

پیش‌بینی میزان سرب خاک با استفاده از خصوصیات زودیافت براساس  
مدل شبکه عصبی مصنوعی  
سامان حاجی‌نمکی، حجت امامی، احمد بازوبندی، امیر فتوت و غلامحسین حق‌نیا

دوره ۳، شماره ۳، پاییز ۱۳۹۶، صفحات ۲۲۴ - ۲۱۴

Vol. 3(3), Autumn 2017, 214 - 224

**Predicting Lead Concentration of Soil using  
Readily Available Properties Based on  
Artificial Neural Network Model**

Haji Namaki S., Emami H., Bazobandi A.,  
Fatovat A. and Haghnia Gh.



[www.jewe.ir](http://www.jewe.ir)

OPEN ACCESS

نحوه ارجاع: حاجی نمکی س.، امامی ح.، بازوبندی ا.، فتوت ا. و حق‌نیا غ. (۱۳۹۶). پیش‌بینی میزان سرب خاک با استفاده از خصوصیات زودیافت براساس مدل شبکه عصبی مصنوعی. محیط‌زیست و مهندسی آب، جلد ۳، شماره ۳، صفحات: ۲۲۴-۲۱۴

**Citing This Paper:** HajiNamaki S., Emami H., Bazobandi A., Fatovat A. and Haghnia Gh. (2017). Predicting lead concentration of soil using readily available properties based on artificial neural network model. J. Environ. Water Eng., 3(3), 214 - 224.

## پیش‌بینی میزان سرب خاک با استفاده از خصوصیات زود یافت براساس مدل شبکه عصبی مصنوعی

سامان حاجی‌نمکی<sup>۱\*</sup>، حجت امامی<sup>۲</sup>، احمد بازوبندی<sup>۳</sup>، امیر فتوت<sup>۴</sup> و غلامحسین حق‌نیا<sup>۴</sup>

<sup>۱</sup> کارشناسی ارشد، گروه علوم خاک، دانشکده کشاورزی، دانشگاه فردوسی، مشهد، ایران

<sup>۲</sup> دانشیار، گروه علوم خاک، دانشکده کشاورزی، دانشگاه فردوسی، مشهد، ایران

<sup>۳</sup> دانشجوی دکتری، گروه علوم خاک، دانشکده کشاورزی، دانشگاه فردوسی مشهد، مشهد، ایران

<sup>۴</sup> استاد، گروه علوم خاک، دانشکده کشاورزی، دانشگاه فردوسی مشهد، مشهد، ایران

نویسنده مسئول\*: samanhajinamaki@gmail.com

نوع مقاله: اصلی

تاریخ دریافت: [۱۳۹۵/۰۷/۳]

تاریخ پذیرش: [۱۳۹۶/۰۳/۱۵]

### چکیده

افزایش تولید آلاینده‌ها از جمله فلزات سنگین یکی از مشکلات جدی و در حال گسترش جامعه بشری است. آلودگی به فلزات سنگین نه تنها بر خصوصیات فیزیکی و شیمیایی خاک تأثیرگذار است، بلکه برای سلامتی انسان از طریق ورود به چرخه غذایی و نفوذ به آب‌های زیرزمینی خطرناک است. مطالعه حاضر با هدف پیش‌بینی میزان سرب خاک به‌عنوان یکی از مهم‌ترین فلزات سنگین با استفاده از خصوصیات زود یافت خاک به کمک مدل شبکه عصبی مصنوعی انجام شد. بدین منظور ۶۳ نمونه از عمق صفر تا ۳۰ سانتی‌متر خاک‌های مختلف واقع در حاشیه رودخانه کشف‌رود در شمال شهرستان مشهد برداشته شد. پارامترهای pH، هدایت الکتریکی، فراوانی نسبی ذرات، کربن آلی و سرب خاک اندازه‌گیری شدند. مدل شبکه عصبی مصنوعی نوع پرسپترون چندلایه برای پیش‌بینی غلظت سرب خاک مورد استفاده قرار گرفت. ارزیابی مدل با استفاده از پارامترهای آماری مانند ضریب تبیین ( $R^2$ )، میانگین خطای مطلق (MAE) و همچنین مجذور میانگین مربعات خطا (RMSE) انجام شد. نتایج نشان داد که کارایی مدل شبکه عصبی مصنوعی مناسب است و می‌تواند به‌عنوان روشی دقیق جهت جایگزین شدن با روش پرهزینه و زمان‌بر اندازه‌گیری مستقیم آزمایشگاهی این فلز سنگین در خاک مورد استفاده قرار گیرد.

واژه‌های کلیدی: سرب؛ شبکه عصبی مصنوعی؛ فلزات سنگین؛ کشف‌رود

## ۱- مقدمه

افزایش تولید آلاینده‌ها از جمله فلزات سنگین یکی از مشکلات جدی و در حال گسترش پیش روی جامعه بشری در عصر حاضر است (Bou-Kheir et al. 2010). یکی از مهم‌ترین آلاینده‌های خاک، فلزات سنگین می‌باشند که باعث کاهش کیفیت خاک می‌شوند. فلزات سنگین گروهی از فلزات و شبه فلزات هستند که مقدار کم آن‌ها هم سمی و خطرناک است. به‌گونه‌ای که از نظر آلاینده‌گی در طبقه اول آلاینده‌ها قرار دارند و در سال‌های اخیر به‌عنوان آلاینده‌های زیست‌محیطی مؤثر بر سلامت انسان، و موجودات زنده بسیار مورد توجه قرار گرفته‌اند (Mirzaee et al. 2015). سرب یکی از آلاینده‌های زیست‌محیطی بوده که برای انسان بسیار سمی است. اگرچه سرب به‌عنوان یک عنصر کم‌تحرک شناخته شده است، اما هنگامی که به شکل‌های محلول در محیط باشد، ریشه گیاه توانایی جذب مقدار زیادی از آن را دارد (Kabata-Pendias 2010). با توجه به اهمیت موضوع، پژوهش‌های زیادی در این زمینه انجام شده است. (Amini et al. 2005) نقشه آلودگی کادمیم و سرب را در خاک‌های منطقه اصفهان، Deligani et al. (2009) غنی‌شدگی و توزیع فلزات سنگین در خاک‌های منطقه ویژه اقتصادی پارس جنوبی و Kasraeian et al. (2014) آلودگی حاصل از پراکنش سرب و نیکل را در اطراف دو کارخانه ذوب فلز در منطقه اصفهان بررسی کردند. جمع‌آوری داده‌ها در فرآیندهای زیست‌محیطی در مقایسه با مدل‌سازی کاری بسیار سخت است (Ghorbani et al. 2015). همچنین تحقیقاتی در رابطه با پارامترهای ورودی و میزان سرب خاک صورت گرفته است. برای مثال خاک دارای ماده آلی، رس، pH، ظرفیت تبادل کاتیونی و کربنات کلسیم بیشتر، توانایی بیشتری را در جذب فلزهای سنگین دارد (Köleli et al. 2004). همچنین (Shuang et al. 2009) به بررسی تأثیر pH و ساختمان خاک بر جذب و انتقال کادمیم و سرب در خاک‌ها پرداختند. تخمین جذب فلزات سنگین، یک مرحله مهم برای تعیین میزان خطر آن‌ها در خاک است که خود بسته به توزیع آن‌ها در خاک و همچنین یافتن راهی برای اصلاح خاک‌های آلوده به این فلزات است. تشخیص میزان خطرناک بودن این فلزات مستلزم مدل‌سازی است. در سال‌های اخیر مدل‌های شبیه‌ساز فرآیندهای خاک، رشد

زیادی داشته‌اند (Ghorbani et al. 2015). تعیین میزان جذب به روش‌های آزمایشی در یک منطقه معمولاً بسیار پرهزینه و زمان‌بر است که روش‌های مدل‌سازی مانند شبکه‌های عصبی مصنوعی برای جایگزین این روش معرفی شده‌اند (Streck Altfelder and Ingwersen 2006; et al. 2007).

کاربرد مدل شبکه عصبی مصنوعی برای پیش‌بینی موارد مختلف در سال‌های اخیر توسط محققان زیادی گزارش شده است. (Singha et al. 2015); (Mitra et al. 2014); (Das et al. 2015); (Bar et al. 2010) از شبکه‌عصبی مصنوعی به‌منظور پیش‌بینی درصد حذف سرب از محلول‌های آبی به‌وسیله ضایعات کشاورزی استفاده کردند. آن‌ها گزارش کردند شبکه‌عصبی مصنوعی با دقت بالا این پیش‌بینی را انجام داده است. (Singha et al. 2015) با استفاده از مدل شبکه‌عصبی مصنوعی میزان جذب سرب به‌وسیله مواد مختلف از محلول‌های آبی را پیش‌بینی و گزارش کردند، شبکه‌عصبی-مصنوعی با کارایی بالاتر نسبت به سایر مدل‌ها میزان جذب سرب را پیش‌بینی کرده است. این مطالعه جهت تخمین سرب به‌عنوان یک خصوصیت دیریافت و پرهزینه خاک (اندازه‌گیری سرب) با استفاده از خصوصیات زودیافت طرح‌ریزی شده است. بررسی منابع نشان می‌دهد تا به‌حال تحقیقی در زمینه بررسی و پیش‌بینی جذب سرب خاک در مناطق گرم و خشک و نیمه‌خشک مانند مشهد انجام نشده است. بنابراین در تحقیق حاضر با استفاده از خصوصیات فیزیکی و شیمیایی زودیافت خاک به پیش‌بینی آن به کمک شبکه‌عصبی مصنوعی پرداخته شد.


## ۲- مواد و روش‌ها

## ۲-۱- منطقه مورد مطالعه

منطقه مورد مطالعه در حاشیه رودخانه کشف‌رود در قسمت شمال شرقی مشهد واقع و دارای اراضی کشاورزی به وسعت ۸۷۰۰ (ha) است. آبیاری این منطقه در ابتدا با آب چاه ولی در زمان کنونی به دلیل محدودیت شدید آبی که در استان خراسان رضوی وجود دارد، به‌منظور ادامه کشاورزی، استفاده بهینه از منابع آبی موجود و جلوگیری از آلودگی محیط‌زیست به سبب رها نمودن فاضلاب خام در بخشی از زمین‌های

این منطقه دارای اقلیم خشک تا نیمه‌خشک و در آن متوسط بارندگی سالیانه ۲۵۰ میلی‌متر، متوسط درجه حرارت سالیانه ۱۵/۶ درجه سانتی‌گراد و میزان تبخیر سالانه ۲۲۲۵ میلی‌متر است.

حاشیه رودخانه از پساب حاصل، از تصفیه فاضلاب شهری برای آبیاری اراضی این منطقه استفاده می‌شود. منطقه مورد مطالعه بین ۵۹ درجه و ۳۶ دقیقه تا ۵۹ درجه و ۸۷ دقیقه طول شرقی و ۳۶ درجه و ۲۴ دقیقه تا ۳۶ درجه و ۵۸ دقیقه عرض شمالی قرار گرفته است (شکل ۱).



شکل ۱- نقشه منطقه مطالعاتی مورد نظر

دستگاه pH متر مدل Ohmmeter 632 در گل اشباع و شوری با هدایت سنج الکتریکی (مدل JENWAY 4310) در عصاره اشباع (Richards 1954) اندازه‌گیری شد. بافت خاک به روش پیپت (Schipper et al. 1996)، کربن آلی خاک به روش Walkley and Black (1934) و غلظت عنصر سنگین سرب با استفاده از عصاره‌گیر DTPA و با دستگاه جذب اتمی (Lindsay and Norvell 1978) تعیین شدند.

نورون‌ها اجزاء اصلی شبکه‌عصبی‌اند که در لایه‌های ورودی و خروجی لایه مخفی، دارای اصول و قاعده شده‌اند. معمول‌ترین روش شبکه‌عصبی در مسائل رگرسیونی شبکه پرسپترون چندلایه ( $MLP^2$ ) است (Devabhaktuni

## ۲-۲- داده‌های تحقیق

تعداد ۶۳ نمونه خاک از مناطق مختلف حوضه رودخانه کشف‌رود از عمق صفر تا ۳۰ سانتی‌متر برداشته شد. نمونه‌برداری به صورت تصادفی، قبل از کشت گیاه در بهمن ۱۳۹۳ انجام گرفت. نمونه‌ها پس از جمع‌آوری به آزمایشگاه خاک‌شناسی دانشکده کشاورزی دانشگاه فردوسی منتقل شدند. سپس جهت آنالیزهای شیمیایی قسمتی از خاک هوا خشک و از الک ۲ میلی‌متری عبور داده شد. pH خاک با

## ۲-۳- شبکه عصبی مصنوعی

شبکه‌عصبی مصنوعی ( $ANN^1$ ) الگوریتمی کامپیوتری است که با اطلاعاتی که از سیستم نورون‌ها مورد تجزیه و تحلیل قرار گرفته، ایجاد می‌شود. شبکه‌عصبی مصنوعی می‌تواند به یک سیستم عصبی با پردازشگرهای همسو برگردد (Bila et

<sup>2</sup> Multilayer perceptron

<sup>1</sup>Artificial neural network

در لایه میانی، توابع عضویت مختلف برای هر نورون، ترکیب مختلف نورون‌ها در هر لایه میانی و تعداد مختلف لایه میانی بررسی شد. شش ورودی شامل درصد رس، شن، سیلت، مقدار کربن آلی، pH و EC برای گرفتن بهترین نتیجه به مدل معرفی شدند. انتخاب پارامترهای ورودی بر اساس دو معیار تعیین شدند. نخست اینکه همبستگی بالایی با خروجی داشته باشند و دوم اینکه برای اندازه‌گیری کم‌هزینه و زود یافت باشند. به‌منظور مقایسه عملکرد مدل شبکه عصبی MLP از پارامترهای آماری مانند ضریب تبیین ( $R^2$ ) (رابطه ۳)، میانگین خطای مطلق (MAE) (رابطه ۴)، و همچنین مجذور میانگین مربعات خطا (RMSE) به‌صورت رابطه (۵) استفاده گردید (Wosten et al. 2001).

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

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

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

میزان هدایت الکتریکی و pH می‌باشند. با توجه به جدول (۱) مشاهده می‌شود خاک‌های منطقه مطالعاتی از نظر ویژگی‌های فیزیکی و شیمیایی بدون محدودیت بودند، به‌گونه‌ای که pH در محدوده خنثی، شوری خاک در حالت مساعد و از نظر مواد آلی فقیر بودند.

(et al. 2000). پرسپترون چندلایه متشکل از سه لایه ورودی، خروجی و لایه مخفی (لایه میانی) است. ورودی نورون‌ها شامل ولتاژ بایاس و وزن‌های ورودی‌هاست. خروجی نورون بسته به ورودی نورون و تابع انتقال است (Kimura and Nakano 2000). نورون K با یک قانون ریاضی به‌صورت روابط (۱) و (۲) زیر توصیف می‌شود:

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

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

که  $X_m$  سیگنال‌های ورودی،  $w_{k1} \dots w_{km}$  وزن نورون  $k$ ، مقایسه خطی خروجی سیگنال‌های ورودی،  $b_k$  ولتاژ بایاس،  $\varphi$  تابع فعال‌سازی و  $y_k$  سیگنال خروجی نورون است. به‌منظور مدل‌سازی، داده‌ها به دودسته تقسیم شدند به‌طوری‌که ۸۰ درصد داده‌ها برای آموزش و ۲۰ درصد برای صحت‌سنجی اختصاص داده شدند (Amini et al. 2005). (Menhaj 2009) برای این منظور دودسته داده به‌طور تصادفی تعیین گردید. به‌طوری‌که از نظر معیارهای آماری از قبیل میانگین و انحراف معیار تا حد ممکن شبیه یکدیگر باشند. همچنین دو گروه داده تفاوت معنی‌داری در سطح ۵ درصد نداشتند (Sarmadian et al. 2009). برای دست‌یابی به بهترین نتیجه ساختارهای متفاوت و مختلفی شامل تفاوت

### ۳- یافته‌ها و بحث

#### ۳-۱- آنالیز داده‌های آزمایش

داده‌های استفاده‌شده در مرحله آموزش و صحت‌سنجی در جدول (۱) ارائه‌شده است. داده‌های استفاده‌شده در مدل شامل درصد ذرات رس، شن، سیلت و کربن آلی همچنین

جدول ۱- معیارهای آماری داده‌های مورد استفاده در مطالعه حاضر

| سیلت (%) | شن (%) | رس (%) | pH   | OC (%) | EC (dS/m) | Pb (mg/kg) | پارامتر آماری |                  |
|----------|--------|--------|------|--------|-----------|------------|---------------|------------------|
| ۴۶/۶۱    | ۲۷/۱۴  | ۲۶/۲۲  | ۷/۸۲ | ۰/۷    | ۱/۱۱      | ۱/۳۸       | میانگین       | داده‌های آموزشی  |
| ۵۰/۶۳    | ۱۲۳/۱۹ | ۹۴/۳۸  | ۰/۰۴ | ۰/۰۴   | ۰/۳۴      | ۰/۶۲       | واریانس       |                  |
| -۰/۲۸    | ۰/۹۲   | ۰/۶۸   | ۰/۰۸ | ۱/۰۹   | ۲/۳۵      | ۱/۴        | چولگی         |                  |
| ۳۱       | ۱۲/۵   | ۹/۵    | ۷/۱۴ | ۰/۲۷   | ۰/۴۲      | ۰/۲۴       | کمترین        |                  |
| ۶۱       | ۵۸     | ۵۱     | ۸/۳۴ | ۱/۳۲   | ۳/۹       | ۳/۸۶       | بیشترین       |                  |
| ۴۷/۰۴    | ۲۷/۵   | ۲۵/۴۶  | ۷/۹۹ | ۰/۵۱   | ۰/۶       | ۱/۴۷       | میانگین       |                  |
| ۲۷/۲۲    | ۲۰/۵۴  | ۱/۸۱   | ۰/۰۲ | ۰/۰۱   | ۰/۰۴      | ۰/۵۶       | واریانس       | داده‌ها صحت سنجی |
| -۱/۲۱    | ۰/۹۹   | ۰/۴۵   | ۰/۸  | -۰/۷۳  | ۰/۷       | -۰/۵۹      | چولگی         |                  |
| ۳۷/۵     | ۲۲/۵   | ۲۳/۵   | ۷/۷۸ | ۰/۲۷   | ۰/۳۶      | ۰/۲۴       | کمترین        |                  |
| ۵۱/۵     | ۳۵/۵   | ۲۸     | ۸/۳۶ | ۰/۶۶   | ۱/۰۳      | ۲/۳۲       | بیشترین       |                  |

هستند (Barančíková et al. 2004). همان‌گونه که در جدول (۲) مشخص شده است، سرب بیشترین همبستگی را با کربن آلی، pH و میزان رس خاک دارد که با مطالعات قبلی همخوانی دارد (Shuang et Barančíková et al. 2004; al. 2009; Köleli et al. 2004).

جدول (۲) همبستگی بین سرب و پارامترهای ورودی را نشان می‌دهد. نتایج حاصل نشان داد که با افزایش رس خاک میزان پخشیدگی کادمیم و سرب در خاک افزایش پیدا می‌کند. مواد آلی و pH خاک از جمله مهم‌ترین فاکتورهای خاک در کنترل قابلیت در دسترس بودن کادمیم

جدول ۲- همبستگی بین داده‌های ورودی و میزان سرب

| سیلت (%) | شن (%)  | رس (%) | pH     | OC (%) | EC (dS/m) | Pb (mg/kg) |            |
|----------|---------|--------|--------|--------|-----------|------------|------------|
| ۰/۱۹     | ۰/۲۷    | ۰/۳۹** | ۰/۴۹** | ۰/۵۲** | ۰/۱۴      | ۱          | Pb (mg/kg) |
| -۰/۰۸۲   | ۰/۰۵۲   | ۰/۰۱   | ۰/۳۷** | ۰/۰۲۹  | ۱         |            | EC (dS/m)  |
| ۰/۴۷**   | -۰/۵۹** | ۰/۳۲** | ۰/۴۱** | ۱      |           |            | OC (%)     |
| -۰/۰۵۳   | ۰/۱۶    | -۰/۱۵  | ۱      |        |           |            | pH         |
| -۰/۱۶    | ۰/۷۵**  | ۱      |        |        |           |            | رس (%)     |
| -۰/۵۳**  | ۱       |        |        |        |           |            | شن (%)     |
| ۱        |         |        |        |        |           |            | سیلت (%)   |

\*\* همبستگی در سطح ۰/۰۱ معنی دار است


نمودار (۱) نشان داده شده است. در مدل شبکه عصبی علاوه بر انتخاب تعداد لایه‌ها، انتخاب نوع تابع انتقال بر نتایج شبکه عصبی تأثیرگذار است. برای رسیدن به بهترین عملکرد چهار تابع فعال‌سازی سیگموئیدی، گاوسین، هایپربولیک سکانت و هایپربولیک تانژانت از نظر دقت پیش‌بینی مقایسه شدند (Ghorbani et al. 2015). بهترین مدل با پنج لایه میانی تابع فعال‌سازی سیگموئید انتخاب شد. همان‌گونه که در جدول (۳) مشخص شده است، تابع انتقال سیگموئیدی با

### ۳-۲- شبکه عصبی مصنوعی

حالت‌های مختلف شبکه عصبی مصنوعی برای پیش‌بینی میزان سرب طراحی شد، به‌گونه‌ای که با اعمال تغییر در تعداد نورون‌ها و نوع توابع فعال‌سازی، سعی در بهبود دقت مدل و کاهش میزان خطا شد. شکل (۲) نشان‌دهنده میزان خطا در انتخاب هر یک از لایه‌های میانی است. تعداد لایه میانی مدل با سعی و خطا پنج لایه به دست آمد که در

۰/۰۶ در مرحله صحت‌سنجی بهترین عملکرد را در پیش‌بینی میزان سرب خاک داشتند.

داشتن ضریب تبیین ( $R^2$ )، مجذور میانگین مربعات خطا (RMSE) و میانگین خطای مطلق (MAE) به ترتیب برابر با ۰/۹۴، ۰/۱۱۳ و ۰/۰۴۲ در مرحله آموزش و ۰/۸۶، ۰/۱۵۷ و




نمودار ۲- مقادیر RMSE لایه‌های میانی متفاوت برای پیش‌بینی میزان سرب

جدول ۳- نتایج حاصل از شبکه‌عصبی مصنوعی برای پیش‌بینی میزان سرب

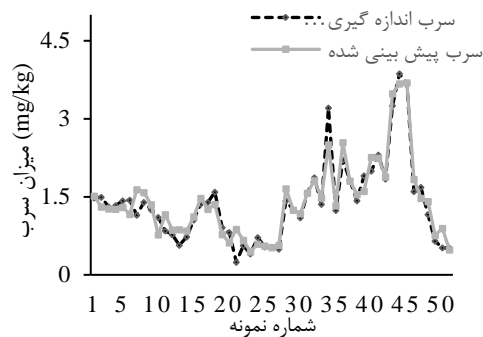
| آلاینده | تابع محرک          | تعداد لایه‌های پنهان | مرحله محاسباتی | ضریب تبیین ( $R^2$ ) | RMS Error (mg/kg) | MAE (mg/kg) |
|---------|--------------------|----------------------|----------------|----------------------|-------------------|-------------|
| سرب     | گاوسین             | ۵                    | آموزش          | ۰/۸۱                 | ۰/۴۷              | ۰/۹۷        |
|         | سکانت هایپربولیک   | ۵                    | آموزش          | ۰/۳۸                 | ۲/۲۷              | ۳/۸         |
|         | تانژانت هایپربولیک | ۵                    | آموزش          | ۰/۶۲                 | ۱/۸۴              | ۲/۲۹        |
|         | سیگموئید           | ۵                    | آموزش          | ۰/۹۴                 | ۰/۱۱۳             | ۰/۰۴۲       |
|         | گاوسین             | ۵                    | صحت یابی       | ۰/۷۴                 | ۰/۸۳              | ۱/۱۷        |
|         | سکانت هایپربولیک   | ۵                    | صحت یابی       | ۰/۴۲                 | ۳/۲۸              | ۶/۷         |
|         | تانژانت هایپربولیک | ۵                    | صحت یابی       | ۰/۵۸                 | ۲/۴۷              | ۳/۲         |
|         | سیگموئید           | ۵                    | صحت یابی       | ۰/۸۶                 | ۰/۱۵۷             | ۰/۰۶۰       |

است که اظهار داشتند شبکه‌عصبی مصنوعی می‌تواند فلز سنگین سرب را به‌خوبی پیش‌بینی کند، است. همان‌طور که در شکل‌های (۳) و (۴) نشان داده شده است اختلاف بین مقادیر اندازه‌گیری شده و پیش‌بینی شده به‌وسیله مدل در هر دو مرحله آموزش و صحت‌سنجی ناچیز است. به‌طوری‌که مقدار ضریب تبیین بین مقدار سرب اندازه‌گیری شده و پیش‌بینی شده به‌وسیله مدل در مراحل آموزش و صحت‌سنجی به ترتیب برابر با ۰/۹۴ و ۰/۸۶ می‌باشد که نشان‌دهنده دقت بالای مدل است.

میزان سرب پیش‌بینی شده در مقابل میزان سرب اندازه‌گیری شده در مراحل آموزش و صحت‌سنجی با استفاده از ساختار بهینه مدل به‌دست‌آمده (مدل با تابع انتقال سیگموئید و پنج لایه میانی) در نمودارهای (۳) و (۴) نشان داده شده است. با توجه به نتایج جدول (۳) میزان RMSE و MAE در مراحل آموزش و صحت‌سنجی به ترتیب برابر (۰/۱۱۳ و ۰/۱۵۷) و (۰/۰۴۲ و ۰/۰۶) است و این گویای کارایی بالای مدل است. نتیجه به‌دست‌آمده در تطابق با نتایج سایر محققین از جمله Bazoobandi et al. (2015) و Anagu et al. (2009)




ب- صحت سنجی




الف- آموزش

نمودار ۳- مقایسه پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده سرب برای مرحله: الف- آموزش و ب- صحت سنجی



ب- صحت سنجی



الف- آموزش

نمودار ۴- نمودار همبستگی داده‌های پیش‌بینی شده و اندازه‌گیری شده سرب برای مرحله: الف- آموزش و ب- صحت سنجی

### ۳-۳- آنالیز حساسیت

آنالیز حساسیت اطلاعاتی در مورد روابط مهم هریک از متغیرها بیان می‌کند (Bouten and Schaap 1996). آنالیز حساسیت به روش (Hunter et al. 2000) انجام شد. در این روش 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 خطای اصلی به دست می‌آید. به عبارت دیگر بیشترین تغییر خطا، نشان از بیشترین حساسیت شبکه به یک پارامتر خاص بوده و حساس‌ترین پارامتر یا تأثیرگذارترین پارامتر این‌گونه معرفی می‌شود. با توجه به جدول (۴) مشاهده می‌شود که بیشترین تغییر در میزان ضریب تبیین و خطا با حذف میزان کربن آلی از مدل به دست آمده است. میزان هدایت الکتریکی کمترین تغییر را در میزان خطا و ضریب تبیین ایجاد کرده است. با توجه به جدول (۴) مشاهده می‌شود که با حذف مقدار کربن آلی، بیشترین افزایش در  $RMSE$  و  $R^2$  ایجاد شده است. بنابراین کربن آلی به عنوان پارامتر مهم یا تأثیرگذار محسوب می‌شود. دلیل این حساسیت این است که میزان جذب سرب متأثر از میزان کربن آلی است (Streck and Richter 1997; Ingwersen 2001).



جدول ۴- آنالیز حساسیت داده‌های ورودی بر سرب خاک

| R <sup>2</sup> | RMSE | MAE   | روش                     |
|----------------|------|-------|-------------------------|
| ۰/۸۶           | ۰/۱۵ | ۰/۰۶۰ | بهترین مدل MLP          |
| ۰/۸۱           | ۲/۱۱ | ۱/۸۱  | MLP بدون pH             |
| ۰/۸۲           | ۱/۸۳ | ۱/۲۹  | MLP بدون شن             |
| ۰/۷۹           | ۲/۸۱ | ۲/۱۷  | MLP بدون رس             |
| ۰/۸۵           | ۰/۸۳ | ۰/۲۷  | MLP بدون هدایت الکتریکی |
| ۰/۸۳           | ۱/۲  | ۱/۰۴  | MLP بدون سیلت           |
| ۰/۶۸           | ۳/۲۵ | ۲/۸۹  | MLP بدون کربن آلی       |

#### ۴- نتیجه‌گیری

۲. با توجه به میزان خطای پایین ( $RMSE=0/15$ ) و ضریب تبیین بالای مدل ( $R^2=0/86$ ) می‌توان نتیجه گرفت روش شبکه‌عصبی مصنوعی روشی مناسب جهت این مدل‌سازی بوده است.

۳. اختلاف بین میزان پیش‌بینی و میزان اندازه‌گیری شده بسیار اندک بود و نتایج به‌خوبی کارایی بالای مدل شبکه‌عصبی مصنوعی را در این مطالعه نشان داد.

۴. با انجام آنالیز حساسیت مشخص شد که در مدل شبکه‌عصبی طراحی‌شده میزان کربن آلی و رس بیشترین تأثیر را در پیش‌بینی میزان سرب خاک و همچنین میزان هدایت الکتریکی کمترین تأثیر را داشت که به رفتار این عوامل در برابر سرب در واکنش‌های خاک برمی‌گردد.

مطالعه حاضر به‌منظور ارزیابی روش‌های هوش مصنوعی مانند مدل شبکه‌عصبی مصنوعی برای پیش‌بینی میزان سرب با استفاده از ویژگی‌های فیزیکی و شیمیایی زود یافت خاک انجام شد. بدین منظور مدل شبکه‌عصبی مصنوعی نوع پرسپترون چندلایه (MLP) با ساختارهای مختلف از نظر تعداد لایه‌ها و نوع توابع انتقالی طراحی شد. شبکه‌عصبی-مصنوعی توسط تعداد زیادی از محققان در بحث‌های زیست‌محیطی استفاده شده است و برای تکمیل کاربرد این روش‌ها در این موضوع خاص تحقیقات زیاد دیگری لازم است. مهم‌ترین نتایج این پژوهش را می‌توان به‌صورت زیر بیان نمود:

۱. بهترین تابع انتقالی تابع سیگموئیدی و تعداد ۵ لایه میانی با بالاترین ضریب تبیین و کمترین میزان خطا انتخاب شد.

#### References

- Altfielder S., Duijnsveld W. H. M., Streck T., Meyenburg G. and Utermann J. (2007). Quantifying the influence of uncertainty and variability on groundwater risk assessment for trace elements. *Vandose Zone J.*, 6, 668-678.
- Amini M., Abbaspour K. C., Khademi H., Fathianpour N., Afyuni M. and Schulin R. (2005). Neural network models to predict cation exchange capacity in arid regions of Iran. *Euro. J. Soil Sci.*, 56, 551-559.
- Anagu I., Ingwersen J., Utermann U. and Streck T. (2009). Estimation of heavy metal sorption in German soils artificial neural networks. *Geoderm.*, 152, 104-112.
- Kasraeian A., Karimian N., and Ghafouri V. (2014). Evaluation of spatial distribution of soil cadmium and cadmium hot points in a part of an arable lands in west of Shiraz in Fars Province by kriging method. *Water Wastewater*, 4, 44-50.
- Bar N., Biswas M. N. and Das, S. K. (2010). Prediction of pressure drop using artificial neural network for gas non-Newtonian liquid flow through piping

- components. *Indus. Eng. Chem. Res.*, 49, 9423-9429.
- Barančíková G., Madams M. and Rybář O. (2004). Crop contamination by selected trace elements. *J. Soil Sedim.*, 4, 37-42.
- Bazoobandi A., Saberi I., Ghorbani H. and Emamgholizadeh S. (2015). Prediction of soil Cd and pb using neural network. 5<sup>th</sup> Int. conference on novel finding in bioscience and agriculture, Tehran [In Persian].
- Das B., Ganguly N., Bar N., and Das S.K. (2015). Holdup prediction in inverse fluidization using non-Newtonian pseudoplastic liquids: Empirical correlation and ANN modeling. *Powder Technol.* 273, 83-90.
- Deligani F., Khazemi G., Parvinnia M. and Khakshor M. (2009). Enrichment and distribution of heavy metals in soils of South Pars Special Economic Zone in Assaluyeh. 5<sup>th</sup> Int. Conference on Civil Engineering, University of Shiraz [In Persian].
- Ghorbani H., Kashi H., Hafezi Moghadas N. and Emamgholizadeh S. (2015). Estimation of soil cation exchange capacity using multiple regression, artificial neural networks, and adaptive neuro-fuzzy inference system models in Golestan Province, Iran. *Commun. Soil Sci. Plant Anal.*, 46, 763-780.
- Hunter A., Kennedy L., Henry J. and Ferguson I. (2000). Application of neural networks and sensitivity analysis to improve prediction of trauma survival. *Comput. Meth. Prog. Bio.*, 62, 11- 19.
- Ingwersen J. (2001). The environmental fate of cadmium in the soils of the waste water irrigation area of Braunschweig: measurement, modeling and assessment. PhD thesis, Technische, Universität Braunschweig, Germany.
- Ingwersen J. and Streck T. (2006). Modeling the environmental fate of cadmium in a large wastewater irrigation area. *J. Environ. Qual.*, 35, 1702- 1714.
- Kabata-Pendias A. (2010). Trace elements in soils and plants. CRC press.
- Bou-Kheir R., Greve M. H., Abdallah C. and Dalgaard T. (2010). Spatial soil zinc content distribution from terrain parameters: A GIS-based decision-tree model in Lebanon. *Environ. Pollut.*, 158, 520-528.
- Köleli N., Eker S. and Cakmak I. (2004). Effect of zinc fertilization on cadmium toxicity in durum and bread wheat grown in zinc-deficient soil. *Environ. Pollut.*, 131, 453-459.
- Lindsay W. L. and Norvell W. A. (1978). Development of a DTPA soil test for zinc, iron, manganese, and copper. *Soil Sci. Soci. Am. J.*, 42, 421-428.
- Menhaj M. (2009). Fundamental of artificial neural networks. Amirkabir Press [In Persian].
- Mirzaee R., Ghorbani H. and Hafezimoghghaddam N. (2015). The distribution pattern of heavy metals in the surface soils of Golestan Province. *Res. Soil (Soil Sci. Water)*, 1, 93-103 [In Persian].
- Mitra T., Singha B., Bar N. and Das S. K. (2014). Removal of Pb (II) ions from aqueous solution using water hyacinth root by fixed-bed column and ANN modeling. *J. Hazard. Mat.*, 273, 94-103.
- Richards L. A. (1954). Diagnosis and improvement of saline and alkali soils. *Soil Sci.*, 78, 154.
- Sarmadian F., Taghizadeh R. A. and Akbarzadeh E. (2009). Comparison of neuro-fuzzy neural network and multiple regression analysis to predict soil properties (Case Study: Golestan). *J. Soil Water Res.*, 41, 211-220 [In Persian].

- Bouten W. and Schaap M. G. (1996). Modelling water retention curves of sandy soils using neural networks. *Water Res.*, 32, 3033-3040.
- Schipper L. A., Williamson J. C., Kettles H. A. and Speir T. W. (1996). Impact of land-applied tertiary-treated effluent on soil biochemical properties. *J. Environ. Qual.*, 25, 1073-1077.
- Shuang H., RenDuo Z., JiaYing Z. and Rong P. (2009). Effects of pH and soil texture on the adsorption and transport of Cd in soils. *J. Sci. China Ser. E-Tech Sci.*, 52(11), 3293-3299.
- Singha B., Bar N. and Das S. K. (2015). The use of artificial neural network (ANN) for modeling of Pb(II) adsorption in batch process. *J. Molecul. Liquids*, 211, 228-232.
- Streck T. and Richter J. (1997). Heavy metal displacement in a sandy soil at the field scale: I Measurements and parameterization of sorption. *J. Environ. Qual.*, 26, 49-56.
- Walkley A. and 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 Sci.*, 37, 29-38.
- Wosten J. H. M., Pachepsky Y. A. and Rawls W. J. (2001). Pedotransfer functions: bridging the gap between available basic soil data and missing soil hydraulic characteristics. *J. Hydro.*, 251, 123-150.
- Bila S., Harkouss Y., Ibrahim M., Rousset J., Goya E., Baillargeat D., Verdeyme M., Aubourg M. and Guillon P. (1999). An accurate wavelet neural-network-based model for electromagnetic optimization of microwave circuits. *Int. J. RF. Microwave Comput.- aided Eng.*, 93, 297-306.
- Devabhaktuni V., Yagoub M., Fang Y., Xu J. and Zhang Q. (2001). Neural networks for microwave modeling: model development issues and nonlinear modeling techniques, *Int. J. RF. Microwave Comput.-aided Eng.*, 11, 4-21.
- Kimura M. and Nakano R. (2000). Dynamical systems produced by recurrent neural networks. *Sys. Comput. Japan.*, 31, 818-28.

## Predicting Lead Concentration of Soil using Readily Available Properties Based on Artificial Neural Network Model

**Saman Haji Namaki<sup>1\*</sup>, Hojjat Emami<sup>2</sup>, Ahmad Bazobandi<sup>3</sup>, Amir Fatovat<sup>4</sup>,  
and GholamHossein Haghnia**

<sup>1</sup> M.Sc., Soil Science Department, Faculty of Agriculture, Ferdowsi University, Mashhad, Iran

<sup>2</sup> Associate Prof., Department of Soil Sciences, Faculty of Agriculture, Ferdowsi University, Mashhad, Iran

<sup>3</sup> Ph.D. Scholar., Soil Science Department, Faculty of Agriculture, Ferdowsi University, Mashhad, Iran

<sup>4</sup> Prof., Department of Soil Sciences, Faculty of Agriculture, Ferdowsi University, Mashhad, Iran

\*Corresponding author: samanhajinamaki@gmail.com

Type of Paper: **Original**

Received: September 24, 2016

Accepted: June 5, 2017

### Abstract

Increased generation of pollutants such as heavy metals is one of the serious and developing environmental issues threatening human society. Heavy metal pollution not only affects the physical and chemical properties of the soil but also it is dangerous to human health through entering into the food chain and finding its way into the groundwater. The present study was conducted to predict soil lead concentration, as one of the most important heavy metals, using readily available soil properties based on artificial neural network model. For this purpose, 63 soil samples were collected from 60-cm depth of the land surrounding Kashafrud River located in Mashhad City. Measured parameters included pH, electrical conductivity, particle size distribution, organic carbon, and Pb content in soil. The multilayer perceptron (MLP) as an artificial neural network model was used to predict the Pb concentration in soil. The performance of this model was assessed by the coefficient of determination ( $R^2$ ), mean absolute error (MAE), and also root mean square error (RMSE). The results showed that artificial neural network model is a suitable method to determine Pb concentration in soil rather than the direct laboratory measurement, which is an expensive and time-consuming method.

**Keywords:** Lead, Artificial Neural Network, Heavy Metal, Kashafrud.