

تخمین پایداری خاکدانه در خاک‌های جنگلی استان گیلان بوسیله شبکه عصبی مصنوعی و توابع انتقالی رگرسیونی

عاده علی جانپور شلمانی^{1*}، محمود شعبانپور²، حسین اسدی² و فرید باقری³

تاریخ دریافت: 89/4/24 تاریخ پذیرش: 90/4/21

1- دانشجوی سابق کارشناسی ارشد، دانشگاه گیلان، رشت، ایران

2- استادیار، گروه خاک‌شناسی دانشگاه گیلان، رشت، ایران

3- عضو هیات علمی، مرکز تحقیقات چای کشور، لاهیجان

* مسئول مکاتبه: E-mail: adele.alijanpour@yahoo.com

چکیده

استفاده از شبکه‌های عصبی مصنوعی و توابع انتقالی رگرسیونی در برآورد ویژگی‌های دیریافت خاک از جمله پایداری خاکدانه‌ها، هزینه و زمان لازم برای اندازه‌گیری مستقیم این ویژگی‌ها را کاهش می‌دهد. در این پژوهش 100 نمونه خاک از جنگل‌های استان گیلان تهیه شد. ماده آلی، جرم ویژه ظاهری، کربنات کلسیم معادل، جرم ویژه حقیقی، تخلخل، مقاومت مکانیکی خاک، رس، شن، سیلت، pH و هدایت الکتریکی به عنوان متغیرهای مستقل و میانگین هندسی قطر خاکدانه‌ها (GMD) به عنوان متغیر وابسته تعیین شدند. نمونه‌ها به صورت تصادفی به دو سری شامل 80 داده برای آموزش و 20 داده برای آزمون مدل‌ها تقسیم شدند. برای ایجاد توابع انتقالی رگرسیونی از روش گام به گام و به منظور تشکیل شبکه‌های عصبی مصنوعی از الگوریتم آموزشی مارکوارت-لورنبرگ و ساختار پروسپترون سه لایه با شش نرون در لایه پنهان استفاده شد. بر اساس نتایج ماتریس همبستگی بین GMD به عنوان متغیر وابسته و متغیرهای مستقل، تعداد 18 گروه متغیر مستقل برای داده‌ها انتخاب شدند. این متغیرها یک بار به عنوان متغیرهای ورودی توابع انتقالی رگرسیونی چندگانه و یک بار به عنوان متغیرهای ورودی شبکه عصبی مصنوعی به کار رفتند. بر اساس آماره-های ضریب تبیین تصحیح شده (R^2_{adj})، ریشه دوم میانگین مربعات خطا ($RMSE$) و برتری نسبی (RI) مدل با متغیرهای ورودی pH ، جرم ویژه حقیقی، سیلت و مقاومت مکانیکی خاک بهترین مدل شبکه عصبی مصنوعی برای برآورد GMD داده‌های مورد آزمایش شناخته شد.

واژه‌های کلیدی: پایداری خاکدانه، شبکه‌های عصبی مصنوعی، میانگین هندسی قطر خاکدانه‌ها (GMD)

Estimation of Soil Aggregate Stability in Forest's Soils of Guilan Province by Artificial Neural Networks and Regression Pedotransfer Functions

A Alijanpour Shalmani^{1*}, M Shabanpour², H Asadi² and F Bagheri³

Received: 15 July 2010 Accepted: 12 July 2011

¹Former Msc Student, Univ. of Guilan, Rasht, Iran

²Asist. Prof., Dept. of Soil Sci., Univ. of Guilan, Rasht, Iran

³Academic Member, Tea Research Center, Lahijan, Iran

*Corresponding author: E-mail: adele.alijanpour@yahoo.com

Abstract

Using artificial neural networks (ANNs) and regression pedotransfer functions to predict the surrogate soil properties such as aggregate stability reduces time and cost needed for their direct measurements. In this research, 100 soil samples were collected from the forest soils of Guilan province. Organic matter, bulk density, equivalent carbonate calcium, particle density, porosity, soil mechanical resistance, clay, sand, silt, pH and electrical conductivity all were measured as independent variables. Geometric mean diameter (*GMD*) was computed as dependent variable by appropriate method. The samples were divided into two data subsets randomly: 80 for model calibration and 20 for model test. Regression pedotransfer functions were generated by stepwise method. For establishing ANNs we used Marquardt-Levenburg training algorithm and a 3-layer perceptron structure with 6 neurons in one hidden layer. According to the correlation matrix between *GMD* as dependent variable and independent variables, 10 groups input variables were selected. They were employed once by multi-variate regression pedotransfer functions and once by artificial neural networks. According to the adjusted coefficient of determination (R^2_{adj}), root mean square error (*RMSE*) and relative improvement (*RI*) a model resulted from applying ANNs and using input variables of pH, particle density, silt and soil mechanical resistance turned to be the best model for predicting *GMD* of the examined soils.

Keywords: Aggregate stability, Artificial neural networks, Geometric mean diameter (*GMD*)

مقدمه

خاکدانه‌ها در اثر جذب آب و یا برخورد با آلات و ادوات کشاورزی متلاشی نشوند، آبیاری، بارندگی، زهکشی و عملیات کاشت و داشت و برداشت نیز تأثیر سوئی در

مقاومت خاکدانه را در مقابل نیروهایی که به آن وارد می‌شود پایداری خاکدانه گویند. پایداری خاکدانه‌ها در ارزیابی کیفیت خاک اهمیت فراوانی دارد، زیرا اگر

مارکوارت (1963) الگویی آموزشی بنام الگوی پس انتشار خطا طراحی کرد که به کاربران اجازه می‌دهد که در زمینه‌های مختلف از شبکه‌ها استفاده کنند. اسخاپ و همکاران (2001) از 620 نمونه خاک برای ایجاد مدل‌های شبکه عصبی استفاده کردند. شبکه عصبی بکار گرفته شده دارای یک لایه پنهان و شش نرون بود که در 50 بار تکرار به دقت مناسب دست پیدا کرد. ضریب همبستگی لگاریتم هدایت هیدرولیکی از 0/42 در مدل شبکه عصبی *TXT* (فقط شامل بافت) به 0/7 در مدلی که شامل درصد سیلت، شن، رس، جرم ویژه ظاهری و θ_{33kPa} بود افزایش پیدا کرد. آن‌ها نتایج به دست آمده را با نتایج بدست آمده از توابع انتقالی مقایسه کردند و دریافتند که شبکه‌های عصبی مصنوعی روش بهتری برای مدل‌سازی است. محمدی (2002) با مطالعه بر روی 23 نمونه خاک از بافت‌های مختلف موجود در استان‌های چهارمحال و بختیاری و اصفهان دریافت که شبکه‌های عصبی در برآورد ساختمان و پایداری خاکدانه دقت بسیار بارزتری نسبت به توابع انتقالی رگرسیونی دارند.

رایان و همکاران (2005) از شبکه‌های عصبی مصنوعی برای برآورد میزان آزاد سازی نیترات از خاک‌های اراضی مرتعی گرمسیری نیوزیلند بهره بردند. مقادیر R^2 بدست آمده بین 0/67 تا 0/85 متغیر بود. آن‌ها بیان کردند که شبکه‌های عصبی مصنوعی در برآورد متغیرهای دیرپافت پیچیده اکوسیستمیک خاک از قدرت بالایی برخوردارند. لنتز و همکاران (2005) گزارش دادند که شبکه‌های عصبی مصنوعی روش‌های قابل اعتمادی برای شبیه سازی داده‌های دیر یافت خاک هستند.

اهداف عمده این پژوهش عبارت بودند از: 1) ارائه مدلی هوشمند مبتنی بر شبکه‌های عصبی مصنوعی به منظور تخمین پایداری خاکدانه خاک‌های جنگلی استان گیلان و 2) مقایسه شبکه‌های عصبی مصنوعی و توابع انتقالی رگرسیونی در برآورد پایداری خاکدانه.

مواد و روش‌ها

جهت تخمین پایداری خاکدانه، از جنگل‌های مناطق سیاهکل، فومن، شفت، رودبار، تالش، لنگرود، املش، ماسال، رودسر و رضوانشهر استان گیلان، نمونه-

ساختمان خاک نداشته و خاک پایداری نسبی و شرایط فیزیکی مطلوبی خواهد داشت (بای‌وردی 1372).

ساختمان آرمانی خاک را می‌توان در اراضی مرتعی و خاک‌های جنگلی یافت، که در آب پایدار بوده و دارای جرم ویژه ظاهری کم می‌باشند (امرسون 1991). وجود ماده آلی در خاک باعث افزایش پایداری خاکدانه می‌شود و وجود ماده آلی به همراه رس می‌تواند پایداری خاکدانه‌ها را بهبود بخشد (چنو و همکاران 2000). شرسا و همکاران (2007) دریافتند که در اراضی تحت کشت، خاکدانه‌های کوچک فراوان هستند، حال آنکه در اراضی جنگلی خاکدانه‌ها، بزرگتر و پایدارتر هستند. بارال و همکاران (1998) در بررسی اثر آهن و ماده آلی بر پایداری خاکدانه‌های کوچکتر از چهار میلی‌متر، دریافتند که در خاکی با ماده آلی و آهن بیشتر، خاکدانه‌ها پایدارتر هستند.

نئوفلدت و همکاران (1999) پایداری بیشتر خاکدانه‌ها در مراتع را به شبکه‌ی قوی ریشه‌ای، عدم بهم خوردن و خرد شدن خاکدانه‌ها و تولید مواد پلی‌ساکاریدی گیاهان مرتعی نسبت دادند. زاهویسیها و همکاران (2005) در بررسی پایداری خاکدانه‌ها و ارتباط آن با برخی ویژگی‌های شیمیایی خاک در خاک‌های قرمز ناحیه‌ی نیمه حاره‌ی چین دریافتند که با افزایش رس خاک، پایداری خاکدانه‌ها افزایش می‌یابد.

اندازه‌گیری مستقیم پایداری خاکدانه، دشوار، وقت‌گیر و پرهزینه است و برآورد غیرمستقیم آن ساده‌تر و اقتصادی‌تر می‌باشد، بنابراین استفاده از روش‌هایی که بتوانند رابطه این ویژگی را با استفاده از پارامترهایی زودپافت مانند بافت خاک، کربن آلی، کربنات کلسیم معادل، جرم ویژه ظاهری، مقاومت مکانیکی، جرم ویژه حقیقی، pH و EC با دقت مناسب برآورد کند، لازم به نظر می‌رسد. امروزه شبکه‌های عصبی مصنوعی به عنوان یک روش هوشمند پردازش داده‌ها، در شاخه‌های متفاوت علوم کاربرد زیادی پیدا کرده است. این روش به دلیل مدل‌سازی ساختار تحلیل اطلاعات توسط مغز، قدرت تعمیم‌دهی، توانایی آموزش و یادگیری، عدم نیاز به یک مدل ریاضی از پیش تعیین شده و ساختار تبدیل غیرخطی داده‌ها می‌توانند روابط پیچیده بین پارامترهای ورودی و خروجی را به خوبی درک کنند و خروجی‌های مطلوب را برآورد نماید (منهاج 1381).

در مدل‌های شبکه عصبی مصنوعی و توابع انتقالی رگرسیونی، *GMD* به عنوان متغیر وابسته می‌باشد و متغیرهای مستقل به عنوان متغیرهای زود یافت شامل کربنات کلسیم معادل، درصد ماده آلی، pH، جرم ویژه حقیقی، درصد رس، درصد شن، درصد سیلت و مقاومت مکانیکی خاک بودند.

بر اساس نتایج ماتریس همبستگی بین *GMD* به عنوان متغیر وابسته و متغیرهای مستقل، تعداد 18 گروه متغیر مستقل برای داده‌ها انتخاب شدند که این متغیرها یک بار به عنوان متغیرهای ورودی توابع انتقالی رگرسیونی و یک بار به عنوان متغیرهای ورودی شبکه عصبی مصنوعی به کار رفتند.

به منظور اشتقاق معادلات رگرسیون خطی چند-گانه از نرم افزار *SPSS* و برای ایجاد شبکه‌های عصبی مصنوعی نرم افزار *Neurosolution 5* و بسته نرم افزاری *Neuralbuilder* بکار رفت. در تمام شبکه‌های عصبی مصنوعی از الگوریتم آموزشی مارکوارت-لورنبرگ و تابع فعال‌ساز تانژانت سیگموئیدی و از یک لایه پنهان استفاده شد. تعداد نرون‌های لایه پنهان تمامی شبکه‌های عصبی مصنوعی بر اساس آزمون و خطا برابر شش نرون در نظر گرفته شد. تعداد تکرار برای رسیدن به حداقل میزان خطا و حداکثر پایداری شبکه به صورت میانگین برابر 1000 منظور گردید. الگوریتم برآورد خطا با الگوریتم پس انتشار خطا¹ صورت گرفت و از شبکه عصبی مصنوعی با ساختار پرسپترون سه لایه (نویابان 1382، مردان و همکاران 2006) استفاده شد.

به منظور سنجش اعتبار و صحت توابع انتقالی به ترتیب داده‌های آموزشی و آزمونی مورد استفاده قرار گرفتند. از آماره‌های ضریب تبیین تصحیح شده (\bar{R}_{adj}^2)، ریشه دوم میانگین مربعات خطا (*RMSE*) و برتری نسبی (*RI*) به ترتیب به منظور تعیین میزان ضریب اطمینان برآورد و میزان مانده‌های برآورد و میزان برتری یک مدل بر مدل دیگر استفاده شد.

مقادیر *RMSE* برای داده‌های مورد استفاده در آموزش مدل‌های توابع انتقالی رگرسیونی و شبکه‌های عصبی مصنوعی و داده‌های مورد استفاده در آزمون شبکه‌های عصبی مصنوعی با استفاده از معادله 2 و

بررداری انجام شد. نمونه‌برداری از عمق 0-20 سانتی‌متری به صورت تصادفی با روش مرکب انجام شد. در کل تعداد 100 نمونه خاک برداشته شد و به منظور تعیین برخی خواص فیزیکی و شیمیایی به آزمایشگاه انتقال داده شد. تعیین پایداری خاکدانه در خاک هوا-خشک کوبیده نشده و عبور کرده از الک 9/5 میلی‌متر، انجام گرفت. سایر آزمایش‌ها روی خاک هوا-خشک که به نرمی کوبیده و از الک دو میلی‌متر عبور داده شده بود، صورت گرفت. جرم ویژه ظاهری به روش سیلندر، مقاومت مکانیکی خاک به طور مستقیم در محل نمونه‌برداری با استفاده از دستگاه نفوذسنج مخروطی، توزیع اندازه و ارزیابی پایداری خاکدانه به روش الک تر، بافت خاک به روش هیدرومتر و جرم ویژه حقیقی به روش پیکنومتر اندازه‌گیری شد (کلوت 1986). همچنین ماده آلی خاک به روش والکی-بلاک، کربنات کلسیم معادل به روش تیتراسیون، *pH* در عصاره 1:2/5 محلول 0/01 مولار کلریدکلسیم و خاک با استفاده از *pH* متر و هدایت الکتریکی به روش هدایت سنجی اندازه‌گیری شد (پیچ و همکاران 1982).

غیر نرمال بودن داده‌ها از مواردی است که می‌تواند فرضیات مدل‌های رگرسیونی را غیر معتبر سازد زیرا این آزمون‌ها بر فرض نرمال بودن داده‌ها استوار است. اما در بکارگیری شبکه عصبی مصنوعی، چون شبکه‌ی طراحی شده از الگوریتم پس انتشار خطا استفاده می‌کند نسبت به نرمال بودن داده‌ها حساسیت ندارد (دعائی و همکاران 2006).

با استفاده از آزمون معنی‌دار بودن چولگی و کشیدگی و به کمک نرم‌افزار *SPSS* آزمون نرمال بودن توزیع داده‌ها انجام گرفت. نتایج این آزمون نشان داد که توزیع همه متغیرهای به کار رفته در مدل، به جز هدایت الکتریکی نرمال است. تبدیل زیر برای نرمال کردن توزیع هدایت الکتریکی صورت گرفت:

$$EC^* = EC^{0.2} \quad [1]$$

به منظور تعیین میزان همبستگی بین متغیرهای مستقل داده‌ها، از نرم افزار *SPSS14* استفاده شد. سپس داده‌ها به وسیله نرم افزار *MS.Excel* به صورت تصادفی به دو گروه 80 تایی داده‌های آموزشی و 20 تایی داده‌های آزمونی تقسیم شدند.

¹ Back propagation error

بالایی (ضریب همبستگی برابر 0/6 یا بیشتر) ندارند. مقادیر همبستگی بین متغیرهای مستقل نشان داد که بین هر یک از متغیرهای pH و کربنات کلسیم معادل، درصد شن و درصد سیلت و درصد شن و به همین علت نمی‌توان از همبستگی بالایی وجود دارد و در صد شن و درصد رس pH و کربنات کلسیم معادل با هم و درصد شن و درصد سیلت با هم و درصد شن و درصد رس همراه یکدیگر در مدل استفاده کرد.

بین GMD با هدایت الکتریکی، جرم ویژه ظاهری و تخلخل همبستگی معنی‌داری وجود نداشت (0.05) و (p=0.01). به همین دلیل از این متغیرها به عنوان متغیرهای زودیافت ورودی مدل‌ها استفاده نشد.

توابع انتقالی با استفاده از روش رگرسیون چندگانه و شبکه عصبی مصنوعی و مقایسه عملکرد آن‌ها برای داده‌ها جنگلی ایجاد شد.

معادلات رگرسیونی اشتقاق یافته به منظور برآورد GMD نمونه‌های آموزشی داده‌ها در جدول 1 داده شده است. آماره‌های ارزیابی مدل‌های مختلف در مورد داده‌های آموزش و آزمون توابع انتقالی رگرسیونی ($PTFs$) و شبکه‌های عصبی مصنوعی (ANN) برای برآورد GMD داده‌ها در جدول 2 ذکر شده است. در این جداول کلیه مقادیر ضریب تبیین تصحیح شده در توابع انتقالی رگرسیونی و شبکه عصبی مصنوعی در سطح یک درصد معنی‌دار بود. مقایسه کلی \bar{R}_{adj}^2 و $RMSE$ داده‌های آموزشی شبکه‌های عصبی مصنوعی و توابع انتقالی رگرسیونی در برآورد GMD برای پردازش داده‌ها نشان داد که شبکه‌های عصبی مصنوعی دارای \bar{R}_{adj}^2 بالاتر و $RMSE$ پایین‌تری در مقایسه با توابع انتقالی رگرسیونی می‌باشد، در نتیجه شبکه‌های عصبی مصنوعی درصد بیشتری از تغییرات موجود در داده‌ها را پیش‌بینی می‌کند (تاماری و همکاران 1996، قیلمی و اسل 2006 و هیولمنز و همکاران 2006). مقایسه مقادیر RI داده‌های آموزشی مدل‌های شبکه عصبی نسبت به توابع انتقالی رگرسیونی نشان داد که استفاده از شبکه‌های عصبی مصنوعی دقت برآورد GMD و کارایی مدل‌ها را در برآورد آن، نسبت به توابع انتقالی رگرسیونی به مقدار قابل ملاحظه‌ای افزایش می‌دهد (میناسنی و مک برانتی 2002).

توسط برنامه کوتاهی که در نرم افزار *Excel* نوشته شد، بدست آمد.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2} \quad [2]$$

Y_i : مقدار واقعی داده،

\hat{Y}_i : مقدار برآورد شده توسط مدل،

n: تعداد مشاهدات

$RMSE$: ریشه دوم میانگین مربعات خطا

از لحاظ آماری حداقل مقدار $RMSE$ برابر صفر بوده و زمانی است که مقادیر پیش‌بینی شده با مقادیر اندازه‌گیری شده برابر باشند. هر چقدر مقدار این آماره کمتر باشد، طبیعتاً برآوردهای انجام شده توسط مدل تخمین زنده دارای دقت بیشتری خواهد بود.

به منظور تعیین برتری نسبی هر یک از مدل‌های توابع انتقالی رگرسیونی و شبکه عصبی نسبت به مدل‌های دیگر از لحاظ دقت پیش‌بینی از آماره برتری نسبی (RI) استفاده شد. این آماره برای ارزیابی برتری یک مدل بر مدل دیگر استفاده می‌شود که این دو مدل می‌توانند از یک نوع یا از دو نوع متفاوت باشند. این آماره بر اساس معادله 3 و بوسیله برنامه کوتاهی که در نرم‌افزار *Excel* نوشته شد، محاسبه شد.

$$RI = \frac{RMSE_a - RMSE_b}{RMSE_a} \times 100 \quad [3]$$

$RMSE_a$: ریشه دوم میانگین مربعات خطای مربوط به مدل فرضی a ،

$RMSE_b$: ریشه دوم میانگین مربعات خطای مربوط به مدل فرضی b

RI : برتری نسبی مدل b بر a

دامنه تغییرات آماره RI بین 0 و 100 قرار دارد. RI برابر با 100 بیانگر این است که استفاده از این مدل نسبت به مدل دیگر، 100 درصد برتری داشته است. RI برابر با صفر نشان می‌دهد که مدل از نظر قدرت برآورد نسبت به مدل دیگر برتری ندارد (میناسنی و مک برانتی 2002).

نتایج و بحث

با توجه به نتیجه ماتریس همبستگی، متغیرهای مستقل به کار رفته در یک گروه با یکدیگر همبستگی

شبکه را به نوعی تغییر می‌دهد که کمترین اختلاف بین مقادیر پیش‌بینی شده و اندازه‌گیری شده باشد (میناسنی و همکاران 2004). از طرف دیگر شبکه‌های عصبی مصنوعی در مقایسه با توابع انتقالی رگرسیونی نسبت به همراستایی و ناهماهنگی موجود در داده‌ها حساسیت کمتری نشان می‌دهند و این عوامل تأثیر کمتری در قدرت برآورد آن‌ها می‌گذارد (منهاج 1381).

علت برآورد دقیق‌تر شبکه‌های عصبی مصنوعی نسبت به توابع انتقالی رگرسیونی را می‌توان در نحوه عمل شبکه پرسپترون سه لایه دانست، عملکرد این شبکه به این صورت است که ابتدا الگویی به شبکه عرضه می‌شود و خروجی آن محاسبه می‌شود، سپس شبکه این خروجی را با مقادیر اندازه‌گیری شده متغیر یا متغیرهای خروجی مقایسه می‌کند و ضرایب وزنی

جدول 1- معادلات رگرسیونی اشتقاق یافته به منظور برآورد GMD در نمونه‌های آموزش برای هر یک از 18 گروه متغیر مستقل (n= 100)

معادلات رگرسیونی	متغیرها
$GMD^1 = 6.333 + 0.114Load^2 + 0.007Si^3 - 2.414PD^4$	Load-Si-PD
$GMD = -0.128 + 0.124Load + 0.009Si - 0.015 CaCO_3^5$	Load-Si- CaCO ₃
$GMD = 6.667 + 0.110Load - 0.005Sa^6 - 2.352PD$	Load-Sa-PD
$GMD = 0.553 + 0.119Load - 0.007Sa - 0.016 CaCO_3$	Load -Sa-CaCO ₃
$GMD = 7.402 + 0.111Load - 2.650PD - 0.016 CaCO_3$	Load -PD-CaCO ₃
$GMD = 10.572 + 0.009Si - 3.613PD - 0.024 CaCO_3$	Si-PD- CaCO ₃
$GMD = 10.751 - 0.008Sa - 3.429PD - 0.024 CaCO_3$	Sa-PD- CaCO ₃
$GMD = 6.524 + 0.108Load + 0.006Si - 2.416PD - 0.015 CaCO_3$	Load-Si-PD- CaCO ₃
$GMD = 6.834 + 0.105Load - 0.005Sa - 2.348PD - 0.015 CaCO_3$	Load-Sa-PD-CaCO ₃
$GMD = 7.239 + 0.117Load - 2.658PD$	Load-PD
$GMD = 6.764 - 0.010pH - 2.364PD - 0.005Sa + 0.109Load$	pH -PD-Sa-Load
$GMD = 6.486 - 0.013pH - 2.432PD + 0.006Si + 0.112Load$	pH -PD-Si-Load
$GMD = 11.468 - 0.112pH - 3.546PD - 0.007Sa$	pH-PD-Sa
$GMD = 11.558 - 0.127pH - 3.731PD + 0.006Si$	pH-PD-Si
$GMD = 0.328 - 0.007pH - 0.007Sa + 0.126Load$	pH -Sa-Load
$GMD = -0.37 - 0.007pH + 0.009Si + 0.130Load$	pH-Si-Load
$GMD = 6.143 - 0.007pH - 2.395PD + 0.003Si + 0.098Load + 0.01Cl^7 + 0.06OM^8$	pH-PD-Si-Load- Cl -OM

¹GMD: Geometric mean diameter (mm)

²Load: Soil mechanical resistance (kg N)

³Si: Silt (%)

⁴PD: Particle density (g/cm³)

⁵CaCO₃: Equivalent carbonate calcium (%)

⁶Sa: Sand (%)

⁷Cl: Clay (%)

⁸OM: Organic matter (%)

جدول 2- آماره‌های ارزیابی مدل‌های مختلف در مورد داده‌های آموزشی و آزمون‌ی توابع انتقالی رگرسیونی (PTFs) و شبکه‌های عصبی مصنوعی (ANNs) برای برآورد GMD داده‌ها

ANN ¹ s		ANN to PTFs	PTF ² s			ANNs			متغیرها
RMSE ³ (t)	⁴ \bar{R}_{adj} ² (t ⁵)	RI(c ⁶)	\bar{R}_{adj} ²	RMSE(c)	RI _{9i} (c)	\bar{R}_{adj} ²	RMSE(c)	RI ⁷ _{12i} (c)	
0/299	0/35	96/25	0/39	0/294	2/72	0/98	0/011	54/54	Load-Si-PD
0/175	0/62	93/29	0/35	0/313	8/62	0/96	0/021	76/19	Load-Si-CaCO ₃
0/306	0/33	96/55	0/40	0/290	1/37	0/98	0/010	50/00	Load-Sa-PD
0/132	0/71	96/09	0/37	0/307	6/84	0/98	0/012	58/33	Load -Sa-CaCO ₃
0/369	0/20	91/06	0/40	0/291	1/71	0/94	0/026	80/77	Load -PD-CaCO ₃
0/359	0/22	89/97	0/22	0/379	24/53	0/92	0/038	86/84	Si-PD- CaCO ₃
0/291	0/37	92/66	0/24	0/368	22/28	0/94	0/027	81/48	Sa-PD- CaCO ₃
0/210	0/54	96/20	0/40	0/290	1/37	0/98	0/011	54/54	Load-Si-PD-CaCO ₃
0/342	0/26	97/90	0/41	0/286	-	0/99	0/006	16/66	Load-Sa-PD-CaCO ₃
0/482	0	81/75	0/39	0/296	3/37	0/87	0/054	90/74	Load-PD
0/481	0/01	97/61	0/39	0/294	2/72	0/98	0/007	28/57	pH -PD-Sa-Load
0/323	0/30	98/32	0/38	0/298	4/02	0/99	0/005	-	pH -PD-Si-Load
0/447	0/03	91/79	0/22	0/378	24/33	0/93	0/031	83/87	pH-PD-Sa
0/271	0/41	66/06	0/20	0/386	25/90	0/72	0/131	96/18	pH-PD-Si
0/109	0/76	76/89	0/35	0/316	9/49	0/87	0/073	93/15	pH -Sa-Load
0/095	0/79	91/90	0/34	0/321	10/90	0/95	0/026	80/76	pH-Si-Load
0/096	0/27	94/31	0/38	0/299	4/34	0/95	0/017	70/58	pH-PD-Si-Load-Cl -OM
0/480	0/01	92/73	0/40	0/289	1/03	0/93	0/021	76/19	Load-Si-PD-CaCO ₃ - Cl -OM

¹ Artificial neural networks

² Regression pedotransfer functions

³ Root mean square of residual

⁴ \bar{R}_{adj} = Adjusted correlation coefficient

⁵ Test

⁶ Calibration

⁷ Relative importance


زمانی که مدل‌ها آزمون می‌شوند الزامی نیست مانند آموزش مثلا اگر مدل 12 به مدل 14 برتری داشته باشد آزمون نیز همین روند را پیروی کند و یا اگر مدل خاصی در آموزش قوی‌تر است الزاما در آزمون نیز همان مدل، قوی‌ترین مدل باشد.

نمودارهای بهترین مدل شبکه عصبی مصنوعی (ANN) به همراه الگوی متناظر آن‌ها در توابع انتقالی رگرسیونی (PTFs) برای داده‌های آموزشی در شکل 1 آورده شده است. در نمودارها هرچه نقاط به خط 1:1 نزدیک‌تر باشد نشان دهنده انحراف کمتر مقادیر برآوردشده از مقادیر واقعی (اندازه‌گیری شده) و برآورد دقیق‌تر مدل است. بنابراین با توجه به نمودار مقادیر برآورد شده توسط شبکه نسبت به توابع انتقالی رگرسیونی از انحراف کمتری برخوردار است.

با استفاده از جدول 2 بهترین مدل شبکه در برآورد GMD داده‌های آموزشی برای داده‌ها، مدل با متغیرهای ورودی مقاومت مکانیکی خاک، درصد سیلت، جرم ویژه حقیقی و pH بود. در نتیجه زمانی که از این متغیرها استفاده شود برآورد دقیق‌تری برای GMD داده‌ها نسبت

به سایر مدل‌های شبکه عصبی مصنوعی دارد. همچنین مدل با متغیرهای ورودی مقاومت مکانیکی خاک، درصد شن، pH و کربنات کلسیم معادل بیشترین دقت برآورد GMD نسبت به سایر مدل‌ها در توابع انتقالی رگرسیونی را دارد.

در بررسی بهترین مدل از داده‌های آزمون استفاده نشد، چون آزمون مدل‌ها در تشخیص روابط بین داده‌هایی که قبلا مشاهده نشده است به کار می‌رود و الزاما بهترین مدل در داده‌های آموزشی، بهترین مدل در داده‌های آزمون نمی‌باشد (رضائی و سلطانی 1377).



شکل 1- نمودارهای بهترین مدل شبکه عصبی مصنوعی (ANN) به همراه الگوی متناظر آن در توابع انتقالی رگرسیونی (PTFs) برای داده‌های آموزشی مدل‌های تخمین زنده GMD بر اساس مقادیر \bar{R}_{adj}^2 (PH-PD-Si-Load) برای پردازش داده‌های جنگل

منابع مورد استفاده

- بای بوردی م، 1372. فیزیک خاک. انتشارات دانشگاه تهران.
- رضایی ع و سلطانی ا، 1377. مقدمه‌ای بر تحلیل رگرسیون کاربردی. انتشارات دانشگاه صنعتی اصفهان.
- منهاج م ب، 1381. مبانی شبکه‌های عصبی مصنوعی (جلد اول). انتشارات دانشگاه صنعتی امیرکبیر.
- نوابیان م، 1382. تخمین هدایت آبی اشباع با استفاده از توابع انتقالی. پایان نامه‌ی کارشناسی ارشد، دانشکده کشاورزی دانشگاه تهران.
- Barral MT, Arias M and Guerif J, 1998. Effect of iron and organic matter on the porosity and structural stability of soil aggregates. *Soil & Tillage Research* 46: 261-272.
- Chenu C, Le Bissonnias Y and Arrouays D, 2000. Organic matter influence on clay wettability and soil aggregate stability. *Soil Sci Soc Am J* 64: 1479-1486.
- Doai M, Shabanpaour Shahrestani M, Bagheri F and Navabiyan M, 2006. Comparison of regression pedotransfer functions and artificial neural networks to simulation of soil hydraulic properties. Accepted in. 18th WCSS. USA.
- Emerson WW, 1991. Structural decline of soils, assessment and prevention. *Aust J Soil Res* 24: 905-921.
- Ghielmi L and Eccel E, 2006. Descriptive models and artificial neural networks for spring frost prediction in an agricultural mountain area. *Computers and Electronics in Agriculture* 54: 101-114.
- Heuvelmans G, Muys B and Feyen J, 2006. Regionalisation of the parameters of a hydrological model: Comparison of linear regression models with artificial neural nets. *Journal of Hydrology* 319: 245-265.
- Klut A (ed.), 1986. *Method of Soil Analysis. Part 1. Physical and Mineralogical Properties*. ASA and SSSA. Madison, WI.
- Lentzsch P, Wieland R and Wirth S, 2005. Application of multiple regression and neural network approaches for landscape-scale assessment of soil microbial biomass. *Soil Biology and Biochemistry* 37: 1577-1580.
- Marquardt DW, 1963. An algorithm for least-squares estimation of nonlinear parameter. *J Soc Ind Appl Math* 11: 431-441.
- Merdun H, Cinar O, Meral R and Apan M, 2006. Comparison of artificial neural network and regression pedotransfer functions for prediction water retention and saturated hydraulic conductivity. *Soil & Tillage Res* 90: 108-116.
- Minasny B and Mcbartney AB, 2002. The neuro method for fitting neural network parametric pedotransfer functions. *Soil Sci Soc Am J* 66: 352-361.

- Minasny B, Hopman JW, Harter TX, Eching T, Toli A and Denton MA , 2004. Neural networks prediction of soil hydraulic functions for alluvial soils using multi step outflow data. *Soil Sci Soc Am J* 68: 417- 429.
- Mohammadi J, 2002. Testing an artificial neural network for predicting soil water retention characteristics from soil physical and chemical properties. Paper No. 378 and 943. 17th WCSS. Thailand. Paper no:378. Paper no: 943
- Neufeldt H, Ayarza MA, Resck DVS and Zech W, 1999. Distribution of water-stable aggregate in Cerrado Oxisols. *Soil & Tillage Res* 93: 85-99.
- Page AL, Miller RH and Keeney DR, 1982. *Method of Soil Analysis. Part 2. Chemical and Microbiological Properties*. ASA and SSSA. Madison, WI.
- Ryan M, Müller C, Di HJ and Cameron KC, 2005. The use of artificial neural networks (ANNs) to simulate N₂O emissions from a temperate grassland ecosystem *Ecological Modeling* 175: 189-194.
- Schaap MG, Leij FJ and Van Genuchten MTh, 2001. A computer program for estimating soil hydraulic parameters with hierarchical pedotransfer functions. *Journal of Hydrology* 251: 202-220.
- Shrestha BM, Singh BR, Sitaula BK, Lai R and Barjacharya RM, 2007. Soil aggregate and particle-associated organic carbon under different land use in Nepal. *Soil Sci Soc Am J* 71: 1194-1203.
- Tamari S, Wosten JHM and Ruiz-Suarez JC, 1996. Testing an artificial neural network for predicting soil hydraulic conductivity. *Soil Sci Soc Am J* 60: 1732-1741.