



تخمین مقادیر شاخص مخروطی خاک به کمک مدل شبکه‌های عصبی مصنوعی و مقایسه آن با مدل رگرسیونی

* یوسف عباسپور گیلانده^۱ و علیرضا شایگانی سلطانیپور^۲

^۱دانشیار گروه مهندسی مکانیک ماشین‌های کشاورزی، دانشگاه محقق اردبیلی،

^۲دانش آموخته کارشناسی ارشد گروه مهندسی مکانیک ماشین‌های کشاورزی، دانشگاه محقق اردبیلی

تاریخ دریافت: ۹۱/۱۰/۱۷؛ تاریخ پذیرش: ۹۲/۴/۱۷

چکیده

شاخص مخروطی خاک به‌عنوان یکی از معیارهای بیان‌کننده مقاومت مکانیکی خاک تحت تأثیر عوامل مختلفی از جمله محتوی رطوبتی خاک و فشردگی خاک‌های زراعی قرار می‌گیرد. امروزه با وجود پیشرفت‌های چشم‌گیر در توسعه کشاورزی دقیق، مدیریت تولید محصول در ارتباط با خصوصیات فیزیکی خاک به چند سال اخیر برمی‌گردد که یکی از مهم‌ترین این خصوصیات، مقاومت مکانیکی خاک است که به‌طور عموم با نقشه‌های شاخص مخروطی خاک بیان می‌شود. در این پژوهش برای اندازه‌گیری و تعیین عوامل مؤثر بر مقدار شاخص مخروطی خاک، آزمایش‌های مزرعه‌ای در سه نوع خاک و در داخل هر نوع خاک از آزمایش فاکتوریل بر پایه طرح بلوک کامل تصادفی (RCDB) و با ۵ تکرار استفاده شد. در داخل هر بافت خاک سطوح مختلف رطوبت در ۳ سطح (خشک، نیمه‌مرطوب و مرطوب)، عمق در ۳ سطح (۱۰-۰، ۲۰-۰ و ۳۰-۰ سانتی‌متر) و تعداد تردد تراکتور در ۳ سطح (۰، ۱۰ و ۲۰ بار عبور) بر روی شاخص مخروطی خاک بررسی شد. پس از تجزیه و تحلیل داده‌ها مشخص گردید که اثرات نوع خاک، عمق، سطوح مختلف رطوبت و تردد تراکتور بر روی مقادیر شاخص مخروطی خاک در سطح ۱ درصد معنی‌دار بوده است. در این پژوهش برای تعیین مدل ریاضی شاخص مخروطی خاک (عامل وابسته) از رگرسیون چندمتغیره خطی استفاده شد. ۴ عامل مستقل درصد محتوی رطوبتی، جرم مخصوص ظاهری، هدایت الکتریکی و عمق نمونه‌برداری در این مدل مورد استفاده قرار گرفتند. نتایج به‌دست آمده نشان داد اثر همه متغیرهای مستقل بروی شاخص مخروطی به‌عنوان متغیر وابسته در سطح ۱ درصد معنی‌دار شده است. شبکه‌های عصبی مصنوعی طراحی شده در این پژوهش که به‌منظور تخمین شاخص مخروطی خاک

* مسئول مکاتبه: abbaspour@uma.ac.ir

مورد استفاده قرار گرفتند، از نوع شبکه‌های چندلایه پس‌انتشار برگشتی بودند که به منظور آموزش شبکه از سه الگوریتم گرادیان نزولی با مومنتوم، الگوریتم لونیبرگ-مارکوات و الگوریتم گرادیان نزولی مقیاسی استفاده گردید. شبکه پس‌انتشار برگشتی با الگوریتم آموزشی لونیبرگ-مارکوات با تابع تبدیل لگاریتم سیگموئیدی نتایج بهتری را نسبت به سایر الگوریتم‌های آموزشی در شبیه‌سازی داده‌ها و آموزش شبکه عصبی مصنوعی ارائه کرد. استفاده از دو لایه مخفی هر کدام با ۳۴ نرون دارای بهترین عملکرد نسبت به سایر الگوریتم‌های آموزشی و همچنین الگوریتم آموزشی لونیبرگ-مارکوات با یک لایه مخفی نشان داد. مقایسه نتایج به دست آمده از مدل شبکه عصبی مصنوعی و مدل‌های رگرسیونی به منظور پیش‌بینی شاخص مخروطی خاک نشان داد که مدل شبکه عصبی مصنوعی قادر به مدل کردن مقادیر شاخص مخروطی با دقت بالاتر نسبت به مدل‌های رگرسیونی ارائه شده در این پژوهش می‌باشد. نتایج این پژوهش می‌تواند در مدیریت فشردگی خاک در خاک‌های دشت اردبیل و همچنین تعیین عمق بهینه ادوات خاک‌ورز اولیه مورد استفاده قرار گیرد.

واژه‌های کلیدی: شاخص مخروطی، بافت خاک، رطوبت، جرم مخصوص ظاهری، هدایت الکتریکی، شبکه عصبی مصنوعی، الگوریتم لونیبرگ-مارکوات

مقدمه

یکی از خصوصیات مهم خاک که در بحث رابطه بین خاک، گیاه و همچنین مطالعه اثر متقابل خاک-ماشین مطرح می‌باشد، استحکام خاک یا به عبارت دیگر مقاومت مکانیکی خاک می‌باشد. مقاومت مکانیکی خاک به صورت مقاومت در برابر تغییر شکل خاک توصیف می‌گردد. حفظ نسبت‌های مناسب بین فازهای جامد، مایع و گاز خاک از اهمیت ویژه‌ای برخوردار است. زیرا افزایش فاز جامد (کاهش فاز مایع و گاز)، باعث افزایش مقاومت مکانیکی خاک شده و به دنبال آن رشد و توسعه ریشه گیاهان در داخل خاک کاهش می‌یابد. تراکم خاک از جمله شاخص‌های نشان‌دهنده تخریب ساختمان فیزیکی خاک می‌باشد که به صورت افزایش در جرم مخصوص ظاهری یا کاهش تخلخل تعریف می‌شود (زارعیان، ۱۹۸۵). مهم‌ترین اثرات تراکم خاک بر محصول را می‌توان به صورت حساسیت بیش از حد گیاه به خشکی، تهویه ناکافی، کاهش جذب آب توسط گیاه، کاهش بازده عناصر غذایی، رشد غیریکنواخت گیاهان، کند شدن جوانه‌زنی، سیستم ریشه‌ای بد شکل و در نهایت کاهش محصول بیان کرد (هورن و همکاران، ۱۹۹۵).

از دیدگاه مهندسین ماشین‌های کشاورزی، تراکم خاک باعث افزایش مقاومت مکانیکی خاک شده و به دنبال آن افزایش نیروی مقاوم کششی، افزایش مصرف سوخت، افزایش زمان انجام کار و افزایش سائیدگی ادوات کشاورزی را به دنبال خواهد داشت. بر طبق پژوهش‌های انجام شده در حدود ۶۰ درصد از انرژی مکانیکی مورد مصرف در کشاورزی مکانیزه صرف عملیات خاک‌ورزی و تهیه بستر بذر می‌گردد (جاکوبز و فینری، ۱۹۹۳).

معیارها و روش‌های مختلفی به منظور مشخص نمودن تراکم یا فشردگی خاک در داخل یک زمین زراعی وجود دارد و پژوهش‌گران مختلف، شاخص‌ها و روش‌های متفاوتی را برای این کار ارایه کرده‌اند که از آن جمله می‌توان به شاخص رنگ خاک (تشخیص فشردگی از طریق مشاهده)، اندازه‌گیری جرم مخصوص ظاهری، رادارهای نفوذکننده در داخل زمین و اندازه‌گیری شاخص مخروطی خاک را نام برد (ریپر و همکاران، ۱۹۹۰؛ آپدایاها و همکاران، ۱۹۹۴). در بین این روش‌ها از آن‌جا که نفوذسنج‌های مخروطی داده‌های به نسبت دقیق‌تری را براساس فشردگی خاک ارایه می‌کنند و همچنین کارکردن با آن‌ها راحت و سریع می‌باشد، بیش‌تر مورد پذیرش می‌باشند. به علاوه با استفاده از این روش می‌توان تغییرات مقاومت مکانیکی خاک را در ارتباط با عمق در مقایسه با سایر روش‌ها در اختیار بگذارد (مولکوئین و همکاران، ۱۹۷۷؛ کلارک، ۱۹۹۹). ولی باید توجه نمود یافتن روش‌هایی که بتواند با کم‌ترین هزینه و با استفاده از داده‌های قابل دسترس مانند جرم مخصوص ظاهری، رطوبت خاک و... مناسب‌ترین تابع را برای تخمین شاخص مخروطی خاک ایجاد کند، بسیار دارای اهمیت می‌باشد.

امروزه با وجود پیشرفت‌های چشم‌گیر در توسعه کشاورزی دقیق، مدیریت تولید محصول در ارتباط با خصوصیات فیزیکی خاک به چند سال اخیر بر می‌گردد. همراه با افزایش اطلاعات در واحد کوچکی از سطح مزرعه و با رقم خوردن فن‌آوری جدیدی تحت عنوان کشاورزی دقیق، تولیدکنندگان محصولات کشاورزی با استفاده از سیستم موقعیت‌سنج جهانی توانایی جمع‌آوری داده‌های متغیرهای مؤثر در تولید محصول مانند داده‌های پارامترهای خاک در نقاط مختلف مزرعه را دارند که این داده‌ها می‌تواند در مدیریت فشردگی خاک از طریق خاک‌ورزی دقیق مورد استفاده قرار گیرند.

با توجه به محدودیت‌های روش‌های تحلیلی و ترسیم خط برآزش (رگرسیون) در کاربردهای پیش‌بینی، استفاده از داده‌های پارامترهای مختلف خاک مانند جرم مخصوص ظاهری، رطوبت خاک و... به منظور پیش‌بینی شاخص مخروطی، مجموعه داده‌های خوبی را برای کار در شبکه عصبی مصنوعی فراهم می‌کند. با استفاده از این روش مقادیر پارامترهای ورودی و خروجی بدون هیچ‌گونه

فرضیه و یا رابطه ریاضی از پیش تعیین شده‌ای به همدیگر مرتبط می‌شوند (گو، ۱۹۹۵؛ کوشواها و ژانگ، ۱۹۹۸؛ لواین و همکاران، ۱۹۹۶). در چنین مواردی که اطلاعات کافی از روابط بین پارامترها در دسترس نمی‌باشد، شبکه عصبی مصنوعی به‌عنوان یک ابزار قوی در مدل کردن سیستم خاک عمل خواهد کرد که استفاده از شبکه عصبی مصنوعی بسیاری از محدودیت‌های روش‌های تحلیلی را برطرف می‌نماید و مطابق با شرایط فعلی و شرایط حاکم بر سیستم و به کمک داده‌های واقعی آموزش دیده و برای کاربردهای بعدی تعمیم داده می‌شود. پارامترهایی که برای پیش‌بینی شاخص مخروطی خاک مورد استفاده قرار می‌گیرند شامل پارامترهای مختلف خاک از جمله جرم مخصوص ظاهری، رطوبت و هدایت الکتریکی خاک خواهند بود که در مطالعات مختلف اثرات این پارامترها روی شاخص مخروطی خاک مورد بررسی قرار گرفته است. دلیل استفاده از شبکه عصبی مصنوعی برای این کار قدرت پیش‌بینی بالای این روش و همچنین نبود رابطه ریاضی مشخص بین متغیرهای مستقل و وابسته در این پژوهش می‌باشد.

پژوهش‌ها نشان داده است که ارتباط نزدیکی بین مقادیر شاخص مخروطی خاک به‌عنوان پارامتر مشخص‌کننده تراکم و فشردگی خاک‌های زراعی و جرم مخصوص ظاهری (پیدجن و سانه، ۱۹۷۷؛ هندرسون و همکاران، ۱۹۸۸) و همچنین بین شاخص مخروطی و محتوی رطوبتی خاک (فائور و داماتا، ۱۹۹۸) وجود دارد. اگرچه محتوی رطوبتی تأثیر قابل‌ملاحظه‌ای روی مقاومت خاک و مقادیر شاخص مخروطی دارد، اما هنوز هیچ رابطه مشخص و دقیقی برای تعیین ارتباط بین شاخص مخروطی و محتوی رطوبتی پیشنهاد نشده است (لیپین و همکاران، ۱۹۹۸). همچنین شاخص مخروطی می‌تواند با توجه به تأثیر بافت خاک بر میزان مقاومت مکانیکی خاک، تابع هدایت الکتریکی خاک نیز باشد (عباسپور گیلانده و خلیلیان، ۲۰۰۹). با توجه به این‌که هنوز مدل‌های ارایه شده برای ارتباط بین شاخص مخروطی و عوامل درصد محتوی رطوبت خاک، جرم مخصوص ظاهری و هدایت الکتریکی خاک دقیق نبوده و در بسیاری از موارد برای یک نوع خاک معین ارایه شده است، مطالعه و بررسی در به‌دست آوردن یک مدل جامع و کامل همچنان ادامه دارد.

ولز و بیرد (۱۹۸۷) با استفاده از نتایج به‌دست آمده از آزمایش‌های نفوذ در سه نوع خاک مختلف (سیلتی لومی، سیلتی رسی لومی و لومی شنی) با ۲ چگالی و ۴ سطح رطوبتی، رابطه‌ای تجربی برای تخمین شاخص مخروطی پیشنهاد کردند.

$$CI = K_1 + K_2(BD) + K_3(PCL) + K_4(POM) + K_5[\text{Log}(MC)]^2 + K_6[\text{Log}(MC)]^3 \quad (1)$$

که در آن، CI: شاخص مخروطی بر حسب (کیلوگرم بر سانتی مترمربع)، BD: چگالی مواد بر حسب (کیلوگرم بر سانتی مترمکعب)، PCL: درصد رس (درصد)، POM: درصد مواد آلی (درصد)، MC: مقدار رطوبت براساس خاک مرطوب و $K_1 - K_6$: ثابت‌ها. اوها و همکاران (۱۹۸۸) رابطه زیر را برای تخمین شاخص مخروطی پیشنهاد کردند:

$$\frac{CI}{P_c} = A \left(\frac{T_s}{\theta_p} \right)^{n\theta} \quad (2)$$

که در آن، CI: شاخص مخروط (kpa)، P_c : فشار (kpa)، T_s : مقاومت برشی به دست آمده از حد سیلان، محتوی رطوبتی و فشار ایستائی (kpa)، θ_p : فشار بیش باری (kpa) و n و A : ثابت‌های وابسته به خاک هستند. در این مدل، شاخص مخروط برای خاک‌های لومی شنی، لومی رسی و رسی با استفاده از مقاومت برشی، فشار بیش باری، محتوی رطوبتی و مقدار انرژی فشردگی به کار رفته برای خاک تخمین زده می‌شود.

باسکر (۱۹۹۰) ۱۰ تابع مختلف را برای ارزیابی دقت‌شان در پیش‌بینی شاخص مخروط به واسطه محتوی رطوبتی برای خاک‌های الک شده با بافت‌های شنی تا لومی شنی آزمایش نمود. تابع $PR = a\mu^b BD^c$ بیش‌ترین R^2 را تولید کرد که در این رابطه μ مکش متریک خاک و a ، b و c ثابت‌های خاک هستند.

وورهایس و والکر (۱۹۹۷) در یک پژوهش انجام شده روی خاک لومی سیلتی، رابطه زیر را بین شاخص مخروطی و درصد رطوبت خاک بیان نمودند:

$$CI = \frac{4527}{75} - \frac{137}{9(MC)} \quad (3)$$

که در آن، MC: درصد رطوبت خاک (براساس وزن خشک) و CI: شاخص مخروطی (kpa). آن‌ها نتیجه گرفتند که با افزایش درصد رطوبت، شاخص مخروطی کاهش می‌یابد.

علی‌مردانی و صلح‌جو (۲۰۰۴) در پژوهش‌های خود بر خلاف پژوهش‌های قبلی نشان دادند که با افزایش درصد رطوبت، شاخص مخروطی کاهش پیدا می‌کند. آن‌ها سعی کردند تا یک مدل ریاضی را برای شاخص مخروطی در ارتباط با جرم مخصوص ظاهری و محتوی رطوبتی به‌دست آورند. آن‌ها پس از تجزیه و تحلیل داده‌هایشان، دو مدل خطی و غیرخطی زیر را به‌منظور تخمین شاخص مخروطی ارائه نمودند:

$$CI = 2192 + 5388(BD) - 233(MC) \quad (4)$$

$$CI = \frac{4336(BD)^4}{(MC)^{1/66}} \quad (5)$$

که در آن‌ها، BD: جرم مخصوص ظاهری براساس وزن خشک (گرم بر سانتی‌متر مکعب) و Mc: درصد رطوبت خاک خشک.

ضریب تبیین مدل خطی ۰/۸۶ و برای مدل غیرخطی ۰/۸۸ به‌دست آمد. با توجه با اختلاف ناچیز ضرایب بین دو مدل و درجه ۴ بودن مدل غیرخطی، آن‌ها استفاده از مدل خطی را برای تخمین مقادیر شاخص مخروطی در خاک‌های غالب منطقه زرقان فارس که لومی رسی می‌باشد توصیه کردند.

مواد و روش‌ها

آزمایش‌های مزرعه‌ای: آزمایش‌های مزرعه‌ای در مزرعه پژوهشی دانشکده کشاورزی دانشگاه محقق اردبیلی با ارتفاع ۱۳۵۰ متر از سطح دریا، طول جغرافیایی ۴۸ درجه و ۲۰ دقیقه و عرض جغرافیایی ۳۸ درجه و ۱۹ دقیقه با سه بافت خاک لومی رسی، رسی و لومی انجام شد. از یک دستگاه نفوذسنج مخروطی به‌منظور اندازه‌گیری مقاومت به نفوذ خاک استفاده گردید. مقادیر شاخص مخروطی براساس نیروی اندازه‌گیری شده برای فشار دادن یک مخروط با سطح مقطع ۱۳۰ میلی‌متر مربع و زاویه نوک ۳۰ درجه به داخل خاک مطابق با استاندارد ASAE محاسبه شد. مقادیر شاخص مخروطی خاک از عمق ۰-۳۰ سانتی‌متر اندازه‌گیری شدند (عباسپور گیلانده و همکاران، ۲۰۱۰).

به‌منظور اندازه‌گیری درصد محتوی رطوبتی خاک، بعد از برداشت نمونه‌های خاک موردنظر در عمق‌های معین، آن‌ها با ترازوی حساس الکترونیکی وزن شدند و سپس در آونی با درجه حرارت ۱۰۵

درجه سانتی‌گراد و به مدت ۲۴ ساعت قرار داده شدند. پس از گذشت ۲۴ ساعت، دوباره نمونه‌های خاک وزن شدند و در نهایت از رابطه زیر درصد رطوبت خاک (براساس وزن خشک) تعیین شد:

$$Mc = \left(\frac{W_w - W_d}{W_d} \right) \times 100 \quad (6)$$

که در آن، W_w : وزن مرطوب خاک (گرم) و W_d : وزن خشک خاک (گرم). برای تعیین جرم مخصوص ظاهری خاک، نمونه‌هایی از خاک مزرعه از عمق ۳۰-۰ سانتی‌متر را بدون دست‌خوردگی برداشته و پس از خشک نمودن در حرارت ۱۰۵ درجه سانتی‌گراد و به مدت ۲۴ ساعت، وزن خشک خاک و حجم نمونه برداشت شده اندازه‌گیری شد و جرم مخصوص ظاهری خاک از تقسیم وزن به حجم نمونه خاک تعیین شد.

برای تعیین هدایت الکتریکی خاک، ابتدا محلول سوسپانسیونی تهیه شد که در آن نسبت خاک به آب ۱:۲ بود. سپس برای شفاف شدن آن، محلول سوسپانسیون از کاغذ صافی عبور داده شد. سپس با استفاده از یک دستگاه کندانکتومتر مقدار هدایت الکتریکی (EC) سوسپانسیون تعیین شد. از آنجا که قابلیت هدایت الکتریکی یک محلول باید در دمای ۲۵ درجه سانتی‌گراد گزارش شود و با توجه به این‌که در دامنه ۳۰-۱۵ درجه سانتی‌گراد به‌ازای افزایش هر درجه سانتی‌گراد، هدایت الکتریکی ۲ درصد افزایش پیدا می‌کند بنابراین برای تصحیح هدایت الکتریکی خاک از رابطه زیر استفاده شد:

$$EC_{25} = EC_t - 0.02(t - 25)EC_t \quad (7)$$

طراحی مدل شبکه عصبی مصنوعی: شبکه‌های طراحی شده در این پژوهش که به‌منظور پیش‌بینی مقادیر شاخص مخروطی خاک از نوع شبکه چندلایه پس‌انتشار برگشتی می‌باشند. از سه روش الگوریتم گرادیان نزولی با مومنتم، الگوریتم لوببرگ-مارکوات و الگوریتم گرادیان نزولی مقیاسی به‌منظور آموزش شبکه استفاده گردیده است.

شبکه‌های چندلایه در کارهای پیش‌بینی قابلیت بسیار خوبی را از خود نشان می‌دهند به شرطی که نرون کافی در لایه مخفی وجود داشته باشد. در حالت کلی نمی‌توان در مورد تعداد لایه‌های مخفی و نیز تعداد مناسب نرون‌های لایه مخفی اظهار نظر قطعی کرد و انتخاب تعداد نرون‌های لایه میانی به‌صورت سعی و خطا انجام می‌گیرد. در این پژوهش نیز تعداد لایه‌های مخفی و تعداد نرون‌ها در لایه میانی (یا لایه‌های میانی) متناسب با تعداد نرون‌های لایه میانی بر مبنای مقایسه عملکرد شبکه‌ها

انتخاب شد. همچنین در این پژوهش از توابع تبدیل تانژانت سیگموئیدی، لگاریتم سیگموئیدی و تابع محرک خطی بین لایه‌های شبکه استفاده گردید. به منظور بهبود خاصیت تعمیم‌پذیری شبکه روش توقف زودرس اختیار شد. مطابق این روش داده‌ها به سه زیرمجموعه آموزش، معتبرسازی و آزمایش تقسیم شدند. به این ترتیب که یک چهارم داده‌ها (۲۵ درصد) برای آزمایش، یک چهارم داده‌ها (۲۵ درصد) برای ارزیابی و نیمی (۵۰ درصد) برای آموزش در نظر گرفته شد. این داده‌ها به صورت تصادفی از میان نمونه‌های ورودی برداشته شدند.

بهترین روش آموزش برای داده‌های مورد استفاده و همچنین مقایسه عملکرد شبکه‌های ساخته شده بر اساس معیارهای میانگین مربعات خطا (MSE)، مجموع مربعات خطا (SSE) و ضریب تبیین (R^2) مدل برازش شده خطی بین داده‌های واقعی و داده‌های پیش‌بینی شده انجام گردید. به منظور مقایسه آماری میزان دقت شبکه‌های طراحی شده، از معیار دقت پیش‌بینی مدل استفاده گردید که میزان دقت پیش‌بینی مدل (P.A.) نسبت اختلاف بین داده‌های واقعی با داده‌های پیش‌بینی شده به داده‌های واقعی تعریف می‌گردد.

داده‌های مورد استفاده در شبکه عصبی مصنوعی طراحی شده: از آنجا که هدف از توسعه مدل شبکه عصبی مصنوعی در این پژوهش پیش‌بینی مقادیر شاخص مخروطی خاک می‌باشد، باید بردارهای ورودی از میان پارامترهای مؤثر بر آن‌ها انتخاب گردند. در این پژوهش پارامترهای ورودی به شبکه عصبی مصنوعی برای پیش‌بینی مقادیر شاخص مخروطی خاک، پارامترهای خصوصیات فیزیکی و مکانیکی خاک (جرم مخصوص ظاهری، هدایت الکتریکی و محتوی رطوبتی خاک) بودند. داده‌های موردنیاز از قسمت‌های مختلف مزرعه‌های آزمایشی انتخاب گردید. انتخاب داده‌ها به نحوی بود که بتواند تغییرات هر یک از پارامترهای سهمیم در کار پیش‌بینی را به خوبی بیان کرده و شرایط حاکم بر مزرعه‌های آزمایشی را به خوبی بیان کنند.

نتایج و بحث

تجزیه واریانس داده‌ها: نتایج به دست آمده از تجزیه واریانس داده‌های مربوط به اندازه‌گیری شاخص مخروطی خاک در جدول ۱ آمده است. ضریب تغییرات داده‌های شاخص مخروطی خاک (CV) معادل ۱۳/۳۳ درصد می‌باشد، که این میزان پراکندگی با توجه به تعداد تیمارهای مختلف و شرایط مختلف مناطق آزمایشی منطقی به نظر می‌رسد.

با توجه به جدول تجزیه واریانس مشاهده می‌شود که اثرات اصلی بافت خاک، رطوبت، تردد تراکتور و عمق به‌طور مجزا بر شاخص مخروطی خاک معنی‌دار است (سطح احتمال ۱ درصد)، ضمن این‌که اثرات متقابل دوتایی بافت خاک در رطوبت، بافت خاک، رطوبت و تردد تراکتور در عمق بر شاخص مخروطی خاک نیز معنی‌دار است (سطح احتمال ۱ درصد). همچنین اثر متقابل رطوبت در تردد تراکتور بر شاخص مخروطی خاک در سطح احتمال ۵ درصد معنی‌دار می‌باشد و تنها اثر متقابل بافت خاک در تردد تراکتور بر شاخص مخروطی خاک معنی‌دار نیست که این نشان می‌دهد اثر این دو فاکتور بر روی شاخص مخروطی خاک مستقل از یکدیگر می‌باشد. همه اثرات متقابل سه‌تایی همان‌طور که در جدول ۱ مشاهده می‌شود در سطح احتمال ۱ درصد بر شاخص مخروطی خاک معنی‌دار می‌باشند. همچنین اثرات متقابل چهارتایی بافت خاک در رطوبت در تردد تراکتور در عمق بر شاخص مخروطی خاک در سطح احتمال ۱ درصد معنی‌دار می‌باشد. اثر معنی‌دار چهارگانه بر شاخص مخروطی خاک نتیجه قابل ملاحظه‌ای است که استفاده از سیستم‌های مدل‌سازی پیشرفته مانند شبکه عصبی مصنوعی را کاملاً موجه می‌سازد. نتایج این بخش نشان می‌دهند که باید اثر چهار عامل بافت خاک، رطوبت، تردد تراکتور و عمق را در بررسی شاخص مخروطی خاک در نظر گرفت.

ارایه مدل رگرسیونی شاخص مخروطی خاک: برای تعیین مدل ریاضی شاخص مخروطی خاک، در ارتباط با درصد محتوی رطوبتی خاک، جرم مخصوص ظاهری، هدایت الکتریکی و عمق از مقادیر به‌دست آمده هر یک از متغیرهای ذکر شده استفاده شد. به این منظور در هر کرت آزمایشی با ۵ تکرار مقادیر عوامل مستقل «درصد محتوی رطوبتی، جرم مخصوص ظاهری، هدایت الکتریکی و عمق نمونه‌برداری» و عامل وابسته «شاخص مخروطی خاک» ثبت شد. برای انجام عملیات آماری از رگرسیون چندمتغیره خطی استفاده شد. در این حالت رگرسیون برای ۴ عامل مستقل (درصد محتوی رطوبتی، جرم مخصوص ظاهری، هدایت الکتریکی و عمق نمونه‌برداری) و عامل وابسته (شاخص مخروطی خاک) برای تعیین مدل ریاضی انجام شد. مدل خطی به‌دست آمده برای تعیین مدل ریاضی شاخص مخروطی خاک در زیر آمده است:

$$CI = 26/2 \times D + 1298/6 \times BD - 28/8 \times MC + 133/3 \times \log EC - 1062/6 \quad (8)$$

که در آن، CI: شاخص مخروطی خاک (kpa)، D: عمق خاک (mc)، BD: جرم مخصوص ظاهری (گرم بر سانتی‌متر مکعب) و EC: هدایت الکتریکی خاک ($\mu\text{s}/\text{cm}$) می‌باشد. برای پذیرش مدل

رگرسیون خطی به دست آمده بررسی فرض نرمال بودن مانده‌ها، فرض ثابت بودن واریانس، مستقل بودن و شاخص Leverage انجام شد و نتایج نشان از قابل قبول بودن مدل رگرسیون خطی به دست آمده به منظور پیش‌بینی مقادیر شاخص مخروطی خاک را داشت.

جدول ۱- نتایج تجزیه واریانس داده‌های شاخص مخروطی خاک.

منابع تغییرات	درجه آزادی	میانگین مربعات
تکرار	۴	۱۵۹۴۹/۵۱۵ ^(ns)
بافت خاک	۲	۶۱۲۵۷۸۲/۷۲۴ ^{**}
رطوبت	۲	۴۳۰۸۵۳/۷۷۲ ^{**}
بافت × رطوبت	۴	۵۵۵۵۴۵/۵۵۶ ^{**}
تردد تراکتور	۲	۱۸۲۳۲۹۰/۴۵۹ ^{**}
بافت × تردد تراکتور	۴	۳۲۱۸۹/۹۵۷ ^(ns)
رطوبت × تردد تراکتور	۴	۴۳۴۶۶/۴۷۵ [*]
بافت × رطوبت × تردد تراکتور	۸	۱۰۷۴۶۳/۸۳ ^{**}
عمق	۲	۶۰۲۹۳۲۵/۹۸۷ ^{**}
بافت × عمق	۴	۱۳۵۲۰۶/۱۴۶ ^{**}
رطوبت × عمق	۴	۵۷۴۳۹/۸۵۶ ^{**}
بافت × رطوبت × عمق	۸	۵۰۶۴۸/۲۵۷ ^{**}
تردد تراکتور × عمق	۴	۱۲۱۷۶۷/۲۸۷ ^{**}
بافت × تردد تراکتور × عمق	۸	۱۶۱۷۲۰/۱۶۲ ^{**}
رطوبت × تردد تراکتور × عمق	۸	۵۸۷۶۷۰/۶۷ ^{**}
بافت × رطوبت × تردد تراکتور × عمق	۱۶	۷۹۹۱۲/۸۳۱ ^{**}
خطا	۳۲۰	۱۴۸۷۹/۱۶۵
مجموع	۴۰۴	-

* معنی دار در سطح احتمال ۵ درصد، ** معنی دار در سطح احتمال ۱ درصد و ^{ns} غیر معنی دار.

تخمین شاخص مخروطی خاک با استفاده از شبکه عصبی مصنوعی: جدول ۲ نمونه‌ای از نتایج به دست آمده شبکه‌های طراحی شده برای پیش‌بینی مقادیر شاخص مخروطی خاک با استفاده از الگوریتم لوبنبرگ-مارکوارت با لایه (لایه‌های میانی) میانی و تعداد نرون‌های متفاوت در لایه

(لایه‌های) میانی را نشان می‌دهد. نوع تابع انتقال به‌کار رفته بین لایه‌های میانی از نوع تانژانت سیگموئیدی و بین لایه میانی و لایه خروجی از نوع خطی می‌باشد. به‌طوری‌که در جدول ۲ نشان داده شده است، شبکه‌ای با ۳۴ نرون در هر یک از لایه‌های میانی به‌منظور پیش‌بینی مقادیر شاخص مخروطی خاک دارای کم‌ترین میانگین و مجموع مربعات خطا، بالاترین ضرایب تبیین، دقت شبیه‌سازی و ضریب همبستگی است. ذکر این نکته در این‌جا ضروری است که شبکه انتخاب شده بالا دارای بالاترین مقدار در هر یک از معیارهای عملکرد شبکه نمی‌باشد اما از آن‌جا که نسبت به دیگر شبکه‌ها در دیگر معیارهای عملکرد شبکه دارای مقادیر مناسبی می‌باشد بنابراین این توپولوژی برای شبکه طراحی شده انتخاب شد.

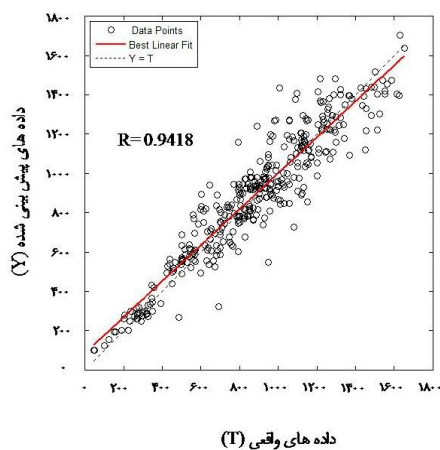
جدول ۲- شاخص‌های کمی ارزیابی شبکه‌های ساخته شده با استفاده از الگوریتم آموزشی لونیگ-مارکوات.

تعداد نرون‌ها	پارامترهای شبکه		پارامترهای آماری شبکه		ضرایب تبیین شبکه		میانگین دقت شبیه‌سازی (درصد)	ضریب تبیین
	lr	mc	MSE	SSE	آموزش	ارزیابی		
۲۸+۳۰	۰/۳	۰/۳	۰/۰۷۲	۱۶/۲	۰/۹۶	۰/۷۶	۸۷/۹۸	۰/۸۸
۳۰+۳۰	۰/۳	۰/۳	۰/۰۶۶۹	۱۵/۱	۰/۹۷	۰/۶۸	۸۸/۰۴	۰/۸۹
۳۰+۳۲	۰/۳	۰/۳	۰/۱۱۹	۳۶/۷	۰/۹۱	۰/۸۳	۸۸/۰۹	۰/۸۷
۳۲+۳۲	۰/۳	۰/۳	۰/۰۷۴۱	۱۶/۷	۰/۹۴	۰/۸۲	۸۷/۷۶	۰/۸۷
۳۲+۳۴	۰/۳	۰/۳	۰/۰۸۹۵	۲۰/۱	۰/۹۵	۰/۷۴	۸۸/۷۸	۰/۸۸
۳۴+۳۴	۰/۳	۰/۳	۰/۰۸۷۵	۱۹/۷	۰/۹۵	۰/۸۳	۸۸/۲۹	۰/۸۹


در شکل ۱ نموداری که نشانگر بهترین خط برازش یافته بین مقادیر واقعی (T) و پیش‌بینی شده توسط شبکه (Y) نشان داده شده است و ضرایب رگرسیون بین آن‌ها برای پیش‌بینی شاخص مخروطی ۰/۹۲ استخراج شده است. شبکه ساخته شده با ۳۴ نرون در هر یک از لایه‌های میانی برای پیش‌بینی مقادیر شاخص مخروطی دارای بیش‌ترین شیب، کم‌ترین عرض از مبدأ و بیش‌ترین ضریب همبستگی است. این مقادیر به‌ترتیب ۰/۹۱۹۵، ۸۶/۰۶ و ۰/۹۴۱۹ برای پیش‌بینی مقادیر شاخص مخروطی می‌باشد. به‌دلیل حجم انبوه نمودارها، فقط نمودار مربوط به بهترین الگوریتم (trainlm) و مناسب‌ترین تعداد نرون در لایه (لایه‌های) مخفی ارائه شده است. پس از هر بار آموزش شبکه (در هر الگوریتم و برای هر تعداد نرون در لایه‌های پنهان) نموداری که نشانگر روند تغییرات خطای داده‌های آموزشی،

ارزیابی و تست شبکه است در نرم افزار MATLAB ترسیم گردید. شکل ۱ (نمودار سمت چپ)، نمونه‌ای از نمودارهای اشاره شده را برای تغییرات خطای داده‌های آموزشی، ارزیابی و تست برای یک شبکه نمونه طراحی شده نشان می‌دهد. نتایج برای الگوریتم لونیبرگ-مارکوات نشان داد که با استفاده از شبکه‌ای با توپولوژی $1+34+34$ میانگین مربعات خطا در اپاک ۱۲ برابر $0/0875$ به دست آمده است. نمودارهای رگرسیون در مراحل آموزش، ارزیابی و تست شبکه نشان داد که بالاترین ضریب همبستگی $0/975$ به مرحله آموزش اختصاص دارد. در بهترین شرایط ضریب همبستگی مراحل ارزیابی و تست به ترتیب $0/913$ و $0/925$ می‌باشند.

جدول ۳ خلاصه نتایج شبکه‌های ساخته شده با استفاده از سه الگوریتم آموزشی نام‌برده در بالا، مقایسه دقت و پارامتر آماری به دست آمده برای شبکه‌ها را نشان می‌دهد. مشخصات ارایه شده شامل الگوریتم‌های آموزشی مورد استفاده، ساختار شبکه (شامل بهترین شبکه یک و دو لایه)، ضرایب تبیین شبکه در مراحل آموزش، ارزیابی و تست، نوع تابع انتقال به کار رفته، میانگین دقت شبیه‌سازی و ضریب تبیین کلی شبکه می‌باشد. همچنین در هر یک از شبکه‌ها از نرخ یادگیری، مومنت $0/3$ و تابع انتقال خطی در لایه خروجی استفاده شده است. به طوری که در جدول ۳ مشاهده می‌گردد استفاده از الگوریتم آموزشی لونیبرگ-مارکوات نتایج بهتری را نسبت به سایر الگوریتم‌های آموزشی در شبیه‌سازی و آموزش شبکه عصبی مصنوعی ارایه می‌کند. در مورد استفاده از الگوریتم آموزشی لونیبرگ-مارکوات با استفاده از هر دو تابع انتقال تانژانت سیگموئیدی و لگاریتم سیگموئیدی شبکه‌های دو لایه در مقایسه با شبکه‌های تک‌لایه نتایج بهتری را ارایه می‌دهد. الگوریتم آموزشی لونیبرگ-مارکوات با تابع انتقال لگاریتم سیگموئیدی با دو لایه مخفی و 34 نرون در هر یک از لایه‌های مخفی نسبت به همین شبکه تک‌لایه با 24 نرون در لایه مخفی دارای میانگین مربعات کم‌تر و ضرایب تبیین بالاتر شبکه در هر سه مرحله آموزش، ارزیابی و تست می‌باشد. همچنین مشاهده شد که در الگوریتم آموزشی لونیبرگ-مارکوات تابع انتقال لگاریتم سیگموئیدی در مقایسه با تانژانت سیگموئیدی نتایج بهتری را ارایه می‌دهد. در دو الگوریتم آموزشی دیگر (گرادیان مزدوج مقیاسی و گرادیان نزولی با مومنت) روند خاصی مشاهده نشد.



(ب)



(الف)

شکل ۱- (الف) نمودار روند تغییرات خطای داده‌های آموزش، ارزیابی و تست و
 (ب) نمودار رگرسیون شبکه برای مرحله ارزیابی شبکه برای پیش‌بینی مقادیر شاخص مخروطی خاک.

جدول ۳- شبکه‌های طرح شده با استفاده از سه الگوریتم آموزشی با تعداد بهینه نرون در لایه (لایه‌های) مخفی.

الگوریتم آموزشی	تابع انتقال	ساختار بهینه شبکه	میانگین مربعات	ضرایب تبیین شبکه			میانگین دقت شبیه‌سازی (درصد)	ضریب تبیین
				آموزش	ارزیابی	آزمون		
گرادیان مزدوج	tansig	۲۰+۱	۰/۱۳۱	۰/۸۷	۰/۸۶	۰/۸۶	۸۸/۹۷	۰/۸۶
مقیاسی	logsig	۱۲+۱۲+۱	۰/۱۳۷	۰/۸۶	۰/۸۷	۰/۸۶	۸۸/۷۱	۰/۸۶
گرادیان نزولی با مومنتم	tansig	۱۲+۱۲+۱	۰/۱۳۰	۰/۸۷	۰/۸۶	۰/۸۵	۸۷/۹۷	۰/۸۶
گرادیان نزولی با مومنتم	logsig	۶+۱	۰/۱۴۱	۰/۸۶	۰/۸۵	۰/۸۵	۸۸/۰۷	۰/۸۵
گرادیان نزولی با مومنتم	tansig	۶+۶+۱	۰/۱۴۰	۰/۸۵	۰/۸۵	۰/۸۴	۸۷/۴۴	۰/۸۵
گرادیان نزولی با مومنتم	logsig	۱۲+۱	۰/۱۲۶	۰/۸۷	۰/۸۶	۰/۸۵	۸۷/۷۸	۰/۸۶
گرادیان نزولی با مومنتم	logsig	۶+۶+۱	۰/۱۱۶	۰/۸۸	۰/۸۷	۰/۸۶	۸۸/۳۸	۰/۸۷
گرادیان نزولی با مومنتم	tansig	۲۵+۱	۰/۰۹۷۴	۰/۹۲	۰/۸۵	۰/۸۵	۸۷/۹۸	۰/۸۷
گرادیان نزولی با مومنتم	tansig	۱۲+۱۳+۱	۰/۰۹۸۱	۰/۹۳	۰/۸۵	۰/۸۷	۸۸/۸۱	۰/۸۸
گرادیان نزولی با مومنتم	logsig	۲۴+۱	۰/۱۰۲	۰/۹۴	۰/۸۲	۰/۸۷	۸۶/۴۸	۰/۸۸
گرادیان نزولی با مومنتم	logsig	۳۴+۳۴+۱	۰/۰۸۷۵	۰/۹۵	۰/۸۳	۰/۸۶	۸۸/۲۹	۰/۸۹

مقایسه مدل شبکه عصبی مصنوعی با مدل‌های رگرسیونی به منظور پیش‌بینی شاخص مخروطی خاک: به منظور ارزیابی مدل شبکه عصبی مصنوعی، داده‌های به دست آمده از این مدل با داده‌های مدل‌های رگرسیونی موجود به منظور پیش‌بینی شاخص مخروطی خاک مورد مقایسه قرار گرفتند. مدل‌های رگرسیونی که در این پژوهش مورد استفاده قرار گرفتند شامل مدل ارایه شده توسط وورهیس و والکر (۱۹۷۷)، اسکوتی و همکاران (۱۹۸۲) و مدل رگرسیون خطی چندگانه برآورد شده در این پژوهش با استفاده از مقادیر درصد محتوی رطوبتی، جرم مخصوص ظاهری، عمق و هدایت الکتریکی خاک می‌باشد.

در مورد مدل‌های مختلف استفاده شده در این پژوهش باید به این نکته توجه داشت که مدل وورهیس و والکر (۱۹۸۲) برای خاک لومی سیلتی و مدل ارایه شده توسط اسکوتی و همکاران (۱۹۸۲) برای سه نوع خاک لومی شنی، لومی رسی شنی و لومی ارایه شده است. مدل‌های رگرسیونی ارایه شده توسط وورهیس و والکر (۱۹۸۲) و اسکوتی و همکاران (۱۹۸۲) به ترتیب عبارتند از:

$$CI = \frac{4527}{75} - \frac{137}{9(MC)} \quad (9)$$

$$CI = 450/5mc^{-2} + 0/0197 \quad (10)$$

که در آن‌ها، CI: شاخص مخروطی خاک، MC: محتوی رطوبتی و BD (گرم بر سانتی‌متر مکعب): جرم مخصوص ظاهری خاک می‌باشند. مدل رگرسیونی خطی چندگانه مورد استفاده برای پیش‌بینی مقادیر شاخص مخروطی با استفاده از مقادیر جرم مخصوص ظاهری (گرم بر سانتی‌متر)، درصد محتوی رطوبتی، هدایت الکتریکی و عمق خاک (سانتی‌متر) به دست آمد. این رابطه عبارت است از:

$$CI = 26/2 \times D - 28/8 \times MC + 133/3 \times \log EC - 1062/6 \quad (11)$$

جدول ۴ نتایج به دست آمده از مدل شبکه عصبی مصنوعی و مدل‌های رگرسیونی به منظور پیش‌بینی شاخص مخروطی خاک را ارایه می‌نماید. به طوری که ملاحظه می‌گردد مدل شبکه عصبی مصنوعی قادر به مدل کردن مقادیر شاخص مخروطی خاک با دقت بالاتر نسبت به مدل‌های رگرسیونی ارایه شده در این پژوهش می‌باشد. مدل ارایه شده توسط وورهیس و والکر (۱۹۸۲) برای خاکی با بافت لومی سیلتی می‌باشد و از آن‌جا که این مدل شاخص مخروطی خاک را تنها با استفاده از

مقادیر محتوی رطوبتی برآورد می‌کند بنابراین مشاهده می‌شود ضریب تبیین و میانگین دقت شبیه‌سازی مدل دارای مقادیر بسیار پایینی در مقایسه با مدل شبکه عصبی مصنوعی ارائه شده در این پژوهش می‌باشد. مدل ارائه شده توسط اسکوتی و همکاران (۱۹۸۲) برای سه نوع خاک با بافت شنی لومی، شنی رسی لومی و لومی می‌باشد. در این مدل نیز شاخص مخروطی خاک با استفاده از مقادیر محتوی رطوبتی جرم مخصوص ظاهری برآورد شده است. همان‌طور که مشاهده می‌شود این مدل نیز در مقایسه با مدل شبکه عصبی مصنوعی دارای مقادیر بسیار پایین ضریب تبیین و میانگین دقت شبیه‌سازی می‌باشد. اگرچه مدل رگرسیون چندمتغیره خطی به‌دست آمده در این پژوهش نسبت به مدل‌های رگرسیونی ارائه شده توسط وورهیس و والکر (۱۹۸۲) و اسکوتی و همکاران (۱۹۸۲) دارای دقت بیش‌تری در ضریب تبیین و میانگین دقت شبیه‌سازی می‌باشد اما در مقایسه با مدل شبکه عصبی مصنوعی طراحی شده به‌منظور برآورد شاخص مخروطی خاک دارای دقت پایین‌تری می‌باشد. بنابراین مقایسه نتایج به‌دست آمده از مدل شبکه عصبی مصنوعی و مدل‌های رگرسیونی نشان داد که مدل شبکه عصبی مصنوعی قادر به مدل کردن مقادیر شاخص مخروطی با دقت بالاتر نسبت به مدل‌های رگرسیونی ارائه شده در این پژوهش می‌باشد.

جدول ۴- مقایسه نتایج به‌دست آمده از مدل شبکه عصبی مصنوعی و مدل رگرسیونی.

میانگین دقت شبیه‌سازی (درصد)	ضریب تبیین مدل				مدل‌های ارائه شده
	کل	تست	ارزیابی	آموزش	
۸۷/۲۹	۰/۸۹	۰/۸۶	۰/۸۳	۰/۹۵	مدل شبکه عصبی مصنوعی
۹/۳۷			۰/۲۷		مدل رگرسیونی وورهیس و والکر
۳۵/۹۹			۰/۲۲		مدل رگرسیونی اسکوتی و همکاران
۴۱/۵۵			۰/۸۲		مدل رگرسیونی چندمتغیره خطی

منابع

1. Abbaspour-Gilandeh, Y., Ahani, M., Askari Asli-Ardeh, E., Rasooli Sharabiani, V., and Sofalian, O. 2010. Design, construction and evaluation of a tractor-mounted soil cone penetrometer with multiple-adjustable-probes. *J. Agric. Engin. Res.* 11: 1. 19-34.
2. Abbaspour-Gilandeh, Y., and Khalilian, A. 2009. Using of soil EC data for zoning the production field by artificial neural network for applying the precision tillage. *Proceeding of 11th Iranian Soil Science Congress*, Gorgan, Iran.

3. Alimardani, R., and Solhjou, A.A. 2004. Mathematical model to determine the cone index in a clay loam soil of ZARGHAN area of Fars. Iran. Agric. Sci. J. 10: 2. 135-144. (In Persian)
4. Bowen, H.D. 1976. Correlation of penetrometer cone index with root impedance. ASAE paper No. 76-1516, ASAE, st. Joseph, Mich. 49085, USA.
5. Busscher, W.J. 1990. Adjustment of flat-tipped penetrometer resistance data to a common water content. Trans ASAE. 33: 519-524.
6. Clark, R.L. 1999. Evaluation of the potential to develop soil strength maps using a cone penetrometer. ASAE paper No. No.99-3109, ASAE, st. Joseph, Mich. 49085, USA.
7. Faure, A.G., and Da Mata, J.D.V. 1994. Penetration resistance value along compaction curves. J. Geotech. Eng. 120: 46-59.
8. Goh, A. 1995. Back-propagation neural network for modeling complex systems. Artificial Intelligence in Engineering. 9: 143-151.
9. Henderson, C., Levett, A., and Lisle, D. 1988. The effect of soil water content and bulk density on the compactability and soil penetration resistance of some Western Australian sandy soils. Aust. J. Soil Res. 26: 391-400.
10. Horn, R., Domzal, H., Slwinska-jukiewicz, A., and Van Ouwerkerk, C. 1995. Soil compaction processes and their effects on the structure of arable soils and the environment. Soil Tillage Research. 35: 23-36.
11. Jacobs, C.O., and Finnery, J.B. 1993. Soil management farming press publication, Pp: 187-189.
12. Kushwaha, R.L., and Zhang, Z.X. 1998. Evaluation of factors and current approaches related to computerized design of tillage tools: a review. J. Terramech. 35: 69-86.
13. Lapen, D.R., Topp, G.C., Edwards, M.E., Gregorich, E.G., and Curnoe, W.E. 2004. Combination cone penetration resistance/water content instrumentation to evaluate cone penetration-water content relationships in tillage research. Soil Tillage Research. 79: 51-62.
14. Levine, E.R., Kimes, D.S., and Sigillito, V.G. 1996. Classifying soil structure using neural networks. Ecological modelling, 92: 101-108.
15. Mulqueen, J., Stafford, J.V., and Tanner, D.W. 1977. Evaluation of penetrometers for measuring soil strength. J. Terramech. 14: 3. 137-151.
16. Ohu, J.O., Raghavan, G.S.V., and McKyes, E. 1988. Cone index prediction of compacted soils. Trans. ASAE. 31: 2. 306-310.
17. Oskoui, K.E., Rackhamt, D.H., and Witney, B.D. 1982. The determination of plough draught-Part II The measurement and prediction of plough draught for two mouldboard shapes in three soil series. J. Terramech. 19: 5. 153-164.
18. Pidgeon, J.D., and Soane, B.D. 1977. Effects of tillage and direct drilling on soil properties during the growing season in a long-term barley mono-culture system. J. Agric. Sci. 88: 431-442.

19. Raper, R.L., Asmussen, L.E., and Powell, J.B. 1990. Sensing hard pan depth with ground-penetrating radar. *Trans. ASAE*. 33: 1. 41-46.
20. Upadhyaya, S.K., Chancellor, W.J., Perumral, J.V., Schafer, R.L., Gill, W.R., and Vandenberg, G.E. 1994. *Advances in Soil Dynamics (Vol. 1)*. American Society of Agricultural Engineers, 330p.
21. Voorhess, M.L., and Walker, P.N. 1977. Tractionability to a function of soil moisture. *Trans ASAE*. 20: 5. 806-809.
22. Wells, L.G., and Baird, R.D. 1978. A technique for predicting vehicular tractive performance. ASAE paper NO. 78-1040, St. Joseph, Michigan.
23. Zareian, S. 1985. Effect of soil moisture on plough draft and soil crumbling. *Iran. Agric. Sci. J.* 1-4: 11-16.



Soil cone index prediction using artificial neural networks model and its comparison with regression models

***Y. Abbaspour-Gilandeh¹ and A.R. Shaygani-Soltanpour²**

¹Associate Prof., Dept. of Agricultural Machinery Engineering, University of Mohaghegh Ardabili, Ardabil, Iran, ²M.Sc. Graduate, Dept. of Agricultural Machinery Engineering, University of Mohaghegh Ardabili, Ardabil, Iran

Received: 01/06/2013; Accepted: 07/08/2013

Abstract

Soil cone index as one of the criteria that states mechanical strength of the soil is affected by many factors including soil moisture content and soil compaction. Despite widespread progress in the development of precision agriculture, crop production management in relation to soil physical properties goes back to the last few years. One of the most important soil characteristics that affects crop yield is soil mechanical resistance. This characteristic is expressed generally by soil cone index maps. In this study, for measuring and determining the factors affecting soil cone index, field experiments were carried out on three soil types. Within each soil type, the factorial experiment based on randomized complete block design (RCDB) with five replications was used. The effects of soil moisture content at three levels (dry, semi-humid and humid), sampling depth at three levels (0-10, 10-20 and 20-30 cm) and number of tractor traffic at three levels (0, 10 and 20 Time passes) was investigated on soil cone index. After data analysis, it was revealed that the effects of soil type, sampling depth, different levels of soil moisture and tractor traffic were significant on soil cone index values ($P < 0.01$). In order to develop a mathematical model for soil cone index, multivariate linear regression was used. Independent factors were soil moisture content, soil bulk density, electrical conductivity and sampling depth whereas soil cone index was the dependent factor. The results showed that the effect of all independent variables on soil cone index as the dependent variable were significant at probability level of 1%. Back propagation neural networks with three different training algorithms (gradient descending algorithm with momentum, descending scaled gradient and Levenberg-Marquardt) were adopted for predicting soil cone index parameter. Back propagation neural networks with Levenberg-Marquardt training algorithm presented better accuracy in simulation and prediction as compared to others. Using Levenberg-Marquardt training algorithm with two hidden layers with 34 neurons in each layer presented the best performance than other algorithms and even Levenberg-Marquardt training algorithm with one layer. Comparison of results of artificial neural network models and regression models to predict the soil cone index indicated that the neural network model could model soil cone index values with higher accuracy than the regression models. The results of this study could be utilized in soil compaction management of Ardabil plain soils and also in determination of the optimum tillage depth in these areas.

Keywords: Soil cone index, Soil texture, Soil moisture content, Soil electrical conductivity, Artificial neural network, Levenberg-Marquardt training algorithm

* Corresponding Authors; Email: abbaspour@uma.ac.ir