

Estimation of Potential of the Ground Water Arsenic Contamination in Sanandaj Area Using Artificial Neural Network Model

Saman Moradi¹, Jamil Amanoollahi^{2*}, Farshid Ghorbani²

1. M.Sc. Student, Environment Science, Faculty of Natural Resources, University of Kurdistan, Sanandaj, Iran

2. Assistant Professor, Department of Environmental Sciences, Faculty of Natural Resources, University of Kurdistan, Sanandaj, Iran

* E-mail: j.amanollahi@uok.ac.ir

Received: 17 Jun. 2018 P; Accepted: 26 Sep. 2018

ABSTRACT

Background & objective: Identification of ground waters contaminated by arsenic using surface soil parameters and modeling this relationship in two models including artificial neural network and multiple linear regression can be useful in managing the water resources of the region.

Material & methods: The purpose of the present study was to estimate the potential of arsenic pollution in the Sanandaj ground waters using multiple linear regression (MLR) and artificial neural network (ANN) models. In this regards, 35 number of wells were selected among the permissible wells with considering watershed area, appropriate distribution, and different geological structure. The water samples stored in polyethylene bottles and kept at 4°C until transferred to the laboratory. For consideration of the relationship between the soils characteristics around the wells and ground water, the soil samples were collected from 0-20 cm of topsoil with composite sampling technique. The soil samples were air-dried and prepared for analysis. For long term storage of water samples nitric acid were added and the concentration of arsenic in water samples were measured by graphite furnace atomic absorption analyzer. Physical and chemical characteristics of the soil samples including: arsenic, arsenate, arsenite, phosphate, nitrate, total iron, amorphous iron, total manganese, amorphous manganese, clay, sand, silt, organic matter, pH and CEC were measured. Then all water and soil data were normalized and finally, accuracy of the MLP and ANN models was assessed to investigate the relationship between arsenic of water and soil parameters.

Results: Results showed that the arsenic concentration of ground waters were lower than the standard level in the study area. This can be due to high concentration of arsenate in the study area soils compared arsenite and increasing the cationic exchange capacity of soil under the influence of clay particles, organic matter and free iron oxides.

Conclusion: Comparison of models accuracy result showed that ANN model with $R=0.835$, $RMSE=0.156$ and $MAE=0.118$ in the training phase and $R=0.816$, $RMSE=0.177$ and $MAE=0.158$ in the testing phase has higher accuracy and lower errors in the estimation of ground waters arsenic contamination than MLP model.

Keywords: Arsenic, Groundwater, Multiple linear regression, Artificial neural network. Arsenate

برآورد پتانسیل آلودگی آرسنیک آب‌های زیرزمینی شهرستان سنندج با استفاده از مدل شبکه عصبی مصنوعی

سامان مرادی^۱، جمیل امان‌اللهی^{۲*}، فرشید قربانی^۲

^۱ دانش آموخته کارشناسی ارشد، محیط زیست، دانشکده منابع طبیعی، دانشگاه کردستان، سنندج، ایران

^۲ استادیار، گروه محیط زیست، دانشکده منابع طبیعی، دانشگاه کردستان، سنندج، ایران

تاریخ دریافت مقاله: ۱۳۹۷/۳/۲۷؛ تاریخ پذیرش: ۱۳۹۷/۷/۴

چکیده

زمینه و هدف: شناسایی آب‌های زیرزمینی آلوده به آرسنیک با استفاده از پارامترهای سطحی خاک و مدل‌سازی این رابطه در دو مدل شبکه عصبی مصنوعی و رگرسیون خطی چندگانه می‌تواند در مدیریت منابع آبی منطقه مفید باشد. **مواد و روش‌ها:** در این مطالعه برآورد پتانسیل آلودگی آرسنیک آب‌های زیرزمینی سنندج با استفاده از مدل‌های رگرسیون خطی چندگانه و شبکه عصبی مصنوعی مورد آزمون قرار گرفت. در این راستا از بین چاه‌های مجوزدار شهرستان سنندج ۳۵ چاه با در نظر گرفتن حوضه آبریز، پراکندگی مناسب و ساختار زمین شناختی متفاوت انتخاب شدند. نمونه‌های آب هر چاه در ظرف‌های پلی اتیلنی و در دمای ۴ درجه سانتی‌گراد و نمونه‌های خاک از عمق ۲۰-۰ سانتی‌متری خاک سطحی بالادست چاه‌ها به صورت مرکب جمع‌آوری و به آزمایشگاه منتقل شدند. در آزمایشگاه غلظت آرسنیک نمونه‌های آب با دستگاه جذب اتمی به روش کوره اندازه‌گیری گردید. ویژگی‌های فیزیکی و شیمیایی خاک شامل: آرسنیک، آرسنات، آرسنیت، فسفات، نترات، آهن کل، آهن بی‌شکل، منگنز کل، منگنز بی‌شکل، درصد رس، درصد شن، درصد سیلت، ماده آلی خاک، pH و CEC اندازه‌گیری شدند. در ادامه دقت مدل‌های رگرسیون چندگانه و شبکه عصبی مصنوعی برای بررسی رابطه بین پارامترهای ذکر شده خاک و آرسنیک موجود در آب مورد آزمون قرار گرفت.

یافته‌ها: نتایج نشان داد که غلظت آرسنیک آب‌های زیرزمینی منطقه کمتر از حد استاندارد است که این می‌تواند به دلیل بالا بودن غلظت آرسنات خاک‌های منطقه نسبت به آرسنیت و افزایش ظرفیت تبادل کاتیونی خاک تحت تأثیر ذرات رس، ماده آلی و اکسیدهای آزاد آهن باشد.

نتیجه‌گیری: مقایسه‌ی دقت مدل‌ها نیز نشان داد که مدل شبکه عصبی با $R=0/835$ و $RMSE=0/106$ و $MAE=0/118$ در مرحله آموزش و $R=0/816$ و $RMSE=0/177$ و $MAE=0/108$ در مرحله آزمون دارای دقت بیشتر و خطای کمتری در برآورد آلودگی آرسنیک آب‌های زیرزمینی نسبت به مدل رگرسیون خطی چندگانه است.

کلمات کلیدی: آرسنیک، آب‌های زیرزمینی، رگرسیون خطی چندگانه، شبکه عصبی، آرسنات

مقدمه

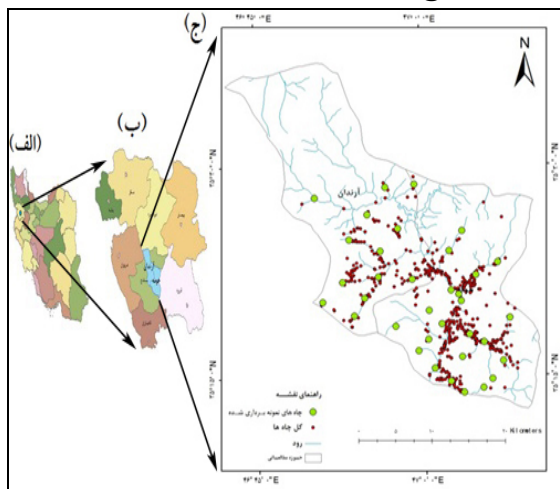
آلودگی آب‌های زیرزمینی یکی از مهم‌ترین مباحث زمین‌شناسی زیست محیطی، بخصوص در مناطقی که آب‌های سطحی وجود ندارند یا ناچیز هستند به شمار می‌آید.^۱ آب‌های زیرزمینی منبع تأمین آب برای میلیون‌ها نفر در جهان بوده و آلوده شدن آن‌ها تأثیرات عمده‌ای بر سلامت انسان‌ها، فعالیت صنایع^۲، کشاورزی و محیط زیست دارد^۳. یکی از مهم‌ترین گروه آلاینده‌های آب زیرزمینی که به طور طبیعی یا انسانی باعث آلودگی آن می‌شود، عناصر جزئی و کمیاب سمی هستند. این عناصر نقش چندانی در تشکیل پوسته زمین ندارند، اما دارای اهمیت زیادی در اقتصاد و بوم‌شناسی^۴، تجمع در گیاهان^۵، کاهش کیفیت آب شرب^۶، کاهش کیفیت آب رودخانه‌ها^۷ و بسیاری زمینه‌های دیگر هستند. یکی از آلودگی‌های خاک که بعنوان تهدیدی فزاینده برای سلامتی انسان و کیفیت محیط زیست مطرح است میزان آرسنیک خاک است. افزایش آرسنیک در خاک، سبب افزایش خطر ریسک شست‌شوی آرسنیک و ورود آن در آب‌های زیرزمینی می‌شود^۸. وجود مواد مادری دارای تشکیلات آذرین در خاک و یا راه‌یابی جریان‌های عمقی آب به سطح از علل اصلی افزایش میزان آرسنیک در خاک هستند^۹. خاک‌های با آرسنیک کل بیش از ۱۰ میلی‌گرم بر کیلوگرم آلوده به شمار می‌روند^{۱۰}. امروزه عوامل انسان ساز شامل مصرف بی‌رویه سموم آرسنیک‌دار، فاضلاب، فضولات حیوانی و پسماندهای صنعتی (مانند رنگ‌ها) نیز باعث افزایش میزان آرسنیک در خاک و آب شده است. آرسنیک به

دلیل وارد شدن به سفره‌های آب زیرزمینی و در نتیجه زنجیره غذایی یکی از مهم‌ترین چالش‌های زیست محیطی بسیاری از کشورها است^{۱۱} که می‌تواند سبب تهدید سلامت

جامعه شود. استفاده از روش‌های سنتی برای بررسی وضعیت کیفی سفره‌های آب زیرزمینی زمان بر و پرهزینه است. در سال‌های اخیر، روش‌های متنوعی در زمینه مدیریت بهتر برای حفظ کیفیت آب و پیش‌بینی شاخص‌های کیفی آب‌های سطحی به کار رفته است. اکثر این روش‌ها، نیازمند داشتن اطلاعات وسیعی از فرایندهای هیدرولوژیکی متفاوت است که دسترسی به آن‌ها همواره محتاج صرف زمان و هزینه بوده است^{۱۲}

مدل رگرسیون خطی چندگانه (MLR) روشی است که برای ارتباط خطی بین یک متغیر وابسته و یک یا چند متغیر مستقل مورد استفاده قرار می‌گیرد^{۱۳}. مدل‌های رگرسیون چندگانه به دلیل صحت تفسیرشان^{۱۴}، به طور گسترده‌ای در زمینه‌ی پیش‌بینی آلودگی‌های محیط زیست مورد استفاده قرار می‌گیرند^{۱۵}. یکی از مدل‌هایی که بطور گسترده‌ای در مطالعات مربوط به پیش‌بینی پارامترهای مختلف منابع آب مورد استفاده قرار گرفته و پژوهشگران بر دقت بالای این روش در مقایسه با روابط تجربی و رگرسیونی تاکید نموده‌اند مدل شبکه عصبی مصنوعی است^{۱۶}. شبکه عصبی مصنوعی زیر مجموعه‌ای از تکنیک‌های هوش مصنوعی است که ساختار و عملکرد آن به صورت کلی همانند مغز انسان است. که به صورت پیش‌رونده و موفق برای سیستم‌های غیرخطی در زمینه‌های علمی و مهندسی به کار می‌رود^{۱۷}. در این راستا می‌توان به کاربرد این مدل در پیش‌بینی تغییرات کیفیت آب‌های زیرزمینی در منطقه‌ای متاثر از بیماری قانقاریا تایوان^{۱۸}، شناسایی منابع آلودگی نامشخص آب زیرزمینی^{۱۹}، شناسایی منابع غیرقابل دسترس آلودگی آب‌های زیرزمینی با استفاده از غلظت مشاهده شده^{۲۰}، ارزیابی آلودگی آب‌های زیرزمینی در پروژه جاده‌های فرانسه^{۲۱}، پیش‌بینی فضایی آلودگی نترات در

هانگ و همکاران^{۲۲} در بررسی رابطه‌ی آلودگی نیترات آب‌های زیر زمینی با پارامترهای خاک سطحی در منطقه‌ی شاندونگ چین بیان کردند که نمونه گیری از آب و خاک باید در خاک‌های دارای ساختار مختلف زمین شناسی و با پراکنش مناسب در سطح منطقه باشد.



شکل ۱: (الف) کشور ایران، (ب) استان کردستان، (ج) نقاط نمونه برداری در حوزه مطالعاتی

همچنین بیان داشتند که تعداد نمونه‌ها بستگی به تنوع ساختار زمین شناسی منطقه خواهد داشت. لذا در این مطالعه نیز نقشه چاه‌های کم عمق و نیمه عمیق در منطقه مورد مطالعه از سازمان آب منطقه‌ای تهیه و از بین آن‌ها ۳۵ حلقه چاه انتخاب شدند. انتخاب چاه‌ها با در نظر گرفتن پراکنندگی مناسب (فواصل چاه‌ها از یکدیگر) و دسترسی به چاه‌ها (جاده اسفالت یا خاکی) (شکل ۱-ج) و ساختارهای مختلف زمین-شناسی (شکل ۲) صورت گرفت^{۲۲}.

نمونه‌های آب گرفته شده از هر حلقه چاه (مجموع ۳۵ نمونه) در ظرف‌های پلی اتیلنی که از قبل با اسید نیتریک ۲ درصد و آب مقطر شست و شو داده شده بودند در دمای ۴ درجه سانتی گراد به آزمایشگاه منتقل و با استفاده از دستگاه

آب‌های زیرزمینی^{۲۲}، تحلیل فضایی الگوی پراکنش آلودگی نیترات نیتروژن آب‌های زیرزمینی در مناطق کشاورزی فشرده شاندونگ چین^{۲۳}، پیش‌بینی نیترات آلودگی آب‌های زیرزمینی در مناطق روستایی و کشاورزی نوار غزه^{۲۴} اشاره کرد. در داخل کشور نیز در رابطه با کاربرد این مدل می‌توان مدل‌سازی و شبیه‌سازی حذف آرسنیک، کروم و کادمیوم از آب توسط فرایند نانو فیلتراسیون^{۲۵}، و شبیه‌سازی شوری آب زیرزمینی^{۲۶} را نام برد. در ایران وجود خاک‌های آلوده به آرسنیک در استان کردستان و زنجان گزارش شده است^{۲۷} که شست‌شوی آن می‌تواند سبب آلوده شدن آب‌های زیرزمینی این مناطق به آرسنیک شود. با توجه به وجود پتانسیل آلودگی آرسنیک در آب‌های زیر زمینی استان کردستان به نظر می‌رسد برای مدیریت پایدار این منابع، بررسی رابطه‌ی خصوصیات خاک سطحی با میزان آلودگی آرسنیک آب‌های زیرزمینی ضروری باشد. در این راستا استفاده از مدل‌های مختلف و مقایسه‌ی دقت نتایج آن‌ها در برآورد میزان آلودگی می‌تواند سبب انتخاب مدل بهینه و به تبع آن افزایش دقت برآورد گردد. لذا هدف اصلی این مقاله مقایسه‌ی دقت مدل‌های شبکه‌ی عصبی مصنوعی و رگرسیون خطی چند گانه در برآورد پتانسیل آلودگی آرسنیک در آب‌های زیرزمینی شهرستان سنندج است.

مواد و روش‌ها

منطقه مورد مطالعه

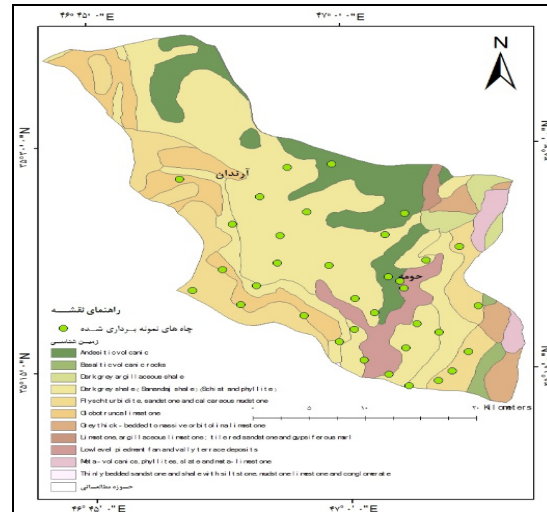
شهرستان سنندج، مرکز استان کردستان با مساحت ۳۶۸۸/۶ هکتار و ارتفاع ۱۴۰۰ متر از سطح دریا با مختصات جغرافیایی ۳۵ درجه و ۱۷ دقیقه عرض شمالی و ۴۷ درجه و ۱۸ دقیقه طول شرقی در غرب ایران و در بخش جنوبی استان کردستان قرار دارد (شکل ۱-الف و ب).

نمونه‌برداری آب زیرزمینی و خاک

شکل ۲: نقشه چاه‌های انتخاب شده بر اساس ساختار زمین شناختی

روش نمونه‌برداری به صورت مرکب و از عمق ۰ تا ۲۰ سانتی‌متری خاک سطحی صورت گرفت^{۲۲}. سپس نمونه‌های خاک در پاکت‌های کاغذی ریخته شد و با زدن برچسب‌هایی که مشخصات جغرافیایی (X,Y)، شماره ایستگاه چاه‌ها و اسم روستا درج شده به آزمایشگاه منتقل شدند. نمونه‌های خاک نیز پس از انتقال به آزمایشگاه مورد آنالیز قرار گرفتند و میزان قطر ذرات خاک، ماده آلی، فسفر قابل جذب، نیترات خاک، ظرفیت تبادل کاتیونی (CEC)، آرسنیک و آرسنیت، اکسیدهای آزاد آهن و منگنز بی‌شکل در آنها اندازه‌گیری شدند. جدول شماره ۱ روش سنجش پارامترهای مورد ذکر را نشان می‌دهد.

جذب اتمی (Biotech مدل PHOENI986 محصول کشور انگلستان) میزان آرسنیک آب اندازه‌گیری گردید. نمونه‌های خاک از بالا دست و نزدیک چاه‌های نمونه‌برداری شده (۳۵ حلقه چاه) برداشت شدند.



جدول ۱: روش سنجش و شماره استاندارد پارامترهای اندازه‌گیری شده در نمونه‌های آب و خاک

شماره استاندارد	روش سنجش	خصوصیات فیزیکی و شیمیایی
۳۵۰۰	اسپکتوفتومتری جذب اتمی ^{۲۸}	آرسنیک آب
۳۵۰۰	اسپکتوفتومتری جذب اتمی ^{۲۹}	آرسنیک خاک
۳۵۰۰	کسر آرسنیت از آرسنیک	آرسنات
۳۵۰۰	اسپکتوفتومتری جذب اتمی ^{۲۸}	آرسنیت
۴۱۱۰	اولسن ^{۳۰} ، دستگاه اسپکتوفتومتر	فسفات
۴۱۱۰	اسپکتوفتومتر ^{۳۱}	نیترات
۲۳۵۰	والکی بلک ^{۳۲}	ماده آلی
۲۳۵۰	سیترات دی تیونات ^{۳۳}	منگنز کل
۲۳۵۰	اسپکتوفتومتری جذب اتمی	منگنز بی شکل
۲۳۵۰	اسید آمونیوم اگزالات ^{۳۴}	
۲۳۵۰	اسپکتوفتومتری جذب اتمی	آهن کل
۲۳۵۰	سیترات دی تیونات ^{۳۳}	
۲۳۵۰	اسپکتوفتومتری جذب اتمی	آهن بی شکل
۲۳۵۰	اسید آمونیوم اگزالات ^{۳۴}	
۲۵۱۰	اسپکتوفتومتری جذب اتمی	ظرفیت تبادل کاتیونی
۲۵۱۰	استات سدیم، فلم فتومتر ^{۳۵}	
۱۰۷۵۰	روش هیدرومتری ^{۳۶}	سیلت

برآورد پتانسیل آلودگی آرسنیک آب‌های زیرزمینی شهرستان سنندج با استفاده از مدل شبکه عصبی مصنوعی

شماره استاندارد	روش سنجش	خصوصیات فیزیکی و شیمیایی
۱۰۷۵۰	روش هیدرومتری ^{۳۶}	ماسه
۱۰۷۵۰	روش هیدرومتری ^{۳۶}	رس

جدول ۲: تنظیمات دستگاه جذب اتمی برای سنجش آرسنیک، منگنز و آهن در نمونه‌های آب و خاک

شرایط دستگاه جذب اتمی	فلزات سنگین
Band width = 0.4nm	آرسنیک آب،
Filter Factor = 1	آرسنیک خاک،
Analytical line = 193.7nm	آرسنات و
Detection limit = 0.16mg/l	آرسنیت
Band width = 0.4nm	منگنز کل و
Filter Factor = 1	منگنز بی شکل
Analytical line = 279.5nm	
Detection limit = 0.002mg/l	
Band width = 0.2nm	آهن کل و
Filter factor = 1	آهن بی شکل
Analytical line 248.3nm	
Detection limit = 0.0046	

عدم اغتشاشات بستگی دارد، چرا که این روش‌ها در مقابل اطلاعات نادرست حساسیت بالایی داشته ورود چنین داده‌هایی منجر به بروز خطاهای بزرگ و فاحش در نتایج می‌شود. بهترین کارایی این روش در برابر متغیرهای با توزیع نرمال است^{۳۷}.


نرمال‌سازی داده‌ها

ابتدا تبعیت داده‌ها از توزیع نرمال به وسیله آزمون کولموگروف اسمیرونوف بررسی شد. نظر به نرمال نبودن توزیع، جهت نرمال نمودن داده‌ها از رابطه‌ی (۱) استفاده شد. نکته قابل توجه در آموزش شبکه‌های عصبی مصنوعی قبل از استفاده در مدل، نرمال سازی داده‌ها است. این عمل کمک شایانی به آموزش بهتر و سریع‌تر مدل می‌کند. وارد کردن داده‌ها به صورت خام باعث کاهش دقت و سرعت در شبکه می‌شود^{۳۷}. قبل از آموزش شبکه عصبی، داده‌های ورودی به آن باید استاندارد شوند. این کار مانع کوچک شدن بیش از حد

تنظیمات دستگاه جذب اتمی برای سنجش آرسنیک شامل آرسنیک آب و خاک، آهن و منگنز در هر دو حالت کل و بی شکل در جدول شماره ۲ نشان داده شده است. میزان استاندارد آرسنیک در خاک ۵۰ ppb، در آب ۱۰ ppb، آهن کل ۳۰۰۰ mg/kg، منگنز کل ۲۰-۳۰۰۰ mg/kg است و بهترین غلظت نیترات خاک که در آن گیاهان بالاترین حد رشد را خواهند داشت ۲-۳۰ ppm است. در این تحقیق رابطه‌ی بین میزان آرسنیک اندازه‌گیری شده در نمونه‌های آب بعنوان متغیر پاسخ و متغیرهای اندازه‌گیری شده‌ی نمونه‌های خاک به عنوان متغیرهای مستقل در دو مدل رگرسیون خطی چندگانه و شبکه عصبی مصنوعی مورد آزمون قرار گرفتند.

رگرسیون خطی چندگانه تک عاملی

با استفاده از روش‌های رگرسیون چندگانه می‌توان به بررسی همزمان چندین متغیر مستقل متفاوت پرداخت. عملکرد مناسب این روش تا حد زیادی به صحت داده‌ها و



شکل ۳: ساختار شبکه عصبی مصنوعی

درون یابی

امروزه بصورت وسیعی از روش های متداول درون یابی برای تهیه نقشه پهنه بندی کمی و کیفی منابع آب زیرزمینی استفاده می شود^{۴۲}. بصورت خلاصه می توان گفت وظیفه درون یابی آن است که به بررسی آن دسته از متغیرها می پردازد که دارای وابستگی مکانی بین مقادیر هستند، مقادیری مانند فاصله و جهت قرارگیری که بین این ها یک ارتباط فضایی وجود دارد^{۴۳}. روش معکوس فاصله (IDW) از جمله روش های درون یابی است. در این روش مقادیر پیکسل های مجهول از طریق میانگین گیری مقادیر معلوم در نزدیکی هر پیکسل برآورد می شود. مقادیری که به مرکز پیکسل نزدیک تر هستند در برآورد مقادیر مجهول تاثیر و وزن بیشتری دارند، به این صورت است که هر چه فاصله از مرکز پیکسل مجهول بیشتر شود اثر بخشی پیکسل معلوم در برآورد نقطه مجهول و محاسبه میانگین کاهش پیدا می کنند^{۴۴}.

یافته ها

سازمان بهداشت جهانی (WHO) و آژانس حفاظت محیط زیست آمریکا (US EPA) حداکثر مجاز آرسنیک در آب آشامیدنی را ۱۰ میکروگرم بر لیتر مشخص کرده اند. خلاصه ای آماری از جمله کمترین، بیشترین، میانگین و انحراف معیار خواص فیزیکی و شیمیایی خاک های مورد بررسی در جدول ۳ نشان داده شده است. در جدول ۴ نیز ضرایب همبستگی آرسنیک آب با آرسنات، آرسنیت، فسفات، نترات، ماده آلی، منگنز کل و بی شکل، آهن کل و بی شکل، ظرفیت تبادل

وزن ها می شود. برای نرمال سازی داده ها از رابطه (۱) استفاده شد^{۳۸}.

$$X_n = (X - X_{\min}) / (X_{\max} - X_{\min}) \quad (1)$$

X داده مشاهده شده

Xmax حداکثر داده مشاهده شده

Xmin حداقل داده مشاهده شده

شبکه عصبی مصنوعی

شبکه عصبی مصنوعی نوعی سامانه ی پردازش اطلاعات است که عملکردی شبیه شبکه عصبی زیست شناختی دارد^{۳۹}. هر شبکه ی عصبی مصنوعی از سه لایه اصلی ورودی، پنهان (مخفی) و خروجی تشکیل شده است. در هر لایه چند عنصر پردازشگر (نرون) وجود دارد، که به نرون های لایه مجاور متصل هستند. واحدهای لایه ورودی وظیفه توزیع مقادیر ورودی ها به لایه بعد و لایه خروجی نیز پاسخ سیگنال های خروجی را ارائه می دهد. در این دو لایه، تعداد نرون ها برابر با تعداد ورودی ها و خروجی ها می باشد و لایه یا لایه های پنهان وظیفه ارتباط لایه های ورودی به لایه های خروجی و به دست آوردن روابط خطی و غیرخطی بین متغیرها را بر عهده دارند^{۴۰}. در یک مدل شبکه عصبی این که وزن های موجود در شبکه عصبی به نحو مطلوبی برآورد شوند حائز اهمیت است. به منظور برآورد مقادیر مطلوب بردار وزن ها روش های متعددی استفاده می شود که مهم ترین و پرکاربردترین آن ها در شبکه عصبی پرسپترون چند لایه مورد استفاده قرار می گیرد. در این روش مقدار خطا مجدداً به مدل شبکه های عصبی منتقل و مقادیر وزن ها را تعدیل می نماید^{۴۱}. در این پژوهش برای طراحی شبکه عصبی پرسپترون چند لایه از جعبه ابزار شبکه عصبی در نرم افزار متلب نسخه b ۲۰۱۴ استفاده شد (شکل ۳). مدل استفاده شده در شبکه عصبی پس از آزمون و خطای فراوان دارای یک لایه پنهان و ۲۲ نرون به عنوان مناسب ترین مدل بوده است. الگوریتم آموزشی از نوع لونیگ - مکوارد است.

برآورد پتانسیل آلودگی آرسنیک آب‌های زیرزمینی شهرستان سنندج با استفاده از مدل شبکه عصبی مصنوعی

کاتیونی، رس خاک و سیلت خاک نشان داده شده است. بر پایه استاندارد ملی ایران (۱۳۸۸) نیز حد مجاز آرسنیک در آب آشامیدنی ۱۰ میکروگرم بر لیتر است. مقدار آلودگی آرسنیک اندازه‌گیری شده در بعضی از ایستگاه‌ها نزدیک به آستانه استاندارد آلودگی و در اکثر ایستگاه‌ها کمتر از آستانه استاندارد می‌باشد.

جدول ۳: مقادیر اندازه‌گیری شده ویژگی‌های فیزیکی و شیمیایی خاک‌های مورد مطالعه

انحراف معیار	میانگین	بیشترین	کمترین	خصوصیات فیزیکی و شیمیایی
۰/۲۱۲	۵/۳	۹/۷	۲/۴	آرسنیک آب
۰/۲۶۹	۴/۷	۱۱/۱	۰/۷۷	آرسنیک خاک
۰/۲۴۲	۳۳۱	۴۵۵	۲۳۳	آرسنات
۰/۲۶۶	۴/۴	۱۰/۸	۰/۴۵	آرسنیت
۰/۱۷۸	۹/۸	۱۵/۹۴	۲/۷	فسفات
۰/۲۳۶	۰/۶۶۵	۰/۷۴۵	۰/۴۹۱	نیترات
۰/۲۰۳	۲/۲۱	۴/۹۳	۰/۳۴	ماده آلی
۰/۲۱۲	۰/۱۷۱	۰/۲۵۸	۰/۱۱۳	منگنز کل
۰/۱۹۴	۰/۰۴	۰/۰۹۸	۰	منگنز بی شکل
۰/۲۳۳	۱/۶۹	۳/۲۴	۰/۹۷	آهن کل
۰/۲۱۱	۰/۴۵۶	۰/۹۷	۰/۲۱۵	آهن بی شکل
۰/۲۲۳	۵۶/۶	۶۰/۸۴	۵۰/۰۲	ظرفیت تبادل کاتیونی
۰/۲۱۳	۲۸/۲۹	۴۴/۵۶	۹/۸۴	سیلت
۰/۲۲۴	۵۰/۹۴	۸۴/۷۲	۲۸/۸۸	ماسه
۰/۲۰۸	۲۰/۷۶	۳۷/۲۸	۵/۲۸	رس

جدول ۴: ضرایب حاصل از مدل رگرسیون متغیرهای مستقل در رابطه با آرسنیک آب

متغیرهای مستقل	ضرایب	انحراف استاندارد	آزمون t
As(III)	-۰/۲۴۷	۰/۱۹۰	-۱/۲۹۸
As(V)	۰/۱۰۳	۰/۱۳۸	۰/۷۴۷
PO_4^{-2}	-۰/۴۱۲	۰/۲۶۵	-۱/۵۵۶
NO ₂	۰/۰۴۹	۰/۱۸۱	۰/۲۶۹
OM	۰/۵۰۸	۰/۲۳۱	۲/۱۹۹
Mn _d	۰/۱۲۹	۰/۲۵۲	۰/۵۱۲
Mn _o	-۰/۲۶۶	۰/۳۳۹	-۰/۷۸۳
Fe _d	-۰/۲۴۷	۰/۱۹۵	-۱/۳۶۸
Fe _o	-۰/۲۳۲	۰/۲۸۴	-۰/۸۱۸
CEC	-۰/۳۷۵	۰/۲۲۴	-۱/۶۷۴


Silt	-۰/۰۳۹	۰/۲۶۴	-۰/۱۴۶
Clay	۰/۳۶۴	۰/۴۱۲	۱/۳۹۴
Constant*	۰/۵۸۱	۰/۲۶۶	۲/۱۸۰

Constant*: ضریب ثابت در فرمول رگرسیونی می‌باشد.

نتایج حاصل از شبکه عصبی مصنوعی

مدل‌های شبکه عصبی مصنوعی جهت طراحی نیازمند سه دسته داده آموزشی، اعتبارسنجی و آزمون است. از داده‌های آموزشی به منظور پیدا کردن رابطه بین ورودی‌ها و خروجی‌های مشاهده‌ای استفاده می‌گردد، از داده‌های اعتبارسنجی به منظور کنترل و نظارت بر یادگیری صحیح شبکه استفاده می‌شود و از داده‌های آزمون برای ارزیابی عملکرد شبکه پیشنهادی استفاده می‌گردد.

در این پژوهش ۷۰ درصد کل داده‌ها، برای آموزش، ۱۵ درصد اعتبارسنجی و ۱۵ درصد آزمون مدل اختصاص یافت. در این مدل که توسط داده‌های خاک (داده‌های مستقل x) به برآورد مقدار آرسنیک آب‌های زیرزمینی (داده وابسته y) پرداخته شده است، در مرحله آموزش $R=۰/۸۳۵$ و $MAE=۰/۱۱۸$ و $RMSE=۰/۱۵۶$ (شکل ۶) در مرحله آزمون مقادیر $R=۰/۸۱۶$ و $RMSE=۰/۱۷۷$ و $MAE=۰/۱۵۸$ (شکل ۷) به دست آمد.




شکل ۵: نمودار نتایج حاصل از شبیه‌سازی آرسنیک آب‌های زیرزمینی در مرحله آزمون با استفاده از مدل رگرسیون خطی چندگانه

غلظت آلودگی آرسنیک در خاک تحت تاثیر عوامل زیادی می‌باشد که می‌توان به این موارد اشاره کرد: کلوئیدهای موجود در خاک (مواد معدنی رس، مواد آلی، کربنات کلسیم و اکسیدهای آزاد آهن، فسفات، کربنات موجود در خاک، ظرفیت تبادل کاتیونی خاک، بافت خاک، سنگ بستر (رس‌های آهکی، ماسه سنگ آهکی، بازالت، داسیت) ^{۴۵}.

نتایج استفاده از آنالیز رگرسیون خطی چندگانه

در این مدل که توسط داده‌های خاک (داده‌های مستقل x) به برآورد مقدار آرسنیک آب‌های زیرزمینی (داده وابسته y) پرداخته شده است، در مرحله آموزش $R=۰/۶۳۶$ و $MAE=۰/۱۲۴$ و $RMSE=۰/۱۵۵$ (شکل ۴) و در مرحله آزمون مقادیر $R=۰/۵۱۷$ و $RMSE=۰/۳۶۹$ و $MAE=۰/۳۳۸$ (شکل ۵) به دست آمد.

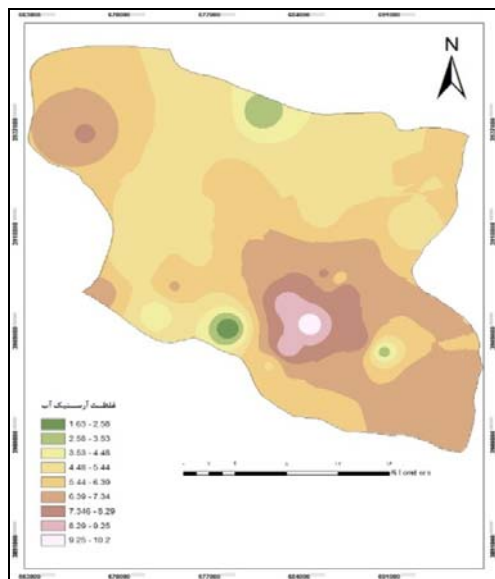


شکل ۴: نمودار نتایج حاصل از شبیه‌سازی آرسنیک آب‌های زیرزمینی در مرحله آموزش با استفاده از مدل رگرسیون خطی چندگانه


برآورد پتانسیل آلودگی آرسنیک آب‌های زیرزمینی شهرستان سنندج با استفاده از مدل شبکه عصبی مصنوعی



شکل ۶: نمودار نتایج حاصل از شبیه‌سازی آرسنیک آب‌های زیرزمینی در مرحله آموزش با استفاده از مدل شبکه عصبی مصنوعی



شکل ۸: نقشه درون‌یابی غلظت آرسنیک آب‌های زیرزمین



شکل ۷: نمودار نتایج حاصل از شبیه‌سازی آرسنیک آب‌های زیرزمینی در مرحله آزمون با استفاده از مدل شبکه عصبی مصنوعی

نتایج حاصل از درون‌یابی

همانطور که از شکل ۸ پیداست بیشترین مقدار غلظت آرسنیک در دو منطقه شمال غربی و جنوب شرقی قرار دارد که لکه جنوب شرقی وسیع‌تر و در انتها حوضه آبریز قرار گرفته است. سایر مناطق دیگر که آلودگی کمتری دارند به صورت خیلی واضحی در ابتدا و سرشاخه حوضه آبریز قرار دارند و در مقابل آنها یا خروجی حوضه آبریز دارای بار غلظت بیشتری از آلودگی آرسنیک است.

بحث

تغییرات آلودگی آرسنیک در آب‌های زیرزمینی

معیار کیفیت خاک توسط سازمان حفاظت محیط زیست ایالات متحده آمریکا برای آرسنیک کل ۲۰ میلی‌گرم بر کیلوگرم است، با توجه به حد مجاز آرسنیک در خاک، مقدار آرسنیک خاک‌های ایستگاه‌های نمونه‌برداری کمتر از آستانه استاندارد بود. آرسنیک آزاد شده از کانی‌های اولیه در خاک شامل دو جز اصلی آرسنیت (نماینده فاز محلول) و آرسنات (نماینده فاز غیر محلول) می‌باشد. آرسنیت سمیت بیشتری نسبت به آرسنات دارد و در نتیجه بر اثر آب‌شویی میزان آرسنیت در منابع آب‌زیرزمینی مشاهده می‌شود^{۴۶}. با افزایش

ظرفیت تبادل کاتیونی خاک افزایش یافته و به طبع آن جذب آرسنیک نیز افزوده می‌شود.^{۴۴} با توجه به اینکه خاک‌های منطقه مطالعاتی دارای ظرفیت تبادل کاتیونی نسبتاً بالایی می‌باشد تثبیت آرسنیک توسط ظرفیت تبادل کاتیونی خاک افزایش پیدا می‌کند که این امر نیز می‌تواند یکی از دلایل کمتر از حد استاندارد بودن غلظت آرسنیک آب‌های زیر زمینی منطقه باشد. توزیع آرسنیک معمولاً در بافت خاک تحت تأثیر سایر ذرات متفاوت است. سمیت آرسنیک در خاک‌های بسیار ریز کمتر است چون تحرک آرسنیک در این خاک‌ها تحت تأثیر اکسیدهای آهن قرار دارد.^{۴۵} به طور کلی سطوح اکسیدها در حاشیه ذرات شکسته شده رس‌ها در pHهای پایین دارای مثبت باردار هستند بنابراین باعث جذب آنیون‌ها و به ویژه آرسنات می‌شوند.^{۴۶} بیشترین تثبیت آرسنیک به شکل آرسنات در خاک‌های با محتوای رس و سیلت به وقوع می‌پیوندد. با توجه به اینکه خاک‌های منطقه مطالعاتی دارای بافت متوسطی است پس انتظار می‌رود که احتمال حل شدن آرسنیک در خاک وجود داشته باشد و به آب زیرزمینی راه یابد. با توجه به اینکه تعداد پارامترهای مستقل و تأثیرگذار بر غلظت آرسنیک خاک مورد مطالعه نسبتاً زیاد است و پارامترهای مانند فسفات و نترات در غلظت‌های متفاوت دارای رفتارهای مختلفی است و همچنین اثر کاهش ظرفیت تبادل کاتیونی و اثر افزایشی بافت خاک بر حل شدن آرسنیک خاک و به تبع آن ورود آن به سفره‌های آب زیرزمینی منطقه، لذا نمی‌توان به راحتی به تفسیر تأثیر پارامترها بر آرسنیک خاک منطقه پرداخت و به همین دلیل است که از مدل شبکه عصبی مصنوعی برای پیدا کردن روابط پیچیده غیرخطی استفاده شده است.

مقایسه و ارزیابی مدل رگرسیون خطی چندگانه

تک عاملی با مدل شبکه عصبی مصنوعی

یافته‌های پژوهش حاضر برتر بودن مدل شبکه عصبی را

میزان سهم آرسنیت مخاطرات زیست‌محیطی آرسنیک از جمله آب‌شویی و آلودگی منابع آبی افزایش پیدا می‌کند در حالیکه با افزایش سهم آرسنات میزان اثرات سمی آرسنیک کاهش می‌یابد.^{۴۷} تثبیت آرسنیک در خاک با ترغیب تشکیل آرسنات همراه است که تحرک و آب‌شویی آرسنیک را کاهش می‌دهد.^{۴۸} با توجه به اینکه مقدار غلظت آرسنات خاک‌های ایستگاه‌های نمونه‌برداری نسبت به آرسنیت بیشتر است پس تثبیت آرسنیک در خاک‌های نمونه‌برداری شده بصورت آرسنات است و نگرانی در مورد مخاطرات زیست‌محیطی آرسنیک از جمله آب‌شویی و آلودگی منابع آبی کم می‌شود که این می‌تواند یکی از دلایل کمتر از حد استاندارد بودن غلظت آرسنیک آب‌های زیر زمینی منطقه باشد. آرسنیک با غلبه بر نیروی جاذبه بین یون‌های فسفات جذب شده در سطح کلوئیدهای خاک می‌تواند جایگزین فسفات شود. اما افزایش بیشتر در میزان فسفات منجر به معکوس شدن این فرآیند شده و باعث واجذب آرسنات می‌شود.^{۴۹} آرسنات با غلبه بر نیروی جاذبه میان یون‌های نترات جذب شده در سطح کلوئیدهای دارای بار مثبت در خاک از جمله اکسیدهای آزاد آهن جایگزین آن‌ها می‌گردد.^{۵۰} افزایش بیش از حد آنیون‌های نترات در خاک معمولاً در پی استفاده از کودهای کشاورزی است و باعث آزاد شدن آرسنات از سطح کلوئیدها به درون محلول خاک و مانع از تشکیل آرسنات در خاک می‌گردد.^{۵۱} در pHهای بالا ۸/۵ تا ۹/۵ اتصال آرسنیک با اکسیدهای آهن ضعیف‌تر از pHهای پایین‌تر است و بنابراین باعث آلودگی بیشتری می‌شود.^{۵۲} بیشینه جذب آرسنات توسط اکسیدهای آزاد آهن در pH بین ۴ تا ۷/۵ اتفاق می‌افتد.^{۵۳} که می‌توان نتیجه گرفت با توجه به دامنه pH خاک‌های منطقه (۷/۵ تا ۷/۹) اکسیدهای آهن تأثیری بر افزایش یا کاهش حل شدن آرسنیک خاک در منطقه مطالعاتی نداشته‌اند. ظرفیت تبادل کاتیونی خاک تحت تأثیر ذرات رس، ماده آلی و اکسیدهای آزاد آهن قرار دارد. لذا انتظار می‌رود که با حضور این عوامل

نتایج دقیقتری است. برتری شبکه عصبی نسبت به رگرسیون خطی چندگانه توسط پژوهشگران دیگری در رابطه با مطالعات آب زیر زمینی ثابت شده است و با نتایج این مطالعه نیز همخوانی دارد از جمله این پژوهش‌ها می‌توان به نتایج^{۲۳} اشاره کرد. ال‌تاباچ و همکاران (۲۰۰۷) که با استفاده از شبیه‌سازی شبکه‌های عصبی مصنوعی به ارزیابی آلودگی آب‌های زیرزمینی در پروژه جاده‌های فرانسه پرداختند. نشان دادند که نتایج مدل شبکه عصبی مصنوعی برای ارزیابی خطر رسیدن آلودگی به منابع آب زیرزمینی نسبت به رگرسیون چندگانه خطی دارای دقت بالاتر است^{۲۰}. پورکیت و همکاران (۲۰۰۸) نیز با استفاده از مدل شبکه عصبی مصنوعی به مطالعه آلودگی آرسنیک در آب‌های زیرزمینی مالدا هند پرداختند و نتایج حاکی از آن بود که شبکه عصبی پرسپترون چند لایه پیش‌بینی مناسب‌تری نسبت به مدل‌های رگرسیون خطی چندگانه و رگرسیون برداری پشتیبان دارد^{۶۲}. حسینی و همکاران (۲۰۱۴) پهنه‌بندی غلظت نترات آب زیرزمینی را با استفاده از شبکه عصبی مصنوعی فازی توسعه داده شده بر اساس رگرسیون برداری پشتیبان انجام دادند و نتایج آنها نشان داد که شبکه عصبی مصنوعی فازی توسعه داده شده بر اساس رگرسیون برداری در مقایسه با مدل‌های تکنیک زمین آمار، خطی، درجه دوم، چند جمله‌ای و توابع هسته گاوسی عملکرد بهتری دارد^{۶۳}.

بررسی تغییرات مکانی آرسنیک با استفاده از عملیات درون‌یابی

بیشترین مقدار غلظت آرسنیک در شمال غربی و جنوب شرقی منطقه مطالعاتی است که لکه جنوب شرقی وسیع‌تر و در انتهای حوضه آبریز قرار گرفته دارد که دلیل ایت امر می‌تواند تجمع غلظت آرسنیک در انتهای حوضه آبریز و همچنین فعالیت‌های شهر نشینی باشد و سایر مناطق دیگر که آلودگی کمتری دارند به صورت خیلی واضحی در ابتدا و

نسبت به مدل رگرسیون خطی چندگانه بیان می‌دارد. به طوری که استفاده از شبکه عصبی مصنوعی صحت نتایج پیش‌بینی را نسبت به مدل رگرسیون خطی چندگانه تک عاملی به میزان ۳۰٪ در مرحله آزمون و ۲۰٪ در مرحله آموزش افزایش داده است. این مسئله مهر تایید بر پیچیده‌تر بودن شبکه عصبی نسبت به رگرسیون خطی چندگانه تک عاملی است چرا که یکی از قابلیت‌های شبکه عصبی توانایی بالای آن در شبیه‌سازی مسائل غیرخطی پیچیده است. طبق نظر اسچاپ و همکاران^{۵۷} در سال ۱۹۹۸ معادلات خاصی برای طراحی شبکه‌های عصبی لازم نیست و شرط به دست آوردن نتیجه‌ی دقیق ایجاد رابطه مناسب بین داده‌های ورودی و خروجی است. این امر زمانی بیشتر نمود پیدا می‌کند که داده‌ها دارای نویز باشد که مدل‌های دیگر قادر به ارائه‌ی نتایج دقیقی نیستند ولی مدل شبکه عصبی به دلیل قابلیت تعمیم بسیار بالایی که دارد دارای عملکرد خیلی بهتری خواهد بود^{۵۸}. این شبکه‌ها از مثال‌ها درس می‌آموزند حتی در صورتی که داده کافی وجود نداشته باشد این مدل روابط بین داده را در صورت ناشناخته بودن روابط یا دشوار بودن توصیف آن‌ها، کشف می‌کند. شبکه‌های عصبی برخلاف روش‌های خطی به صورت مدل آزاد هستند، یعنی پیش فرض‌های بسیار کمی دارند. حساس نبودن این شبکه به وجود تعداد محدودی خطا در داده‌های آماری یکی دیگر از برتری‌های این شبکه در مقایسه با مدل‌های خطی است. تنها محدودیت این شبکه‌ها در غیر قابل تفسیر بودن نتایج حاصل از مدلسازی از نظر میزان تأثیر هر متغیر ورودی بر خروجی مورد نظر است. برتری شبکه عصبی نسبت به رگرسیون خطی چندگانه و توسط محققین زیادی ثابت شده است. الکامل و همکاران^{۵۹} (۲۰۰۱)، چالولاکو و همکاران^{۶۰} (۲۰۰۳)، و کای و همکاران^{۶۱} (۲۰۰۹) دقت مدل شبکه عصبی مصنوعی و رگرسیون خطی چندگانه را در برآورد میزان آلودگی هوا با هم مقایسه کردند نتایج آنها نشان داد که مدل شبکه عصبی مصنوعی دارای قابلیت ارائه‌ی

سرشاخه حوضه آبریز قرار دارند.

عصبی مصنوعی می‌تواند روش مناسبی برای پیدا کردن این روابط پیچیده و غیرخطی باشد. که یافته‌های پژوهش حاضر نیز برتر بودن مدل شبکه عصبی را نسبت به مدل رگرسیون خطی چندگانه نشان می‌هد.

نتیجه گیری

با توجه به اینکه تعداد پارامترهای مستقل و تأثیرگذار بر غلظت آرسنیک خاک مورد مطالعه نسبتاً زیاد است مدل شبکه

References

- Nazari M, Burston M, Bishop P, Lerner D. Urban Ground-Water Pollution: A Case Study from Coventry, United Kingdom. *Ground Water* 1993; 31: 417-24.
- Jousma G, Bear J, Haimes YY, Walter F. Groundwater Contamination: Use of Models in Decision-Making: Proceedings of the International Conference on Groundwater Contamination: Use of Models in Decision-Making, Amsterdam, The Netherlands, Organized by the International Ground Water Modeling Center (IGWMC), Indianapolis Delft. *Sp Sci & Bu Me* 2012: 26-9.
- Movahhed S, Kalantari RR, Khezri M, Azari A. Determining and analyzing corrosion potential of groundwater in Ghorveh through simulating corrosion indices. *J Environ Health Eng* 2017;4(3): 233-42 [In Persian].
- Aiuppa A, Federico C, Allard P, et al. Trace metal modeling of groundwater-gas-rock interactions in a volcanic aquifer: Mount Vesuvius, Southern Italy. *Chem Geol* 2005; 216: 289-311.
- Mortazavi S, Hatami Manesh M. Determination of heavy metals pollution load index in sediments and aquatic plant (*Nasturtium microphyllum*) in Bashar river, Yasuj. *J Environ Health Eng* 2017;5(2): 157-72 [In Persian].
- Aghalari Z, Jafarian S. Survey of nitrite and nitrate in mineral water available in the city of Babol in 2015. *J Environ. Health Eng* 2017; 5(1):65-72 [In Persian].
- Alizadeh M, Mirzaei R, Kia SH. Determining the spatial trend of water quality indices across Kan and Karaj river basins. *J Environ Health Eng* 2017;4(3): 243-56 [In Persian].
- Jiang J. Removing arsenic from groundwater for the developing world-a review. *Water Sci Technol* 2001;44: 89-98.
- Sisr L, Mihaljevič M, Ettler V, et al. Effect of application of phosphate and organic manure-based fertilizers on arsenic transformation in soil columns. *Environ Monit Assess* 2007;135: 435-473.
- Adriano DC. Trace elements in terrestrial environments: biogeochemistry, bioavailability, and risks of metals. *Springer* 2001: 165.
- Garg N, Singla P. Arsenic toxicity in crop plants: physiological effects and tolerance mechanisms. *Environ Chem Lett* 2011; 9: 303-321.
- Chen JC, Chang N, Shieh W. Assessing wastewater reclamation potential by neural network model. *Eng Appl Artif Intel* 2003; 16: 149-157.
- Kuzmanovski I, Aleksovska S. Optimization of artificial neural networks for prediction of the unit cell parameters in orthorhombic perovskites; Comparison with multiple linear regression. *Chemomet Intell Lab* 2003; 67: 167-174.
- Zhou Q, Jiang H, Wang J, et al. A hybrid model for PM_{2.5} forecasting based on ensemble empirical mode decomposition and a general regression neural network. *Sci Total Environ* 2014; 496: 264-274.
- Cobourn WG. An enhanced PM_{2.5} air quality forecast model based on nonlinear regression and back-trajectory concentrations. *Atmos Environ* 2010; 44: 3015-3023.
- Kuo JT, Hsieh MH, Lung WS, She N. Using artificial neural network for reservoir eutrophication prediction. *Ecol Model* 2007; 200: 171-177.
- Hassan J. ARIMA and regression models for prediction of daily and monthly clearness index. *Renew Energy* 2014; 68: 421-427.
- Kuo YM, Liu CW, Lin KH. Evaluation of the ability of an artificial neural network model to assess the variation of groundwater quality in an area of blackfoot disease in Taiwan. *Water Res* 2004; 38: 148-158.
- Singh RM, Datta B. Artificial neural network modeling for identification of unknown pollution sources in groundwater with partially missing concentration observation data. *Water Resour Manag* 2007; 21: 557-572.
- El Tabach E, Lancelot L, Shahrou I, Najjar Y. Use of

- artificial neural network simulation metamodelling to assess groundwater contamination in a road project. *Math Comput Model* 2007; 45: 766-776.
21. Gemitzi A, Petalas C, Pisinaras V, Tsihrintzis V. Spatial prediction of nitrate pollution in groundwaters using neural networks and GIS: An application to South Rhodope aquifer (Thrace, Greece). *Hydrol Proce* 2009; 23: 372-383.
 22. Huang J, Xu J, Liu X, et al. Spatial distribution pattern analysis of groundwater nitrate nitrogen pollution in Shandong intensive farming regions of China using neural network method. *Math Comput Model* 2011; 54: 995-1004.
 23. Al-Mahallawi K, Mania J, Hani A, et al. Using of neural networks for the prediction of nitrate groundwater contamination in rural and agricultural areas. *Environ Earth Sci* 2012; 65: 917-928.
 24. Akhovat A, Mousavi SM. Modeling and Simulation of Arsenic, Chromium and Cadmium Removal from Water by Nanofiltration Process by Artificial Neural Networks. 1st Environmental remediation technologies conference, Sharif university of technology, Iran 2011: [In Persian].
 25. Derakhshan S, Gholami V, Darvari Z. Simulation of Ground Water Salinity by Using Artificial Neural Network (ANN) on the Mazandaran province coasts. *Irrig Sci Eng* 2013; 36(2): 61-70 [In Persian].
 26. Karimi nezhad MT, Tali MG, Mahmoudi MH, et al. Spatial Variability of as and Cd Concentrations in Relation to Land Use, Parent Material and Soil Properties in Topsoils of Northern Ghorveh, Kurdistan Province, Iran. *World Appl Sci J* 2010; 11: 1105-1113.
 27. Jalali Lichaei M, Nabi-Bidhendi M. Comparison between multiple linear regression and artificial neural networks for porosity and permeability estimation. *Geosci* 2006; 61: 140-149 [In Persian].
 28. Way C. Standard methods for the examination of water and wastewater. Water Environment Federation, Secaucus, 2012 NJ, USA.
 29. Giacomino A, Malandrino M, Abollino O, et al. An approach for arsenic in a contaminated soil: speciation, fractionation, extraction and effluent decontamination. *Environ Pollut* 2010; 158: 416-423.
 30. Olsen SR. Estimation of available phosphorus in soils by extraction with sodium bicarbonate. 1954.
 31. Jackson M, Soil Chemical Analysis, 1967. Pub. By Prentice-Hall of India Pvt. Ltd., New Delhi, India. pp, 41-196.
 32. Walkley A, Black IA. An examination of the Degtjareff method for determining soil organic matter, and a proposed modification of the chromic acid titration method. *Soil Sci* 1934; 37: 29-38.
 33. Mehra O, Jackson, M. Iron oxide removal from soils and clays by a dithionite-citrate system buffered with sodium bicarbonate. *Proc. 7th Nat. Conf. Clays* 1960; 317-327.
 34. McKeague J, Day JH. Dithionite-and oxalate-extractable Fe and Al as aids in differentiating various classes of soils. *Canadian J Soil Sci* 1996; 46: 13-22.
 35. Bower CA, Reitemeier R, Fireman M. Exchangeable cation analysis of saline and alkali soils. *Soil Sci* 1952; 73: 251-262.
 36. Day PR. Particle Fractionation and Particle-Size Analysis. *Methods of Soil Analysis. Part 1. Physical and Mineralogical Properties, Including Statistics of Measurement and Sampling* (ed C. A. Black), 1965; pp. 545-567. American Society of Agronomy, Soil Science Society of America.
 37. Zhu YM, Lu X, Zhou Y. Suspended sediment flux modeling with artificial neural network: An example of the Longchuanjiang River in the Upper Yangtze Catchment. *China Geo* 2007; 84: 111-125.
 38. Dastorani MT, Azimi Fashi K, Talebi A, Ekhtesasi MR. Estimation of Suspended Sediment Using Artificial Neural Network (Case Study: Jamishan Watershed in Kermanshah). *J Watershed Manag Res* 2012; 3(6): 61-74 [In Persian].
 39. Demuth H, Beale M. *Neural Network Toolbox (Version 4) For Use with Matlab. The Mathworks, Inc Available online at: https://www.mathworks.com/help/pdf_doc/nnet/nnet_ugpdf 1998.*
 40. Minasny B, McBratney A. The neuro-m method for fitting neural network parametric pedotransfer functions. *Soil Sci Soc Am J* 2002; 66: 352-361.
 41. Back B, Back BJR. Financial statement planning in the presence of tax constraints. *Euro J Oper Res* 1995; 85: 66-81.
 42. Missaghi.F, Mohammadi.k. Estimation of groundwater levels using conventional interpolation techniques and comparison with geostatistics technique. Twenty-first meeting on Earth Sciences Geo Survey and Min Explo of Country 2002: 588-590.
 43. Hassani Pak AA. *Geostatistics. Tehran University Press* 1998: 328 [In Persian].
 44. A MS, Abyaneh.H TZ. Evaluation of geostatistical methods for estimating electrical conductivity and pH of stream waters in Hamedan-Bahar plain. *J Water Soil Conser* 2009;16: 169-187.
 45. Khodakarami L, Soffianian AR, Mohamadi T, Mirghafari NA. Study of heavy metals concentration Copper, Zinc and Arsenic soil using GIS and RS techniques (Case study: Kaboudarahang, Razan and Khonjin- Talkhab

- catchment in Hamedan province). *Appl RS GIS Tech Nat Resour Sci* 2011; 2(1): 79-89 [In Persian].
46. Giacomino A, Malandrino M, Abollino O, et al. An approach for arsenic in a contaminated soil: speciation, fractionation, extraction and effluent decontamination. *Environ Poll* 2010; 158: 416-423.
 47. Wauchope R. Fixation of arsenical herbicides, phosphate, and arsenate in alluvial soils. *J Environ Qual* 1975; 4: 355-358.
 48. Álvarez-Benedí J, Bolado S, Cancillo I, et al. Adsorption-desorption of arsenate in three Spanish soils. *Vadose Zone J* 2005; 4: 289-290.
 49. Jain A, Loeppert RH. Effect of competing anions on the adsorption of arsenate and arsenite by ferrihydrite. *Environ Qual* 2000; 29: 1422-1430.
 50. Smith E, Naidu R, Alston A. Chemistry of arsenic in soils: I. Sorption of arsenate and arsenite by four Australian soils. *Environ Qual* 1999; 28: 1719-1726.
 51. Anawar HM, Akai J, Sakugawa H. Mobilization of arsenic from subsurface sediments by effect of bicarbonate ions in groundwater. *Chemo* 2004; 54: 753-762.
 52. Kinniburgh D, Jackson M, Syers J. Adsorption of alkaline earth, transition, and heavy metal cations by hydrous oxide gels of iron and aluminum. *Soil Sci Soc Am J* 1976; 40: 796-799.
 53. Kinniburgh D, Smedley P. A review of the source, behaviour and distribution of arsenic in natural waters. *Appl Geo* 2002 17:517-68.
 54. Frost R, Griffin R. Effect of pH on adsorption of arsenic and selenium from landfill leachate by clay minerals. *Soil Sci Soc Am J* 1977;41: 53-57 .
 55. Majedi S, Soori b, Shiradi A. The zoning of arrsenic presence in some calcareous soils of Qorveh plain using logistic regression. *Iranian J Soil Res*. 2013; 27: 227-238 [In Persian].
 56. Anagu I, Ingwersen J, Utermann J, et al. Estimation of heavy metal sorption in German soils using artificial neural networks. *Geod* 2009; 152: 104-12.
 57. Schaap MG. Using neural network to predict soil water retention and soil hydraulic conductivity. *Soil Till Res* 1998; 47: 37- 42.
 58. Robles LA, Ortega JC, Fu JS, et al. A hybrid ARIMA and artificial neural networks model to forecast particulate matter in urban areas: The case of Temuco, Chile. *Atmos Environ* 2008; 42: 8331- 340.
 59. Elkamel A, Abdul-Wahab S, Bouhamra W, et al. Measurement and prediction of ozone levels around a heavily industrialized area: A neural network approach. *Advan Environ Res* 2001; 5: 47-59.
 60. Chaloulakou A, Grivas G, Spyrellis N. Neural Network and Multiple Regression Model for PM₁₀ Prediction in Athens: A Comparative Assessment. *J Air Waste Manag Associ* 2003; 53 (10): 1183-190.
 61. Cai M, Yin Y, Xie M. Prediction of hourly air pollutant concentrations near urban arterials using artificial neural network approach. *Transport Res D* 2009. 14: 32-41.
 62. Purkait B, Kadam S, Das S. Application of artificial neural network model to study arsenic contamination in groundwater of Malda District, Eastern India. *J Environ Inform* 2008; 12: 140-49.
 63. Hosseini SM, Mahjouri N. Developing a fuzzy neural network-based support vector regression (FNN-SVR) for regionalizing nitrate concentration in groundwater. *Environ Monit Assess* 2014; 186: 3685-699.