمار

داده‌های موجود برای انجام محاسبات لازم به‌منظور تعیین شوری و اسیدیته و غلظت ذرات جامد آب زیرزمینی منطقه مطالعاتی از شرکت سهامی آب منطقه‌ای استان مرکزی تهیه شده است که در این پژوهش از ۴۰ چاه مشاهداتی مربوط به سال ۱۳۹۷ با پراکنش مناسب در آبخوان کميجان که بیانگر وضعیت کلی دشت باشد استفاده گردید (شکل ۱). شرط استفاده آنالیزهای زمین‌آمار این است که داده‌ها توزیع نرمال داشته باشند و از طرفی میانگین و واریانس آنها خیلی متغیر نباشد که در این تحقیق آزمون نرمال بودن داده‌ها بررسی شد. بر این اساس با استفاده از نرم‌افزار SPSS، آزمون کلموگروف-اسمیرنوف در سطح ۵ درصد انجام شد. همچنین با استفاده از آزمون گرافیکی Q-Q Plot نرمال بودن داده‌ها مورد بازبینی قرار گرفت.

برای مدل‌سازی زمین‌آمار و بررسی روابط مکانی بین نقاط اندازه‌گیری شده از مدل‌سازی نیم‌تغییرنما یا سمی‌واریوگرام استفاده گردید که مطابق با رابطه ۱ بیانگر ساختار واریانس نمونه‌های معلوم برداشت شده نسبت به فواصل آنها است و ساختار تغییرپذیری نسبت به فاصله مکانی یا زمانی را نشان می‌دهد (۳۱، ۳۰).

جدول ۱- جزئیات شبکه توسعه یافته ANN (MLPLM)


پارامتر	نوع / مقدار
تعداد نرون‌ها در لایه ورودی	۳
تعداد لایه‌های مخفی	۲
تعداد نرون‌ها در لایه مخفی	۶
تعداد نرون‌ها در لایه خروجی	۱
الگوی آموزش	Levenberg-Marquardt
تابع آموزش	Trainlm
تابع تبدیل	Tansig for hidden layer Purelin for output layer

جدول ۲- جزئیات شبکه توسعه یافته ANN (MLPBFG)

پارامتر	نوع/ مقدار
تعداد نرون‌ها در لایه ورودی	۳
تعداد لایه‌های مخفی	۲
تعداد نرون‌ها در لایه مخفی	۶
تعداد نرون‌ها در لایه خروجی	۱
الگوی آموزش	Quasi-Newton
تابع آموزش	Trainbfg
تابع تبدیل	Tansig for hidden layer Purelin for output layer

فازی و شبکه عصبی مصنوعی می‌باشد و از مزایای هر دو روش استفاده می‌کند. به‌طوریکه از شبکه عصبی مصنوعی برای بهینه کردن مدل فازی استفاده می‌شود. در این روش شبکه عصبی مصنوعی به‌جای بهینه کردن وزن‌ها، قوانین و توابع عضویت فازی را بهینه می‌کند. در روش نروفازی تنها می‌توان از روش فازی ساگنو که خروجی آن ثابت یا خطی که خروجی آن ثابت یا خطی است، استفاده کرد (۲۳). در شکل ۲ مدل فازی مرتبه اول نوع ساگنو به‌همراه قانون فازی و همچنین مدل فازی-عصبی معادل آن نشان داده شده است (۱).

علاوه بر مدل‌های شبکه عصبی مصنوعی، از مدل ANFIS نیز برای مدل‌سازی کیفیت آب زیرزمینی دشت کمبجان استفاده شد. انفیس بر اساس ترکیب شبکه‌های عصبی مصنوعی و سیستم استنتاج فازی توسط Jang در سال ۱۹۹۳ ارائه شده است (۱۴، ۱۱). فازی‌سازی، استلزام، نرمال کردن، نافازی‌سازی و جمع‌بندی پنج لایه هستند که هر نوع معماری ANFIS را ایجاد می‌کند. در این رویکرد قوانین مدل فازی در طول فرایند آموزش توسعه می‌یابند. با فرض وجود دو ورودی مانند روش نروفازی شبکه تطبیق‌پذیر و قابل آموزشی است که به لحاظ عملکرد کاملاً مشابه سیستم استنتاج فازی است. این روش در حقیقت ترکیبی از روش



شکل ۲- مدل فازی مرتبه اول سوگنو با دو قانون فازی و سیستم ANFIS معادل آن
Figure 2. The first model sugeno fuzzy model with two rules and its equivalent ANFIS system

جدول ۳- جزئیات شبکه توسعه یافته ANFIS

پارامتر	نوع/ مقدار
ساختار فازی	Sugeno-type
FIS اولیه برای آموزش	Genfis
تعداد ورودی‌ها	۳
روش بهینه‌سازی	Hybrid
تعداد خوشه‌ها	۸
بیشترین تعداد گره	۱۰۰
اندازه مرحله اولیه	۰/۱
نرخ کاهش اندازه مرحله	۰/۹۹
نرخ کاهش اندازه مرحله	۱

بودن واحد مقادیر کیفی، دامنه تغییرات این طبقات با استفاده از رابطه ۲ استاندارد شد.

$$x_i = \frac{Z_i - Z_{i(\min)}}{Z_{i(\max)} - Z_{i(\min)}} \quad (2)$$

جزئیات ساختاری سیستم استنتاج نرو فازی تطبیقی در جدول ۳ آورده شده است. برای پهنه‌بندی مقادیر TDS، EC و pH با استفاده از مدل‌های هوشمند، با توجه به متفاوت

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (P_i - O_i)^2}{n}} \quad (۴)$$


که x و P_i مقدار برآوردی از مدل، y و O_i مقدار مشاهده‌ای و n تعداد داده‌ها می‌باشد.

نتایج و بحث

روند تغییرات مکانی پارامترهای کیفی نشان می‌دهد که خط روند EC و TDS به شکل محدب است؛ به طوریکه بیشترین مقادیر ثبت شده مربوط به منطقه پست دشت (اراضی میانی دشت) می‌باشد. اما در مورد pH این روند به شکل مقعر بوده و بیانگر این مطلب است که با دور شدن از اطراف منطقه پست دشت، مقدار pH آب زیرزمینی افزایش پیدا می‌کند (شکل ۳).

که در آن z_i برابر با مقادیر داده مورد نظر، $z_i(\min)$ برابر با کمترین مقدار داده مورد نظر، $z_i(\max)$ برابر با مقدار داده مورد نظر و x_i برابر با وزن نرمال شده داده مورد نظر است. در این پژوهش پس از استانداردسازی، ۷۰ درصد داده‌ها برای آموزش و ۳۰ درصد مابقی برای صحت‌سنجی تعیین شدند. این جداسازی بر اساس پیش فرض نرم‌افزار متلب و محدودیت داده‌ها تعیین شد. دقت تخمین هر یک از سناریوهای مدل‌های شبکه هوشمند بر اساس روابط ۳ و ۴ با استفاده از معیارهای ضریب تبیین (R^2) و جذر میانگین مربع خطاها (RMSE) در دو مرحله آموزش و صحت‌سنجی مورد بررسی قرار گرفت (۲). بعد از مشخص شدن بهترین مدل برای مقادیر EC، TDS و pH، داده‌های مربوطه به نرم‌افزار ArcGIS 10.3 انتقال داده شد و اقدام به پهنه‌بندی این پارامترها در منطقه مورد مطالعه گردید.

$$R^2 = \left(r = \frac{n(\sum xy) - (\sum x)(\sum y)}{\sqrt{[n\sum x^2 - (\sum x)^2][n\sum y^2 - (\sum y)^2]}} \right)^2 \quad (۳)$$



شکل ۳- آزمون روند تغییرات مکانی EC و pH آب زیرزمینی دشت کمیجان
Figure 3. Trend test of spatial variability of EC and pH of groundwater of Komijan Plain

متغیر بهتر ترسیم می‌گردد. طبق نتایج، در متغیر EC مدل کروی، در متغیر TDS مدل خطی و در متغیر pH مدل نمایی می‌باشد.

نتایج تجزیه و تحلیل واریوگرام متغیرها در جدول ۴ آمده است. مناسب‌ترین مدل با توجه به کمترین خطا (RMSE) و ضریب همبستگی بالا (R^2) تعیین گردید. بدین صورت که هر چه RMSE کوچک‌تر باشد و R^2 بیشتر باشد، ساختار فضایی

جدول ۴- نتایج حاصل از بررسی نیم‌تغییر نمای متغیرهای کیفیت آب زیرزمینی
Table 4. The result of semi-vibrational assessment of groundwater quality variables

pH	TDS	EC	پارامتر
نمایی	خطی	کروی	مدل
۰/۸۳	۰/۶۹	۰/۸۵	ضریب همبستگی مکانی (R^2)
۰/۰۰۶۸	۰/۰۴۳	۰/۰۰۳۶	جذر میانگین مربعات (RMSE)

داشتن ضریب تبیین بالا (به ترتیب ۰/۷۳، ۰/۶۶ و ۰/۸۵ برای متغیرهای EC، TDS و pH) و خطای میانگین مربعات کمتر، عملکرد بهتری نسبت به روش کوکریجینگ داشته است.

جدول ۵ نتایج حاصل از روش‌های زمین‌آمار کوریجینگ و کوکریجینگ را نشان می‌دهد. مشاهده می‌گردد که روش زمین‌آمار کوریجینگ در تمامی متغیرهای مورد بررسی با

جدول ۵- نتایج حاصل از روش‌های زمین‌آمار در برآورد متغیرهای کیفی آب زیرزمینی
Table 5. The results of geostatistical methods in estimating groundwater quality variables

متغیر	کوریجینگ	کوکریجینگ با متغیر ارتفاع
RMSE	R2	RMSE
۰/۷۳	۰/۶۵	۵۶۷/۸۳
۰/۶۶	۰/۵۱	۴۶۴/۹۷
۰/۸۵	۰/۸۲	۰/۹۸

نقشه‌های پراکندگی برای تخمین متغیرهای کیفی آب زیرزمینی و مقادیر واقعی آن‌ها برای تمام مدل‌ها در فاز آزمایش در شکل‌های ۴ تا ۶ نمایش داده شده است. با توجه به نتایج می‌توان گفت که بین مقادیر مشاهده‌ای و مقادیر پیش‌بینی شده برای مدل‌های غیرخطی (MLP، MLP-LM، ANFIS و BFG) ارتباط با معنایی وجود دارد. با توجه به نتایج، مدل شبکه عصبی نرو فازی تطبیقی دقت بالایی برای تخمین مقادیر کیفی آب زیرزمینی دارد. یکی از مزایای مدل ANFIS سادگی اجرای آن می‌باشد.

شکل ۴- پراکندگی تخمین متغیرهای کیفی آب زیرزمینی و مقادیر واقعی آن‌ها برای متغیر PH




Figure 4. The distribution of estimates of groundwater quality variables and their actual values for the pH variable




Figure 5. The distribution of estimates of groundwater qualitative variables and their real values for EC variables




Figure 6. The distribution of estimates of groundwater quality variables and their actual values for the TDS variable

حالی‌که روش MLP-LM کمترین ضریب تبیین را دارد. برای متغیرهای EC و TDS نیز روش ANFIS دقت بالاتری را نشان می‌دهد. علاوه بر ضریب تبیین، مجذور میانگین مربعات خطا برای هر مدل محاسبه شده است. کمترین مقدار خطا برای متغیرهای کیفی آب زیرزمینی متعلق به روش ANFIS است.


نتایج حاصل از ارزیابی سه مدل هوشمند در جدول ۶ آمده است. مقایسه نتایج این تحقیق بر اساس معیارهای ضریب تبیین و مجذور میانگین مربعات خطا به‌دست آمده است. تخمین متغیر (pH) کیفی آب زیرزمینی بر اساس R^2 به‌ترتیب برابر ۰/۶۰۲۶، ۰/۶۲۳۵ و ۰/۶۵۰۳ به‌ترتیب برای MLP-LM، MLP-BFG و ANFIS است. مشخص است که روش ANFIS مقدار ضریب تبیین بالاتری دارد؛ در

جدول ۶- نتایج ارزیابی مدل‌های هوشمند بر اساس $RMSE$ و R^2

متغیر	شاخص ارزیابی/مرحله	MLP-LM	MLP-BFG	ANFIS
pH	Train/RMSE	۰/۷۰۱	۰/۰۲۸۲	۷/۸۸-۰۷
	Train/ R^2	۰/۷۱۹۴	۰/۹۱۶۳	۱
	Test/RMSE	۰/۱۵۴۵	۰/۱۵۰۴	۰/۱۴۴۹
	Test/ R^2	۰/۶۰۲۶	۰/۶۲۳۵	۰/۶۵۰۳
EC	Train/RMSE	۵۰/۷۱	۸۱/۹۴	۰/۰۲۱۳
	Train/ R^2	۰/۹۹۰۲	۰/۹۷۴۶	۱
	Test/RMSE	۷۳	۸۹/۵۲	۵/۶۶
	Test/ R^2	۰/۹۶۶۴	۰/۹۴۹۵	۰/۹۹۹۷
TDS	Train/RMSE	۴۳/۵۹	۴۴/۹۹	۰/۰۲۷۶
	Train/ R^2	۰/۹۸۵۵	۰/۹۸۴۵	۱
	Test/RMSE	۶۶/۹۶	۴۵/۵۵	۱۶/۹۵
	Test/ R^2	۰/۷۸۳۹	۰/۹۰	۰/۹۸۶۱


کميجان را با دقت بیشتری مدل‌سازی کرده است. لذا پهنه‌بندی متغیرهای کیفیت آب زیرزمینی با بهترین مدل ANFIS در شکل‌های ۷ تا ۹ آمده است.

با مقایسه نتایج از مقادیر $RMSE$ و R^2 مدل زمین‌آمار با مدل پهنه شبکه هوشمند (انفیس) در جداول ۵ و ۶ مشاهده می‌شود که مدل ANFIS نسبت به مدل زمین‌آمار دارای کارایی بالاتری است و کیفیت منابع آب زیرزمینی دشت




شکل ۷- پهنه‌بندی EC با استفاده از مدل ANFIS

Figure 7. The modeling of EC using ANFIS model



شکل ۸- پهنه‌بندی TDS با استفاده از مدل ANFIS
Figure 8. The modeling of TDS using ANFIS model



شکل ۹- پهنه‌بندی pH با استفاده از مدل ANFIS
Figure 9. The modeling of pH using ANFIS model

نتیجه‌گیری کلی

نماهای مختلف و نیز سه مدل شبکه هوشمند (MLP-LM، BFG-MLP و ANFIS) استفاده گردید. مقایسه روش‌های زمین‌آمار در برآورد متغیرهای کیفی آب زیرزمینی نشان داد که روش کریجینگ نسبت به کوکریجینگ عملکرد بهتری در

در این پژوهش به‌منظور پهنه‌بندی متغیرهای کیفیت آب زیرزمینی (TDS، EC و pH) در محدوده مطالعاتی کمیجان، از روش‌های زمین‌آمار کریجینگ و کوکریجینگ با برآزش

کشاورزی دشت در دهه اخیر با خطر شوری خاک روبرو شده است. خشکسالی‌های اتفاق افتاده و حفر چاه‌های عمیق و نیمه عمیق و افزایش سطح زیر کشت سبب تشدید تخریب منابع آبی و افت آب زیرزمینی دشت کم‌یجان شده است که شوری خاک را نیز در بر داشته است. از طرفی با توسعه شهرهای کم‌یجان و میل‌اجرد، افزایش تولید فاضلاب خانگی و نفوذ آن به آب‌های زیرزمینی همراه با مواد شیمیایی کشاورزی، کودها و نمک‌ها باعث گردیده که میزان املاح در آب‌زیرزمینی افزایش یابد و کیفیت کاهش داشته باشد. به‌طوری که منابع آب زیرزمینی در محدوده غربی دارای شوری و املاح بالا و اسیدیته می‌باشد که با شوری خاک منطقه نیز مطابقت دارد. در یک جمع‌بندی می‌توان بیان کرد که نتایج این تحقیق نشان می‌دهد کاربرد مدل شبکه عصبی- فازی تطبیقی در محیط سامانه اطلاعات جغرافیایی به‌عنوان ابزار توانمندی در تهیه نقشه‌های پهنه‌بندی کیفیت آب زیرزمینی، مطرح می‌باشد. با توجه به این‌که یکی از اصول اولیه مدیریت، اطلاع از اولویت‌های مدیریتی می‌باشد، این الگو و نتایج حاصل از آن می‌تواند راه‌کار مناسبی برای اعمال مدیریت مناسب در بهره‌برداری در دشت کم‌یجان است و همچنین برای سایر مناطق که با خطر تخریب منابع آب و خاک روبرو هستند می‌تواند کارا باشد.

تخمین متغیرها داشته است. مقایسه مدل‌های شبکه هوشمند نیز نشان داد روش ANFIS عملکرد بهتری نسبت به دو مدل دیگر دارد. همچنین مقایسه روش‌های زمین‌آمار و ANFIS نشان داد که شبکه عصبی فازی- تطبیقی با کارایی بالایی توانسته است متغیرهای کیفیت آب‌زیرزمینی را در محدوده مطالعاتی کم‌یجان شبیه‌سازی نماید. با توجه به نتایج حاصل از نقشه‌های پهنه‌بندی مشخص گردید که در متغیر EC بخش شمالی دشت از وضعیت مناسبی برخوردار است؛ در حالی که در بخش مرکزی متمایل به غرب دشت، میزان EC بالاتر از ۲۰۰۰ میکروزیمنس بر سانتیمتر می‌باشد. همچنین در متغیر TDS نیز در بخش شمالی دشت میزان TDS کم در حالی که در بخش جنوب و جنوب‌غربی دشت میزان TDS بالای ۱۰۰۰ میلی گرم بر لیتر است. بررسی تغییرات میزان pH نیز نشان داد که میزان تغییرات این متغیر کم است و بیش‌ترین میزان pH در بخش شمالی و کم‌ترین میزان آن در بخش جنوبی می‌باشد. به‌دلیل توزیع نامناسب و نامتعادل اراضی شهری در این محدوده، دلیل افت کیفیت آب در مناطق مرکزی و جنوبی، نیز می‌تواند برداشت‌های بیش از حد سفره آب زیرزمینی و تخریب منابع آب و خاک در نتیجه زمین‌های کشاورزی و مناطق مسکونی متمرکز و پراکنده باشد. همچنین با توجه به مطالعات صحرایی، پوشش و کاربری اراضی

منابع

1. Abareshi, F., M. Meftah Halghi, H. Sanikhani and A.A. Dehghani. 2014. Comparison of three intelligence techniques for predicting water table depth fluctuations (Case study: Zarringol plain). *Journal of Water and Soil Conservation*, 21(1): 163-180 (In Persian).
2. Alidoosti Shahraki, M., V. Azaimi and S.S. Sharifi Bonab. 2013. Comparison of Neural Network and Neural Network Wavelet Methods in Estimation of Effective Rainfall using meteorological data. *Proceedings of the 2nd International Conference on Plant, Water, Soil and Air Modeling*, 10 pp (In Persian).
3. Azimi, S., M.A. Moghaddam and S.H. Monfared. 2019. Prediction of annual drinking water quality reduction based on Groundwater Resource Index using the artificial neural network and fuzzy clustering. *Journal of Contaminant Hydrology*, 220: 6-17.
4. Baalousha, H. 2010. Assessment of a groundwater quality monitoring network using vulnerability mapping and geostatistics: A case study from Heretaunga Plains. New Zealand. *Agricultural Water Management*, 97(2): 240-246.
5. Bayat, M. 2014. Preparation of Soil Salinity Map in Range in the Khondab using Remote Sensing, Case Study: Chezan Plain, M.Sc. thesis. Islamic Azad University, Arak Branch, 77 pp (In Persian).
6. Bose, N.K. and P. Liang. 1996. *Neural network fundamentals with graphs, algorithms, and applications*, McGraw-Hill Series in Electrical and Computer Engineering, 478 pp, McGraw-Hill College, New York.
7. Bui, D.T., K. Khosravi, M. Karimi, G. Busico, Z.S. Khozani, H. Nguyen, M. Mastrocicco, D. Tedesco, E. Cuoco and N. Kazakis. 2020. Enhancing nitrate and strontium concentration prediction in groundwater by using new data mining algorithm. *Science of the Total Environment*, 136836.
8. Ghasemi, S., N. Ganji Khorramdel, M. Mardian. 2015. An Analysis in exceed probability of threshold for EC and pH waterground resource using geostatistical methods in the Arak- Farahan plain. *Applied Research of Water Sciences*, 1(1): 71-82 (In Persian).
9. Ghorbani, M.A., R.C. Deo, M.H. Kashani, M. Shahabi and S. Ghorbani. 2019. Artificial intelligence-based fast and efficient hybrid approach for spatial modelling of soil electrical conductivity. *Soil and Tillage Research*, 186: 152-164.
10. Haji hashemi jazi, M.R., M. Atashgahi and A.H. Hamidian. 2011. Spatial estimation of groundwater quality factors using geostatistical methods (case study: Golpayegan plain). *Journal of Natural Environmental, Iranian Journal of Natural Resources*, 4(63): 347-357 (In Persian).
11. Haykin, S.S. 1999. *Neural Networks: A Comprehensive Foundation*, Prentice Hall International.
12. Jang, C.S., S.K. Chen and Y.M. Kuo. 2011. Establishing an irrigation management plan of sustainable groundwater based on spatial variability of water quality and quantity. *Journal of Hydrology*, 414-415: 201-210.

13. Iranian Ministry of Energy. 2018. Report on the groundwater production and balancing plan in Iran, Regional Water Company of Markazi, (In Persian).
14. Jang, J.S.R. 1993. ANFIS: adaptive-network-based fuzzy inference system. IEEE Transactions on Systems, Man and Cybernetics, 23: 665-685.
15. Khaledian, M.R., S.A. Moussavi, H. Asadi, M. Norouzi and M. Aligoli. 2015. Mapping of Soil Saturated Hydraulic Conductivity in Navroud-Assalem Watershed in Guilan Province. Journal of Water and Soil, 29(4): 787-796 (In Persian).
16. Khashei-Siuki, A., B. Ghahraman and M. Kouchakzadeh. 2013. Comparison of ANN, ANFIS and Regression Models to Estimate Groundwater level of Neyshaboor Aquifer. Iranian Journal of Irrigation and Drainage, 1(7): 10-22 (In Persian).
17. Kisi, O. 2007. Streamflow forecasting using different artificial neural network algorithms. J. Hydrologic Engineering, 12(5): 532-539.
18. Kisi, O., H. Sanikhani, M. Zounemat-Kermani and F. Niazi. 2015. Long-term monthly evapotranspiration modeling by several data-driven methods without climatic data. Computers and Electronics in Agriculture, 115: 66-77.
19. Koohi Cheleh Karan, N., R. Asadi and P. Lajmire. 2009. Estimation of geostatistical methods for estimation of groundwater salinity parameter (Case study: Darab Plain). National Conference on Water Critical Management. Islamic Azad University, Marvdasht Branch, 9 pp (In Persian).
20. Lohani, A.K. and G. Krishan. 2015. Groundwater Level Simulation Using Artificial Neural Network in Southeast, Punjab, India. Journal of Geology & Geophysics, 4: 206-211.
21. Maroufpoor, S., M. Jalali, S. Nikmehr, N. Shiri, J. Shiri and E. Maroufpoor. 2020. Modeling groundwater quality by using hybrid intelligent and geostatistical methods. Environmental Science and Pollution Research, <https://doi.org/10.1007/s11356-020-09188-z>.
22. Matkan, A., B. Arabi, H. Lashkari and B. Mirbagheri. 2012. Estimation of Precipitation Changes Using Integrated Artificial Neural Networks Technique and Geostatistics in Northwest of Iran, Iranian Remote Sensing and GIS, 4(4): 37-54.
23. Moradi, M., H. Hassan Vagharfard, A. Asadollah Khouzani and V. Mahmudinezhad. 2011. Evaluation of different interpolation methods in zoning of groundwater salinity using Cross-Validation (Case study: Shahrekord plain). Journal of Remote Sensing and GIS, 3(1): 35-44 (In Persian).
24. Nadiri, A., A. Asghari Moghaddam, H. Abghari and E. Fijani. 2013. Development of Artificial Intelligence Committee Machine for Transmissivity Estimation, Case study: Tasuj Plain. Iran-Water Resources Research, 3(1): 1-14 (In Persian).
25. Najafi, H., K.A. Woodbury. 2015. Online heat flux estimation using artificial neural network as a digital filter approach, Int. J. Heat Mass Transfer, 91: 808-817.
26. Nikbakht, S. and M. Delbari. 2014. Estimation of groundwater levels using geostatistical methods. Journal of Water and Sustainable Development, 1(1): 49-56 (In Persian).
27. Ostovari, Y., H. Beigi Harchegani and A.R. Davoodian. 2011. Assessment Spatial Variability and Mapping of Some Water Quality Parameters for Use in Drip Irrigation Design in Lordegan Plain, Iran. Iranian Journal of irrigation and drainage, 2(5): 242-253 (In Persian).
28. Saadipoor, Ch., M. Roodpeyma, A. Karami, N. Davatgar and S.M. Salahedin. 2017. Evaluation of spatial variation of soil saturated hydraulic conductivity using spatial statistic (Case study: Laghar plain). Journal of Water and Soil Conservation, 23(6): 375-382 (In Persian).
29. Safavi, M., O. Mohammadrezapour, E. Bahrami, M. Mohamadi sedigh and M. Salarijazi. 2018. Geostatistical assessment of spatial and temporal variations of groundwater quality parameters in Qorveh and Dehgolan South plain. Irrigation and Water Engineering, 33: 167-183 (In Persian).
30. Shabani, M. 2011. Evaluation of geostatistical methods in the preparation of groundwater quality maps and their zoning (Case study: Neyriz plain, Fars province). Journal of Natural Geography, 4(13): 83-96 (In Persian).
31. Sheikh Goodarzi, M., S.H. Mousavi and N. Khorasani. 2012. Imulating Spatial Changes in Groundwater Qualitative Factors Using Geostatistical Methods (Case Study: Tehran - Karaj Plain). Journal of Natural Environment, Iranian Journal of Natural Resources, 65(1): 83-93 (In Persian).
32. Taormina, R., K.W. Chau and R. Sethi. 2012. Artificial Neural Network Simulation of Hourly Groundwater Levels in a Coastal Aquifer System of the Venice Lagoon, Engineering Applications of Artificial Intelligence, 8(25): 1670- 1676.
33. Tapoglou, E., G.P. Karatzas, I.C. Trichakis and E.A. Varouchakis. 2014. Spatial temporal hybrid neural network-Kriging model for groundwater level simulation. Journal of Hydrology, 519 (Part D): 3193-3203.
34. Wagh, V.M., D.B. Panaskar, A.A. Muley, S.V. Mukate, Y.P. Lolage and M.L. Aamalawar. 2016. Prediction of groundwater suitability for irrigation using artificial neural network model: a case study of Nanded tehsil, Maharashtra, India. Modeling Earth Systems and Environment, 2: 196-207.

Comparison and Assessment of Intelligent and Geostatistical Models for Analysis of Spatial Variations of Groundwater Quality (Komijan Plain)

Mahnoosh Moghaddasi¹, Mehdi Mardian² and Mohsen Parsa³

1- Associate Professor of Water Engineering, Faculty of Agriculture Arak University
(Corresponding Author: m-moghaddasi@araku.ac.ir)

2- Ph.D. of Watershed Management and Engineering, Sari University of Agricultural Sciences & Natural Resources

3- MSc. of Water Engineering, Arak University

Received: 27 October 2019

Accepted: 2 August 2020

Extended Abstract

Introduction and Objective: Nowadays, with development of urban, industrial and agricultural, apply of groundwater is more important. So sustainability and development the exploitation of groundwater for types of different customers and goals, it is necessary that quantitative and qualitative characteristics it be investigated and evaluated.

Material and Methods: Fuzzy Adaptive Neural Network (FANN) and Geostatistical method on based Geographic Information System are used for Komijan plain, Markazi province, Iran. The first, data 36 wells was collected from Rural Water and Sewage Company. Then using semi variogram types such as: gussian, linear, spherical and also Kriging and Co-Kriging methods, geostatistical model was evaluated using indicators: R^2 and RMSE. Then, for Fuzzy Adaptive Neural Network model Membership functions such as: triangular, generalized bells and gaussian was investigated and the best model was determined using indicators: R^2 and RMSE.

Results: According to results R^2 and RMSE in geostatistical, spherical, linear and exponential modle was selected as best for EC, TDS and pH variables, repectively. Also on based semi variogram, Kriging method has a better performance than the cokriging method for all studied variables with high determination coefficient 0.73, 0.66 and 0.85 respectively for EC, TDS and pH and lower in RMSE. The results showed in Fuzzy Adaptive Neural Network, EC variable, the fuzzy generalized bell function with a correlation coefficient of 0.98 and mean square error of 144.59 in the test stage, is good. For TDS variable, gaussian function with a correlation coefficient of 0.98 and mean square error of 0.33 119 at the test stage is best. also for pH variable, the generalized bell function with a correlation coefficient of 0.99 and mean square error of 103.10 at the test stage has a better performance than other fuzzy functions in the modeling. By comparing the results of Geostatistical and Fuzzy Adaptive Neural Network, it can be seen that the FANN model has a higher efficiency than Geostatistical model.

Conclusion: Regarding the results of zoning maps, it is shown that in the northern part of the plain, EC has low, while in the central and west, EC is above 2000 μ Siemens/cm. Also for TDS variable, t is low in the northern part of the plain, while in the south and southwest, is above 1000 mg /lit. Alos changes in pH value showed that variation of this variable is low and the highest level of pH is in the northern part and the lowest in the southern part.

Keywords: Artificial Neural Network, ANFIS, Co- Kriging, Electrical Conductivity, Kriging