

برآورد میزان غلظت کادمیوم خاک با استفاده از مدل‌های ANN و ANFIS

احمد بازوبندی^۱، صمد امامقلی زاده^{۲*}، هادی قربانی^۲ تورج افشاری بدرلو^۱

۱. دانش آموخته کارشناسی ارشد خاکشناسی، گروه آب و خاک، دانشکده کشاورزی، دانشگاه صنعتی شاهرود

۲. دانشیار گروه آب و خاک، دانشکده کشاورزی، دانشگاه صنعتی شاهرود

(تاریخ دریافت: ۱۳۹۵/۱۰/۲۳، تاریخ تصویب ۱۳۹۶/۰۶/۲۹)

چکیده

بررسی سطوح آلودگی خاک به فلزات سنگین مانند میزان کادمیوم خاک برای سلامتی انسان و مدیریت محیط‌زیست انسان مهم و ضروری است. با توجه به این که اندازه‌گیری مستقیم کادمیوم خاک زمان‌بر و هزینه‌بر است، در این پژوهش، از دو روش هوشمند مصنوعی شامل مدل شبکه عصبی مصنوعی (ANN) و شبکه عصبی فازی تطبیقی (ANFIS) برای تخمین میزان کادمیوم خاک به‌عنوان یکی از خطرناک‌ترین فلزات سنگین استفاده شد. برای برآورد میزان غلظت کادمیوم خاک از عناصر زود یافت خاک مانند درصد سیلت، شن، کربن آلی، pH، EC، T.N و P به‌عنوان پارامترهای ورودی به مدل استفاده شد و از طریق دو مدل ANN و ANFIS ارتباط میان پارامترهای مذکور و میزان غلظت کادمیوم برقرار گردید. برای آموزش و صحت‌سنجی مدل‌های مذکور از ۲۵۰ نمونه خاک که از خاک‌های استان گیلان گرفته شد، استفاده شد. ارزیابی مدل‌ها با استفاده از پارامترهای آماری مانند ضریب تبیین (R^2)، میانگین خطای مطلق (MAE)، مجذور میانگین مربعات خطا (RMSE) انجام شد. نتایج به‌دست‌آمده نشان داد مدل شبکه عصبی مصنوعی با ضریب تبیین (R^2) ۰/۸۳ و همچنین مجذور میانگین مربعات خطا (RMSE) ۱/۰۱ و میانگین خطای مطلق (MAE) برابر ۰/۵۴ روش مناسب‌تری نسبت به شبکه عصبی فازی تطبیقی است. همچنین نتایج آنالیز حساسیت پارامترهای ورودی به مدل‌ها نشان داد درصد کربن آلی و EC خاک به ترتیب بیشترین و کمترین تأثیرگذاری را بر میزان کادمیوم دارند. مدل پیشنهادی می‌تواند برای برآورد میزان غلظت کادمیوم خاک در سایر نقاط در محدوده مورد مطالعه که اندازه‌گیری غلظت کادمیوم خاک انجام نشده است و همچنین برای سایر مناطق با داشتن شرایط مشابه مورد استفاده قرار گیرد.

کلید واژگان: کادمیوم، فلزات سنگین، مدل‌های هوشمند مصنوعی، استان گیلان

۱. مقدمه

در سال‌های اخیر آلودگی گیاهان به فلزات سنگین از طریق منابع کشاورزی، امنیت غذایی و سلامت انسان‌ها را در بسیاری از کشورهای توسعه‌یافته و در حال توسعه تحت تأثیر قرار داده است (Rodriguez *et al.*, 2007). همچنین از جمله مهم‌ترین اثرات آلودگی در یک اکوسیستم، وجود فلزات سنگین در بافت‌های زنده موجودات در یک منطقه آلوده است. تجمع فلزات سنگین در آب، هوا و خاک، یک مشکل زیست‌محیطی بسیار مهم است. یکی از اساسی‌ترین مسائل در ارتباط با فلزات سنگین، عدم متابولیسم شدن آن‌ها در بدن است. در برخی موارد مشاهده شده است که فلزات سنگین پس از ورود به بدن دیگر از بدن دفع نشده بلکه در بافت‌هایی مثل چربی، عضلات، استخوان‌ها و مفاصل رسوب کرده و انباشته می‌گردند که همین امر موجب بروز بیماری‌ها و عوارض متعددی در بدن می‌شود. به‌طور کلی اختلالات عصبی، انواع سرطان‌ها، فقر مواد مغذی، بر هم خوردن تعادل هورمون‌ها از نتایج اثرات ورود فلزات سنگین به بدن انسان است (Schilcher, 1983). مهم‌ترین آلاینده‌های خاک شامل فلزات سنگین، بارش‌های اسیدی و مواد آلی هستند که از این میان فلزات سنگین به‌واسطه غیرقابل تجزیه بودن، سمیت زیاد، اثرات تجمعی و سرطان‌زایی مورد توجه هستند (Mico *et al.*, 2006). کادمیوم از جمله فلزات سنگین است که برای بیشتر ساختارهای زیستی خطر فراوان ایجاد می‌کند و سمیتی ۲ تا ۲۰ برابر بیشتر از سایر عناصر سنگین به همراه دارد (Wasiol *et al.*, 1998). سازمان مواد سمی و بیماری‌های آمریکا^۱ کادمیوم را در اولویت لیست ده ماده خطرناک و سمی خود قرار داده است (Kammeno., 2000). ردیابی و اندازه‌گیری فلزات سنگین برای رشد گیاهان در خاک‌های کشاورزی در یک محدوده وسیع کاری سخت و بعضاً

غیرممکن است. بر اساس مطالعات بررسی غلظت فلزات سنگین در گیاهان مستلزم آزمایش‌های خاک، آنالیز گیاهی و آزمایش‌های بسیار هزینه‌بر و وقت‌گیر صحرائی است (Liu *et al.*, 2011). با گسترش مدل‌های هوشمند در علوم مختلف از جمله کشاورزی و لزوم پیش‌بینی دقیق‌تر جایگزینی آن‌ها به جای مدل‌های قدیمی اهمیت پیدا می‌کند. از جمله مدل‌هایی که با پیشرفت روزافزون در حال گسترش هستند می‌توان به مدل‌های شبکه‌های هوشمند مانند شبکه عصبی مصنوعی از نوع پرسپترون چندلایه (ANN/MLP)، مدل استنتاج تطبیقی عصبی - فازی (ANFIS)، الگوریتم ژنتیک (GA)، برنامه‌ریزی بیان ژن (GEP) و غیره اشاره کرد. از میان مدل‌های مذکور در این پژوهش دو مدل شبکه‌های عصبی مصنوعی و عصبی فازی تطبیقی مورد استفاده قرار گرفت. معضلات زیست‌محیطی یکی از حوزه‌های کاربرد وسیع این‌گونه مدل‌هاست. Liu و همکاران (۲۰۱۱) با استفاده از مدل هوشمند فازی-عصبی به کمک خصوصیات خاک (رطوبت، جوانه‌زنی، pH، تعرق و...) میزان فلزات سنگین را در برنج پیش‌بینی کردند و با مقایساتی که انجام دادند به این نتیجه رسیدند که مدل فازی عصبی خطای کمتر و ضریب تبیین بالاتر و همچنین کارایی بالاتری نسبت به رگرسیون خطی و پرسپترون چندلایه دارد. استفاده از سایر خصوصیات خاک برای رسیدن به میزان آلودگی خاک و آب از مزایای این گونه روش‌هاست به گونه‌ای که Anagu و همکاران (۲۰۰۹) به کمک خصوصیات خاک اعم از بافت خاک، pH، EC، کربن آلی و... با استفاده از شبکه عصبی مصنوعی توانست میزان جذب فلزات سنگین مانند کادمیوم، سرب، آنتیموان را در خاک سطحی و خاک زیرین را با ضریب تبیین ۰/۹۴ و RMSE برابر ۰/۰۶ پیش‌بینی کند. آن‌ها نتیجه گرفتند که مدل شبکه عصبی مصنوعی ابزاری مناسب برای مدل‌سازی جذب فلزات سنگین است. مقایسه این‌گونه روش‌ها در کاربردهای مختلف نشان از فراگیری این روش‌هاست. Murat و Ozgur (۲۰۱۴) به بررسی COD با مقایسه

¹ Agency for Toxic Substances and Disease Registry (ATSDR)

بررسی توانایی و مقایسه استفاده از مدل‌های هوشمند در تخمین پارامتر کادمیوم با استفاده از پارامترهای زود یافت است. از آنجایی که اندازه‌گیری مستقیم پارامتر کادمیوم خاک زمان و هزینه‌بر است، در صورت موفقیت‌آمیز بودن پیش‌بینی فلزات سنگین با استفاده از مدل‌های هوشمند تا حد زیادی می‌توان مشکل صرف زمان و هزینه‌های گزاف را در بخش‌های آزمایشگاهی کاهش داد و همچنین نمونه‌برداری‌ها را به حداقل رساند. مطالعاتی در مورد رابطه بین پارامترهای ورودی با میزان کادمیوم انجام شده است: خاک دارای ماده آلی، رس، pH ظرفیت تبادل کاتیونی و کربنات کلسیم بیشتر، توانایی بیشتری را در جذب فلزهای سنگین دارد (Koleli *et al.*, 2004). در پژوهش دیگری Shuang و همکاران (۲۰۰۹) به بررسی تأثیر pH و ساختمان خاک بر جذب و انتقال کادمیوم در خاک‌ها پرداختند. نتایج حاصل نشان داد که با افزایش رس خاک میزان پخشیدگی کادمیوم در خاک افزایش پیدا می‌کند. مواد آلی و pH خاک از جمله مهم‌ترین فاکتورهای خاک در کنترل دستیابی زیستی کادمیوم هستند (Barančíková *et al.*, 2004). بین pH خاک و جذب کادمیوم توسط گیاه رابطه خطی وجود دارد (Tudoreanu & Phillips, 2004). به دلیل وجود کادمیوم در کودهای فسفره از فسفر نیز استفاده شد.

۲. مواد و روش‌ها

۲.۱. داده‌های مورد استفاده در مدل‌سازی

به منظور مدل‌سازی، داده‌ها به دودسته تقسیم شدند به طوری که ۸۰ درصد داده‌ها برای آموزش و ۲۰ درصد برای صحت‌سنجی اختصاص داده شد (Amini *et al.*, 2005; Menhaj., 2009) برای این منظور دودسته داده به طور تصادفی (بر اساس روش نمونه‌گیری تصادفی ساده^۱) تعیین گردید به طوری که از نظر معیارهای آماری از قبیل میانگین و واریانس تا حد ممکن شبیه

مدل‌های عصبی، عصبی فازی و K نزدیکی پرداختند و نتیجه گرفتند که مدل ترکیبی شبکه عصبی مصنوعی و K نزدیکی بهترین روش با ضریب تبیین ۰/۸۸ برای تخمین COD است. Liu و همکاران (۲۰۱۰) از مقایسه مدل فازی و عصبی فازی برای طیف‌سنجی پارامترهای زیستی و پیش‌بینی مس و کادمیوم استفاده کردند، آن‌ها گزارش کردند که مدل تعمیم‌یافته عصبی فازی پویا با بهترین کارایی، ضریب تبیین برابر با ۰/۹۲ برای مس و ۰/۸۸ برای کادمیوم و کمترین میزان خطا RMSE برابر با ۰/۷۹ برای مس و ۰/۵۷ برای کادمیوم، مناسب‌ترین مدل برای پیش‌بینی میزان کادمیوم و مس است. استفاده از دو مدل مذکور در بحث کشاورزی معطوف به بخش پیش‌بینی محصولات نیز شده است، به گونه‌ای که، Khoshnevisan و همکاران (۲۰۱۴) گزارش کردند مدل عصبی فازی با ضریب تبیین بالا (۰/۹۷) و میزان خطای پایین (RMSE=۰/۰۴۶) محصول گندم را به خوبی و با استفاده از ورودی‌های انرژی پیش‌بینی کرده است. همچنین گزارش کردند استفاده از شبکه‌های عصبی فازی مختلف در سطح‌های متفاوت می‌تواند دقت پیش‌بینی محصول را افزایش دهد. در تمام این مطالعات مشخصاً شبکه عصبی مصنوعی، عصبی فازی و یا ترکیبی از این روش‌ها استفاده شده است که نشان از کاربرد مناسب این روش است، حال آنکه خاک محیطی پویا و متغیر است و از منطقه‌ای به منطقه دیگر تفاوت‌های مشخصی در خصوصیات آن وجود دارد. در این پژوهش هدف استفاده از این مدل‌ها در خاک‌های استان گیلان است که مشخصاً خصوصیات خاک‌های مناطق مرطوبی مانند استان گیلان با مطالعات قبلی که در مناطق خشک و نیمه‌خشک و همچنین مناطق استوایی انجام شده تفاوت‌های فاحشی دارد. مطالعه حاضر باهدف بررسی کارایی دو مدل هوشمند مصنوعی شامل شبکه عصبی مصنوعی (ANN) و شبکه عصبی فازی تطبیقی (ANFIS) برای تخمین میزان کادمیوم خاک در خاک‌های استان گیلان انجام شد. تأکید مطالعه حاضر،

¹ The simple random sampling approach

کربن آلی (O.C.)، درصد شن، درصد رس، ازت کل (T.N.)، فسفر (P) و EC به ترتیب ۰/۱۶، ۰/۱۳، ۰/۰۸، ۰/۱۲، ۰/۰۸، ۰/۰۹، ۰/۱۶ و ۰/۱۱ به دست آمد که بیانگر نرمال بودن توزیع متغیرها است.

هفت ورودی شامل ویژگی فیزیکی و شیمیایی خاک مانند درصد رس، شن، فسفر کل، میزان کربن آلی، میزان نیتروژن خاک، pH و EC برای حصول به بهترین نتیجه به مدل معرفی شد. انتخاب پارامترهای ورودی بر اساس دو معیار تعیین شدند. نخست اینکه همبستگی بالایی با خروجی داشته باشند (همبستگی بین پارامترها با استفاده از محاسبه ضریب همبستگی پیرسون محاسبه شد) و مورد بعد اینکه برای اندازه گیری کم هزینه و زود یافت باشند. همان گونه که در جدول ۱ مشخص شده است، محاسبه مقدار ضریب همبستگی پیرسون بین میزان غلظت کادمیوم خاک و پارامترهای pH، کربن آلی (O.C.)، درصد شن و درصد رس، P، T.N. و EC نشان می دهد که مقدار آن ها به ترتیب ۰/۴۱، ۰/۸۱، ۰/۴۳، ۰/۵۶، ۰/۶۹- و ۰/۵۲ است. همچنین نتیجه آزمون مذکور نشان می دهد که ارتباط بین میزان غلظت کادمیوم خاک و پارامترهای مذکور در سطح ۱ درصد معنی دار است که در جدول ۱ با نماد ستاره (*) مشخص شده است.

یکدیگر باشند همچنین دو گروه داده تفاوت معنی داری در سطح ۵ درصد وجود نداشته باشد (Sarmadian., 2009 Tomasella et al., 2000;).

به منظور بررسی شبیه بودن داده ها از لحاظ میانگین و واریانس در این تحقیق، از آزمون تی تست (t-test) و آزمون لون (Levene) در سطح ۵ درصد استفاده شد. بر اساس نتایج به دست آمده مقدار عدد sig آزمون لون برای پارامترهای غلظت کادمیوم خاک، pH، کربن آلی (O.C.)، درصد شن، درصد رس، ازت کل (T.N.)، فسفر (P) و EC به ترتیب ۰/۳۸۵، ۰/۳۷۰، ۰/۸۲۲، ۰/۱۷، ۰/۱۶، ۰/۹۵ و ۰/۲ به دست آمد. با توجه به اینکه اعداد sig آزمون لون بزرگتر از ۰/۰۵ است، لذا اختلاف واریانس داده ها معنی دار نیست. همچنین مقدار عدد sig در آزمون t-test برای پارامترهای مذکور به ترتیب برابر با ۰/۲۵۴، ۰/۵۴۸، ۰/۰۹، ۰/۲۰، ۰/۲۱، ۰/۲۰۴، ۰/۲۹۶، ۰/۹۲۶ به دست آمد که بیشتر از ۰/۰۵ است، پس اختلاف میانگین داده ها معنی دار نیست. همچنین نرمال بودن داده ها با استفاده از آزمون کالموگروف-اسمیرنوف در نرم افزار SPSS انجام گرفت. نتایج به دست آمده نشان داد که داده ها نرمال نیستند، لذا از رابطه $X_N = \frac{X - X_{min}}{X_{max} - X_{min}}$ برای نرمال سازی استفاده شد که بر اساس مقدار عدد sig آزمون مذکور برای پارامترهای میزان غلظت کادمیوم خاک، pH،

جدول ۱. همبستگی بین ورودی های مدل و میزان کادمیوم به عنوان خروجی (روش پیرسون)

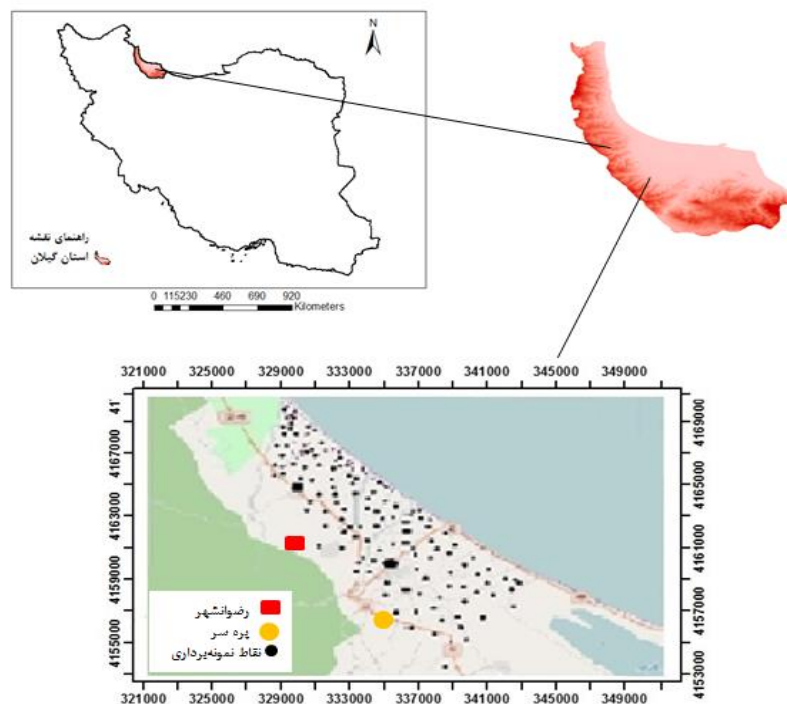
pH	EC (dSm ⁻¹)	فسفر (ppm)	نیتروژن کل (ppm)	شن (درصد)	کربن آلی (درصد)	کادمیوم (ppm)	
۰/۴۱*	۰/۵۲*	۰/۶۹*	۰/۵۶*	-۰/۴۳*	۰/۸۱*	۱	کادمیوم (ppm)
۰/۵۶	۰/۴۱	۰/۴۲	۰/۸۵*	-۰/۶۱	۱		کربن آلی (درصد)
۰/۳۲	۰/۲۵	۰/۳۵	-۰/۵۳	۱			شن (درصد)
۰/۴۹*	۰/۴۱	۰/۴۷	۱				نیتروژن کل (ppm)
۰/۳۳	۰/۲۹	۱					فسفر (ppm)
۰/۳۱	۱						EC (dSm ⁻¹)
۱							pH

*معنی داری در سطح ۱ درصد

اندازه‌گیری آلودگی است و معمولاً آلودگی با افزایش عمق کاهش می‌یابد از لایه‌های سطحی خاک نمونه‌برداری انجام شد، تعداد و موقعیت نمونه‌ها بر اساس وسعت و موقعیت منطقه و امکان نمونه‌برداری به صورت کاملاً تصادفی مشخص شد و پس از آماده‌سازی اولیه بافت خاک به روش هیدرومتری (Bouyoucos., 1962)، فسفر خاک به روش Olsen & Sommers (1982)، pH در خمیر اشباع (Page *et al.*, 1982) و درصد کربن و ماده آلی به روش اکسایش با دی کرومات (Walkly & Black., 1934) فلزات سنگین با روش تیزاب سلطانی ($\text{HNO}_3 + \text{HCl}$) با دستگاه جذب اتمی AA200 ساخت کشور آمریکا اندازه‌گیری شدند (Page *et al.*, 1982).

۲,۲. منطقه مورد مطالعه و داده‌های مورد استفاده

منطقه مورد مطالعه در استان گیلان با مساحت ۱۴۷۱۱ کیلومترمربع در میان رشته‌کوه‌های البرز و تالش در شمال ایران جای گرفته است. استان گیلان بین 36° تا 36° شمالی و $48^{\circ} 25'$ تا 50° شرقی از نصف‌النهار گرینویچ قرار دارد. ۲۵۰ نمونه خاک از عمق (۰-۳۰ سانتیمتری) سطحی خاک از استان گیلان نمونه‌برداری شد (شکل ۱)، به منظور کنترل کیفیت آنالیزها از نمونه‌های استاندارد آزمایشگاهی با دامنه تغییرات حدود ۲ تا ۱۰ پی‌پی‌ام استفاده شد و نتایج حاصل مؤید دقت قابل قبول فرآیند آنالیز بود. نمونه‌برداری از خاک با توجه به هدف نمونه‌برداری از اعماق مختلف انجام می‌گیرد، چون هدف در خصوص



شکل ۱. موقعیت مکان نمونه‌برداری در منطقه مورد مطالعه

قرار گرفته تحریک می‌شود. شبکه عصبی مصنوعی می‌تواند به یک سیستم عصبی با پردازشگرهای همسو برگردد (Bila *et al.*, 1999). نرون‌ها اجزای اصلی شبکه

۳,۲. شبکه عصبی مصنوعی (ANN)

شبکه عصبی مصنوعی الگوریتمی کامپیوتری است که با اطلاعاتی که از سیستم نرون‌ها مورد تجزیه تحلیل

عصبی‌اند که در لایه‌های ورودی و خروجی لایه مخفی دارای اصول و قاعده شده‌اند. معمول‌ترین روش شبکه عصبی در مسائل رگرسیونی شبکه پرسپترون چندلایه (MLP) است (Devabhaktuni et al., 2000). پرسپترون چندلایه متشکل از سه لایه ورودی، خروجی و لایه مخفی یا لایه میانی است. ورودی نرون‌ها شامل ولتاژ بایاس و وزن‌های ورودی‌هاست. خروجی نرون بسته به ورودی نرون و تابع انتقال است (Kimura & Nakano 2000). نرون K با یک ضابطه ریاضی به صورت زیر توصیف می‌شود:

عصبی‌اند که در لایه‌های ورودی و خروجی لایه مخفی دارای اصول و قاعده شده‌اند. معمول‌ترین روش شبکه عصبی در مسائل رگرسیونی شبکه پرسپترون چندلایه (MLP) است (Devabhaktuni et al., 2000). پرسپترون چندلایه متشکل از سه لایه ورودی، خروجی و لایه مخفی یا لایه میانی است. ورودی نرون‌ها شامل ولتاژ بایاس و وزن‌های ورودی‌هاست. خروجی نرون بسته به ورودی نرون و تابع انتقال است (Kimura & Nakano 2000). نرون K با یک ضابطه ریاضی به صورت زیر توصیف می‌شود:

$$U_K = m \sum_{j=1}^m w_{kj} \cdot x_j \quad (1)$$

$$y_k = \varphi(U_k + b_k) \quad (2)$$

که X_1, \dots, X_m سیگنال‌های ورودی‌اند w_{k1}, \dots, w_{km} وزن نرون k اند u_k مقایسه خطی خروجی سیگنال‌های ورودی، b_k ولتاژ بایاس، φ (*) تابع فعال‌سازی و y_k سیگنال خروجی نرون است.

۴.۲. شبکه استنتاج تطبیقی عصبی - فازی

(ANFIS)

شبکه عصبی فازی ترکیبی از شبکه عصبی و سیستم فازی است که از قدرت یادگیری شبکه عصبی برای رول‌های اگر- آنگاه استفاده کرده تا با توابع عضویت مناسب اجزا را آموزش داده و نتیجه پایانی مناسبی را منتج شود (Tay & Zhang., 2000 Azamathulla et al., 2009;). الگوریتم استنتاج فازی به‌عنوان شالوده‌ای از ANFIS روشی است که در آن رول‌های فازی برای استنباط یک تقریب جدید مجموعه فازی که مجموعه فازی را اثبات می‌کند به کار گرفته شده‌اند (Khoshnevisan et al., 2014). سیستم استنتاج فازی (FIS) عمدتاً برای مسائلی که یا مدل کردن دقیق سیستم مشکل است یا توصیف مسئله مورد مطالعه مبهم و دوپهلوی است به کار گرفته می‌شود

همان‌طور که از شکل پیداست، ساختار شبکه ANFIS از ۵ لایه تشکیل شده است: لایه ۱: این لایه، لایه ورودی‌ها است که در آن میزان تعلق هر ورودی به بازه‌های مختلف فازی مشخص می‌شود.


لایه ۲: در این لایه مقادیر ورودی به هر گره در هم ضرب شده و حاصل که وزن ۴ قانون‌ها است، به دست می‌آید.

لایه ۳: گره‌های این لایه عمل محاسبه وزن نسبی قوانین را انجام می‌دهد.

لایه ۴: این لایه، لایه قوانین نامیده می‌شود، قوانین از عملیات بر روی سیگنال‌های ورودی به این لایه به دست

تشکیل شده است. تنها گره این لایه وظیفه جمع‌بندی تمامی ورودی‌های به این گره را بر عهده دارد.

می‌آیند. لایه ۵: این لایه آخرین لایه شبکه است و از یک گره



شکل ۲. شماتیک شبکه استنتاج تطبیقی عصبی فازی با ۵ لایه (جانگ ۱۹۹۳)

۶.۲. ارزیابی مدل

به منظور ارزیابی عملکرد الگوریتم‌های شبکه عصبی و عصبی فازی از پارامترهای آماری مانند ضریب تبیین (R^2) (رابطه ۳)، میانگین خطای مطلق (MAE) (رابطه ۴)، مجذور میانگین مربعات خطا (RMSE) (رابطه ۵) که از روابط زیر قابل محاسبه هستند، استفاده گردید (Wosten *et al.*, 2001).

$$R^2 = \frac{\left[\sum_{i=1}^n (\hat{y}_i - \bar{y})(y_i - \bar{y}) \right]^2}{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2 \sum_{i=1}^n (y_i - \bar{y})^2} \quad (3)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n \left| \hat{y}_j - y_j \right| \quad (4)$$

$$RMSE = \left[\frac{\sum_{i=1}^n (\hat{y}_j - y_j)^2}{n} \right]^{\frac{1}{2}} \quad (5)$$

که در این روابط n تعداد کل نمونه‌ها، y_i مقادیر مشاهده شده، \hat{y}_j خروجی پیش‌بینی شده، \bar{Y} میانگین مقدار پیش‌بینی شده است.

اجرای مدل با استفاده از نرم‌افزار MATLAB R2013a

انجام شد. پارامترهای ورودی (همانند شبکه عصبی) به منظور مقایسه‌ای که در نهایت بین مدل‌ها می‌شود مانند مدل شبکه عصبی در نظر گرفته شد. داده‌ها همانند شبکه عصبی ۸۰٪ برای آموزش مدل و ۲۰٪ مرحله صحت‌سنجی برای نرم‌افزار تعریف شدند.

۵.۲. آنالیز حساسیت

آنالیز حساسیت اطلاعاتی در مورد روابط مهم هریک از متغیرها بیان می‌کند (Schaap & Bouten., 1996). رویه انجام آنالیز حساسیت را Hunter و همکاران (۲۰۰۰) توضیح داده‌اند. اولین شبکه با تمام پارامترها طراحی می‌شود و میزان خطا ثبت می‌شود، شبکه بعدی با حذف یکی از پارامترها شبکه طراحی می‌شود و میزان خطا ثبت می‌شود. میزان حساسیت هر پارامتر آن درصدی از خطا است که با حذف پارامتر از شبکه در مقایسه با خطا اصلی به دست می‌آید. به عبارت دیگر بیشترین تغییر خطا نشان از بیشترین حساسیت شبکه به یک پارامتر است و حساس‌ترین پارامتر یا تأثیرگذارترین پارامتر این‌گونه معرفی می‌شود.

۳. نتایج

شاخص‌های آماری محاسبه‌شده از داده‌های اندازه‌گیری شده از منطقه مورد مطالعه که در جدول ۲ مشخص شده است، نشان می‌دهد، با توجه به pH اندازه‌گیری شده، اسیدیته خاک‌ها تقریباً در حالت خنثی بوده و همچنین ماده آلی خاک همان‌طور که انتظار می‌رود بالاست که با توجه به مرطوب بودن منطقه تقریباً

دارای ۲ درصد ماده آلی است. بافت تقریباً سنگین و نزدیک به رسی، خاک از نظر شوری مساعد است و در بالاترین حد EC برابر ۳/۸ است که نزدیک به حد شوری است. با توجه به میزان کادمیوم و از آنجا که حد معمول غلظت این عنصر سمی در بافت‌های گیاهی ۰/۱ میلی‌گرم بر کیلوگرم و در خاک ۱/۵ تا ۲ میلی‌گرم بر کیلوگرم است (Rump and Krist, 1988) مشخص می‌شود خاک به شدت دچار سمیت کادمیوم است.

جدول ۲. شاخص‌های آماری داده‌های مورد استفاده در مطالعه


پارامتر آماری	pH	کربن آلی (درصد)	شن (درصد)	رس (درصد)	نیترژن کل (ppm)	فسفر (ppm)	EC (dSm ⁻¹)	کادمیوم (ppm)
میانگین	۷/۶۱	۱/۴۹	۳۳/۲۹	۳۷/۸۰	۰/۵۸	۱۱/۷۵۵	۲/۷۶	۷/۲۸
واریانس	۰/۰۵۹	۰/۱۱	۴۹/۷۱	۴۳/۸۳	۰/۰۱۷	۱۳/۹۶	۰/۳۷	۵/۶۵
چولگی	-۰/۲۳	-۰/۵۰	۰/۴۶	-۱/۳۴	-۱/۰۰۴	۰/۷۰	-۰/۶۴	-۰/۱۳
کمترین	۶/۵	۰/۷	۲۰	۱۹	۰/۲۲	۰/۶	۱/۵۰	۱/۳
بیشترین	۷/۵	۲	۵۳	۴۵	۰/۷۴۶	۲۰	۳/۶۰	۱۲/۷
میانگین	۷/۰۹۳۰	۱/۴۱	۲۷/۵۹	۳۶/۲۵	۰/۵۵	۱۲/۲۷	۲/۷۵	۷/۷۱
واریانس	۰/۰۷۸	۰/۰۹۲	۴۸/۸۲	۵۷/۶۹	۰/۰۱۷	۱۱/۲۱	۰/۲۵	۵/۴۵
چولگی	-۰/۷۱	-۰/۴۵	۱/۳۳	-۰/۵	-۰/۲۳	۰/۹۲	-۰/۷۹	۰/۲
کمترین	۶/۱	۰/۶۰	۱۰	۱۲	۰/۱۴	۷	۱/۲۰	۳/۲
بیشترین	۷/۷	۲	۶۸	۵۴	۰/۸۴	۲۳/۵۰	۳/۸۰	۱۳/۳

داده‌های آماری
داده‌های صحت‌سنجی

۱،۳. نتایج شبکه عصبی مصنوعی

ساختارهای مختلفی از شبکه‌های عصبی مختلفی برای پیش‌بینی میزان کادمیوم خاک طراحی شد. برای دستیابی به بهترین نتیجه معماری‌های متفاوت و مختلفی شامل تفاوت در لایه مخفی، توابع عضویت



مختلف برای هر نرون، ترکیب مختلف نرون‌ها در هر لایه مخفی و تعداد مختلف لایه مخفی بررسی شد. بر اساس سعی و خطای انجام‌شده، بهترین شبکه با تعداد ۵ لایه مخفی و ۷ ورودی و یک خروجی بهترین شبکه تعیین شد (شکل ۳).



شکل ۳. مقادیر RMSE لایه‌های پنهان متفاوت برای پیش‌بینی میزان کادمیوم

هرچه تعداد لایه میانی کمتر باشد مناسب‌تر است. Gurney (۱۹۹۷) بیان داشت تعداد مینیمم لایه میانی بیشتر عمومیت دارد. نتایج مدل شبکه عصبی مصنوعی (MLP) در جدول ۳ و شکل ۴ نشان داده شده است.

در مطالعات قبلی Fausett (۱۹۹۴) و Behrens و همکاران (۲۰۰۵) یک لایه میانی همچون Hecht-Nielsen (۱۹۹۱) ۲ لایه میانی را پیشنهاد کردند. Kaluarachchi و Morshed (۱۹۹۸) بیان داشتند که



شکل ۴. میزان کادمیوم پیش‌بینی شده در مقابل میزان اندازه‌گیری شده. الف (در مرحله آموزش) و ب (در مرحله صحت سنجی) با استفاده از مدل MLP

قرار گرفت تا مقدار کادمیوم پیش‌بینی شود. با سعی و خطای انجام شده بهترین روش یادگیری و تابع محرک به ترتیب تابع گوسین و روش یادگیری هیبرید به دست آمد. جدول ۳ و شکل ۵ نتایج حاصل از بهترین ساختار



۲,۳. نتایج مدل عصبی فازی (ANFIS)

همچنین با معرفی متغیرهای ورودی به مدل ساختار مختلفی از مدل استنتاج عصبی فازی (ANFIS) با تغییر دادن توابع محرک و الگوریتم بهینه‌سازی مورد استفاده

به دست آمده از مدل استنتاج عصبی فازی (ANFIS) برای تخمین میزان کادمیوم را نشان می دهد.

جدول ۳. نتایج حاصل از اجرای بهترین تابع شبکه ANFIS برای تخمین میزان کادمیوم

مدل	فلز سنگین	تابع محرک	روش یادگیری	مرحله محاسباتی	ضریب تبیین (R^2)	RMSE	MAE
ANFIS	کادمیوم	گوسین	هایبرید	آموزش صحت یابی	۰/۹۹	۰/۰۷۲۲	۰/۰۰۶۷۳
ANN	کادمیوم	گوسین	-----	آموزش صحت یابی	۰/۸۳	۱/۰۱	۰/۵۴




شکل ۵. پراکنش داده های اندازه گیری شده و پیش بینی شده میزان کادمیوم الف (در مرحله آموزش) و ب (در مرحله صحت سنجی) با استفاده از مدل ANFIS

۳.۳. نتایج آنالیز حساسیت

از آنجایی که آنالیز حساسیت، حساسیت خروجی برای تغییر هر متغیر مستقل را تعیین می‌کند (Safa & Samarasinghe., 2011)، در مطالعه حاضر از نتایج حاصل از مدل شبکه عصبی مصنوعی که با توجه به نتایج کارایی بالاتری از مدل فازی عصبی داشته است، استفاده شد. به این صورت که ابتدا هر یک از متغیرهای ورودی از مدل حذف شد و نتایج مدل‌های مختلف طراحی شده در نظر گرفته شد و متغیری که بیشترین تفاوت در معیارهای سنجش مدل را ایجاد کرد به‌عنوان حساس‌ترین متغیر و به همین صورت میزان حساسیت

مدل به هریک از متغیرها مشخص شد. همان‌گونه که در شکل ۶ نشان داده شده است میزان کربن آلی بیشترین تأثیر را در مدل داشته و حذف آن بالاترین تغییر را در معیارهای سنجش مدل دارد که با نظر Barančíková و همکاران (۲۰۰۴) که گزارش کردند مواد آلی خاک از جمله مهم‌ترین فاکتورهای خاک در کنترل قابلیت در دسترس بودن کادمیوم هستند، مطابقت دارد. همچنین مشاهده می‌شود که میزان EC کمترین سطح تأثیرگذاری بر مدل را داشته است و به عبارتی کم‌اهمیت‌ترین متغیر محسوب می‌شود.



شکل ۶. آنالیز حساسیت سهم لایه‌های ورودی در تخمین میزان کادمیوم خاک

خاک گردیده است که معمولاً این تغییرات منفی بوده و موجب مشکلاتی برای زندگی انسان‌ها و محیط‌زیست می‌شود. کادمیوم در بافت‌های زنده مصرف بیولوژیک نداشته لذا امکان انباشتگی پیدا می‌کند و از آنجاکه حد معمول غلظت این عنصر سمی در بافت‌های گیاهی ۰/۱ میلی‌گرم بر کیلوگرم و در خاک ۱/۵ تا ۲ میلی‌گرم بر کیلوگرم است (Rump and Krist, 1988)، تجمع بیش از این مقدار، می‌تواند باعث آلودگی خاک گردیده و امکان انتقال این عنصر را به زنجیره غذایی انسان فراهم می‌آورد. با توجه به اهمیت موضوع پژوهش حاضر به منظور بررسی ارتباط بین میزان غلظت کادمیوم خاک و عناصر زود

در مجموع با توجه به نتایج به‌دست‌آمده از دو مدل شبکه عصبی و عصبی فازی در پیش‌بینی میزان جذب کادمیوم در خاک مشاهده شد که مدل شبکه عصبی با کارایی بالاتری نسبت به مدل عصبی فازی، میزان جذب کادمیوم را می‌تواند پیش‌بینی کند.

۴. بحث و نتیجه‌گیری

فعالیت و دخالت‌های انسانی در سطح کره زمین منجر به بروز تغییرات فیزیکی، شیمیایی و زیستی از جمله در ارتباط با تغییرات فلزات سنگین مانند میزان کادمیوم در

شبکه عصبی به خوبی توانایی پیش بینی پارامترهای وابسته مختلفی همچون COD را دارا می‌باشند. یکی از دلایل موفقیت آمیز بودن شبکه عصبی در مقابل مدل ANFIS در برآورد عنصر کادمیوم خاک، قابلیت بالای مدل در ایجاد رابطه غیرخطی بین متغیرهای ورودی و خروجی مدل بوده و همچنین حساسیت کم مدل به پراکنش غیر نرمال داده‌ها و همچنین نسبت به سایر شروط روش‌های آماری معمول است (راحتی نمین و همکاران، ۱۳۹۱). این قابلیت و انعطاف پذیری مدل این توانایی را به مدل می‌دهد تا بتواند روابط میان متغیرهای مستقل و وابسته را آشکار کند.

آنالیز حساسیت بر روی پارامترهای مذکور در برآورد میزان کادمیوم مشخص کرد که کربن آلی بیشترین تأثیر را در تغییر این برآورد دارد. تأثیر کربن آلی به عنوان یک کمپلکس مثبت با فلزات سنگین کاملاً قابل پیش بینی و مشخص بود و با فرضیات مطالعه مطابقت داشت. نمونه‌ای مشخص از این ارتباط را می‌توان در مطالعه Barančíková و همکاران (۲۰۰۴) دید که با افزایش کربن آلی خاک میزان فلزات سنگین موجود در خاک نیز افزایش پیدا کرده است. ظرفیت تبادل کاتیونی بالای ترکیبات آلی در خاک عامل اصلی این ارتباط است چرا که با افزایش مواد آلی و به تبع آن کربن آلی باعث افزایش میزان ظرفیت تبادل کاتیونی کل خاک شده و به عبارتی فضای موجود برای جذب فلزات سنگین افزایش می‌یابد. در مجموع نتایج حاصل از این تحقیق حاکی از برتری مدل هوشمند شبکه عصبی مصنوعی به عنوان تکنیکی جایگزین برای روش‌های مرسوم در تخمین متغیرهای مورد نیاز در اتخاذ تصمیمات مدیریتی در بخش کشاورزی است و استفاده از این مدل‌ها می‌تواند از دغدغه‌های مسائل آزمایشگاهی کاهش دهد و جایگزین حجم زیادی از هزینه‌ها شود، چراکه با استفاده از این مدل‌ها نیاز به نمونه برداری در مقیاس بالا نیست و می‌توان با جایگزین کردن مدل‌های هوشمند و برآورد پارامترهای مورد نیاز نمونه برداری و آنالیز نمونه‌ها را به

یافت خاک مانند درصد رس، شن، کربن آلی، pH، EC، T.N و P خاک و همچنین برآورد میزان غلظت کادمیوم خاک با استفاده از مدل‌های ANN و ANFIS انجام گرفت. Anagu و همکاران (۲۰۰۹) و Liu و همکاران (۲۰۱۰) نیز از پارامترهای زود یافت به منظور پیش بینی میزان فلزات سنگین استفاده کردند و گزارش آن‌ها نیز دلیلی بر این ادعاست که با بهره‌گیری از مدل‌های کارآمدی همچون شبکه عصبی می‌توان در مطالعات زیست محیطی وابسته به سلامت انسان همانند معضل فلزات سنگین تغییرات قابل ملاحظه‌ای در نوع و روش مطالعه ایجاد کرد. از مدل‌های هوشمند مذکور جهت برقراری ارتباط میان متغیرهای مذکور (مستقل) و میزان غلظت کادمیوم خاک (وابسته) استفاده گردید. برای ارزیابی مدل و همچنین مقایسه این مدل‌ها معیارهای آماری ضریب تبیین (R^2)، میانگین خطای مطلق (MAE)، مجذور میانگین مربعات خطا (RMSE) بکار برده شد.

اولین یافته‌ای که از پژوهش حاضر به دست آمد، این بود که از توانایی مدل هوشمند مصنوعی می‌توان جهت پیش بینی میزان غلظت کادمیوم خاک بر اساس عناصر زود یافت خاک استفاده کرد و هزینه اندازه‌گیری عناصر دیر یافت خاک را کاهش داد. به عبارتی با توجه به معیارهای آماری مورد استفاده، برای تخمین غلظت کادمیوم روش شبکه عصبی روشی مناسب با بهترین کارایی، بیشترین ضریب تبیین و کمترین میزان خطا است. همچنین نتایج اندازه‌گیری نشان می‌دهد غلظت کادمیوم خاک منطقه مورد مطالعه دارای حداقل ppm ۱/۳ و حداکثر ppm ۱۳/۳ است که این نشان دهنده آلودگی بالای خاک مورد مطالعه است. نتایج خوب مدل شبکه عصبی نشان می‌دهد حتی در صورتی که دامنه تغییرات عنصر مورد مطالعه زیاد باشد، مدل توانایی پیش بینی آن را با کمک متغیرهای کمکی (متغیرهای ورودی به مدل) دارد. همان گونه که محققین دیگر همچون Murat و Ozgur (۲۰۱۴) گزارش کردند که مدل

شکل قابل توجهی کاهش داد. همچنین پیشنهاد می‌شود
عملکرد مدل شبکه عصبی مصنوعی با سایر مدل‌های
هوشمند مانند بردار پشتیبان (SVM)، برنامه‌ریزی بیان
ژن (GEP) و دیگر مدل‌های هوشمند مقایسه شود.

Reference

- Akbarzadeh, A., Mehrjardi, R.T., Rouhipour, H., Gorji, M., Rahimi, H.G., 2009. Estimating of soil erosion covered with rolled erosion control systems using rainfall simulator (neuro-fuzzy and artificial neural network approaches). *Journal of Applied Science Research*, 5: 505–14.
- Amini, M., Afyuni, M., Fathianpour, N., Khademi, H., Fluchler, H., 2005. Continuous soil pollution mapping using fuzzy logic and spatial interpolation. *Geoderma*, 124, 223–233
- Azamathulla, H. M., Chang, C.K., Ghani, A.A., Ariffin, J., Zakaria, N.A., Abu Hasan, Z. 2009. An ANFIS-based approach for predicting the bed load for moderately sized rivers, *Journal of Hydrology and Environmental Research*, 3 35-44.
- Bila, S., Harkouss, Y., Ibrahim, M., Rousset, J., Goya, E., Baillargeat, D., Verdeyme, M., Aubourg, M., Guillon, P., 1999. An accurate wavelet neural-network-based model for electromagnetic optimization of microwave circuits. *International Journal of RF and Microwave Computer-Aided Engineering*, 93: 297–306.
- Barančíková G, Madaras M and Rybár O, 2004. Crop contamination by selected trace elements. *Soils and Sediments*, 4: 37-42.
- Behrens, T., Förster, H., Scholten, T., Steinrücken, U., Spies, E., Goldschmitt, M., 2005. Digital soil mapping using artificial neural networks *Journal of Plant Nutrition and Soil Science*, 168, 21-33.
- Bouyoucos, G.J. 1962. Hydrometer method improved for making particle size analysis of soils. *Agronomy Journal*, 56: 464-465 .
- Covelo, E.F., Andrade, M.L., Vega, F.A., 2004. Heavy metal adsorption by humic umbrisols: selectivity sequences and competitive sorption kinetics, *Journal of Colloid and Interface Science*, 280(1): 1-8
- Coelho, M.C., Farias, T.L., Roupail, N.M., 2005. Impact of speed control traffic signals on pollutant emissions. *Transportation Research Part D*, 10, p. 323–340.
- Devabhaktuni, V., Yagoub, M., Fang, Y., Xu, J., Zhang, Q., 2001. Neural networks for microwave modeling: model development issues and nonlinear modeling techniques, *International Journal of RF and Microwave Computer-Aided Engineering*, 11:4–21
- Erfanmanesh, M., Afyuni. 2000. Environmental pollution: Water, Soil, Air, Fourth Edition, Arkan Publish(In Farsi)
- Fausett, L.V., 1994. *Fundamentals of Neural Networks: Architectures, Algorithms, and Applications*. Prentice Hall, Englewood Cliff, N.J.
- Gurney, K., 1997. *An Introduction to Neural Networks*. UCL press, London
- Hayati, M., Rashdi, A. M., Rezaee, A., 2011. Prediction of grain size of nanocrystalline nickel coatings using adaptive neuro-fuzzy inference system, *Solid State Sciences*, 13, 163-167.
- Hunter, A., Kennedy, L., Henry, J., Ferguson, R.I., 2000. Application of neural networks and sensitivity analysis to improve prediction of trauma survival *Computer Methods and Programs in Biomedicine*. 62,11-19.
- Hecht-Nielsen, R., 1990. *Neuro computing*. Addison-Wesley, Reading, Mass.
- Anagu, I., Ingwersen, J., Utermann, U., Streck, T., 2009. Estimation of heavy metal sorption in German soils using artificial neural networks *Geoderma*. 152. 104–112
- Jang, J.S.R., 1993. ANFIS: adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems, Man and Cybernetics*, 23: 665–685.
- Liu X., Wu J., and Xu, J., 2010a. Characterizing the risk assessment of heavy metals and sampling uncertainty analysis in paddy field by geostatistics and GIS *Environmental Pollution*, 141: 257-264.

- Liu, M.L., Liu, X.N., Li, M., Fang, M.H., Chi, W.X., 2010b. Neural-network model for estimating leaf chlorophyll concentration in rice under stress from heavy metals using four spectral indices. *Biosystems Engineering* 106,223–233
- Kammeno, O., 2000. River flow modeling using artificial neural networks. *ASCE Journal of Hydrology Engineering*, 9 (1): 60–63.
- Kimura, M., Nakano, R., 2000. Dynamical systems produced by recurrent neural networks. *Systems and Computers in Japan*; 31:818–28.
- Khoshnevisan, B., Rafiee, S.H., Omid, M., Mousazadeh, H., 2014. Development of an intelligent system based on ANFIS for predicting wheat grain yield on the basis of energy inputs, *Information Processing in Agriculture*.10:1016.
- Koekkoek, E.J.W., Booltink, H. 1999. Neural network models to predict soil water retention. *European Journal of Soil Science*. 50: 489-495.
- Mirmahmudi, M., 2013. Environmental principles, printing, publishing the University Jihad Mashhad (In Farsi)
- Menhaj, M., 2009. Fundamental of Artificial neural networks. Amirkabir Press. (In Farsi)
- Mico´, C., Recatala´, Peris, M., Sa´nchez, J., 2006. Assessing heavy metal sources in agricultural soils of an European Mediterranean area by multivariate analysis. *Chemosphere*. 65:863–872.
- Morshed, J., Kaluarachchi J.J. (1998) Parameter estimation using artificial neural network and genetic algorithm for free-product migration and recovery. *Water Resource Resesrch*. 34 (5), 1101-1113.
- Olsen, S.R., Sommers, L.E., 1982. Phosphorous. Pp. 423-424. In: *Methods of soil analysis (2nded) part2*. Soil Science Society of America, Madison, WI.
- Page, A. L., Miller, R. H., Keeney, D. R., 1982. Methods of soil analysis. Part 2. Chemical and microbiological properties. American Society of Agronomy. In *Soil Science Society of America (Vol. 1159)*
- Raheli Namin, B., Salman, A., Mahiny., H., Moradi, R., 2012. Quantification of Underground Water Quality Parameters Using Land Use/Cover (Ghareh-Su Watershed, Golestan Province). *Journal of Natural Environment*, 65(1): 67-82.
- Rezaei, M., Majdi, A., Monjezi, M., 2012. An intelligent approach to predict unconfined compressive strength of rock surrounding access tunnels in longwall coal mining. *Neural Computing Application* 24(1):233–241.
- Rodriguez, L., Rinco´ N, J., Asencio I., Rodri´guez-Castellanos, L. 2007. Capabilityof selected crop plants for shoot mercury accumulation from pollutedsoils: phytoremediation perspectives. *International Journal of Phytoremediation* 9, 1–13.
- Rump, P, H. H., Krist, H., 1988. Laboratory manual for the examination of water, wastewater and soil. VCH, New York , U.S.A.
- Safa, M., Samarasinghe, S., 2011. Determination and modelling of energy consumption in wheat production using neural networks, A case study in Canterbury province, New Zealand. *Energy*, 390;36:5140-7.
- Sarmadian, F., Taghizadeh, R. A., Akbarzadeh, E., 2009. Comparison of neuro-fuzzy neural network and multiple regression analysis to predict. *Soil Properties Case Study: Golestan*. *Journal of Soil and Water Research*, 41, 211-220(In Farsi)
- Schaap, M.G., Leij, F.J. 1998. Using neural networks to predict soil water retention and soil hydraulic conductivity *Soil and Tillage Research*, 47: 37–42.
- Schaap, M.G., Bouten, W., 1996. Modelling water retention curves of sandy soils using neural networks. *Water Resource Research*, 32 (10), 3033-3040.
- Schilcher, H., 1983. Contamination of natural products with pesticides and heavy metals Amsterdam: Elsevier Science Publishers; 417-423.
- Shuang, H., Ren Duo, Z., Jia Ying, Z., Rong, P., 2009. Effects of pH and soil texture on the adsorption and transport of Cd in soils, *Journal of Science China Technological Sciences*, 52(11): 3293-3299.
- Tay, J. H., Zhang, X., 2000. A fast predicting neural fuzzy model for high-rate anaerobic wastewater treatment systems, *Water Research*. 34 (11), 2849–2860.

- Tomasella, J., Hodnett, M. G., Rossato, L., 2000. Pedotransfer functions for the estimation of soil water retention in Brazilian soils, *Soil Science Society of America Journal*, 49, 1100-1105.
- Tudoreanu, L., Phillips, C.J.C., 2004. Modeling cadmium uptake and accumulation in plants *Agronomy* 84: 121-157.
- Walkly, A., Black, I.A., 1934. An examination of the degtjareff method for determining soil organic matter and a proposed modification of the chromic acid titration method. *Soil Science* 37: 29-38.
- Wasiol, C.S., Motavalli, P., Kitchen, N.R., Otter, D.K., 1998. Soil phosphorous spatial distribution in pastures receiving poultry litter application. *Agronomy abstracts*. American Society of Agronomy. Madison , W.I.
- Wosten, J. H. M., Pachepsky, Y.A., Rawls, W.J .2001. Pedo transfer functions: bridging the gap between available basic soil data and missing soil hydraulic characteristics. *Journal of Hydrology*. 251, 123–150.
- Yang, F. G., Cao, S. Y., Liu, X. N., Yang, K.J., 2011. Design of groundwater level monitoring network with ordinary kriging *Journal of Hydrodynamic*, 20(3): 339-346.

