

ارزیابی قابلیت هوش مصنوعی در پیش‌بینی میزان هدایت الکتریکی و نیترات در منابع آب زیرزمینی (مطالعه موردی روش‌های عصبی مصنوعی ANN و ANFIS)

نویسنده نجف‌پور

(نویسنده مسؤل)، دکتری علوم و مهندسی آب، کارشناس دفتر محیط زیست و کیفیت منابع آب شرکت آب منطقه‌ای اصفهان، ایران.

Navide.najafpour@gmail.com

نیاز وحدت‌پور

کارشناسی ارشد شیمی، رئیس گروه کیفیت منابع آب شرکت آب منطقه‌ای اصفهان، ایران. n.vahdatpour@yahoo.com

الهام آقابابایی

کارشناسی ارشد مهندسی محیط زیست، کارشناس دفتر محیط زیست و کیفیت منابع آب شرکت آب منطقه‌ای اصفهان، ایران.

elham_aghababaie@yahoo.com

چکیده: منابع آب زیرزمینی در کشور ایران و بسیاری از کشورهای دیگر که آب و هوایی مشابه دارند، مهم‌ترین منابع آب مورد استفاده در کشاورزی و شرب به شمار می‌رود. در دهه‌های اخیر سیستم‌های هوش مصنوعی (AI)، فضایی جدید در ارزیابی مسائل مهندسی آب و محیط زیست ایجاد کرده است. در این مطالعه روش کریجینگ معمول به‌عنوان یک تخمین گر آماری خطی و دو روش هوشمند شبکه عصبی مصنوعی ANN و سیستم استنتاج تطبیقی عصبی فازی ANFIS، در پیش‌بینی مقدار هدایت الکتریکی و نیترات در آب‌های زیرزمینی ارزیابی شدند. به‌منظور انجام مطالعات غلظت نیترات در ۴۰ چاه در دشت لنجان اصفهان به روش اسپکتروفتومتر و همچنین هدایت الکتریکی مورد اندازه‌گیری قرار گرفت. داده‌های ورودی مدل عصبی مصنوعی شامل طول و عرض جغرافیایی و غلظت نیترات و مقدار هدایت الکتریکی به‌عنوان خروجی مدل تعیین شدند. در راستای بررسی عملکرد و کارایی مدل‌های هوش مصنوعی در پیش‌بینی اطلاعات کیفی، اطلاعات کیفی ۵۰ درصد چاه‌ها به‌منظور واسنجی و ۵۰ درصد چاه‌ها به‌منظور صحت سنجی مدل‌ها استفاده شدند. در نهایت، خروجی مدل‌ها با مقدار اندازه‌گیری شده در چاه‌های مشاهده‌ای بر اساس معیارهای ارزیابی متقابل خطا مقایسه شد. نتایج نشان داد مدل ANFIS نسبت به دو مدل درونی‌یابی دیگر عملکرد بهتری در پیش‌بینی مقدار هدایت الکتریکی و نیترات به ترتیب با ریشه میانگین مربعات خطا (RMSE) و $5/362$ (mg/l)، با میانگین اریب خطا (MBE)، $2/365$ و با ضریب همبستگی (R) و $0/767$ داشته است. همچنین مدل ANN به مراتب نتایج بهتری نسبت به روش کریجینگ معمول داشت. بر این اساس مدل ANFIS برای پیش‌بینی مکانی هدایت الکتریکی و نیترات در محدوده مطالعاتی پیشنهاد می‌شود.

واژگان کلیدی: آب زیرزمینی، هوش مصنوعی، توزیع مکانی، نیترات، هدایت الکتریکی.

۱. مقدمه

زیست این منابع آلوده شود، به علت اینکه حرکت آب‌های زیرزمینی بسیار کند می‌باشد، بعد از شروع آلودگی، باید سال‌ها بگذرد تا آب تحت تأثیر قرار گرفته و آلودگی در چاهی ظاهر شود. از بین بردن آلودگی یک آبخوان، زمان بر و مشکل بوده و هرگز نمی‌توان آن را به‌طور کامل انجام داد. بر این اساس سال‌های زیادی طول می‌کشد تا یک لایه آبدار آلوده شده، پس از حذف منبع آلودگی به حالت نخستین برگردد، و اگر اقدام جدی در این خصوص به عمل نیاید کیفیت آب‌های زیرزمینی

منابع آب زیرزمینی بزرگترین ذخیره قابل دسترسی آب شیرین در کره زمین محسوب می‌شوند و با توجه به اهمیت و کمبود این منبع ارزشمند مطالعه پیرامون این موضوع درخور توجه است. استفاده بیش از حد از منابع طبیعی و تولید فراوان محصولات زاید در جامعه مدرن، غالباً آب‌های زیرزمینی را مورد تهدید قرار داده و سبب آلودگی‌های زیادی می‌گردد. اگر محیط

Corresponding author: Navide.najafpour@gmail.com

<https://doi.org/10.48313/jqem.2023.192560>

تاریخ دریافت: ۱۴۰۲/۱۱/۲۳ تاریخ پذیرش: ۱۴۰۲/۱۲/۱۲

دوره ۱۳/ شماره ۲

صفحات ۲۰۷-۲۳۰

آب زیرزمینی برآورد شد. غلظت مجاز هر ۱۱ پارامتر بر اساس استاندارد جهانی WHO و استاندارد آب شرب کشور بنگلادش بررسی گردید. نتایج نشان داد همه پارامترها به غیر از آهن و کدورت در محدوده مجاز هستند. در مرجع [1] پارامترهای کیفی آب زیر زمینی را در آبخوان دشت شهر بابک با استفاده از تکنیک-های زمین آمار و GIS بررسی نمودند. در این مطالعه ابتدا داده های کیفی ۵۶ حلقه چاه با توجه به پراکنش آنها در سال آبی ۱۳۹۰-۹۱ انتخاب و پارامترهای کیفی آنها اندازه‌گیری شد. سپس کنترل و بازسازی داده‌ها صورت گرفت و تغییرات مکانی پارامترهای کیفی و تغییرپذیری آنها با روش‌های مختلف درون‌یابی همچون کریجینگ، کوکریجینگ و عکس مجذور فاصله با توان‌های یک تا سه مورد بررسی قرار گرفت. نتایج نشان داد روش‌های زمین آماری برتری قابل ملاحظه‌ای نسبت به روش‌های معین داشته و روش کریجینگ بهترین روش است. نتایج بررسی تغییرات مکانی و زمانی اکثر پارامترها همبستگی آنها را با هم و روند نزولی بودن آنها را در طول دوره مورد بررسی نشان داد.

در پردازش اطلاعات برای مسائلی که برای آنها راه حل مشخصی موجود نیست، سیستم‌های هوشمند به طور فزاینده‌ای مورد توجه واقع شده است که شبکه‌های عصبی مصنوعی و عصبی فازی از این مجموعه می‌باشند. روش‌های عصبی مصنوعی توانایی زیادی در حل مسائل غیر خطی دارند. در سال‌های اخیر، این شبکه‌ها به طور گسترده در تحقیقات و تدوین مقالات مختلف در علم هیدرولوژی مورد ارزیابی قرار گرفته است. شبکه‌های عصبی و مصنوعی (ANN) برای اولین بار توسط مرجع [6] در مطالعات منابع آب به کار رفت. بر طبق مطالعات قبلی روش ANNs برای ارزیابی تغییرات تراز سطح آب زیرزمینی کاربردی است [7]. مرجع [8] نشان داد شبکه‌های عصبی و مصنوعی در مدل کردن آب‌های زیرزمینی در شهر کاکي هند، از عملکرد خوبی برخوردار است. مرجع [9] از روش کریجینگ معمول و شبکه‌های عصبی و مصنوعی برای تهیه نقشه‌های پهنه‌بندی آرسنیک استفاده نمودند. نتایج آنها نشان داد روش‌های عصبی و مصنوعی از دقت بیشتری نسبت به کریجینگ معمول برخوردار است. مرجع [10] از روش‌های عصبی مصنوعی برای پیش‌بینی غلظت نیترات در آب‌های زیرزمینی در کشور ترکیه استفاده نمودند. ایشان نشان دادند روش‌های ANN نتایج رضایت بخشی در مدل کردن نیترات آب زیرزمینی دارند.

یکی دیگر از سیستم‌های شبیه‌سازی هوش مصنوعی، سیستم استنتاج تطبیقی عصبی-فازی یا به طور اختصار ANFIS می‌باشد. سیستم فازی یک سیستم مبتنی بر قواعد

روز به روز بدتر خواهد شد. آبیاری اراضی کشاورزی با آب‌های بی کیفیت سبب تغییرات خواص فیزیکی و شیمیایی خاک شده که به دنبال آن بازدهی محصولات کاهش خواهد یافت [1]. اندازه‌گیری کیفیت آب در تمامی سطح آبخوان امکان‌پذیر نیست و تعیین کیفیت آب در تمامی سفره آب زیرزمینی پروسه‌ای زمان بر و پرهزینه است. بنابراین تعیین کیفیت آبخوان در مکان‌هایی که نمونه‌برداری انجام نشده، حائز اهمیت است. در این راستا روش‌های زمین آمار با پیش‌بینی الگوی تغییرات و کمیت در نقاطی که نمونه‌برداری انجام نشده نقش به‌سزایی در مدیریت پایدار منابع آب زیرزمینی در سال‌های اخیر داشته است. این روش‌ها در تعیین تغییرات مکانی خواص فیزیکی و شیمیایی خاک و آب زیرزمینی بسیار مفید و پر استفاده‌اند [2]. کریجینگ به‌عنوان یک روش زمین آمار یک مدل کاملاً خطی تصادفی است که بر اساس تئوری احتمالات توسعه داده شده است. روش درون‌یابی کریجینگ دارای مدل‌های مختلف شامل کریجینگ ساده، کریجینگ معمول، کریجینگ گسسته و کریجینگ جهانی است. تفاوت روش کریجینگ با دیگر روش‌های درون‌یابی مانند روش وزن دهی عکس فاصله (IDW) در این است که کریجینگ از واریانس مقدار تخمینی استفاده می‌کند. روش کریجینگ به طور گسترده‌ای در علوم مختلف مانند زمین شناسی، هیدرولوژی، پایش‌های زیست محیطی، علوم اتمسفر و خاکشناسی برای تعیین توزیع مکانی داده‌ها به کار می‌رود.

در مرجع [3] با روش زمین آمار کریجینگ معمول و کوکریجینگ به بررسی کیفیت آب زیر زمینی در دو استان کشور چین پرداختند و نشان دادند که کیفیت منابع آب زیرزمینی تحت تأثیر فعالیت‌های بشر در طبیعت و وضعیت هیدروژئولوژیکی منطقه است. در مرجع [4] میزان شوری ۹۷ حلقه چاه را در آبخوانی در کشور ترکیه در دوره آماری ۲۰۰۴ الی ۲۰۱۰ مورد مطالعه قرار داد. در این پژوهش واریوگرام‌های مناسب برازش داده شده به داده‌ها شامل مدل‌های نمایی و کروی در روش کریجینگ معمولی و کریجینگ شاخص بودند. میزان روند شوری در ۳۱ درصد از دشت دارای شوری پنج دسی‌زیمنس بر سانتی‌متر در سال ۲۰۰۴ بوده که در مقایسه با سال ۲۰۱۰ این مقدار به اندازه ۹ درصد کاهش پیدا کرده است. در مرجع [5] توزیع مکانی ۱۱ پارامتر کیفی آب زیر زمینی در منطقه شهری سیلهدت کشور بنگلادش را بررسی نمودند. در تحقیق آنها از داده‌های ۱۲ ساله ۵۱ حلقه چاه استفاده شد و روش درون‌یابی کریجینگ معمول به صورت کروی، نمایی، نرمال و دایره‌ای انتخاب و تست واریوگرام برای هر یک از پارامترها انجام گردید. و در نهایت توزیع مکانی و زمانی کیفیت

نشریه مهندسی و مدیریت کیفیت

روش‌های هوشمند از دقت بالاتری در پیش‌بینی هدایت الکتریکی در سطح آبخوان برخوردار اند.

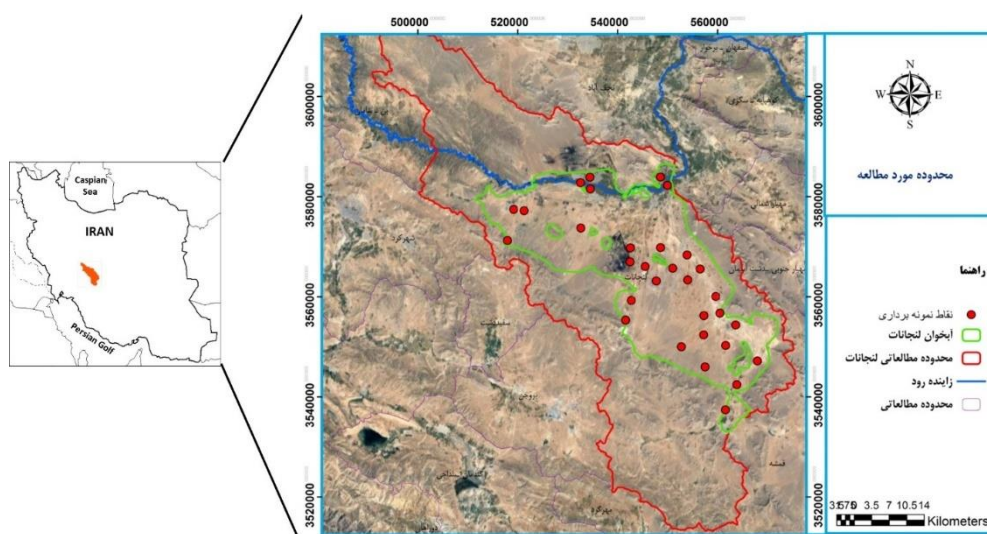
۲. روش تحقیق

- معرفی منطقه مورد مطالعه

دشت لنجانان بخشی از حوضه آبریز رودخانه زاینده رود بوده که در جنوب غربی اصفهان با موقعیت متوسط جغرافیایی ۵۱ درجه و ۳۹ دقیقه طول جغرافیایی و ۳۱ درجه و ۵۶ دقیقه عرض جغرافیایی واقع شده است (شکل ۱). از نظر زمین‌شناسی منطقه بیش‌تر از رسوبات کواترنری پوشیده شده است. آبخوان مربوطه از نوع آزاد و آبرفتی بوده و جنس آن بر اساس لوگ‌های اکتشافی و مشاهده‌ای، شن و ماسه، رس و قلوه سنگ به همراه طبقات کنگلومرایی است. به دلیل برگشت قابل توجه پساب صنعتی و کشاورزی از نظر کیفیت و آلودگی منابع آب زیرزمینی همواره مورد توجه است. ژئومورفولوژی منطقه تا حدود زیادی تابع عوامل زمین‌شناسی، شیب توپوگرافی، فرسایش و وضعیت ساختاری و تکتونیکی منطقه می‌باشد. به طور کلی شیب از سمت جنوب غربی به شمال و شمال شرقی می‌باشد. با توجه به اطلاعات چاهک‌های مشاهده‌ای و ۲۳ لوگ حفاری در منطقه جنس لایه خاک اکثراً لوم ماسه‌ای، لوم شنی و شنی لومی بوده و لایه ناحیه غیر اشباع و محیط آبخوان اکثراً از شن و ماسه، کمی رس و قلوه سنگ تشکیل شده است. در راستای انجام مطالعات کیفیت آب منطقه، نمونه آب ۴۰ حلقه چاه و رشته قنات توسط پژوهشگران این مطالعه در سال ۱۳۹۸ برداشت گردید و پارامترهای کیفیت آب در آنها اندازه‌گیری شد. از این داده‌ها در راستای انجام این مطالعه استفاده گردید.

منطقی "شرط-نتیجه" است که با استفاده از مفهوم متغیرهای زبانی و روند تصمیم‌گیری فازی، فضای متغیرهای ورودی را بر فضای متغیرهای خروجی تصویر می‌کند. ترکیب سیستم‌های فازی که مبتنی بر قواعد منطقی‌اند و روش شبکه‌های عصبی مصنوعی که توان استخراج دانش از اطلاعات عددی را دارند، منجر به ارائه سیستم استنتاج تطبیقی عصبی فازی شده است [11].

محققان بسیاری با ترکیب روش‌های عصبی مصنوعی و فازی به ارزیابی الگوریتم‌های هابیرد در حل مسائل غیر خطی پرداخته اند. به‌عنوان نمونه مرجع [12] تراز آب را با ترکیب روش‌های فازی و عصبی مصنوعی پیش‌بینی نمودند. مرجع [13] روش‌های ANFIS و ANN را بر اساس الگوریتم پردازشی LM برای تعیین افت و خیز روزانه سطح آب زیرزمینی ارزیابی کردند. ایشان اختلاف معنی داری در نتایج دو مدل پیدا نکردند و نشان دادند که الگوریتم‌های محاسباتی از دقت کافی در پیش‌بینی تراز روزانه آب زیرزمینی برخوردارند. مرجع [14] روش ANFIS را در مدل کردن هدایت الکتریکی از ترکیبات آب زیرزمینی به کار بردند و نشان دادند با وجود داده‌های کم روش ANFIS از ظرفیت بهتری در مدل کردن EC نسبت به روش‌های رگرسیون معمول برخوردار است. مرجع [15] روش ANFIS و کریجینگ معمول را در ارزیابی تراز سطح آب زیرزمینی مقایسه نمودند و روش ANFIS دارای دقت بالاتری بود. مرجع [16] از روش‌های کریجینگ، ANN و ANFIS برای درون‌یابی عناصر سنگین در دریای خزر استفاده نمودند و نشان دادند که روش ANFIS در شبیه‌سازی از کمترین خطا برخوردار است. مرجع [17] از روش‌های کریجینگ معمول، ANN و ANFIS در مدل کردن هدایت الکتریکی در دشت تبریز استفاده نمودند و نشان دادند



شکل ۱. موقعیت محدوده و آبخوان مورد مطالعه

به فاصله معلوم h از یکدیگر قرار گرفته‌اند محاسبه (نیم تغییر نما) و در مقابل h طبق رابطه ۲ ترسیم می‌گردد.

$$\gamma(h) = \frac{1}{2Nh} \sum_{I=1}^{N(h)} [Z(x_i + h)]^2 \quad (2)$$

در رابطه ۲، N تعداد داده‌های جفت شده به فاصله h ، $Z(x_i)$ مقدار مشاهداتی در نقطه i ، $Z(x_i + h)$ مقدار مشاهداتی در نقطه‌ای به فاصله h از x_i ، x_i موقعیت جغرافیایی نقطه مشاهداتی i (محل نمونه برداری) و $\gamma(h)$ مقدار تخمینی واریانس برای جفت داده‌ها به فاصله h است [19]. هر نمودار واریوگرام دارای مشخصه‌هایی است که بدین صورت تعریف می‌شوند:

دامنه تأثیر (R): فاصله‌ای که در آن واریوگرام به حد ثابتی می‌رسد و به خط افقی نزدیک می‌شود. این دامنه محدوده‌ای را مشخص می‌کند که می‌توان از داده‌های موجود در آن، برای تخمین مقادیر مجهول استفاده کرد به عبارتی هرچه مقدار R بزرگتر باشد میزان پیوستگی مکانی بیشتر است.

آستانه تأثیر ($C+C_0$): به مقدار ثابتی که واریوگرام در محدوده دامنه تأثیر به آن می‌رسد، آستانه تأثیر گفته می‌شود.

اثر قطعه‌ای (C_0): به مقدار واریوگرام به ازای $h=0$ (در مبدأ مختصات) اثر قطعه‌ای گویند.

- مدل‌های مورد استفاده

این مطالعه بر سه روش درون‌یابی کریجینگ معمول با مدل‌های مختلف، ANFIS و ANN متمرکز شده است که در آنها عرض و طول جغرافیایی به‌عنوان ورودی و مقدار نیترات به‌عنوان خروجی مدل‌ها در نظر گرفته شد. در هر سه روش ۵۰ درصد داده‌ها برای اجرای مدل و ۵۰ درصد از داده‌ها برای صحت‌سنجی نتایج استفاده گردید.

به‌منظور افزایش کارایی مدل و همگرایی بهتر نتایج در مدل‌های عصبی مصنوعی و فازی، همه داده‌ها به شکل نرمال بین دو عدد ۰/۱ و ۰/۹ استاندارد شدند که بدین منظور از رابطه پیشنهادی ۱ استفاده شد [18].

$$x_i = 0.8 \left(\frac{x - x_{min}}{x_{max} - x_{min}} \right) + 0.1 \quad (1)$$

در رابطه ۱، x_i مقدار استاندارد شده، x مقدار واقعی و x_{min} و x_{max} به ترتیب مقادیر حداقل و حداکثر داده‌ها می‌باشد. داده‌های خروجی بعد از عمل شبیه‌سازی به مقادیر استاندارد اولیه بازگشتند. در ادامه شرح مختصری از عملکرد هر یک از روش‌ها آورده شده است.

- کریجینگ

روش‌های زمین‌آمار شاخه‌ای از علم آماری است که بر توزیع مکانی داده‌ها تمرکز دارد. تئوری روش‌های زمین‌آمار اولین بار توسط آیزاک و سرواستاوا مطرح شد. هسته روش‌های زمین‌آمار واریوگرام است که شکل وابستگی و تغییرپذیری مکانی داده‌ها را بیان می‌کند [19]. در این کار مجموع مربع تفاضل زوج نقاطی که

نرمال داشته باشند و یا با تبدیلات آماری دارای توزیع نرمال شوند.

به‌منظور تعیین توزیع داده‌های هدایت الکتریکی و نیترات از آزمون اندرسون دارلینگ با سطح اعتماد ۹۵ درصد استفاده شد. برای نرمال بودن توزیع داده‌ها باید ضریب اندرسون دارلینگ کمتر از $2/5$ و سطح اعتماد بدست آمده بیشتر از $0/05$ باشد [22]. نتایج آزمون نشان داد توزیع داده‌ها در پارامتر EC غیر نرمال و در پارامتر نیترات نرمال است. بنابراین از تبدیل آماری Box-Cox در نرم افزار MiniTab برای نرمال سازی توزیع داده‌ها استفاده شد. شکل ۲ بیانگر نتایج آزمون اندرسون دارلینگ و هیستوگرام برای پارامتر هدایت الکتریکی در حالت غیر نرمال و بعد از استفاده از تبدیل Box-Cox و شکل ۳ نتایج توزیع نرمال برای پارامتر نیترات است.

کریجینگ یک مدل درون‌یابی خطی بهینه می‌باشد که دارای حداقل میانگین مربع خطا است. معادله عمومی روش درون‌یابی کریجینگ مطابق رابطه ۳ است.

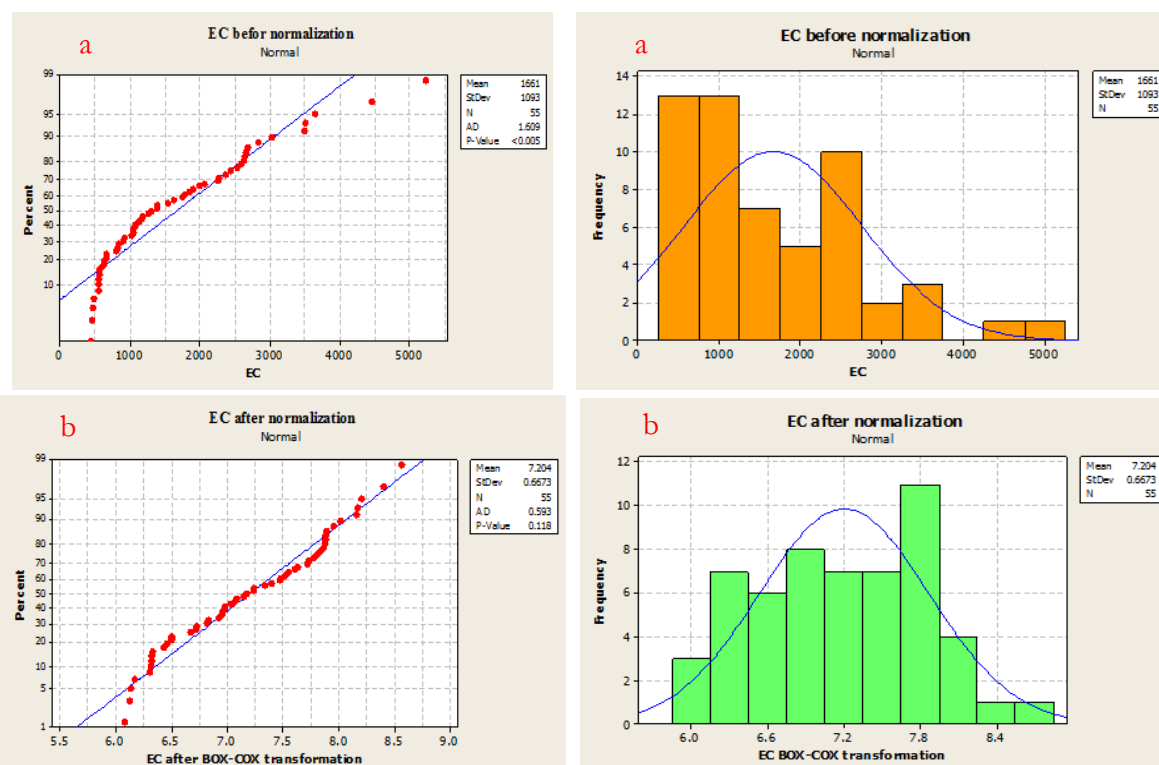
$$\bar{z} = \sum_{i=1}^n \lambda_i Z(x_i) \quad (3)$$

به‌منظور رسیدن به یک تخمین نارایب با روش کریجینگ معمول دستگاه معادلات در رابطه ۴ باید به صورت همزمان حل شوند [20] و [21].

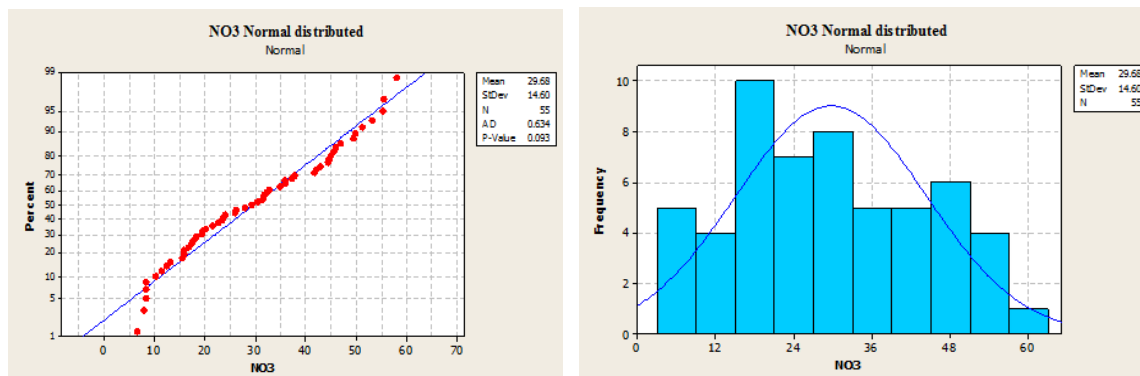
$$\left[\begin{array}{c} \sum_{i=1}^N \lambda_i \gamma(x_i, x_j) - \mu = \gamma(x_i, x) \\ \sum_{i=1}^N \lambda_i = 1 \end{array} \right] \quad (4)$$

در این رابطه $Z(x_i)$ مقدار مشاهداتی پارامتر، λ_i وزن یا اهمیت کمیت وابسته به نمونه i ام و \bar{z} مقدار تخمینی پارامتر، μ ضریب دامنه تاخیر، $\gamma(x_i, x_j)$ مقدار واریوگرام برای برداری با ابتدای x_i و انتهای x_j است.

مدل کریجینگ زمانی که داده‌ها دارای توزیع نرمال باشند دارای بهترین نتایج است بنابراین در استفاده از آن داده‌ها باید توزیع



شکل ۲. هیستوگرام و آزمون اندرسون دارلینگ قبل از نرمال‌سازی داده‌های EC (a) و هیستوگرام و آزمون اندرسون دارلینگ بعد از نرمال‌سازی داده‌های EC با تبدیل Box-Cox (b)



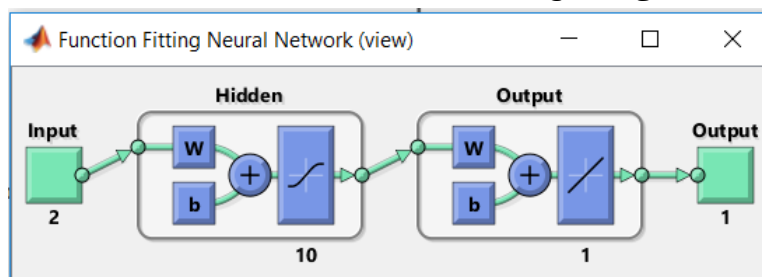
شکل ۳. هیستوگرام و آزمون اندرسون دارلینگ پارامتر نیترات

مورد پیچیدگی و ساختار داده‌های ورودی و خروجی وجود ندارد مناسب است. ANN با الگوریتم انتشار عقب یکی از گسترده‌ترین شبکه‌های عصبی می‌باش [23]. هدف این الگوریتم کاهش خطای کلی است [24].

در این مطالعه یک شبکه عصبی مصنوعی ANN با پرسپترون چند لایه‌های (MLP) شامل ۴ لایه استفاده شد. شبکه با الگوریتم بهینه‌سازی مومنتم و تابع انتقال TanhAxon اجرا شده که بر اساس سعی و خطا بین مدل‌های مختلف انتخاب شود. دو لایه مخفی نیز برای تنظیم وزن نرون‌ها به منظور رسیدن به خروجی‌های بهینه به کار رفت. در این مدل عرض و طول جغرافیایی به‌عنوان ورودی و مقدار غلظت نیترات خروجی مدل تعیین شد (شکل ۴).

شبکه عصبی و مصنوعی ANN و ANFIS

شبکه‌های عصبی مصنوعی با الگوبرداری از سیستم کارکرد مغز انسان، با پردازش داده‌های تجربی و بدون توجه به فیزیک مسئله، قانون نهفته در ورای این اطلاعات را استخراج می‌کنند. در مقایسه با مدل‌های مرسوم، این مدل‌ها به ورودی‌های کمتر و تلاش محاسباتی اندکی نیاز دارند. شبکه‌های عصبی با انتخاب مناسب داده‌های آموزشی به مدل، بیشترین دقت را دارا هستند و پیچیده‌ترین روابط را بین ورودی و خروجی برقرار می‌کنند و ANN قادر به تعمیم و پردازش داده‌های آزمایشگاهی به هم ریخته، ناقص و غیر خطی است. بر خلاف مدل‌های خطی، ANN هیچ محدودیتی روی ویژگی‌های آماری داده‌ها برای پردازش ندارد. روش ANN در مورد داده‌هایی که هیچ ایده‌ای در



شکل ۴. ساختار شبکه عصبی مصنوعی ANN در این مطالعه

سیستم فازی یک سیستم مبتنی بر قواعد منطقی شرط – نتیجه است که با استفاده از مفهوم متغیرهای زبانی و روند تصمیم‌گیری فازی، فضای متغیرهای ورودی را بر فضای متغیرهای خروجی تصویر می‌کند. ترکیب سیستم‌های

ANFIS توسط مرجع [25] معرفی گردید. این روش یک ابزار پیشرفته و اطلاعات محور بوده که برای پردازش سیستم‌های دینامیکی پیچیده و مبهم گسترش داده شد [26].

در رابطه ۵، مقدار ورودی به هر گره و مجموعه پارامترهای تطبیقی نامیده می‌شود.

$$S_1 = \{a_i, b_i, c_i\}$$

لایه دوم، گره‌های قاعده: هر گره در این لایه درجه فعالیت یک قانون را محاسبه می‌کند. به عبارتی سیگنال‌های ورودی را در هم ضرب کرده و به‌عنوان خروجی ارسال می‌کند.

$$w_i = \mu A_i(x) \times \mu B_i(y) \quad (7)$$

$$i = 1, 2$$

لایه سوم: خروجی i امین گره در این لایه، نسبت درجه فعالیت قانون i ام از لایه قبل به مجموع درجه فعالیت کلیه قوانین است.

$$O_i^3 = \bar{w}_i = \frac{w_i}{\sum_{i=1}^n w_i} \quad i = 1, 2 \quad (8)$$

لایه چهارم، گره‌های نتیجه: در این لایه خروجی هر گره بر اساس یک سیستم فازی سوگنو طبق رابطه ۹ محاسبه می‌شود.

$$O_i^4 = \bar{w}_i f_i = \bar{w}_i (p_i x_1 + q_i x_2 + r_i) \quad (9)$$

$$i = 1, 2$$


در رابطه ۹، مجموعه $S_2 = \{p_i, q_i, r_i\}$ پارامترهای متعاقب نامیده می‌شود.

لایه پنجم، گره‌های خروجی: در این لایه هر گره مقدار خروجی نهایی را به صورت زیر محاسبه می‌کند که در آن تعداد گره‌ها برابر با تعداد خروجی‌ها است.

$$O_i^5 = \sum_{i=1}^n \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (10)$$


در مدل ANFIS زمانی عمل شبیه‌سازی به درستی انجام شده است که مجموعه پارامترهای تطبیقی S_1 و مجموعه پارامترهای متعاقب S_2 طوری تخمین زده شوند که مقدار تابع خطای مدل در بخش آموزش و آزمایش به حداقل برسد. به دست آوردن مقدار این پارامترها معمولاً در دو گام صورت می‌گیرد. در گام اول که تا لایه چهارم پیش می‌رود و گام رو به جلو نامیده می‌شود، مجموعه پارامترهای S_1 ثابت فرض شده و مجموعه پارامترهای S_2 با استفاده از الگوریتم حداقل مجذور خطاها (LSE) محاسبه می‌شوند. در گام دوم که گام رو به عقب نامیده می‌شود، مجموعه پارامترهای S_2 ثابت فرض شده و مجموعه پارامترهای S_1 با استفاده از الگوریتم شیب کاهشی به دست می‌آیند. انتخاب تابع عضویت بر اساس آزمایش انواع مختلف توابع عضویت

فازی که مبتنی بر قواعد منطقی بوده، و روش شبکه‌های عصبی مصنوعی که توان استخراج دانش از اطلاعات عددی را دارند، منجر به ارائه سیستم استنتاج تطبیقی عصبی فازی شده است [25]. یک سیستم استنتاج فازی ANFIS و روش ANN به صورت شماتیک در شکل ۵ نشان داده شده است.



شکل ۵. سیستم استنتاج فازی [25]

در این مطالعه عرض و طول جغرافیایی به‌عنوان ورودی و غلظت نیترات خروجی در نظر گرفته شد. ساختار ANFIS از پنج لایه و توابع مربوط به گره‌های هر لایه، تشکیل شده است (شکل ۶). هر ورودی در لایه اول (گره‌های ورودی) دارای دو قانون است (A_1, A_2, B_1 و B_2) که هر کدام دو قانون را در لایه دوم ایجاد می‌کنند (گره‌های قاعده). شرح مختصری از عملکرد پنج لایه در ادامه آورده شده است.



شکل ۶. ساختار ANFIS

لایه اول: در این لایه درجه عضویت گره‌های ورودی به بازه‌های مختلف فازی با استفاده از تابع عضویت مشخص می‌گردد.

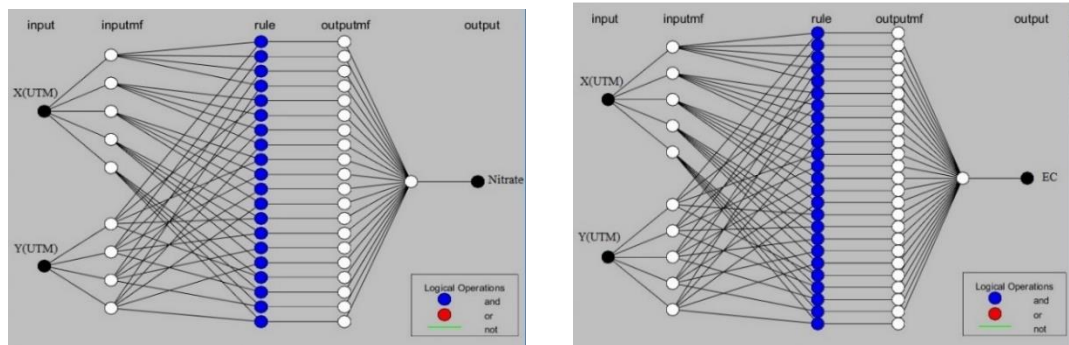
$$Q_i^3 = \mu A_i(x) \quad i = 1, 2 \quad (5)$$

پارامترهای هر گره مشخص‌کننده شکل تابع عضویت در مجموعه فازی آن گره است. توابع عضویت در مجموعه‌های فازی معمولاً توسط توابع زنگوله‌ای شکل به صورت رابطه ۵ بیان می‌شود.

$$\mu A_i(x) = \frac{1}{1 + \left[\frac{(x - c_i)^2}{a_i} \right]^{b_i}} \quad (6)$$

پارامتر هدایت الکتریکی و همین تابع با تعداد عضویت [5] برای پارامتر نیترات استفاده شد. نوع تابع عضویت و تعداد اعضای آن بر اساس سعی و خطا بین توابع مختلف در مدل ANFIS تعیین شد. نتایج نشان داد تابع عضویت گوسی با نوع [4 5] برای هدایت الکتریکی و [5 5] برای نیترات خروجی‌های دقیقی تعیین می‌کند و بنابراین به‌عنوان تابع هدف در این مطالعه استفاده شده است (شکل ۷).

صورت می‌گیرد. به این معنی که توابع عضویت، هر کدام جداگانه مورد بررسی قرار می‌گیرند و مدل ANFIS برای هر کدام از این توابع عضویت به صورت جداگانه آموزش می‌بیند. در پایان میزان خطای مدل‌های حاصل با هم مقایسه می‌شود و تابعی که کمترین میزان خطا را در کمترین زمان آموزش حاصل کند، به‌عنوان تابع عضویت برگزیده خواهد شد [27]. در این مطالعه تابع عضویت گوسی (guss2mf) با تعداد تابع عضویت [4 5] با استفاده از الگوریتم بهینه‌سازی هایبرد برای



شکل ۷. ساختار شبکه استنتاج فازی ANFIS در دو پارامتر کیفیت آب هدایت الکتریکی (شکل راست) و نیترات (شکل چپ) در این مطالعه

ارزیابی مدل‌ها

پارامترهای مختلفی برای ارزیابی متقابل داده‌ها وجود دارد. در این مطالعه از پارامترهای مجذور میانگین مربعات خطا (RMSE)، میانگین انحراف خطا (MBE) و ضریب همبستگی (R) به‌منظور ارزیابی متقابل مقادیر پیش‌بینی شده توسط سه مدل و مقادیر مشاهداتی استفاده شد (روابط ۱۱، ۱۲ و ۱۳).

$$RMSE = \frac{1}{n} \sqrt{\sum_{i=1}^n ((z_p - z_0)^2)} \quad (11)$$

$$MBE = \frac{1}{n} \sum_{i=1}^n (z_p - z_0) \quad (12)$$

$$R = \frac{\sum_{i=1}^n z_p z_0 - \frac{\sum_{i=1}^n z_p \sum_{i=1}^n z_0}{n}}{\sqrt{\left(\sum_{i=1}^n z_p^2 - \frac{(\sum_{i=1}^n z_p)^2}{n}\right) \left(\sum_{i=1}^n z_0^2 - \frac{(\sum_{i=1}^n z_0)^2}{n}\right)}} \quad (13)$$

در روابط فوق، z_p مقدار برآورده شده توسط مدل‌های درونی‌یابی، z_0 مقدار اندازه‌گیری شده و n تعداد داده‌ها است.

۳- یافته‌ها

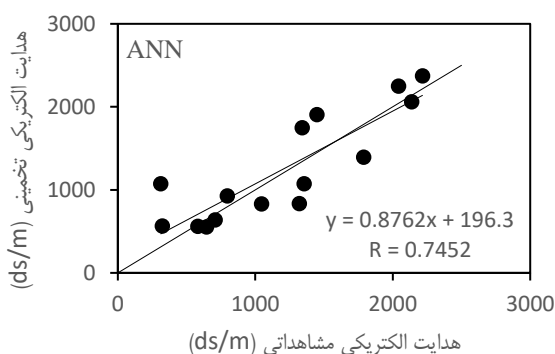
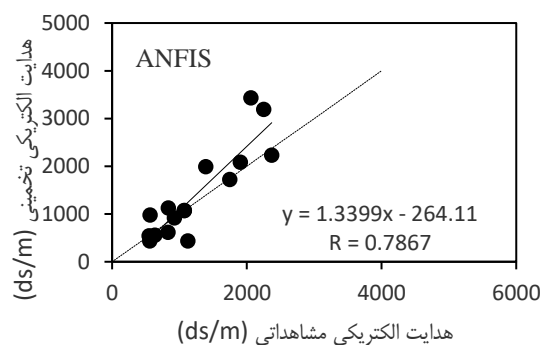
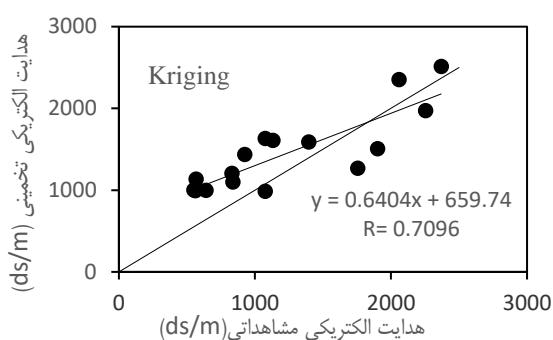
بر طبق نتایج بدست آمده از ترسیم واریوگرام پارامتر نیترات، مناسبترین مدل درونی‌یابی بر روی واریوگرام داده‌ها بر اساس میزان مجموع مربعات باقیمانده (RSS) و بررسی میزان پیوستگی مکانی در هر مدل (از بین مدل‌های خطی، نمایی، گوسی، کروی) انتخاب گردید. بدین صورت که هر چه نسبت اثر قطعه‌ای به آستانه تأثیر $\frac{C_0}{C+C_0}$ از ۰/۲۵ کمتر باشد استحکام و پیوستگی فضایی بیشتر است و اگر این نسبت بین ۰/۲۵ تا ۰/۷۵ باشد همبستگی مکانی متوسط و اگر بزرگتر از ۰/۷۵ باشد میزان همبستگی مکانی ضعیف تلقی می‌شود [2]. بر این اساس مدل درونی‌یابی کریجینگ نمایی در مورد پارامترهای هدایت الکتریکی و نیترات تعیین گردید (جدول ۱).

جدول ۱. بهترین مدل درون یابی در روش کریجینگ معمول بر اساس نتایج واریوگرام

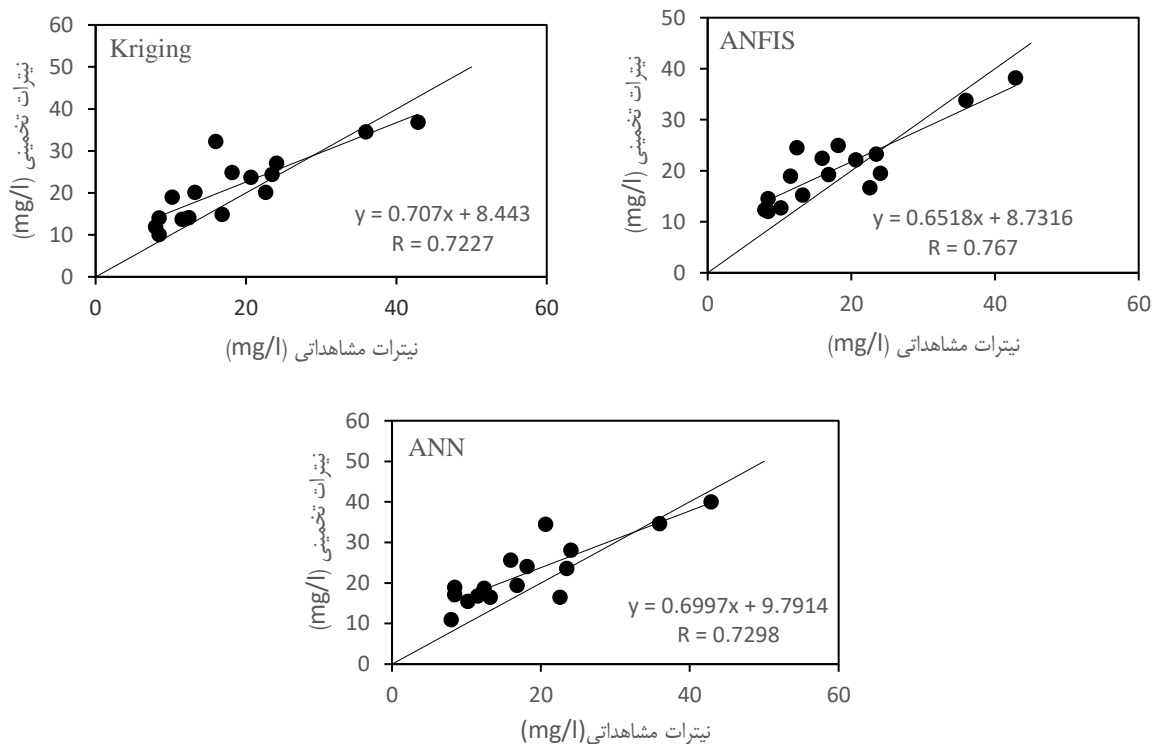
پارامتر	مدل	اثر قطعه‌ای C0	آستانه تاثیر C0+C	ضریب همبستگی مکانی r ²	دامنه تاثیر A0 (متر)	مجموع مربعات باقی مانده RSS	C0/(C+C0)
NO ₃	نمایی	۰/۰۰۰۲	۰/۰۵۴	۰/۸۹۴	۲۷۵۰۰	۰/۰۰۰۴۲۷	۰/۹۴۴
NO ₃	نمایی	۰/۰۰۰۲	۰/۰۵۴	۰/۸۹۴	۲۷۵۰۰	۰/۰۰۰۴۲۷	۰/۹۴۴

نشان داده شده است. نتایج ارزیابی متقابل با پارامترهای مدل کریجینگ، شبکه عصبی مصنوعی ANN و ANFIS برای دو پارامتر هدایت الکتریکی و نیترات در شکل ۸ و ۹ نمودار پراکندگی داده‌های مشاهداتی و تخمینی توسط سه

مدل کریجینگ، شبکه عصبی مصنوعی ANN و ANFIS برای دو پارامتر هدایت الکتریکی و نیترات در شکل ۸ و ۹ نشان داده شده است. نتایج ارزیابی متقابل با پارامترهای مدل کریجینگ، شبکه عصبی مصنوعی ANN و ANFIS برای دو پارامتر هدایت الکتریکی و نیترات در شکل ۸ و ۹



شکل ۸. پراکندگی داده‌های مشاهداتی و تخمینی توسط سه مدل کریجینگ، ANN و ANFIS پارامتر هدایت الکتریکی



شکل ۹. نمودار پراکندگی داده‌های مشاهداتی و تخمینی توسط سه مدل کریجینگ، ANN و ANFIS پارامتر نیترات

میزان خطای بالاتر در پیش‌بینی مقدار هدایت الکتریکی و نیترات آب زیرزمینی است. به علاوه، همان‌طور که از شکل‌های ۷ و ۸ مشخص است تراکم پراکندگی نقاط حول خط ۱:۱ در مدل ANFIS نسبت به دو مدل کریجینگ معمول و ANN بیشتر است. همچنین مدل عصبی مصنوعی ANN تخمین بهتری نسبت به روش کریجینگ معمول داشته است.

بر اساس جدول ۲ و ۳ در مدل عصبی مصنوعی ANFIS نسبت به سایر مدل‌های درون‌یابی به کار رفته دارای حداقل مقدار RMSE و MBE و حداکثر میزان R در هر دو پارامتر هدایت الکتریکی و نیترات است. بر طبق جداول فوق روش کریجینگ معمول نسبت به دو روش هوش مصنوعی ANN و ANFIS با توجه به معیارهای ارزیابی متقابل دارای ضریب همبستگی کم و

جدول ۲. نتایج ارزیابی متقابل پارامتر نیترات با سه مدل کریجینگ معمول، ANFIS و ANN

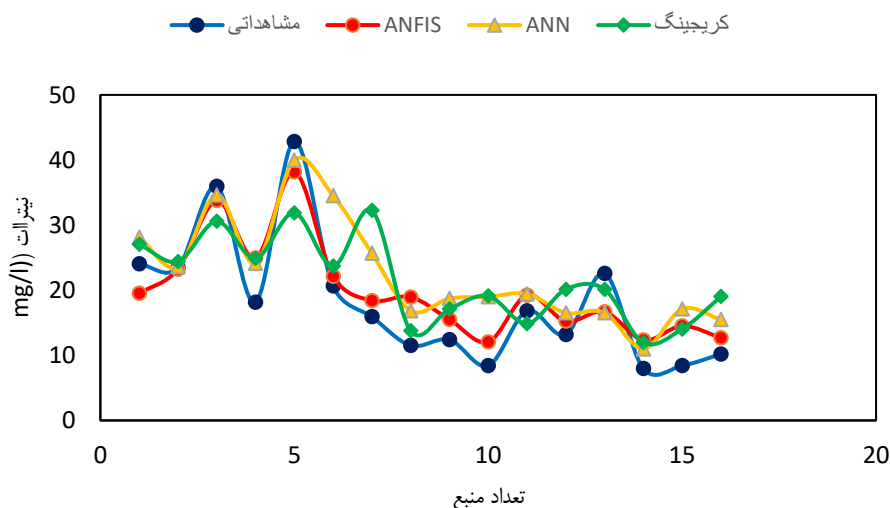
روشن درون‌یابی	R	RMSE	MBE
ANFIS	۰/۷۶۷	۵/۳۶۲	۲/۳۶۵
ANN	۰/۷۲۹۸	۶/۶۰۳	۴/۳۰۱
کریجینگ معمول	۰/۷۲۲۷	۵/۹۳۳	۳/۰۸۵

جدول ۳. نتایج ارزیابی متقابل پارامتر هدایت الکتریکی با سه مدل درونیابی کریجینگ، ANFIS و ANN

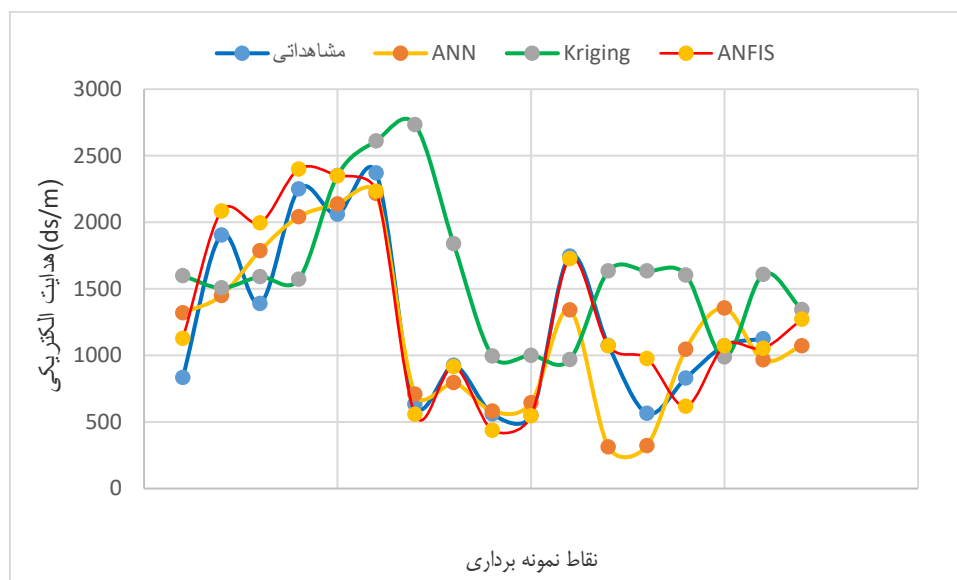
روش درونیابی	R	RMSE	MBE
ANFIS	۰/۷۸۶۷	۲۴۶/۶۳	۷۴/۱۷
ANN	۰/۷۴۵۲	۳۳۰/۰۴	۸۲/۴۳
کریجینگ معمول	۰/۷۰۹۶	۳۸۷/۸۷	۱۹۵/۳۸

پارامترها داشته است. بر طبق جداول ۲ و ۳ و شکل‌های ۷، ۸، ۹ و ۱۰ می‌توان اینگونه اظهار کرد که روش‌های درونیابی غیر خطی قابلیت بهتری در شبیه‌سازی الگوی توزیع مکانی پارامتر هدایت الکتریکی و نیترات نسبت به روش‌های درونیابی خطی داشته است.

در شکل ۱۰ و ۱۱ روند پیش‌بینی سه مدل درونیابی به کار رفته در این مطالعه برای تخمین هدایت الکتریکی و نیترات به شکلی دیگر با یکدیگر و نسبت به مقدار اندازه‌گیری شده مقایسه شدند که همانطور که مشخص است روش استنتاج فازی ANFIS نسبت به دو مدل ANN و کریجینگ عملکرد بهتری در تخمین



شکل ۱۰. روند تغییرات سه مدل کریجینگ، ANN و ANFIS نسبت به داده‌های مشاهداتی در پارامتر نیترات



شکل ۱۱. روند تغییرات سه مدل کریجینگ، ANN و ANFIS نسبت به داده‌های مشاهداتی در پارامتر هدایت الکتریکی

۴- بحث و نتیجه‌گیری

و عناصر سنگین و پارامترهای کیفی آب رودخانه استفاده نمودند تطابق دارد.

در این مطالعه سه روش درون‌یابی شامل تخمین گر خطی کریجینگ معمول و دو روش هوش مصنوعی، ANN و ANFIS برای پیش‌بینی مکانی مقدار هدایت الکتریکی و نیترات در آب‌های زیرزمینی به کار رفت. به‌منظور توسعه مدل‌ها از نقاط با مختصات جغرافیایی مشخص استفاده شد که در آنها میزان هدایت الکتریکی و غلظت نیترات اندازه‌گیری شده بود. سپس خروجی مدل‌ها که شامل تخمین هدایت الکتریکی و نیترات است، با یکدیگر و نسبت به مقادیر مشاهداتی با معیارهای ارزیابی متقابل R، RMSE و MBE مقایسه شد. نتایج نشان داد در هردو پارامتر کیفیت آب زیرزمینی (هدایت الکتریکی و نیترات) روش استنتاج فازی ANFIS از عملکرد بهتری نسبت به سایر روش‌ها برخوردار است. همچنین شبکه عصبی مصنوعی ANN نتایج بهتری در پیش‌بینی مقدار هدایت الکتریکی نسبت به درون‌یابی خطی کریجینگ معمول داشت. با توجه به این مسئله که دو پارامتر هدایت الکتریکی و نیترات نقش مهمی در کیفیت آب زیرزمینی ایفا می‌کنند، بنابراین تخمین دقیق این پارامترها نقش مهمی در تصمیم‌گیری مدیریت کیفی منابع آب زیرزمینی دارد. نتایج این مطالعه با گزارش عملکرد مطلوب شبکه‌های هوش مصنوعی در تحقیقات [28]، [16]، [15]، [13]، [29] و [30] که از این مدل‌ها برای تخمین هدایت الکتریکی، تراز آب زیرزمینی

۵- منابع

- [1]. Jahanshahi, A., Rohimoghaddam, E., & Dehvari, A. (2014). Investigating Groundwater Quality Parameters Using GIS and Geostatistics (Case Study: Shahr-Babak Plain Aquifer). *Water and Soil Science*, 24(2), 183-197.
- [2]. Momeni Damaneh, J., Joulaei, F., Alidadi, H., & Peiravi, R. (2015). Evaluation of Interpolation Methods to Determine Spatial Variations of Groundwater Qualitative Parameters (Case study: Gonabad Plain). *Journal of Research in Environmental Health*, 1(3), 165-176.
- [3]. Li, P. Y., Wu, J., & Qian, H. (2012). Groundwater quality assessment with two multi-criteria decision making methods. *Journal of Geomatics and Geosciences*, 2(3), 868- 877.
- [4]. Arslan, H. (2012). Spatial and temporal mapping of groundwater salinity using ordinary kriging and indicator kriging, the case of Bafra Plain, Turkey. *Water Management Journal*, 113, 57-63.
- [5]. Munna, M. G., Al-Kibriya, N., Nury, H. A., Islam, Sh., & Rahman H. (2015). Spatial

- [16]. Kazemi, S. M., & Hosseini, S. M. (2011). Comparison of spatial interpolation methods for estimating heavy metals in sediments of Caspian Sea. *Expert System Applied journal*, 38, 1632–1649.
- [17]. Jeihouni, M., Delirhasannia, R., Alavipanah, K., Shahabi, M., & Samadianfard, S. (2015). Spatial analysis of groundwater electrical conductivity using ordinary kriging and artificial intelligence methods. *Journal of Original scientific paper*, 32, 191-208.
- [18]. Rahimi khoub, A. (2008). Comparative study of Hargreaves's and artificial neural network's methodologies in estimating reference evapotranspiration in a semiarid environment. *Irrigation science Journal*, 26(3), 253-259.
- [19]. Isaaks, E. H., & Srivastava, R. M. (1989). *An introduction to applied geostatistics*. New York: Oxford University Press.
- [20]. Uyan, M., & Cay, T. (2013). Spatial analyses of groundwater level differences using geostatistical modeling. *Environment Ecology Statistic journal*, 20, 633–646.
- [21]. Ahmadi S H & Sedghamiz A. 2007. Geostatistical analysis of spatial and temporal variations of groundwater level. *Environment Monitoring Assessment journal*. 129: 277–294.
- [22]. Mann, N., Schafer, R., & Singpurwalla, N. (1974). *Methods for Statistical Analysis of Reliability and Life Data*. John Wiley. N. Y.
- [23]. Li, P. Y., Wu, J., & Qian, H. (2012). Groundwater quality assessment with two multi-criteria decision making methods. *Journal of Geomatics and Geosciences*, 2(3), 868- 877.
- [24]. Chen, S. H., Lin, Y. H., Chang, L. C., & Chang, F. J. (2006). The strategy of building a flood forecast model by neuro-fuzzy networks. *Hydrology Progress journal*, 20, 1525–1540.
- [25]. Cheng, C. B., & Lee, E. S. (1999). Applying fuzzy adaptive network to fuzzy regression analysis. *Computing Math Applying journal*, 38, 123–140.
- [26]. Kisi, O. (2005). Suspended sediment estimation using neuro-fuzzy and neural network approaches. *Hydrology Science Journal*, 50, 683–696.
- [27]. Jang, J. S. R. (1993). ANFIS Adaptive network based fuzzy inference system. *IEEE Distribution Analysis and Mapping of Groundwater Quality Parameters for the Sylhet City Corporation (SCC) Area Using GIS. Journal of hydrology Science PC*, 3(1), 1-10.
- [6]. French, M. N., Krajewshi, W. F., & Cuendall, P. P. (1992). Rainfall forecasting in space and time using artificial neural network. *Journal of Hydrology*, 13(7), 1-31.
- [7]. Lallahem, S., Mania, J., Hani, A., & Najjar, Y. (2005). On the use of neural networks to evaluate groundwater levels in fractured media. *Journal of Hydrology*, 307, 92–111.
- [8]. Krishna, B., Satyaj Rao, Y. R., & Vijaya, T. (2008). Modeling groundwater levels in an urban coastal aquifer using artificial neural networks. *Hydrology process journal*, 22, 1180–1188.
- [9]. Chowdhury, M., Alouani, A., & Hossain, F. (2010). Comparison of ordinary kriging and artificial neural network for spatial mapping of arsenic contamination of groundwater. *Environment Resource and Risk journal*, 24, 1–7.
- [10]. Yesilnacar, M. I., Şahinkaya, E., Naz, M., & Ozkaya, B. (2008). Neural Network Prediction of Nitrate in Groundwater of Harran Plain, Turkey. *Environment Geology Journal*, 56, 19–25.
- [11]. Zadeh, L. A. (1965). Fuzzy sets. *Journal of information control*, 8(3), 338–353.
- [12]. Alvisi, S., Mascellani, G., Franchini, M., & Bardossy, A. (2006). Water level forecasting through fuzzy logic and artificial neural network approaches. *Journal of Hydrology Earth System*, 10, 1–17.
- [13]. Affandi, A. K., & Watanabe, K. (2007). Daily groundwater level fluctuation forecasting using soft computing technique. *Natural Science journal*, 5(2), 1–10.
- [14]. Tutmez, B., Hatipoglu, Z., & Kaymak, U. (2006). Modelling electrical conductivity of groundwater using an adaptive neuro-fuzzy inference system. *Computing Geoscience Journal*, 32, 421–433.
- [15]. Kholghi, M., & Hosseini, S. M. (2009). Comparison of groundwater level estimation using neuro fuzzy and ordinary kriging. *Environmental Model Assessment journal*, 14, 729–737.

Transactions on Systems Man and Cybernetics Journal, 23, 665–684.

- [28]. Jeihouni, M., Toomanian, A., Alavipanah, S. K., Shahabi, M., & Bazdar, S. (2015). An application of MC-SDSS for water supply management during a drought crisis. *Environment Monitoring Assessment journal*, 187, 1–16.
- [29]. Khashei, A., Ghahraman, B., & Koochakzadeh, M. (2013). Evaluation of ANFIS, ANN, and geostatistical models to spatial distribution of groundwater quality (case study: Mashhad plain in Iran)", Springer Science and Business Media LLC, (2013), 8(2), 903-912.
- [30]. Montaseri, M., & zamanzad ghavidel, S. (2017). Comparing the Performance of Artificial Intelligence Models in Estimating Water Quality Parameters in Periods of Low and High Water Flow. *Water and Soil*, 30(6), 1733-1747.

Evaluating the Capability of Artificial Intelligence in Predicting the Amount of Electrical Conductivity and Nitrate in Groundwater Resources (A Case Study of Artificial Neural Methods ANN and ANFIS)

Navideh Najafpour

Expert of Environment and Water quality office in Esfahan regional water company navide.najafpour@gmail.com

Niaz Vahdatpour

Head of Water quality office in Esfahan regional water company n.vahdatpour@yahoo.com

Elham Aghababaie

Expert of Environment and Water quality office in Esfahan regional water company elham_ghababaie@yahoo.com

Abstract : In recent decades, artificial intelligence (AI) systems have created a new space in evaluating water and environmental engineering issues. In this study, the usual kriging method as a linear statistical estimator and two intelligent methods of artificial neural network ANN and adaptive neural fuzzy inference system ANFIS were evaluated in predicting the amount of electric conductivity and nitrate in groundwater. In order to conduct studies, nitrate concentration in 40 wells in Lanjanat plain of Isfahan was measured by spectrophotometer and electrical conductivity. The input data of the artificial neural model, including the length and width of the geographies, the nitrate concentration, and the electrical conductivity value were determined as the output of the model. In order to investigate the performance and efficiency of artificial intelligence models in predicting qualitative information, qualitative information of 50% of the wells was used for calibration and 50% of the wells were used for validating the models. Finally, the output of the models was compared with the value measured in the observation wells based on the mutual error evaluation criteria. The results showed that the ANFIS model performed better than the other two interpolation models in predicting the value of electrical conductivity and nitrate, respectively, with the root mean square error (RMSE) and (mg/l) of 5.362, with the mean bias error (MBE) 2.365 with a correlation coefficient (R) of 0.767. Also, the ANN model had far better results than the usual kriging method. Based on this, ANFIS model is proposed for spatial prediction of electrical conductivity and nitrate in the study area.

Keywords: Groundwater, Neural Network, Fuzzy interface, Ordinary Kriging

Introduction

Groundwater sources in Iran and many other countries with similar climates are the most important sources of water used in drinking, agriculture, and industry. It is not possible to measure the water quality in the entire aquifer, and determining the water quality in all the groundwater sources is a time-consuming and costly process. Therefore, it is important to determine the quality of the aquifer in places where sampling has not been done. In this regard, geostatistical methods have played a

significant role in the sustainable management of groundwater resources in recent years by predicting the pattern of changes and quantity in places where sampling has not been done. In recent decades, artificial intelligence (AI) systems have created a new space in evaluating water and environmental engineering issues. Many researchers have evaluated hybrid algorithms in solving non-linear problems by combining artificial neural and fuzzy methods. As a reference example [1] predicted the water level by combining fuzzy and artificial neural methods. Reference [2] evaluated the ANFIS and ANN methods based on the LM processing algorithm to determine the daily rise and fall of the groundwater level. They did not find any significant difference in the results of the two models and showed that the computational algorithms have sufficient accuracy in predicting the daily level of groundwater. Reference [12] used the ANFIS method in modeling the electrical conductivity of groundwater compounds and showed that despite the small data, the ANFIS method has a better capacity in EC modeling than the usual regression methods. Reference [7] compared the ANFIS method and the usual kriging in the assessment of the groundwater level, and the ANFIS method was more accurate. Reference [6] used kriging, ANN and ANFIS methods to interpolate heavy elements in the Caspian Sea and showed that the ANFIS method has the least error in simulation. Reference [5] used conventional kriging, ANN and ANFIS methods in modeling electrical conductivity in Tabriz plain and showed that intelligent methods have higher accuracy in predicting electrical conductivity at the aquifer level.

Material and method

Lanjanat Plain is a part of the catchment area of the Zayandeh Rood River, which is located in the southwest of Isfahan with an average geographical location of 51 degrees and 39 minutes of geographic longitude and 31 degrees and 56 minutes of geographic latitude (Figure 1). In terms of geology, the area is mostly covered with Quaternary sediments. The relevant aquifer is of free and alluvial type and its material is based on exploratory and observational logs, sand, clay and rubble along with conglomerate layers.

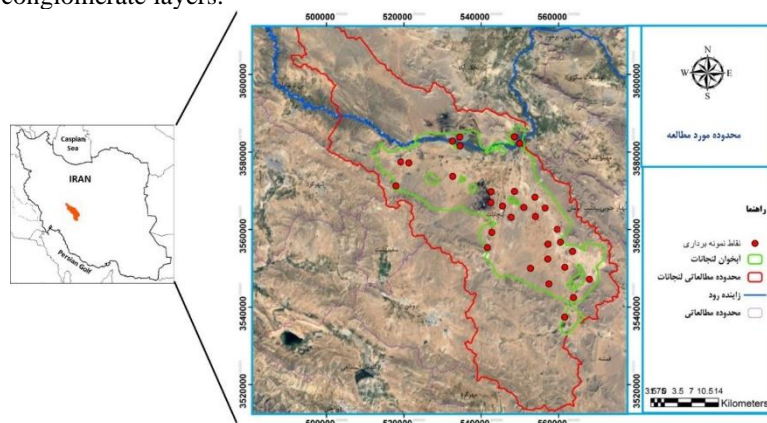


Figure1. Location of study area

To conduct studies, nitrate concentration in 40 wells in Lanjanat plain of Isfahan was measured by spectrophotometer and electrical conductivity. The input data of the artificial neural model, including the length and width of the geographies, the nitrate concentration, and the electrical conductivity value were determined as the output of the model. In order to investigate the performance and efficiency of artificial intelligence models in predicting qualitative information, qualitative information of 50% of the wells was used for calibration and 50% of the wells were used for validating the models. Finally, the output of the models was compared with

the value measured in the observation wells based on the mutual error evaluation criteria.

The usual kriging method as a linear statistical estimator and two intelligent methods of artificial neural network ANN and adaptive neural fuzzy inference system ANFIS were evaluated in predicting the amount of electric conductivity and nitrate in groundwater. In order to increase the efficiency of the model and better convergence of results in artificial and fuzzy neural models, all data were normalized between two numbers 0.1 and 0.9, for this purpose, the proposed relationship 1 was used. [11].

$$x_i = 0.8 \left(\frac{x - x_{min}}{x_{max} - x_{min}} \right) + 0.1 \quad (1)$$

The kriging model has the best results when the data has a normal distribution, so in using it, the data must have a normal distribution or be normalized with statistical transformations. In order to determine the distribution of electrical conductivity and nitrate data, Anderson-Darling test was used with a confidence level of 95%. For the normality of the data distribution, the Anderson-Darling coefficient should be less than 2.5 and the obtained confidence level should be more than 0.05 [10]. The results of the test showed that the distribution of data in EC parameter is abnormal and in nitrate parameter is normal. Therefore, Box-Cox statistical transformation was used in Minitab software to normalize data distribution. Figure 2 shows the results of Anderson-Darling test and histogram for electrical conductivity parameter in non-normal mode and after using Box-Cox transformation and Figure 3 shows the results of normal distribution for nitrate parameter.

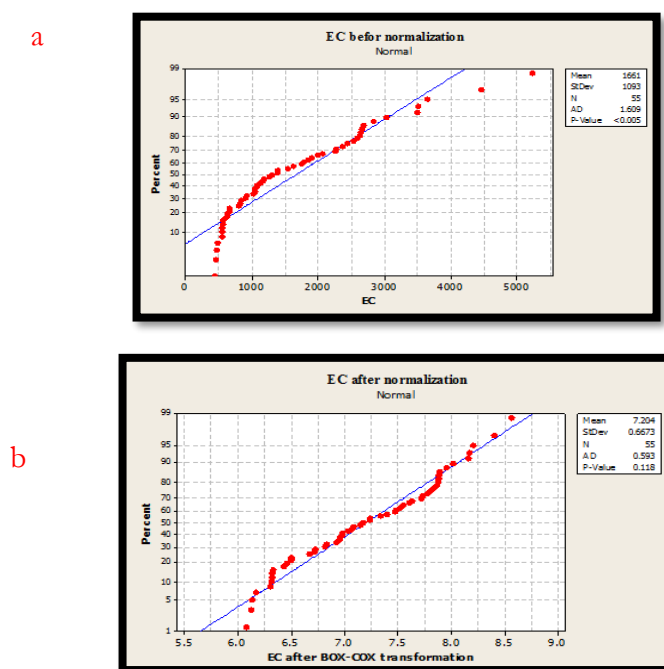


Figure 2. Anderson Darling test result of Electrical Conductivity data before normalizing (a) Histogram and Anderson Darling test result of Electrical Conductivity data after normalizing using Box- Cox transformation (b).




Figure 3. Histogram and Anderson Darling test result of Nitrate

Artificial neural networks extract the hidden law behind this information by sampling the human brain function system, by processing experimental data and without paying attention to the physics of the problem. In comparison with conventional models, these models need less inputs and little computational effort. Neural networks with appropriate selection of training data for the model have the most accuracy and establish the most complex relationships between input and output, and ANN is able to generalize and process messy, incomplete and non-linear laboratory data. Unlike linear models, ANN has no restrictions on the statistical characteristics of the data for processing. ANN method is suitable for data where there is no idea about the complexity and structure of input and output data. ANN with back propagation algorithm is one of the most widespread neural networks [9]. The goal of this algorithm is to reduce the overall error [3]. In this study, an ANN artificial neural network with multilayer perceptron (MLP) including 4 layers was used. The network was implemented with momentum optimization algorithm and TanhAxon transfer function to choose between different models based on trial and error. Two hidden layers were also used to adjust the weight of neurons in order to achieve optimal outputs. In this model, latitude and longitude were determined as input and output nitrate concentration value of the model (Figure 4).

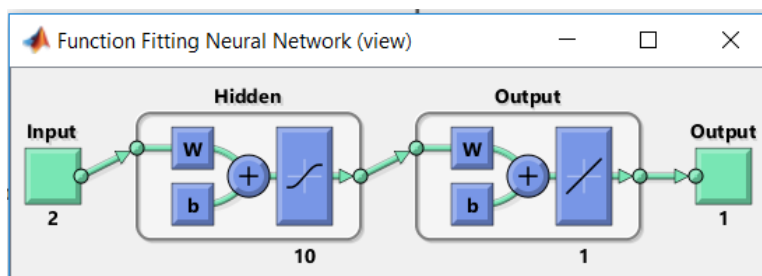


Figure 4. Structure of artificial neural network of ANN in this study

ANFIS was introduced by reference [4]. This method is an advanced and information-oriented tool that was developed to process complex and ambiguous dynamic systems [8].

Fuzzy system is a system based on condition-result logical rules that depicts the space of input variables on the space of output variables by using the concept of linguistic variables and fuzzy decision making process. The combination of fuzzy systems that are based on logical rules, and the method of artificial neural networks that have the ability to extract knowledge from numerical information, has led to the presentation of a fuzzy neural adaptive inference system [4]. An ANFIS fuzzy inference system and the ANN method are schematically shown in Figure 5.




Figure 5- Fuzzy inference system

In this study, latitude and longitude were considered as input and output nitrate concentration. The structure of ANFIS consists of five layers and functions related to the nodes of each layer (Figure 6). Each input in the first layer (input nodes) has two rules (A1, A2, B1 and B2), each of which creates two rules in the second layer (rule nodes). A brief description of the operation of the five layers is given below.




Figure 6. Structure of ANFIS

In order to conduct studies, Gaussian membership function (guss2mf) with the number of membership function [5 4] using the hybrid optimization algorithm was used for the electrical conductivity parameter and the same function with the number of membership [5 5] was used for the nitrate parameter. The type of membership function and the number of its members were determined based on trial and error between different functions in the ANFIS model. The results showed that the Gaussian membership function with the type [5 4] for electrical conductivity and [5 5] for nitrate determines accurate outputs and therefore it is used as the target function in this study (Figure 7).




Figure 7. Structure of Fuzzy inference system of ANFIS for Nitrate (left) and Electrical Conductivity (right) in this study

There are various parameters for mutual evaluation of data. In this study, the parameters of root mean square error (RMSE), mean deviation of error (MBE) and correlation coefficient (R) were used to evaluate the values predicted by three models and observed values (Relations 2, 3 and 4).

$$RMSE = \frac{1}{n} \sqrt{\sum_{i=1}^n ((z_p - z_0)^2)} \quad (2)$$

$$MBE = \frac{1}{n} \sum_{i=1}^n (z_p - z_0) \quad (3)$$

$$R = \frac{\sum_{i=1}^n z_p z_0 - \frac{\sum_{i=1}^n z_p \sum_{i=1}^n z_0}{n}}{\sqrt{\left(\sum_{i=1}^n z_p^2 - \frac{(\sum_{i=1}^n z_p)^2}{n}\right) \left(\sum_{i=1}^n z_0^2 - \frac{(\sum_{i=1}^n z_0)^2}{n}\right)}} \quad (4)$$

Result: For developing the models, points with specific geographic coordinates were used, where the electrical conductivity and nitrate concentration were measured. Then the output of the models, which includes the estimation of electrical conductivity and nitrate, was compared with each other and relative to the observed values with the mutual evaluation criteria of R, RMSE and MBE. The scatter diagram of observational and estimated data by three kriging models, artificial neural network ANN and ANFIS for two parameters electrical conductivity and nitrate are shown in figures 8 and 9. The results of mutual evaluation with RMSE, MBE and R parameters were presented in Tables 1 and 2.

Table 1- Results of mutual evaluation of nitrate parameter with three common kriging models, ANFIS and ANN

MBE	RMSE	R	Interpolation method
2.365	5.362	0.767	ANFIS
4.301	6.603	0.7298	ANN
3.085	5.933	0.7227	Ordinary kriging

Table 2- The results of mutual evaluation of electric conductivity parameter with three interpolation models of Kriging, ANFIS and ANN

MBE	RMSE	R	Interpolation method
74.17	246.63	0.7867	ANFIS
82.43	330.04	0.7452	ANN
195.38	387.87	0.7096	Ordinary kriging

According to Tables 1 and 2, ANFIS artificial neural model has the minimum value of RMSE and MBE and the maximum value of R in both electrical conductivity and nitrate parameters compared to other interpolation models used. According to the above tables, compared to the two artificial intelligence methods ANN and ANFIS, according to the mutual evaluation criteria, the usual kriging method has a low correlation coefficient and a higher error rate in predicting the electrical conductivity and nitrate of groundwater. In addition, as it is clear from figures 8 and 9, the density of the scatter of points around the 1:1 line in the ANFIS model is higher than the two conventional kriging and ANN models. Also, the ANN artificial neural model has a better estimate than the usual kriging method.

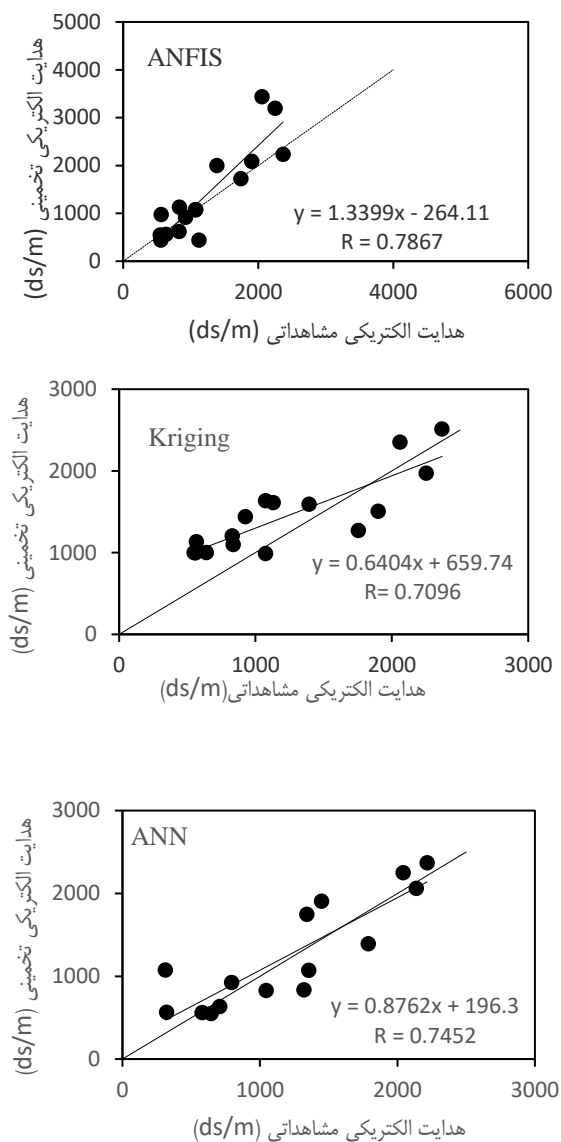


Figure 8. Dispersion of observational and estimated data by three Kriging, ANN and ANFIS models of electrical conductivity parameter

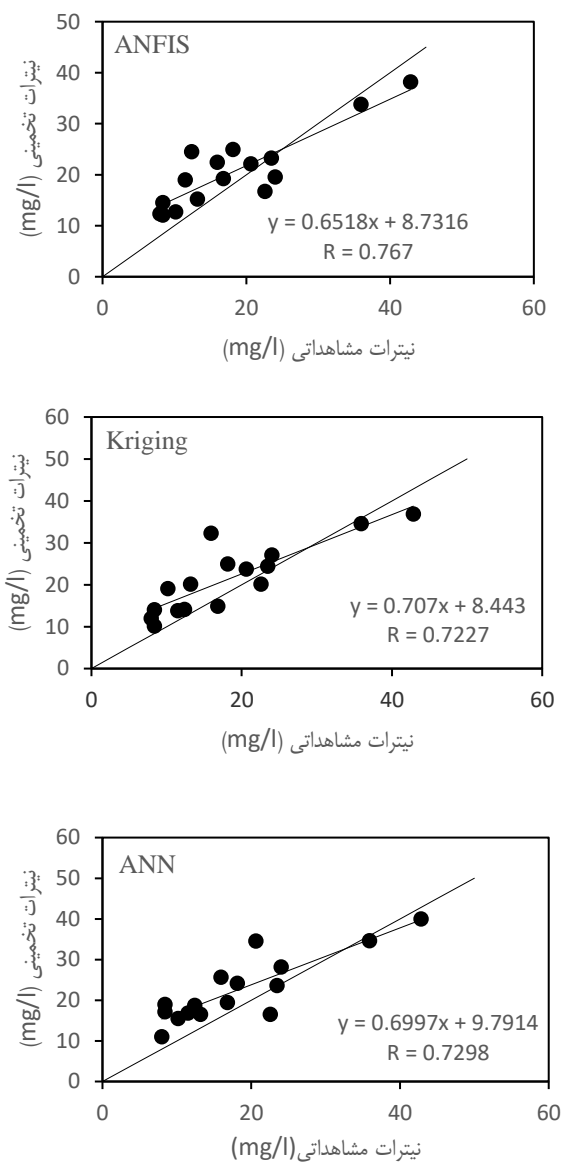


Figure 9. Scatter diagram of observed and estimated data by three Kriging, ANN and ANFIS models of nitrate parameter

The results showed that the ANFIS model performed better than the other two interpolation models in predicting the value of electrical conductivity and nitrate, respectively, with the root mean square error (RMSE) and (mg/l) of 5.362, with the mean bias error (MBE). 2.365 With a correlation coefficient (R) of 0.767. Also, the ANN model had far better results than the usual kriging method. Based on this, ANFIS model is proposed for spatial prediction of electrical conductivity and nitrate in the study area.

References:

- 1- Alvisi, S., Mascellani, G., Franchini, M., & Bardossy, A. (2006). Water level forecasting through fuzzy logic and artificial neural network approaches. *Journal of Hydrology Earth System*, 10, 1–17.
- 2- Affandi, A. K., & Watanabe, K. (2007). Daily groundwater level fluctuation forecasting using soft computing technique. *Natural Science journal*, 5(2), 1–10.
- 3- Chen, S. H., Lin, Y. H., Chang, L. C., & Chang, F. J. (2006). The strategy of building a flood forecast model by neuro-fuzzy networks. *Hydrology Progress journal*, 20, 1525–1540.
- 4- Cheng, C. B., & Lee, E. S. (1999). Applying fuzzy adaptive network to fuzzy regression analysis. *Computing Math Applying journal*, 38, 123–140.
- 5- Jeihouni, M., Delirhasannia, R., Alavipanah, K., Shahabi, M., & Samadianfard, S. (2015). Spatial analysis of groundwater electrical conductivity using ordinary kriging and artificial intelligence methods. *Journal of Original scientific paper*, 32, 191-208.
- 6- Kazemi, S. M., & Hosseini, S. M. (2011). Comparison of spatial interpolation methods for estimating heavy metals in sediments of Caspian Sea. *Expert System Applied journal*, 38, 1632–1649.
- 7- Kholghi, M., & Hosseini, S. M. (2009). Comparison of groundwater level estimation using neuro fuzzy and ordinary kriging. *Environmental Model Assessment journal*, 14, 729–737.
- 8- Kisi, O. (2005). Suspended sediment estimation using neuro-fuzzy and neural network approaches. *Hydrology Science Journal*, 50, 683–696.
- 9- Li, P. Y., Wu, J., & Qian, H. (2012). Groundwater quality assessment with two multi-criteria decision making methods. *Journal of Geomatics and Geosciences*, 2(3), 868- 877.
- 10- Mann, N., Schafer, R., & Singpurwalla, N. (1974). *Methods for Statistical Analysis of Reliability and Life Data*. John Wiley. N. Y.
- 11- Rahimi khoub, A. (2008). Comparative study of Hargreaves's and artificial neural network's methodologies in estimating reference evapotranspiration in a semiarid environment. *Irrigation science Journal*, 26(3), 253-259.
- 12- Tutmez, B., Hatipoglu, Z., & Kaymak, U. (2006). Modelling electrical conductivity of groundwater using an adaptive neuro-fuzzy inference system. *Computing Geoscience Journal*, 32, 421–433.