



دانشگاه کارشناسی ارشد گروه خاک‌شناسی دانشگاه تهران

مجله پژوهش‌های حفاظت آب و خاک

جلد نوزدهم، شماره سوم، ۱۳۹۱

<http://jwfst.gau.ac.ir>

تخمین نقاط شاخص منحنی رطوبتی تعدادی از خاک‌های آهکی به کمک پارامترهای زود یافت خاک به روش شبکه عصبی مصنوعی

*علی بلیانی^۱، مهدی شرف‌آف^۲ و محمود امید^۳

^۱دانشجوی کارشناسی ارشد گروه خاک‌شناسی دانشگاه تهران، ^۲استادیار گروه خاک‌شناسی

دانشگاه تهران، ^۳دانشیار ماشین‌آلات کشاورزی دانشگاه تهران

تاریخ دریافت: ۹۰/۹/۷؛ تاریخ پذیرش: ۹۰/۹/۱۹

چکیده

از آنجایی که اندازه‌گیری منحنی نگهداشت آب خاک و نقاط شاخص آن مانند ظرفیت مزرعه و نقطه پژمردگی دائم با روش‌های مستقیم هزینه بروزمان بر است، یکی از راههای تخمین سریع و کم هزینه این ویژگی‌ها تخمین این صفات از روی خصوصیات زود یافت خاک مانند توزیع اندازه ذرات خاک، مقدار مواد آلی و جرم مخصوص ظاهری می‌باشد. در این پژوهش نقاط شاخص منحنی رطوبتی خاک مانند ظرفیت مزرعه و نقطه پژمردگی دائم و در نهایت رطوبت قابل استفاده با کمک شبکه عصبی از نوع MLP با سه نوع تابع فعال‌سازی و همچنین روش رگرسیون از روی خصوصیات زود یافت خاک تخمین زده شد. برای این منظور ۶۰ نمونه خاک از منطقه ریاط کرج به وسعت ۲۴ هکتار جمع‌آوری و بهوسیله صفحات فشاری مقدار رطوبت نقاط شاخصی از منحنی رطوبتی مانند ظرفیت زراعی و نقطه پژمردگی دائم و در نهایت رطوبت قابل استفاده اندازه‌گیری گردید. سپس خصوصیات زود یافت خاک مانند درصد رس، شن، جرم مخصوص ظاهری، درصد آهک و مواد آلی اندازه‌گیری و با استفاده از روش‌های ذکر شده رطوبت نقاط شاخص یاد شده تخمین زده شد. نتایج حاصل از پژوهش نشان داد که شبکه عصبی مصنوعی با تابع فعال‌سازی سیگموئیدی با تعداد ۶ نرون در لایه ورودی، ۱۰ نرون در لایه مخفی و ۳ نرون در لایه خروجی با شاخص‌های عملکرد R^2 و

*مسئول مکاتبه: alibl363@gmail.com

از RMSE^۱ ۰/۶۱۹۷ تا ۰/۸۹۰۲ و ۰/۶۸۴۶ در مقایسه با سایر توابع فعال‌سازی (روش شبکه عصبی مصنوعی) و روش رگرسیونی به عنوان شبکه بهینه دارای بهترین عملکرد در برآورد خروجی‌های مورد نظر است و درصد آهک خاک با توجه به نتایج آنالیز حساسیت به عنوان یک فاکتور موثر در محدوده بافتی نمونه خاک‌های مورد آزمایش قابل ذکر می‌باشد.

واژه‌های کلیدی: درصد آهک خاک، منحنی رطوبتی خاک، شبکه عصبی مصنوعی، توابع فعال‌سازی

مقدمه

منحنی نگهداشت آب خاک^۱ منحنی است که رابطه‌ای بین پتانسیل ماتریک خاک و درصد رطوبت آن را نشان می‌دهد و نقش برجسته‌ای در مباحث کشاورزی، علوم خاک و فیزیک خاک بر عهده دارد. این منحنی رطوبت موجود در خاک، در محدوده بین خاک اشباع تا خاک خشک را نشان می‌دهد. اما در این بازه رطوبتی نقاطی هستند که از نظر کاربردی در آبیاری و روابط آب و خاک اهمیت زیاد دارند که از آن‌ها به عنوان نقاط پتانسیلی مهم خاک یاد می‌شود. این نقاط پتانسیلی ظرفیت مزرعه^۲ و نقطه پژمردگی دایم^۳ می‌باشند. چون نقطه پژمردگی دایم پایین‌ترین حد رطوبت برای گیاه است بنابراین تفاوت بین دو نقطه ظرفیت مزرعه و پژمردگی دایم باید مقدار رطوبتی باشد که از لحاظ نظری گیاه بتواند از آن استفاده نماید که همان رطوبت قبل دسترس می‌باشد. این مقدار رطوبت که فاصله بین دو حالت ظرفیت مزرعه و نقطه پژمردگی دایم است در خاک‌های با بافت‌های مختلف متفاوت می‌باشد. اندازه‌گیری منحنی رطوبتی خاک و نقاط شاخص آن با روش‌های آزمایشگاهی هزینه برا و زمان بر است. به طور مثال این نقاط می‌توانند مقدار رطوبت در ظرفیت مزرعه و نقطه پژمردگی دائم باشند که به ترتیب مقدار رطوبت خاک در پتانسیل‌های -۳۳ و -۱۵۰۰ کیلو پاسکال را نشان می‌دهند، و با استفاده از روش‌های غیرمستقیم رگرسیونی خطی (خداوردی لو و همایی، ۱۳۸۱ و ویرکن و همکاران، ۱۹۹۲) یا شبکه عصبی مصنوعی از روی خصوصیات زود یافته خاک (ون گتوختن و لیچ، ۱۹۹۲) تخمین زده می‌شوند (پاچپسکی و همکاران، ۱۹۹۶). شبکه عصبی مصنوعی به عنوان یک ابزار برای مدل کردن روابط مابین داده‌های ورودی و نتایج خروجی است که روابط بین آنها پیچیده و

1- Soil moisture retention curve

2- Field capacity

3- Permanent wilting point

دشوار می‌باشد (مک کورد و ایلینگور، ۱۹۹۰). به نظر می‌رسد که کارایی شبکه عصبی مصنوعی بهتر از روش‌های رگرسیونی غیرخطی باشد (هیچت-نیلسون، ۱۹۹۰). استفاده از شبکه‌های عصبی مصنوعی در زمینه‌های گوناگون علوم خاک از جمله در تخمین انتقال املاح در خاک (بازوسکی و کوالکوسکی، ۲۰۰۶)، تبخیر و تعرق پتانسیل (۲۰۰۹)، تخمین میزان خاک هدر رفته در اثر فرسایش خاک (مین یانگ و جان، ۲۰۰۸)، مدل کردن هدایت الکتریکی خاک (نمادر خجسته و همکاران، ۲۰۱۰) و تخمین منحنی رطوبتی خاک (مردان و همکاران، ۲۰۰۶) از روی خصوصیات زود یافته خاک در حال افزایش است، نتایج به دست آمده از این پژوهش‌ها شبکه عصبی مصنوعی را به عنوان یک ابزار قدرتمند در مدل کردن خصوصیات مختلف خاک معرفی کرده و خصوصیات یاد شده را به خوبی مدل‌سازی می‌کند، در بیشتر مطالعات مربوط به منحنی رطوبتی خاک از تابع فعال‌سازی تاثرات هیپربولیک برای برقراری روابط مابین خصوصیات زود یافت و دیر یافت خاک استفاده شده و بیشترین مطالعات مشابه در تخمین منحنی رطوبتی خاک (زونکی و همکاران، ۲۰۰۹؛ فرخیان فیروزی و همایی، ۲۰۰۳؛ خداوردی‌لو و همایی، ۲۰۰۲؛ کوک و بولتینگ، ۱۹۹۹؛ اسکاپ و همکاران، ۱۹۹۸ و...) در شرایط خاک‌های غیر آهکی صورت پذیرفته است، به عنوان مثال زونکی و همکاران تخمین رطوبتی خاک را برای تعداد ۱۱۰ نمونه خاک غیر آهکی با کلاس‌های بافتی مختلف به روش شبکه عصبی مصنوعی و رگرسیونی تخمین زند و نشان دادند شبکه عصبی منحنی رطوبتی را در بیشتر کلاس‌های بافتی بهتر از روش رگرسیونی و با ضریب همبستگی (R^2) بالاتری تخمین می‌زنند. خداوردی‌لو و همایی (۲۰۰۲) نقاط شاخص منحنی رطوبتی ۲۷ نمونه خاک را در شرایط نمونه اخاک‌های با بافت لومی منطقه کرج از روی خصوصیات زود یافته خاک (فرآوانی نسبی ذرات، جرم مخصوص ظاهری، درصد کربنات کلسیم و...) تنها با استفاده از روش سنتی رگرسیونی با ضریب همبستگی بالای تخمین زده، این پژوهش قادر آزمون آنالیز حساسیت جهت مقایسه و تعیین میزان تاثیر پارامترهای مختلف زود یافته خاک بر خروجی مدل بوده و از آنجایی که این نوع توابع انتقالی (روش رگرسیونی) برای تعیین منحنی مشخصه رطوبتی به تعداد زیادی معادله رگرسیونی نیاز دارد استفاده از آن در مدل‌های شبیه‌ساز مشکل است، فرخیان فیروزی و همایی (۱۳۸۲) ویژگی‌های هیدرولیکی خاک‌های گچی را با استفاده از توابع انتقالی رگرسیونی برآورد کردند و نشان دادند که درصد گچ در نمونه خاک‌های مورد آزمایش بر نقاط تشکیل‌دهنده منحنی رطوبتی تاثیر قابل ملاحظه‌ای دارد، کوکوک و کوک و بولتینگ (۱۹۹۹) نشان دادند که استفاده از شبکه‌های عصبی مصنوعی جهت تخمین تعدادی از نقاط منحنی رطوبتی

خاک‌های با مواد آلی بالا و غیرآلکی نتایج بهتری از توابع انتقالی رگرسیونی مانند مدل گوتا و لارسون ۱۹۷۹ ارائه می‌دهند، اسکاپ و همکاران، ۱۹۹۸ با استفاده از شبکه عصبی منحنی رطبیتی خاک را تخمین زدند، آنها دریافتند که شبکه عصبی مصنوعی بکار رفته بهتر از تعدادی از توابع انتقالی رگرسیونی ارائه شده توسط سایر محققان بوده و معمولاً اگر خصوصیات زود یافت بیشتری به عنوان ورودی به کار رود صحت پیش‌بینی‌ها افزایش می‌یابد ولی همیشه اختلاف قابل توجهی بین مقادیر رطبوبت پیش‌بینی شده و اندازه‌گیری شده وجود دارد.

در این پژوهش برآئیم تا نقاط شاخص منحنی رطبیتی تعدادی از خاک‌های آهکی مانند ظرفیت مزرعه و نقطه پژمردگی دائم و در نهایت رطبوبت قبل استفاده با کمک شبکه عصبی از نوع پرسپترون چند لایه^۱ MLP با سه نوع تابع فعال‌سازی سیگنoidی، تائزانت هیپربولیک و تائزانت خطی (در مطالعات مربوط به منحنی رطبیتی به طور معمول از روش تائزانت هیپربولیک استفاده شده است) از روی خصوصیات زود یافت خاک تخمین زده شده و نتایج جهت انتخاب مدل بهینه مقایسه می‌شوند و به علاوه این نتایج با روش رگرسیونی نیز مقایسه شده است، همچنین در انتهای از آزمون آنالیز حساسیت داده‌ها جهت مشاهده میزان تاثیر خصوصیات زود یافت خاک (درصد رس، شن، آهک و ...) به خصوص درصد آهک خاک به عنوان یک ورودی غیرمعمول و به گرفته نشده در سایر مطالعات با توجه به درصد نسبتاً بالای آن در خاک‌های مورد آزمایش بر خروجی‌های مورد نظر در روش شبکه عصبی مصنوعی بهره‌گرفته می‌شود تا میزان تاثیر این پارامتر مشخص گردد که در مطالعات مشابه از این آزمون استاندارد و مهم کمتر استفاده شده است.

مواد و روش‌ها

در این پژوهش تعداد ۶۰ نمونه خاک آهکی از افق سطحی (۰ تا ۲۵ سانتی‌متری) منطقه‌ای در ریاط کریم کرج به مساحت ۲۴ هکتار با مختصات جغرافیایی با طول ۵۱ درجه و ۶ دقیقه و ۹۹ ثانیه و ۵۱ درجه و ۶ دقیقه و ۲۰۲ ثانیه شمالی و عرض ۳۵ درجه و ۴۵ دقیقه و ۴۵ ثانیه و ۲۹ درجه و ۳۵ دقیقه و ۳۹۰ ثانیه شرقی به کمک دستگاه^۲ GPS به روش شبکه‌ای و با فاصله ۱۰۰ متر به ۱۰۰ متر برداشته شد. دامنه تغییرات ویژگی‌های رطبیتی خاک‌های مورد استفاده شده در این پژوهش در جدول ۱

1- Multilayer perceptron
2- Global Position System

خلاصه شده است، خصوصیات دیر یافته چون نقاط شاخص منحنی رطوبتی نمونه‌ها در آزمایشگاه و با کمک دستگاه صفحات فشاری به دست آمد. خصوصیات زود یافته مانند بافت خاک (درصد شن، سیلت، رس) به روش پیپت و جرم مخصوص ظاهری به روش سیلندر، درصد مواد آلی خاک به روش والکی- بلک و درصد آهک خاک به روش گازومتری اندازه‌گیری شدند (جدول ۲).

جدول ۱- دامنه تغییرات ویژگی‌های رطوبتی نمونه‌های مورد استفاده.

ویژگی‌های هیدرولیکی	میانگین	مینیمم	ماکریم
FC	۲۵/۰۹	۱۵/۶۸	۳۳/۳۹
PWP	۱۲/۴۱	۸/۲۵	۱۶/۲۷
AW	۱۲/۸۴	۶/۰۰	۲۱/۰۳

جدول ۲- دامنه تغییرات ویژگی‌های فیزیکی نمونه‌های مورد استفاده.

خصوصیات فیزیکی	میانگین	مینیمم	ماکریم
شن (درصد)	۴۰/۴۷۱	۲۳/۰۰	۸۲/۰۰
رس (درصد)	۱۹/۷۱۰	۵/۰۰	۲۹/۰۰
جرم مخصوص ظاهری (gcm^{-3})	۱/۲۸۴	۱/۲۴	۱/۳۷
مواد آلی (درصد)	۰/۷۶۵	۰/۲۰	۱/۴۰
آهک (درصد)	۱۳/۱۴۸	۹/۰۰	۱۶/۸۰

در این پژوهش برای مدل‌سازی خصوصیات دیر یافت از دو روش شبکه‌های عصبی مصنوعی و رگرسیون چند متغیره استفاده شده است. برای طراحی شبکه‌های عصبی مصنوعی انواع توابع خطی و غیرخطی به عنوان توابع فعال‌سازی استفاده شد. توابع انتقالی استفاده شده شبکه‌های عصبی مصنوعی عبارتند از تابع تانژانت هیپربولیک، تابع سیگموئید و تابع خطی. برای به دست آمدن نقاط شاخص منحنی رطوبتی خاک درصد رطوبت حجمی خاک در مکش $۰/۳$ و ۱۵ بار برای ۶۰ نمونه خاک با کمک دستگاه صفحات فشاری به عنوان یک روش استاندارد و معمول در آزمایشگاه‌های خاک‌شناسی (کلوت، ۱۹۸۶) تعیین و از اختلاف این دو حد رطوبتی آب قابل دسترس گیاه حاصل گردید.

$$\text{AW} = \text{FC} - \text{PWP} \quad (1)$$

مدل‌سازی با شبکه عصبی مصنوعی^۱: در این پژوهش از شبکه‌های پرسپترون چند لایه^۲ یا MLP با الگوریتم پس انتشار خطای BP استفاده شد. در این روش خطای جهت اصلاح وزن‌ها و بایاس‌ها به عقب منتشر می‌شود تا وزن‌های مناسب برای سیستم به دست آید. رابطه بهمنگام سازی وزن‌ها در یادگیری نزول گرادیان با گشتاور به صورت زیر است (نامدار خجسته و همکاران، ۲۰۱۰):

$$W_{ij}(n+1) = W_{ij}(n) + \eta \delta_i(n) X_j(n) + \alpha [W_{ij}(n) - W_{ij}(n-1)] \quad (2)$$

که در آن $W_{ij}(n)$ وزن بین گره‌های i و j در تکرار n و $\delta_i(n)$ خطاهای محلی است که می‌توان آن را به صورت مستقیم از طریق عناصر پردازشی لایه خروجی یا به صورت مجموع وزنی خطاهای در عناصر پردازش لایه مخفی به دست آورد. در این رابطه η و α به ترتیب نرخ یادگیری و ضریب گشتاور بوده و بین ۰/۱ تا ۰/۹ در نوسان می‌باشد.

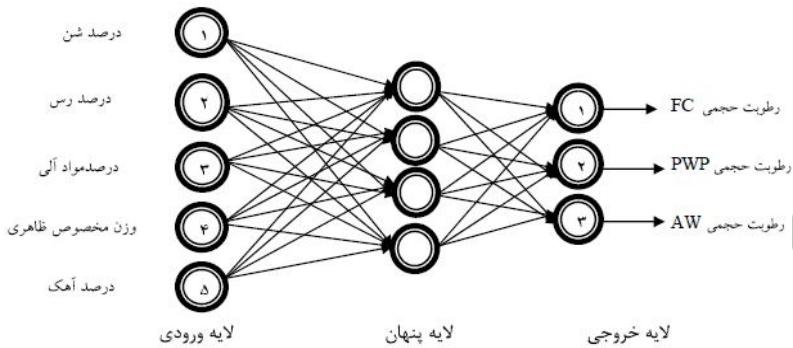
برای طراحی یک مدل یادگیر متنی بر شبکه عصبی مصنوعی لازم است مراحل جمع‌آوری داده‌ها، پیش‌پردازش روی آن‌ها، انتخاب توبولوژی و نوع شبکه (تعیین تعداد لایه‌های پنهان، تعداد نرون‌های هر لایه، انتخاب توابع فعال‌سازی)، تقسیم داده‌ها به بخش‌های آموزش، اعتبار سنجی تقاطعی^۳ و تست ارزیابی مدل و غیره به طور سیستماتیک صورت پذیرد. از شبکه‌های پرسپترون تک لایه عموماً برای طبقه‌بندی الگوهای استفاده می‌شود. نظر به این که در این تحقیق از شبکه‌های عصبی مصنوعی برای توسعه مدل‌های رگرسیون غیر خطی استفاده خواهد شد، بنابر این برای توسعه مدل‌های شبکه از یک لایه پنهان با سه نوع تابع فعال‌سازی از نوع سیگوئیدی، تائزانت هیپربولیک و تائزانت خطی در لایه مخفی و تابع فعال‌سازی خطی در لایه خروجی استفاده گردید. در شکل ۱ شبکه ساده MLP مورد استفاده در این پژوهش با ورودی‌های خصوصیات زود یافت معمول در سایر مطالعات (درصد شن، رس مواد آلی، وزن مخصوص ظاهری) و فاکتور ورودی درصد آهک به عنوان یک فاکتور ورودی غیر معمول نشان داده شده است.

معیار ارزیابی: متداول‌ترین آماره‌های مورد استفاده در روش‌های غیرمستقیم برآورد خصوصیات رطوبتی خاک برای مقایسه بین داده‌های حاصل از تخمین و مقدار واقعی آنها به صورت زیر می‌باشند:

- 1- Artificial neural networks(ANN)
- 2- Multilayer perspetron (MLP)
- 3- Back propagation (BP)
- 4- Cross Validation (CV)

$$R^2 = 1 - \frac{(\sum(\theta_i - \theta_j)^2)}{(\sum(\theta_i - \theta_m)^2)} \quad (3)$$

$$RMSE = (\sum_{i=1}^N (\theta_i - \theta_j)^2 / N)^{1/2} \quad (4)$$



شکل ۱- نمودار ساده شبکه طراحی شده در این پژوهش.

در آمارهای یادشده، R^2 ضریب تعیین می‌باشد که در محدوده صفر تا یک متغیر است و RMSE ریشه میانگین مربعات خطای است. در آزمون و ارزیابی شبکه‌های عصبی مصنوعی هر چه R^2 به عدد یک نزدیک‌تر و RMSE به صفر نزدیک‌تر باشد نتیجه بدست آمده مطلوب‌تر است (عملکرد شبکه مطلوب‌تر می‌باشد). در معادلات ۳ و ۴، θ_i رطوبت اندازه‌گیری شده و θ_j رطوبت تخمین زده شده، θ_m رطوبت میانگین و N تعداد نمونه‌ها می‌باشند از آنجایی که نتایج رطوبت‌های تخمین زده شده به روش شبکه عصبی و رگرسیون با رطوبت اندازه‌گیری ۶۰ نمونه خاک یادشده به صورت یک به یک با یک دیگر مقایسه می‌شوند، این معیارها به عنوان گویاترین و بهترین معیارها برای ارزیابی مدل‌ها می‌باشد (در واقع از روابط غیر خطی جهت برقراری روابط مابین خصوصیات زود یافت و دیر یافت در لایه پنهان شبکه عصبی مصنوعی استفاده شده و نقاط تخمین زده شده حاصل از این روابط با نقاط اندازه‌گیری شده با کمک معیارها یادشده به صورت یک به یک مقایسه شده است).

شبکه‌های بررسی شده در محیط نرم‌افزاری NeuroSolutions 5.0 اجرا شده‌اند. برای جلوگیری از آموزش بیش از حد شبکه که اغلب باعث یادگیری نامناسب مدل می‌شود، ۱۵ درصد از داده‌ها برای اعتبار سنجی تقاطعی CV انتخاب و به مدل معرفی شدند. در این پژوهش از یک شبکه عصبی مصنوعی از نوع MLP با سه نوع تابع فعال سازی تائزاتی^۱، سیگموئیدی^۲ و تائزاتی خطی^۳ و تعداد نرون‌های لایه مخفی از

1- TanhAxon

2- Sigmoidaxon

3- LinearTanhAxon

۲ شروع و افزایش یافتند، تا زمانی که مدل بهترین عملکرد و کمترین خطای داشته باشد. هر شبکه ۲۰ بار آموزش داده شد مقدار خروجی شبکه با خروجی مطلوب مقایسه شدند. شبکه‌ای که دارای کمترین RMSE و بزرگ‌ترین R^2 بود به عنوان مدل بهینه انتخاب گردید. دقت تخمین هر مدل با تابع فعال‌سازی متفاوت با آماره‌های R^2 و RMSE مورد بررسی قرار گرفت و سپس از آزمون آنالیز حساسیت^۱ برای تعیین درجه حساسیت پارامترهای ورودی بر خروجی مورد نظر استفاده شد (آنالیز حساسیت به طور سیستماتیک و در محیط نرم‌افزار 5.0 NeuroSolutions با انتخاب گزینه آنالیز حساسیت از منوی مربوط قابل اجرا می‌باشد). برای توسعه مدل‌های رگرسیونی از نرم‌افزار 13.0 SPSS با برآش مدلی به نام مدل تجربی گوپتا و لارسون ۱۹۷۹ (کوک کوک و بولتینک، ۱۹۹۹) استفاده شده است.

نتایج و بحث

تخمین نقاط شاخص منحنی رطوبتی خاک با استفاده از روش شبکه عصبی مصنوعی: در جدول‌های ۳ تا ۵ نتایج حاصل از ارزیابی دقت برآورده مدل پرسپترون چند لایه MLP با کمک معیارها ارزیابی R^2 و RMSE در تخمین مقدار رطوبت حجمی ظرفیت مزرعه، نقطه پژمردگی دائم و رطوبت قابل دسترس گیاه با استفاده از توابع فعال‌سازی متفاوت تائزانتی، سیگموئیدی و تائزانتی خطی نشان داده شده است. با مقایسه کارایی مدل MLP با توابع فعال‌سازی متفاوت، همان گونه که در جدول‌های ۳ تا ۵ مشاهده می‌شود، زمانی که از توابع فعال‌سازی متفاوت برای برقراری ارتباط بین ورودی‌های مدل MLP یا همان خصوصیات زود یافت خاک و خروجی‌های مدل MLP یا نقاط شاخص منحنی رطوبتی و رطوبت قابل دسترس استفاده می‌گردد، نتایج حاصل از تخمین مدل‌ها مقادیر متفاوتی را نشان می‌دهد. با توجه به جدول‌های ۳ تا ۵ مشاهده می‌شود که در بیشتر موارد ۱۸ مورد از ۳۰ مورد برای هر سه نقطه رطوبتی در مجموع مقدار تخمین رطوبت برای مقدار رطوبت حجمی ظرفیت مزرعه، نقطه پژمردگی دائم و رطوبت قابل دسترس گیاه در مدل MLP با تابع فعال‌سازی سیگموئیدی و توابع تائزانت هیپربولیک و تائزانتی خطی هر کدام در ۶ مورد از ۳۰ مورد برای هر سه نقطه رطوبتی بیشترین کارایی در تخمین خروجی مورد نظر با تعداد نرون‌های متفاوت در لایه مخفی را دارا می‌باشند، شکل (۲)، همچنین نتایج آنالیز حساسیت (شکل ۴) بیانگر تاثیر قابل توجه فاکتور آهک بر خروجی‌های شبکه بهینه بعد از فاکتور ورودی در صد شن می‌باشد.

1- Sensitivity Analysis

علی بلیانی و همکاران

جدول ۳- ارزیابی دقت برآورد مدل MLP با تابع فعال سازی تانژانتی

R ²				RMSE				تعداد نرون‌های لایه مخفی	
رطوبت حجمی در حالت ظرفیت				رطوبت حجمی در حالت ظرفیت مزرعه					
نقشه پژمردگی مزرعه	آب قابل دسترس	نقشه پژمردگی دائم	آب قابل دسترس	نقشه پژمردگی مزرعه	آب قابل دائم	نقشه پژمردگی دسترس	آب قابل دائم		
۰/۸۴۹۶	۰/۵۲۳۸	۰/۵۸۵۰	۲/۴۸۳۱	۱/۸۵۵۰	۲/۰۹۰۳	۲			
۰/۸۲۹۴	۰/۶۱۳۵	۰/۶۰۵۰	۲/۴۲۷۸	۱/۶۴۶۷	۲/۱۲۴۰	۴			
۰/۸۸۷۶	۰/۶۵۰۳	۰/۰۹۱۵	۱/۹۲۰۳	۱/۵۸۰۷	۲/۲۳۴۲	۶			
۰/۸۰۸۰	۰/۵۸۰۷	۰/۵۸۱۵	۲/۱۱۴۸	۱/۶۸۴۰	/۲۵۸۹	۸			
۰/۸۶۰۴	۰/۶۴۷۶	۰/۵۱۲۸	۲/۳۰۷۱	۱/۵۱۰۳	۲/۳۸۲۳	۱۰			
۰/۸۵۷۵	۰/۵۴۵۴	۰/۵۴۲۹	۴/۸۴۹۰	۱/۹۴۸۴	۲/۴۰۹۵	۱۲			
۰/۸۴۵۶	۰/۶۴۴۹	۰/۵۸۹۹	۲/۴۱۴۷	۱/۵۴۸۴	۳/۲۰۷۵	۱۴			
۰/۸۵۰۳	۰/۶۳۳۹	۰/۴۸۱۳	۲/۷۹۰۵	۱/۶۰۷۶	۲/۵۷۱۶	۱۶			
۰/۷۹۶۸	۰/۶۷۰۵	۰/۱۶۸۹	۲/۴۹۹۵	۱/۶۸۷۵	۳/۲۴۱۹	۱۸			
۰/۸۴۶۳	۰/۶۵۷۹.	۰/۵۷۳۱	۳/۱۱۳۶	۱/۶۱۸۴	۲/۸۳۴۰	۲۰			

جدول ۴- ارزیابی دقت برآورد مدل MLP با تابع فعال سازی سیگموئیدی

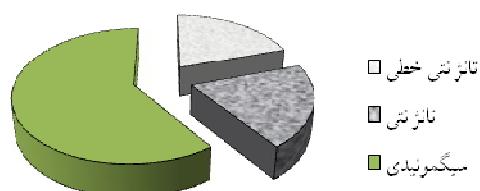
R ²				RMSE				تعداد نرون‌های لایه مخفی	
رطوبت حجمی در حالت ظرفیت				رطوبت حجمی در حالت ظرفیت مزرعه					
نقشه پژمردگی مزرعه	آب قابل دسترس	نقشه پژمردگی دائم	آب قابل دسترس	نقشه پژمردگی مزرعه	آب قابل دائم	نقشه پژمردگی دسترس	آب قابل دائم		
۰/۸۷۶۳	۰/۷۳۵۲	۰/۶۰۵۷	۱/۹۵۰۴	۱/۷۱۹۵	۲/۰۰۴۰	۲			
۰/۸۶۶۱	۰/۶۱۲۷	۰/۶۰۶۰	۲/۰۴۴۶	۱/۷۳۵۴	۲/۰۷۱۱	۴			
۰/۸۲۲۷	۰/۶۲۱۵	۰/۶۰۳۷	۲/۰۳۵۸	۱/۷۵۰	۲/۰۴۹۶	۶			
۰/۸۲۲۲	۰/۶۲۴۳	۰/۶۰۸۹	۲/۰۳۲۷	۱/۷۳۰۰	۲/۰۱۷۸	۸			
۰/۸۹۰۲	۰/۶۴۴۹	۰/۶۱۹۷	۲/۰۲۲۵	۱/۶۸۴۶	۱/۹۷۰۴	۱۰			
۰/۸۸۸۸	۰/۶۲۵۹	۰/۶۱۲۹	۱/۸۵۹۴	۱/۷۲۰۱	۱/۹۹۴۲	۱۲			
۰/۸۶۶۳	۰/۶۲۴۸	۰/۶۱۸۸	۲/۰۶۷۴	۱/۷۳۹۱	۱/۹۸۸۹	۱۴			
۰/۸۸۵۷	۰/۶۰۹۹	۰/۶۱۵۶	۲/۰۴۳۰	۱/۷۲۱۷	۱/۹۸۷۰	۱۶			
۰/۸۷۲۲	۰/۶۳۳۰	۰/۶۱۵۹	۲/۰۴۶۸	۱/۷۲۳۶	۲/۰۰۳۸	۱۸			
۰/۸۸۶۷	۰/۶۰۲۱	۰/۶۱۹۰	۱/۹۵۸۵	۱/۷۴۹۶	۱/۹۹۲۲	۲۰			

جدول ۵- ارزیابی دقت برآورد شبکه MLP با تابع فعال‌سازی تانزانی خطی.

مزرعه	دائم	R ²		RMSE				تعداد نمونه‌های لایه مخفی	
		رطوبت حجمی در حالت		رطوبت حجمی در حالت					
		ظرفیت نقطه پژمردگی	آب قابل دسترس	ظرفیت نقطه پژمردگی	آب قابل دسترس				
۰/۷۶۵۶	۰/۵۷۰۹	۰/۴۵۵۱	۲/۶۴۸۳	۱/۶۹۵۵	۳/۳۶۰۶	۲			
۰/۸۸۸۸	۰/۷۰۰۷	۰/۵۷۷۴	۲/۱۷۰۹	۱/۴۱۶۶	۲/۴۴۶۶	۴			
۰/۸۱۷۰	۰/۵۳۶۸	۰/۶۱۵۰	۲/۳۳۰۵	۱/۷۴۴۸	۲/۱۱۳۳	۶			
۰/۸۸۵۰	۰/۶۱۱۹	۰/۵۴۴۵	۲/۷۵۰۹	۱/۶۳۱۴	۲/۸۸۶۱	۸			
۰/۸۰۹۰	۰/۶۰۱۹	۰/۵۴۳۲	۲/۷۶۶۰	۱/۶۴۹۷	۳/۱۸۴۴	۱۰			
۰/۸۳۸۸	۰/۴۴۰۶	۰/۶۰۵۶	۳/۳۶۸۳	۱/۹۴۰۹	۲/۹۲۳۲	۱۲			
۰/۸۷۱۲	۰/۶۹۹۲	۰/۵۴۵۷	۲/۲۴۷۶	۱/۵۵۱۵	۳/۲۰۱۹	۱۴			
۰/۸۳۱۸	۰/۶۲۴۰	۰/۵۴۳۴	۳/۰۴۶۱	۱/۶۸۷۷	۲/۷۳۸۲	۱۶			
۰/۷۶۲۰	۰/۵۷۸۰	۰/۵۴۹۱	۲/۵۰۱۹	۱/۷۴۴۲	۳/۲۴۲۶	۱۸			
۰/۸۶۴۸	۰/۶۱۱۶	۰/۵۹۷۹	۲/۵۸۹۱	۱/۶۴۷۸	۲/۵۶۶۷	۲۰			

همچنین با توجه به نتایج نشان داده شده در جدول‌های ۳ تا ۵ و شکل (۲) می‌توان نتیجه گرفت که مدل MLP با تابع فعال‌سازی سیگموئیدی با کارایی بیشتری می‌تواند روابط مابین ورودی‌ها یا همان خصوصیات زود یافته خاک و خروجی‌های مدل یا همان نقاط شاخص منحنی رطوبتی را برقرار کند. در میان شبکه‌های متعدد آموخته شده، شبکه عصبی مصنوعی با تابع فعال‌سازی سیگموئیدی شبکه‌ای با تعداد ۶ نمون در لایه ورودی، ۱۰ نمون در لایه میانی و ۳ نمون در لایه خروجی به عنوان یک شبکه بهینه در این پژوهش معرفی می‌گردد.

میزان عملکرد



شکل ۲- میزان عملکرد شبکه MLP با توابع فعال‌سازی متفاوت.

تخمین نقاط شاخص منحنی رطوبتی خاک با استفاده از روش معادلات رگرسیونی SPSS 13.0 در این قسمت خصوصیات زود یافت اندازه‌گیری شده نمونه‌ها را با در نظر گرفتن مدلی به نام مدل تجربی گوپتا و لارسون ۱۹۷۹ به عنوان مدل پیش‌فرض (کوک کوک و بولتینک، ۱۹۹۹) به نقاط شاخص منحنی رطوبتی و رطوبت قبل استفاده را به عنوان خصوصیات دیر یافت در نرم‌افزار آماری SPSS 13.0 مرتبط کرده و معادلات رگرسیون بین این پارامترها به دست آمد.

$$\theta_{FC} = 0.1263Bd + 0.3512lime + 0.3428OM + 0.1217sand + 0.2711clay \quad (5)$$

$$RMSE = 2/4922 \quad R^2 = 0.642$$

$$\theta_{PWP} = 0.232Bd + 0.1682%lime + 0.7000%OM + 0.676%sand + 0.2040%clay \quad (6)$$

$$RMSE = 1/2667 \quad R^2 = 0.76$$

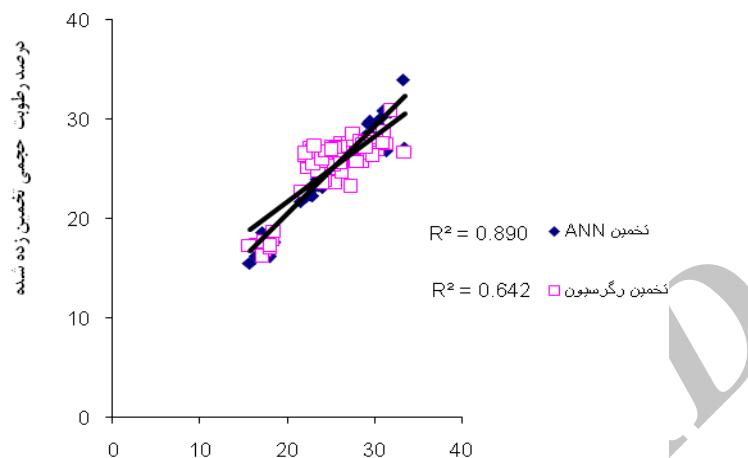
$$\theta_{AW} = 0.05917Bd + 0.35316%lime + 0.38346%OM + 0.5699%sand + 0.07495%clay \quad (7)$$

$$RMSE = 3/2825 \quad R^2 = 0.396$$

معادلات ۵ تا ۷ حاصل از برآش خصوصیات ورودی‌ها و خروجی‌های مورد نظر در محیط نرم‌افزار آماری SPSS13.0 می‌باشند. در معادلات فوق θ_{FC} و θ_{PWP} و θ_{AW} به ترتیب رطوبت در ظرفیت مزرعه (FC)، رطوبت در نقطه پژمردگی دائم (PWP) و رطوبت قبل دسترنس (AW) و Bd، AW، %OM، %lime، %sand، %clay به ترتیب جرم مخصوص ظاهری، درصد آهک، درصد موادآلی، درصدشن و درصد رس خاک می‌باشد.

جدول ۶- مقایسه عملکرد دو روش شبکه عصبی مصنوعی و معادلات رگرسیونی.

رگرسیون	شبکه عصبی صنعتی			خصوصیت مدل شده
	تائزاتی	سیگموئیدی	تائزاتی خطی	
خیلی کم	کم	زیاد	متوسط	FC
چیلی کم	زیاد	متوسط	کم	PWP
خیلی کم	کم	زیاد	متوسط	AW



درصد رطوبت حجمی اندازه گیری شده

شکل ۳- رطوبت حجمی ظرفیت مزرعه در حالت اندازه گیری شده در برابر تخمین مدل شبکه عصبی بهینه و روش رگرسیون.

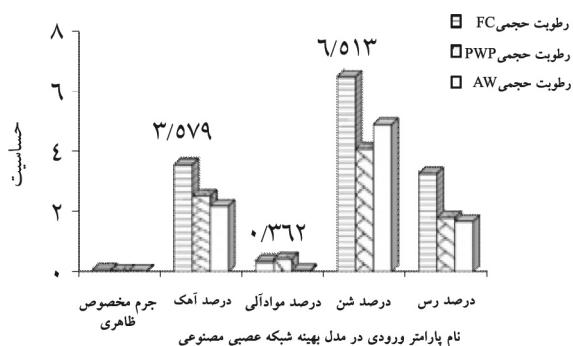
مقادیر R^2 و RMSE معادلات ۵ تا ۷ جهت مقایسه عملکرد روش رگرسیون و شبکه عصبی با توابع فعال‌سازی متفاوت با یکدیگر مقایسه شدند. همان‌گونه که در جدول ۶ نشان داده شده روش شبکه عصبی با عملکرد بهتری نسبت به روش رگرسیونی قادر به تخمین نقاط شاخص منحنی رطوبتی و رطوبت قابل دسترس می‌باشد، با توجه به تعداد بالای نمودارها (۹۰ نمودار جهت مقایسه رطوبت تخمینی سه نوع تابع فعال‌سازی با ۱۰ حالت مختلف و در سه نقطه رطوبتی با روش رگرسیون) تنها در نمودار شکل (۳) که مقادیر محاسبه شده به روش رگرسیون و شبکه عصبی بهینه با تابع فعال‌سازی سیگموئیدی را در حالت رطوبت ظرفیت مزرعه نشان می‌دهد، نقاط تخمین زده شده به دو روش رگرسیون و شبکه عصبی به صورت یک به یک مقایسه شده است. این نتایج مشابه با نتایج پاچپسکی و همکاران (۱۹۹۶) است آن‌ها نشان دادند که کارایی شبکه‌های عصبی بهتر از توابع رگرسیونی رائول و برانکزیک می‌باشد. مردان و همکاران (۲۰۰۶) با استفاده از روش ANN رطوبت موجود در حالت FC، PWP و AW را تخمین زدند و نشان دادند که کارایی روش رگرسیونی بهتر از روش شبکه عصبی مصنوعی می‌باشد اما در این پژوهش نتایج به دست آمده برخلاف روش مردان و همکاران (۲۰۰۶) و مشابه نتایج پاچپسکی و همکاران (۱۹۹۶) است. همچنین کوک کوک و بولتینک (۱۹۹۹)

نشان دادند که شبکه عصبی می‌تواند به عنوان یک روش کار آمد در تخمین منحنی رطوبتی به کار رود. به علاوه شاراد و همکاران (۲۰۰۴) نشان دادند که شبکه‌های عصبی مصنوعی به خوبی می‌تواند در مدل کردن نقاط مختلف منحنی رطوبتی خاک مورد استفاده قرار گیرد. با توجه به نتایج بدست آمده از این پژوهش به طور کلی هرگاه از توابع فعال سازی سیگموئیدی برای ایجاد روابط مابین خصوصیات زود یافته خاک و خصوصیت دیر یافته همچون نقاط تشکیل دهنده منحنی نگهداشت رطوبتی خاک استفاده شود نتایج مطلوبتری حاصل می‌گردد ولی همیشه به طور مطلق این حالت صادق نیست و همان‌گونه که در جدول‌های ۳ تا ۵ نشان داده شده در برخی موارد روابط تانزانی و یا خطی نتایج بهتری را ارائه می‌دهد که از این مطلب می‌توان نتیجه گرفت که از یک رابطه ثابت به طور مطلق نمی‌توان برای برقراری روابط مابین خصوصیات زود یافته و دیر یافته خاک در تمام گستره نقاط تشکیل دهنده منحنی رطوبتی بهره جست که در مطالعات مشابه اشاره‌ای به این مورد نشده است. به عنوان مثال با مقایسه جدول‌های ۳ و ۴ می‌توان مشاهده کرد که روابط تانزانی رطوبت نقطه پژمردگی را نسبتاً بهتر از رابطه سیگموئیدی توصیف می‌کند ولی به طور کلی رابطه سیگموئیدی در این پژوهش با توجه به شکل ۳ نسبت به سایر روابط برتری دارد. یکی دیگر از نکات قابل ذکر در این پژوهش که در مطالعات مشابه به آن توجهی نشده است تخمین بهتر رطوبت ظرفیت مزرعه نسبت به رطوبت پژمردگی دائم در هر سه نوع تابع فعال سازی روش شبکه عصبی و روش رگرسیونی می‌باشد که این حالت را شاید بتوان به این مورد نسبت داد که با تغییر مکش واردہ بر نمونه‌های خاک مورد آزمایش دامنه تغییرات خصوصیات زود یافته خاک بدون تغییر و ثابت باقی (درصد رس، شن، آهک و ...) تغییری نمی‌کند) می‌ماند اما دامنه تغییرات رطوبتی خاک با افزایش مکش روی نمونه‌های خاک کاهش می‌یابد به عبارتی اختلاف مقدار رطوبت نمونه‌ها در مکش‌های ۱۵ بار نسبت به $0/3$ بار به طور طبیعی بسیار ناچیز شده و مقدار رطوبت نمونه‌های با خصوصیات زود یافته متفاوت به هم نزدیک می‌شود که این حالت خود به کاهش همبستگی مابین خصوصیات زود یافته و دیر یافته خاک منجر می‌گردد و از این مورد می‌توان پی برد که کوچکترین خطای ناشی از اندازه‌گیری مقدار رطوبت نمونه‌های مورد آزمایش در مکش‌های بالا (۱۵ بار) به نحو چشمگیری‌تری بر روی تخمین مدل‌ها نسبت به مکش‌های پایین ($0/3$ بار) تاثیر گذاشته و عملکرد مدل‌ها را به شدت کاهش می‌دهد. از موارد ذکر شده در بالا می‌توان به این نتیجه رسید که همواره نمی‌توان از یک نوع تابع برای برقراری روابط مابین خصوصیات زود یافته و نقاط تشکیل دهنده منحنی رطوبتی استفاده کرد و

همچنین هر چه مقدار مکش واردہ بر نمونه‌های آزمایشی افزایش یابد ضریب همبستگی مابین این دو ویژگی کاهش می‌یابد که این خود دقیق‌تری در مکش‌های بالا را طلب می‌کند علاوه بر این موارد می‌توان به این مورد اشاره کرد که همواره نمی‌توان از یک سری خصوصیات زود یافته معمول و روتین در مطالعات مشابه برای تمام انواع خاک‌ها بهره جست و برای هر نوع خاک بسته به خصوصیات زود یافته آن مهم‌ترین خصوصیات زود یافته را باید برگزید همانند نمونه‌های مورد آزمایش در این مطالعه که خصوصیات زود یافته همچون درصد شن، آهک و رس به عنوان مهم‌ترین خصوصیات زود یافته (بر عکس خاک‌های اروپایی شامل درصد رس، شن و مواد آلی) انتخاب می‌شوند که در این شرایط آهک به دلیل درجه تاثیر بیشتر جانشین مواد آلی خاک می‌شود.

آنالیز حساسیت: آنالیز حساسیت، حد یا درجه حساسیت یک مدل ریاضی را به پارامترهای ورودی آن نشان می‌دهد. همان‌گونه که در شکل ۴ نشان داده شده، پارامتر ورودی درصد شن در مدل بهینه شبکه عصبی با تابع فعال‌سازی سیگموئیدی بیشترین تاثیر را بر خروجی‌های مدل دارد و درصد آهک خاک به عنوان دومین پارامتر مهم و موثر بر خروجی‌های مدل یادشده و درصد رس، درصد مواد آلی و جرم مخصوص ظاهری خاک در مرتبه بعدی اهمیت قرار دارند. به نظر می‌رسد درصد شن خاک به عنوان موثرترین پارامتر ورودی، مدل را به درصد بالای این پارامتر در نمونه‌های خاک مورد مطالعه نسبت داد زیرا نمونه خاک‌های مورد مطالعه دارای بافت لوم تا لوم شنی بودند. همچنین در مورد اثر قابل توجه پارامتر ورودی درصد آهک خاک بر خروجی‌های مدل شبکه عصبی بهینه نسبت به فاکتور مواد آلی را می‌توان به درصد بالای آهک و درصد بسیار پایین مواد آلی در نمونه‌های مورد مطالعه نسبت داد در حالی که این فاکتور مهم در سایر مطالعات به خصوص خاک‌های کشورهای اروپایی با توجه درصد بسیار پایین آهک مورد توجه قرار نگرفته است و درصد مواد آلی خاک به عنوان مهم‌ترین فاکتور تاثیرگذار بعد از بافت خاک به دلیل درصد بالای مواد آلی خاک در شرایط این خاک‌ها مورد تأکید قرار گرفته است که این عکس شرایط خاک‌های مورد مطالعه می‌باشد، همچنین به دلیل دامنه تغییرات بسیار پایین پارامتر جرم مخصوص ظاهری و تاثیر بسیار ناچیز این پارامتر بر خروجی‌های مدل می‌توان از این پارامتر ورودی چشم پوشی کرد.

1- Sensitivity analysis



شکل ۴- نمودار آنالیز حساسیت پارامترهای ورودی مدل بهینه شبکه عصبی مصنوعی (ANN) با تابع فعال‌سازی سیگموئیدی.

نتیجه‌گیری کلی

همان گونه که مشاهده شد، در این پژوهش از شبکه عصبی مصنوعی از نوع MLP با توابع فعال سازی متفاوت جهت برقراری روابط غیر خطی مابین ویژگی‌های ورودی و ویژگی‌های خروجی استفاده شد. نتایج بدست آمده حاصل از این پژوهش نشان داد که شبکه عصبی مصنوعی به عنوان یک روش شبیه‌ساز به نحو مطلوب‌تری در مقایسه با روش‌های رگرسیونی قادر به توصیف روابط غیرخطی مابین خصوصیات زود یافت خاک و خصوصیت دیر یافته مانند نقاط شاخص منحنی رطوبتی خاک می‌باشد و زمانی که از توابع غیرخطی از نوع سیگموئیدی استفاده می‌شود نتایج مطلوب‌تری بدست می‌آید (R^2 یا ضریب همبستگی‌های در حدود ۰/۶۱ تا ۰/۸۹ در مقایسه با روش خطی و هیپر بولیک با ضریب همبستگی پایین‌تر) همچنین در این پژوهش با توجه به نتایج آنالیز حساسیت به نظر می‌رسد که فاکتور آهک نیز به عنوان یک فاکتور تاثیرگذار بر خروجی‌های مدل بهینه شبکه عصبی قابل ذکر است (به عنوان مثال با توجه به شکل ۴ درجه حساسیت رطوبت ظرفیت مزروعه به فاکتور آهک ۳/۵ و به مواد آلی ۰/۳۶ می‌باشد) و با توجه به این که درصد بالایی از خاک‌های مناطق خشک و نیمه‌خشک مانند ایران دارای درصد بالای آهک می‌باشند (بیش از ۱۰ درصد) می‌توان از این پارامتر در مدل‌های شبیه‌ساز سود جست با توجه به این که مطالعه مورد نظر در محدوده بافتی و با تعداد نمونه‌های نه چندان زیاد صورت پذیرفته است، توصیه می‌شود برای حصول نتایج بهتر مطالعات مشابه در سطحی وسیع‌تر و با دامنه بافتی گسترده‌تر و با تعداد نمونه‌های بیشتر و دامنه

خصوصیات زود یافت (درصد آهک و مواد آلی) گسترده‌تر صورت پذیرد تا نقش فاکتورهای مهمی همچون آهک در شرایط خاک‌های ایران پر رنگ‌تر گردد.

منابع

- 1.Khodaverdi lo. H. and Homaii, M. 2002. Derivation soil pedotransfer functions for estimating moisture characteristic curve. J. of Agricultural Engineering Research. 3: 10. 46-35.
- 2.Farokhian Firozi, A. and Homaii, M. 2003. Estimating parametric of gypsiferous soils hydraulic properties using pedotransfer functions. J. of Agricultural Enginnering Research. 4: 15. 72-57. (In Persian).
- 3.Buszewski, B., and Kowalkowski, T. 2006. A new model of heavy metal transport in the soil using non-linear artificial neural networks. Environ. Eng. Sci. 23; 4.589-595.
- 4.Gupta, S.C., and Larson, W.E. 1979. Estimating soil water characteristic from particle size distribution, organic matter percent, and bulk density. Water Resour. Res. 15: 1633-1635.
- 5.Hecht-Nielsen, R. 1990. Neurocomputing. Addison-Wesley Publ. Co., Reading, MA.
- 6.Klute, A. 1986. Methods of soil Analysis: Physical and mineralogical methods. Arnold Klute, Albert edition Lee Page Edition, American Society of Agronomy, Madison, Wisconsin. Pp:635-662.
- 7.Koekkoek, E.J.W. and Boolink, H. 1999. Neural network models to predict soil water retention. European Journal of Soil Sci.50:489-495
- 8.McCoord, N.M., and Illingworth, W.T. 1990. A practical guide to neural nets. Addison-Wesley, Publ. Co. the University of Michigan, 344p.
- 9.Merdun, H., Cinar, O., Meral, R. and Apan, M. 2006. Comparison of artificial neural network and regression pedotransfer functions for prediction of soil water retention and saturated hydraulic conductivity. Soil&Till.Res.90:108-116.
- 10.Minyoung, K. and John, E. 2008. Artificial Neural Network estimation of soil erosion and nutrient concentrations in runoff from land application areas. Computers and electronics in agriculture. 64: 268–275
- 11.Namdar-Khojaste, D., Shorafa, M., Omid, M. and Fazeli-Shaghani. M. 2010. Application of artificial neural networks in modeling soil solution electrical conductivity. Soil Sci. 175: 432-437.
- 12.Pachebsky, Y.A., Timalin, D., and Varallyay, G. 1996. Artificial Neural Networks to Etimate Soil Water Retention from Easily Measurable Data. Soil Sci. Soc. Am. J.60:727-733.

- 13.Rahim khoob, A. 2009. Estimation of evapotranspiration based on only air temperature data using artificial neural networks for a subtropical climate in Iran.J Irrig Drain Eng ASCE 122. 2: 97–106
- 14.Schaap, M. G., Leij, F.L., and van Genuchten, M.Th. 1998. Neural network analysis for hierarchical prediction of soil hydraulic properties. Soil Sci. Soc. Am. J. 62: 847–855.
- 15.Sharad, K., Vijay, P., and van Genuchten, M.Th. 2004. Analysis of Soil Water Retention Data Using Artificial Neural Networks. Journal of Hydrological Engineering, 9: 415-420.
- 16.Van Genuchten, M.Th., and Leij, F.J. 1992. On estimating the hydraulic properties of unsaturated soils. pp;1-14 in M.Th. van Genuchten, F.J. Leij, and L.J. Lund, eds. Indirect methods for estimating the hydraulic properties of unsaturated soils. Proc. of the International Workshop on Indirect Methods for Estimating the Hydraulic Properties Unsaturated Soils. 11-13 October 1989, Riverside, Cal., U.S.A.
- 17.Vereecken, H., Diels, J., van Orshoven, J., Feyen, J., and Bouma, 1992. Functional evaluation of pedotransfer functions for the estimation of soil hydraulic properties. Soil Sci. Soc. Am. J. 56: 1371-1378.
- 18.Zhongyi, Q., Guanhua, H., and Jingyu, Y. 2009. Evalution of Reginal Pedotransfer Functions Based on the BP Neural Networks. Pp: 1189–1199, Daoliang Li, Chunjiang Zhao (eds), Computer and Computing Technologies in Agriculture, Springer, Beijing.



Gorgan University of Agricultural
Sciences and Natural Resources

J. of Water and Soil Conservation, Vol. 19(2), 2012
<http://jwst.gau.ac.ir>

Estimation of index points of soil moisture retention curve of some calcareous soils with readily available soil properties by artificial neural network

A. Belyani¹, M. Sharfa² and M. Omid³

¹M.Sc. Student, Dept. of Soil Sciences, University of Tehran, ²Assistant Prof. Dept. of Soil Sciences, University of Tehran, ³Associate Prof. Dept. of Agricultural machinery, University of Tehran

Received: 2011-11-28; Accepted: 2012-12-10

Abstract

Since the measurement of soil moisture retention curve and its index points like field capacity and permanent wilting point are costly and time-consuming using direct methods, one of the quick and low costly estimation methods of these properties is estimating of those properties with respect to soil basic properties including particle size distribution and organic matter content as well as bulk density. In this study, index points of soil moisture retention curve such as field capacity, permanent wilting point and available water were estimated using MLP type neural network with three activate functions and regressions methodology with respect to soil basic properties. In order to conduct the aforementioned issue, 60 soil samples were collected from the case study, the region of Robatkarim of Karaj city, with an area of 24 ha. Then, the moisture content of the index points of soil moisture retention curve was measured by using the pressure plate. Further soil basic properties including the percentages of clay, sand, bulk density and organic matter as well as lime and the moisture content of the index points were measured using the aforementioned methodology. The results of the investigations showed that the artificial neural networks by sigmoid activate function a network with 6 neurons in the input layer and 10 neurons in the hidden layer as well as 3 neurons in the output layer with Performance indicators R^2 and RMSE variations of 0.6197–0.8902 and 1.6846–2.0225, respectively was introduced as the efficient network which had the best performance in estimation of wanted outputs in comparison with another activate functions (method of artificial neural network) and regression method. Percentage of lime according to results of sensitivity analysis is considered as an effective factor in the range of soils texture tested.

Keywords: Percentage of lime; Soil water retention curve; Artificial neural network; Activate transfer

* Corresponding author; Email: alibl363@gmail.com