

## مدل‌سازی تراکم خاک زیر تاثیر تراکتور با استفاده از شبکه عصبی پرسپترون چندلایه

غلامحسین شاه‌گلی<sup>\*1</sup> - حافظ غفوری چپانه<sup>2</sup> - ترحم مصری گندشمن<sup>3</sup>

تاریخ دریافت: 1395/06/25

تاریخ پذیرش: 1395/11/11

### چکیده

یکی از مخرب‌ترین آثار تردد ماشین در مزرعه ایجاد تراکم در خاک‌های کشاورزی است. تراکم خاک‌های کشاورزی موجب افزایش مقاومت مکانیکی خاک، کاهش ریشه دوانی گیاه و نهایتاً کاهش عملکرد محصول می‌شود. مدل‌سازی سیستم‌های اکولوژیک توسط روش‌های متداول مدل‌سازی، به دلیل ماهیت پیچیده آنها در صورت امکان نیز بسیار مشکل است. سیستم‌های هوش مصنوعی و محاسبات نرم به واسطه سادگی و دقت بالا با یکبار تعریف یا آموزش بسیار مورد توجه هستند. هدف از انجام این تحقیق مدل‌سازی سیستم تراکم خاک تحت تاثیر رطوبت خاک، سرعت پیشروی ماشین و عمق خاک توسط شبکه‌های عصبی پرسپترون چندلایه بود. در این پژوهش، رطوبت خاک در پنج سطح 11٪، 13/5٪، 16٪، 19٪ و 22٪، میانگین سرعت پیشروی ماشین در پنج سطح 1، 2، 3، 4 و 5 کیلومتر بر ساعت و عمق‌های مختلف خاک در سطوح 20، 25، 30، 35 و 40 سانتی‌متر در نظر گرفته شد. داده‌های تجربی در مزرعه تحقیقاتی دانشگاه محقق اردبیلی به صورت آزمایش فاکتوریل در قالب طرح بلوک‌های کامل تصادفی در پنج سطح رطوبت، سرعت پیشروی و عمق خاک در سه تکرار به دست آمدند. شبکه عصبی پرسپترون با پنج نرون در لایه پنهان با تابع انتقال سیگموئیدی و تابع انتقال خطی برای نرون خروجی برای مدل‌سازی طراحی و آموزش داده شد. مقایسه نتایج مدل و نتایج تجربی نشان‌دهنده ضریب تبیین  $R^2 = 0/99$  بین این مقادیر بود. مقدار میانگین مربعات خطای مدل و درصد میانگین مطلق خطای سیستم به ترتیب برابر 0/29 و 0/17 درصد به دست آمدند که نشان از دقت بالای مدل شبکه عصبی در تخمین مقادیر تراکم خاک دارد.

واژه‌های کلیدی: پرسپترون چندلایه، تراکم خاک، شبکه عصبی مصنوعی، مدل‌سازی

### مقدمه

و مدیریت نامناسب موجبات تراکم خاک را فراهم می‌کنند. تراکم سبب افزایش استحکام یا مقاومت مکانیکی و کاهش حاصلخیزی خاک به واسطه کاهش اندوخته مواد مغذی و محتوای رطوبتی در دسترس گیاه می‌شود و در نهایت موجب افزایش نیاز به کودها و افزایش هزینه‌های تولید می‌شود. عواقب زیان‌بار بعدی به صورت کاهش رشد گیاه به دلیل میزان کمتر مواد آلی در دسترس در محیط کشت، کاهش چرخه‌ی مواد مغذی و مواد معدنی، کاهش فعالیت میکروارگانیسم‌ها و افزایش تخریب خاک توسط ماشین‌ها نمایان می‌شود (Raper, 2005). وسعت خاک‌های متراکم در کل جهان که فقط از تردد ماشین‌های کشاورزی ناشی می‌شود در حدود 98 میلیون هکتار تخمین زده می‌شود (Flowers and Lal, 1998). تراکم خاک عامل تخریب خاک در 33 میلیون هکتار زمین کشاورزی در کشورهای قاره اروپا (Akker and Canarache, 2001) و 4 میلیون هکتار در جنوب استرالیا معرفی شده است (Carder, 1986). بنابر گزارشات اخیر 15 میلیون هکتار از زمین‌های شرق و مرکز اروپا دارای تراکم متوسط و 36 میلیون هکتار دارای سطح تراکم بالایی می‌باشند (Ferrara et al., 2015). جالب توجه است که درجه کمی از تراکم خاک سطحی برای برخی خاک‌ها می‌تواند مفید باشد (Bouman,

کشاورزی و شیوه‌های تولید مدرن بدون استفاده از تراکتورها و کمباین‌ها در اجرای عملیات کشاورزی، غیرقابل دستیابی است. با افزایش فزاینده اندازه ماشین‌ها، توانایی آن‌ها در آسیب رساندن به محیط کشت که مسئولیت تولید و حمایت از گیاه را به عهده دارد، نیز افزایش می‌یابد. لذا شناخت و مدیریت صحیح عوامل تراکم‌زا در خاک‌های کشاورزی به منظور کاهش اثرات مخرب تراکم از اهمیت ویژه‌ای برخوردار است. بافت خاک و توزیع اندازه ذرات، میزان سستی خاک، محتوای رطوبتی، بار محوری، سرعت بارگذاری و تعداد عبور، از جمله عوامل تأثیرگذار در تراکم خاک‌های کشاورزی هستند. استفاده بیش‌ازحد از ماشین‌ها، کشت بیش‌ازحد فشرده، چرای بیش از حد دام


1 و 3- دانشیار، گروه مهندسی بیوسیستم، دانشکده کشاورزی و منابع طبیعی، دانشگاه محقق اردبیلی

2- کارشناس ارشد مکانیک بیوسیستم، دانشکده کشاورزی و منابع طبیعی، دانشگاه محقق اردبیلی

\* - نویسنده مسئول:

(Email: gshahgoli@yahoo.com

DOI: 10.22067/jam.v8i1.58891




**شکل 1- ساختار یک نورون تنها با تعداد R ورودی و بایاس**  
**Fig. 1. A neuron structure with R inputs and bias**


$$n = w_{1,1} \cdot p_1 + w_{1,2} \cdot p_2 + \dots + w_{1,R} \cdot p_R + b \quad (1)$$

$$a = f(w_{1,1} \cdot p_1 + w_{1,2} \cdot p_2 + \dots + w_{1,R} \cdot p_R + b) = f(n) \quad (2)$$

معمولاً یک نورون تنها برای حل مسائل مهندسی با تعداد ورودی زیاد کافی نیست. به همین دلیل در حل این‌گونه مسائل از شبکه‌های عصبی که متشکل از چندین نرون یا چندین لایه هستند (شکل 2 و 3) و به صورت موازی باهم کار می‌کنند، استفاده می‌شود (Hagan et al., 1996). شبکه‌های چندلایه بسیار قدرتمند هستند، به‌عنوان مثال یک شبکه دولایه با لایه اول سیگموئید و لایه دوم خطی می‌تواند هر تابع دلخواهی را با تعداد نقاط محدود ناپیوستگی تخمین بزند (Demuth and Beale, 1993). در یک شبکه عصبی چندلایه هر لایه دارای ماتریس وزن، بردارهای بایاس و خروجی‌های مختص به خود است و خروجی هر یک از لایه‌های میانی به‌عنوان ورودی لایه بعدی به‌کار می‌رود.



**شکل 2- یک شبکه عصبی یک‌لایه متشکل از S نرون و R ورودی**  
**Fig. 2. A neural network with a layer consisted of S neuron and R inputs**



**شکل 3- نمایشی از یک شبکه عصبی چندلایه با R1 ورودی، Sn نرون در لایه n**  
**Fig. 3. Overview of multilayer neural network with R1 inputs and Sn neuron in layer n**

(2000) که نشان می‌دهد یک سطح بهینه از تراکم خاک برای رشد محصول وجود دارد. مفهوم سطح مطلوب و بهینه تراکم مخصوصاً در سیستم کشت که در آن تردد به شدت کنترل شده و هر عامل خارجی که ایجاد تراکم اجتناب می‌شود مهم می‌باشد (Mason et al., 1988) با افزایش مقاومت مکانیکی خاک به مقدار 2/5 کیلو پاسکال رشد و نفوذ ریشه در خاک کاملاً متوقف می‌شود (Hamza and Anderson, 2005). گیاهانی که در خاک‌های متراکم (چه با محتوای رطوبتی کم و چه با محتوای رطوبتی بالا) رشد کرده‌اند، نسبت به شرایط کنترل شده تراکم خاک ماده خشک و ریشه‌های جانبی کمتری دارند (Panayiotopoulos et al., 1994). در نتیجه تراکم خاک می‌تواند اثرات نامطلوبی در رشد گیاه از طریق افزایش مقاومت مکانیکی در مقابل نفوذ ریشه در خاک، تغییر اندازه و پیکربندی فضای منافذ داشته باشد (Tardieu, 1994; Taylor and Ashcroft, 1972).

شبکه‌های عصبی مصنوعی با الهام از شبکه عصبی زیستی و از واحدهای ساده محاسباتی متصل به هم به نام نرون که به صورت موازی با یکدیگر کار می‌کنند ساخته شده‌اند (Anderson and Rosenfeld, 1990; Hewitson and Crane, 1994). عملیات محاسباتی در شبکه‌های عصبی در نرونها صورت می‌گیرد که ساختار یک نورون تنها در شکل 1 نشان داده شده است. یک نرون مصنوعی از یک واحد پردازشی مقدماتی شامل جمع‌کننده و تابع فعال‌سازی با چندین ورودی و یک خروجی تشکیل شده است. نحوه کار به این صورت است که مقدار ورودی با ضرب در مقدار وزن و وزن‌دار شده و به همراه بایاس وارد تابع جمع می‌شوند و مقدار n (ورودی تابع انتقال) را ایجاد می‌کند (رابطه 1). سپس مقدار n وارد تابع انتقال f شده و در نهایت مقدار a را به‌خود اختصاص می‌دهد که این مقدار خروجی نهایی نرون است (رابطه 2).

در روابط (1) و (2) n ورودی تابع انتقال، R نشان‌دهنده تعداد المان‌های بردار ورودی در یک نرون، P ورودی‌های شبکه، W1 مبین وزن ورودی‌های شبکه، b مقدار بایاس و a مقدار خروجی نهایی نرون را بیان می‌کند.

طبقه‌بندی شده خاک ( $R^2=0/7-0/95$ ) نشان دادند. البته توانایی بالاتر شبکه عصبی در پیش‌بینی پارامترهای تراکم نسبت به تمام مدل‌های آماری موجود قابل توجه بود (Günaydin, 2009). برآورد مقدار شاخص فشردگی خاک به‌منظور تعیین نشست تحکیمی در خاک‌های رسی با اتکا بر توانایی‌های یک شبکه عصبی پرسپترون چندلایه و با استفاده از داده‌های آزمایشگاهی شامل حد روانی، حد خمیری و نسبت تخلخل نشان داد که استفاده از مدل شبکه عصبی علی‌رغم در نظر گرفتن اثر همزمان چندین پارامتر، خطای کمتری نسبت به روابط تجربی ارائه شده توسط سایر محققین نشان می‌دهد. همچنین در این تحقیق بیان شد که تقسیم‌بندی صحیح داده‌ها طی آموزش شبکه، اثر زیادی بر نتایج خروجی دارد. در استفاده از شبکه عصبی مصنوعی برای پیش‌بینی ظرفیت نگهداری رطوبت و هدایت هیدرولیکی خاک در حالت اشباع و با استفاده از خصوصیات پایه خاک شامل مقادیر شن، سیلت و رس، جرم مخصوص ظاهری، تخلخل نتیجه گرفته شد که با افزایش تعداد داده‌ها، پیش‌بینی ظرفیت نگهداری رطوبت و هدایت هیدرولیکی در حالت اشباع بهبود می‌یابد (Schaap et al., 1998). همچنین استفاده از این روش به دلیل دقت و انعطاف‌پذیری زیاد مورد توجه قرار گرفت. گروهی از محققین امکان برآورد سریع هدایت آبی خاک اشباع توسط شبکه عصبی مصنوعی را بررسی کرده و نتیجه گرفتند که در این مورد شبکه‌های عصبی مصنوعی در مقایسه با روابط رگرسیونی، عملکرد بهتری دارند (Navabian et al., 2004).

هدف از این مطالعه پیش‌بینی میزان تراکم ایجاد شده در خاک زیر تاثیر تراکتور تحت تاثیر رطوبت خاک و سرعت پیشروی تراکتور در عمق‌های مختلف خاک با استفاده از توانایی‌های یک شبکه عصبی پرسپترون سیستم محاسباتی هوشمند می‌باشد.

## مواد و روش‌ها

### انجام آزمایشات مزرعه‌ای

آزمایشات در قالب آزمایش فاکتوریل  $5 \times 5 \times 5$  و به‌صورت طرح بلوک‌های کامل تصادفی، تحت شرایط مزرعه‌ای در خاک لومی مزرعه کشاورزی، تحقیقاتی دانشگاه محقق اردبیلی و در سه تکرار اجرا شد. جدول 1 برخی خصوصیات فیزیکی و مکانیکی خاک را نشان می‌دهد. بافت خاک به روش هیدرومتری و رطوبت بحرانی به روش آزمایش پراکتور استاندارد تعیین شد. برای انجام پراکتور حدود  $3 \text{ kg}$  خاک سرنده شده از الک شماره 4 ( $4/76 \text{ mm}$ ) را از خاک مورد نظر تهیه گردید. سپس آب اضافه شده تا رطوبت آن به حدود 8 درصد وزنی برسد تعیین و توسط آیفشان ضمن مخلوط کردن خاک اضافه گردید. نمونه آماده شده را در سه لایه جداگانه در داخل دستگاه استوانه تراکم قرار داده و هر لایه توسط چکش مخصوص دستگاه با

در تحقیقی ماکزیمم جرم مخصوص خشک و رطوبت بهینه خاک از نظر تراکم بر اساس رطوبت حد سیلان، رطوبت حد خمیری، شاخص خمیری و ذرات کوچکتر از  $75 \text{ میکرون}$  و بزرگتر از  $75 \text{ میکرون}$  توسط شبکه عصبی مصنوعی پیش‌بینی شد. ضریب تبیین ( $R^2$ ) به ترتیب  $0/94$  و  $0/94$  در پیش‌بینی جرم مخصوص خشک و رطوبت بهینه خاک به‌دست آمد که نشان‌دهنده توانایی بالای شبکه عصبی مصنوعی در پیش‌بینی پارامترهای تراکم خاک با دقت بالا می‌باشد (Tenpe and Suneet, 2013). در مدل‌سازی رفتار مکانیکی خاک غیراشباع با شبکه عصبی مصنوعی پرسپترون چندلایه پیش‌خور با آموزش از طریق الگوریتم ژنتیک اعلام شد که تقسیم داده‌ها به بخش‌های داده‌های آموزشی، صحت‌سنجی و ارزیابی در افزایش کارایی و عملکرد شبکه عصبی حائز اهمیت است، مقایسه نتایج حاصله از مدل عصبی با نتایج آزمایشی نشان داد که خطای کل مدل  $2/92 \times 10^{-4}$  بوده و ضریب همبستگی  $R^2=0/92$  نشان‌دهنده دقت بالای شبکه عصبی در پیش‌بینی پارامترها نسبت به روش‌های مدل‌سازی کلاسیک می‌باشد (Johari et al., 2011).

در پژوهشی از ساختار شبکه عصبی پرسپترون با الگوریتم آموزشی لورنبرگ-مارکوارت استفاده شد تا هدایت آبی اشباع از پارامترهای با قابلیت اندازه‌گیری آسان و سریع خاک همچون جرم ویژه ظاهری، تخلخل مؤثر، میانگین هندسی قطر ذرات و انحراف معیار آنها برآورد شود (Navabian et al., 2004). نتایج نشان داد که نرون‌های عصبی ایجاد شده قادرند هدایت آبی اشباع را با دقت مناسب ( $R^2=0/83$ ) برآورد نمایند. همچنین، در مقایسه با معادلات رگرسیونی موجود با ضریب تبیین متوسط  $0/68$ ، مدل‌های شبکه عصبی ارائه شده عملکردی مناسب‌تر دارند.

جهت پیش‌بینی مقاومت غلظتی چرخ غیرمحرک با در نظر گرفتن برخی پارامترهای حرکتی مانند فشار باد تایلر، سرعت پیشروی و بار عمودی متغیر روی چرخ که با استفاده از یک آزمونگر تک چرخ در انباره خاک صورت گرفت، از شبکه عصبی مصنوعی استفاده شد. شبکه پس‌انتشار برگشتی با 35 نرون در لایه پنهان و 1 نرون در لایه خروجی و الگوریتم آموزشی بوده است. نتایج شبیه‌سازی شبکه عصبی عدم وابستگی / لورنبرگ-مارکوارت بهترین عملکرد را نشان داد. ضریب همبستگی آزمون شبکه مزبور  $0/92$  بوده است. نتایج شبکه عصبی مصنوعی عدم وابستگی مقاومت غلظتی چرخ به پارامتر سرعت پیشروی را نشان داد و تأیید کرد که با افزایش فشار باد تایلر و کاهش بار عمودی روی چرخ مقاومت غلظتی کاهش خواهد یافت (Geshlaghi and Mardani, 2015).

در تحقیقی اقدام به پیش‌بینی پارامترهای فشردگی (حداکثر جرم مخصوص خشک خاک و محتوای رطوبتی بهینه) خاک‌های مختلف توسط روش‌های آماری و مدل شبکه عصبی گردید، نتایج رگرسیونی و مدل شبکه عصبی رابطه خوبی بین تراکم خاک و خواص

افزایش بار محوری و در نهایت افزایش فشار تماسی بین چرخ و خاک انجام شد. در این حالت وزن روی محور عقب 2086 کیلوگرم اندازه‌گیری شد. برای تمامی آزمایشات، فشار باد تایر ثابت و برابر با 100 کیلو پاسکال بود. در انجام این طرح تغییرات جرم مخصوص ظاهری خاک زیر تایر تراکتور به‌وسیله استوانه‌های نمونه‌برداری اندازه‌گیری شد. برای انجام این مرحله از آزمایش از 15 عدد استوانه فلزی به قطر و ارتفاع 10 سانتی‌متر استفاده شد. پروفیلی به عمق 0/6، عرض 0/7 و طول 5 متر حفر شد تا استوانه‌ها درون آن قرار گیرند. خاک کنده شده از گودال روی پلاستیک ریخته شده و رطوبت اولیه آن مشخص گردید. برای این کار مقداری از خاک کنده شده را در آون در درجه حرارت 105 درجه سانتی‌گراد به مدت 24 ساعت قرار داده و از فرمول رطوبت درصد آن بر مبنای وزن خاک خشک تعیین شد. با توجه به وزن خاک روی پلاستیک و بر اساس فرمول مربوطه جهت رساندن آن به رطوبت مورد نظر وزن آب لازم محاسبه و ضمن مخلوط کردن خاک به آرامی روی خاک پاشیده شد. سپس نمونه‌ای از آن برداشته و رطوبت دقیق مشخص گردید که در سطوح مختلف مشخص گردیده‌اند. همچنین جرم مخصوص ظاهری خاک به‌عنوان پارامتر مشخص‌کننده تراکم ایجاد شده در خاک توسط استوانه‌های با حجم مشخص از تقسیم جرم خاک خشک شده به حجم استوانه‌ها اندازه‌گیری شد. مقداری خاک نرم کف پروفیل ریخته شد و سپس استوانه‌ها در عمق 40 سانتی‌متری داخل پروفیل و در امتداد یک خط و به فاصله مناسب از هم قرار دادند. روی استوانه‌ها به‌آرامی و به‌صورت کنترل‌شده خاک ریخته شد تا استوانه‌ها کاملاً داخل خاک سست قرار گیرند. سپس به همین ترتیب استوانه‌های سایر عمق‌ها نیز داخل پروفیل قرار داده شدند. به هنگام قرار دادن استوانه‌ها در عمق‌های مختلف مانند آن‌چه در شکل 4 مشاهده می‌شود، دقت شد که مرکز استوانه‌ها در عمق موردنظر از سطح خاک قرار گرفته و همچنین استوانه‌های عمق‌های متفاوت زیر هم قرار نگیرند تا تداخلی در کار استوانه‌های زیرین ایجاد نشود. پس از جایگذاری کامل استوانه‌ها، اقدام به عبور از روی پروفیل خاک با سرعت‌های از پیش تعیین‌شده به‌عمل آمد، به هنگام عبور دقت شد که خط وسط تایر عقب تراکتور منطبق بر خط وسط استوانه‌ها باشد چراکه این عامل موجب تأثیر یکسان بار وارده به خاک در دو طرف خط وسط تایر می‌شود و همچنین میزان تراکم ایجادشده در این قسمت از مسیر عبوری دارای عمق بیشتری شده که این عامل در مطالعه تراکم ایجاد شده در عمق‌های زیرین خاک که مورد نظر برای اندازه‌گیری می‌باشد حائز اهمیت می‌باشد.

25 ضربه کوبیده می‌شود. پس برای 3 لایه کلاً 75 ضربه داشتیم. بعد از انجام آزمایش جرم مخصوص خاک مرطوب و در نهایت جرم مخصوص خاک خشک تعیین شد. هرچه مقدار جرم مخصوص به‌دست آمده زیاد باشد نشان‌دهنده تراکم بالای آن خاک در آن شرایط می‌باشد. سپس رطوبت 3 درصد افزایش یافته و آزمایش دوباره انجام گرفت و به همین ترتیب ادامه یافت تا به رطوبت بحرانی که در آن بیشینه جرم مخصوص به‌دست آمد تعیین گردید. مقدار چسبندگی و زاویه اصطکاک داخلی در رطوبت 15٪ به روش آزمایش برش مستقیم تعیین شد.


### جدول 1- برخی خواص فیزیکی و مکانیکی خاک

Table 1- Some physical and mechanical properties of soil

بافت خاک Soil texture	درصد رس Clay%	درصد سیلت Silt%	درصد شن Sand%
لومی Loam	25.008	29.336	45.666
رطوبت بحرانی Critical moisture	22% (d.b)		
پیوستگی خاک Soil cohesion	35 kPa		
زاویه اصطکاک داخلی Internal friction angle	30°		

در این تحقیق اثر تغییرات سرعت پیشروی تراکتور در پنج سطح 1، 2، 3، 4 و 5 کیلومتر بر ساعت، رطوبت خاک در پنج سطح 11٪، 13/5٪، 16٪، 19٪ و رطوبت بحرانی معادل 22٪ و عمق خاک در سطوح 20، 25، 30، 35 و 40 سانتی‌متر بر تراکم خاک بررسی گردید. فرآیند تنظیم سرعت‌های مورد نظر بدین صورت انجام شد که تراکتور برای دستیابی به سرعت 1 کیلومتر بر ساعت با دنده 1 سنگین، برای سرعت 2 کیلومتر بر ساعت با دنده 2 سنگین، برای سرعت 3 کیلومتر بر ساعت با دنده 3 سنگین، برای سرعت 4 کیلومتر بر ساعت با دنده 4 سنگین و برای سرعت 5 کیلومتر بر ساعت با دنده 1 سبک رانده شد. جهت دستیابی به سرعت‌های مورد نظر تراکتور در هر دنده در دو دور موتور 1400 و 1600 دور در دقیقه با سرعت ثابت بر روی خاک مورد آزمایش به مسافت 30 متر جابه‌جا شد که نمودار کالیبراسیون آن برای سرعت‌ها و دنده‌های مختلف به‌صورت خطی رسم شد. بر اساس معادلات کالیبراسیون به‌دست آمده نوع دنده و دور موتور تنظیم شد. برای مثال برای سرعت 5 کیلومتر بر ساعت روی دنده 1 سبک و دور 1140 دور در دقیقه تنظیم شد.

برای انجام آزمایش از یک تراکتور مسی فرگوسن مدل MF-285 مجهز به چرخ‌های عقب مدل 18/4R30 استفاده شد. آزمایش با اتصال گاوآهن برگردان‌دار سوار سه خیشه یک‌طرفه به‌منظور



شکل 4- ترتیب و آرایش قرارگیری استوانه‌های نمونه‌برداری در عمق‌های مختلف  
 Fig. 4. Arrangement of sampler cylinders used in different depths

هرچه تعداد لایه‌ها بیشتر باشد، سیستم قادر به درک پیچیدگی‌های بیشتری است، هرچند از طرف دیگر زیاد بودن تعداد لایه‌ها دقت پیش‌گویی را کم کرده و ممکن است مانع هم‌گرا شدن شبکه شود. در این مورد ثابت شده است که شبکه‌های عصبی با یک لایه پنهان با تابع سیگموئید در لایه میانی و تابع خطی در لایه خروجی قادر به تقریب تمامی توابع مورد نظر با هر درجه تقریب خواهد بود، مشروط بر اینکه به اندازه کافی نورون در لایه پنهان موجود باشد (Hecht-Nielsen, 1987). این قضیه به تقریب‌ساز جهانی معروف می‌باشد (Menhaj, 2005). بر همین اساس در این تحقیق به منظور پیش‌بینی مقادیر جرم خصوص ظاهری خاک یک شبکه پرسپترون با یک لایه مخفی با تابع سیگموئید و تابع انتقال خطی برای نورون خروجی در نظر گرفته شد.

پارامتر دیگر، تعداد نورون‌ها در هر لایه است. نورون‌های لایه‌های میانی در شبکه به‌عنوان تشخیص‌دهنده الگو عمل می‌کنند (Benjamin and Cornell, 2014)، بنابراین تعداد نورون‌ها در لایه پنهان نقش عمده‌ای در قدرت شبکه دارد. کم بودن تعداد نورون‌ها قدرت تجزیه و تحلیل و به دنبال آن دقت عددی پیش‌گویی را کاهش می‌دهد (Haykin and Network, 2004) و شبکه نمی‌تواند نگاشت غیرخطی بین ورودی و خروجی را با دقت لازم منعکس کند. از سوی دیگر زیاد بودن بیش‌ازحد تعداد نورون‌های لایه‌های میانی منجر به تولید نگاشتی غیرخطی و پیچیده شده که در این حالت سیستم داده‌های آموزشی را به‌جای تجزیه و تحلیل به‌خوبی یاد می‌گیرد (حفظ می‌کند)، اما در مقابل داده‌های جدید عملکرد مناسبی ندارد و در واقع قدرت تعمیم خود را از دست می‌دهد. برای غلبه بر این مشکل باید تعداد نورون‌ها به‌گونه‌ای انتخاب شوند که شبکه قدرت کافی و نه بیش از حد برای تولید نگاشت بین ورودی و خروجی داشته باشد. در این پژوهش تعداد مناسب نورون‌های لایه پنهان برای دستیابی به بهترین پیش‌بینی‌ها و کمترین میزان خطا در شبکه بر مبنای روش آزمون و خطا و برابر پنج نورون و با تابع انتقال سیگموئیدی تعیین شد.

پس از خارج کردن استوانه‌های نمونه‌برداری از داخل پروفیل، خاک درون نمونه‌ها به مدت 24 ساعت داخل آون با دمای 105 درجه سانتی‌گراد قرار داده شدند تا نمونه‌های خاک کاملاً خشک شوند. سپس اقدام به توزین نمونه‌های خشک و تعیین جرم مخصوص ظاهری خشک آن از طریق رابطه (3) شد:

$$\rho = \frac{m}{v} \quad (3)$$

در معادله فوق  $\rho$  نشان‌دهنده جرم مخصوص ظاهری پس از بارگذاری ( $\text{kgm}^{-3}$ )،  $m$ : جرم خاک خشک درون استوانه (kg) و  $v$ : حجم استوانه نمونه‌برداری ( $\text{m}^3$ ) می‌باشد. نتایج حاصل از این بخش در طراحی مدل شبکه عصبی به‌کار گرفته شد.

#### مدل شبکه عصبی مصنوعی

##### طراحی شبکه

برای طراحی مدل شبکه عصبی به‌منظور پیش‌بینی مقدار جرم مخصوص ظاهری خاک از جعبه ابزار شبکه عصبی مصنوعی نرم‌افزار MATLAB نسخه 2014a استفاده شد. اولین قدم در پی‌ریزی شبکه عصبی تعیین داده‌های فضای ورودی و هدف است، در این تحقیق پارامترهای محتوای رطوبتی، سرعت پیشروی و عمق به‌عنوان متغیرهای مستقل و ورودی شبکه و مقدار جرم مخصوص اندازه‌گیری شده در هر تیمار به‌عنوان هدف شبکه در نظر گرفته شد. مهم‌ترین مرحله از طراحی شبکه تعیین ساختار یک شبکه عصبی می‌باشد و اولین قدم در تعیین ساختار شبکه، تعیین نوع شبکه است. در این تحقیق به‌منظور پیش‌بینی مقادیر جرم مخصوص ظاهری خاک از شبکه عصبی پرسپترون چندلایه به دلیل توانایی فراوان در مدل‌سازی سیستم‌های پیچیده و غیرخطی که یکی از متداول‌ترین انواع شبکه‌های عصبی در امر مدل‌سازی هستند استفاده شد. مسئله اصلی در طراحی این شبکه‌ها تعیین تعداد مناسب لایه‌های پنهان و تعداد نورون‌های پنهان در لایه‌های میانی است. یک شبکه عصبی مصنوعی می‌تواند دو و یا سه لایه مخفی داشته باشد. به‌طور کلی

بر قانون اصلاح خطاست که برای آموزش شبکه‌های عصبی چندلایه پیش‌خور که عموماً شبکه‌های پرسپترون چندلایه هم نامیده می‌شوند، استفاده می‌شود. ثابت شده است که الگوریتم یادگیری پس‌انتشار خطا پرفرودارترین و بهترین الگوریتم یادگیری در شبکه‌های عصبی چندلایه است (Engelbrecht, 2007; Onwubolu, 2009). قانون پس‌انتشار از دو مسیر اصلی تشکیل می‌شود، در مسیر اول که به مسیر رفت نیز موسوم است، یک الگوی آموزشی به شبکه اعمال می‌شود و تأثیرات آن از طریق لایه‌های میانی به لایه خروجی انتشار می‌یابد تا اینکه نهایتاً خروجی واقعی شبکه MLP، به دست می‌آید. در این مسیر، پارامترهای شبکه (ماتریس‌های وزن و بردارهای بایاس)، ثابت و بدون تغییر در نظر گرفته می‌شوند. در مسیر برگشت پارامترهای شبکه MLP تغییر و تنظیم می‌گردند. این تنظیمات بر اساس قانون یادگیری اصلاح خطا انجام می‌گیرد. سیگنال خطا، در لایه خروجی شبکه تشکیل می‌گردد. بردار خطا برابر با اختلاف بین پاسخ مطلوب و پاسخ واقعی شبکه می‌باشد. مقدار خطا، پس از محاسبه، در مسیر برگشت از لایه خروجی و از طریق لایه‌ها در کل شبکه توزیع می‌شود در این مسیر وزن‌های شبکه به گونه‌ای تغییر می‌کنند تا مجموع مربعات خطای شبکه کمینه شود. جهت توقف الگوریتم پس‌انتشار از دو شاخص به‌طور همزمان می‌توان استفاده نمود. اول اینکه میانگین مربعات خطا در هر سیکل یا Epoch (جمع مربعات خطا برای تمامی الگوهای یادگیری) کمتر از مقدار از پیش تعیین‌شده‌ای باشد و یا اینکه فرم تغییرات در پارامترهای شبکه پس از هر سیکل خیلی کوچک باشد باید توجه داشت که هر سیکل برابر با تعداد تکرار، به‌اندازه تعداد نمونه‌های یادگیری می‌باشد. ثانیاً نرم‌گرادیان خطا از یک مقدار از پیش تعیین‌شده‌ای کوچک‌تر گردد. برای آموزش شبکه عصبی داده‌ها به سه دسته داده‌های آموزشی (training data)، داده‌های اعتبارسنجی یا صحت‌گذاری (validation data) و داده‌های آزمایشی (test data) تقسیم شدند. داده‌های آموزشی شامل 70 درصد از کل داده‌ها که 375 داده بود می‌باشد و در فرایند آموزش برای محاسبه گرادیان و بهینه‌سازی پارامترهای آزاد مورد استفاده قرار گرفتند. از الگوریتم پس‌انتشار خطا برای آموزش شبکه استفاده شد. در روند آموزش مشاهده شد که با افزایش تعداد داده‌های آموزشی به بیش از 70٪ رفته رفته از میزان دقت شبکه کاسته شده و بر میزان خطا در داده‌های ارزیابی و اعتبارسنجی افزوده شد. لذا 70٪ از داده‌ها برای فضای آموزشی در نظر گرفته شد. یکی از نکاتی که حین آموزش باید در نظر گرفته شود، جلوگیری از متخصص شدن شبکه و بروز پدیده حفظ کردن<sup>5</sup> یا قرار گرفتن در مینیمم‌های موضعی در رسیدن به خطای حداقل و کاهش قدرت تعمیم شبکه است به این منظور 15 درصد از داده‌ها که به‌طور تصادفی انتخاب شدند جهت

قابلیت پیش‌بینی و عملکرد شبکه عصبی توسعه داده‌شده با استفاده از روش‌های ریاضی و آماری تعیین می‌شود به‌منظور بررسی عملکرد شبکه، از میانگین مربعات خطا<sup>1</sup> (MSE) به‌عنوان معیاری برای سنجش دقت نتایج شبکه عصبی، استفاده شد معمولاً هرچه مدل بهتر بر داده‌ها منطبق<sup>2</sup> باشد مقدار آن کمتر می‌شود (رابطه 4).

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y}_i)^2 \quad (4)$$

در روابط فوق n نشان‌دهنده‌ی تعداد مشاهدات،  $y_i$  بیان‌کننده مقادیر اندازه‌گیری شده و  $\bar{y}_i$  نشان‌دهنده مقدار پیش‌بینی شده است.

قابلیت پیش‌بینی سیستم توسعه داده‌شده توسط درصد میانگین مطلق خطای سیستم (MAPE)<sup>3</sup> که نشان‌دهنده انحراف بین مقادیر تجربی و پیش‌بینی شده است به‌صورت رابطه (5) محاسبه شد.

$$MAPE = \frac{100}{n} \sum \left| \frac{y - \bar{y}}{y} \right| \quad (5)$$

مشابه با رابطه (4) در رابطه فوق نیز، n نشان‌دهنده تعداد مشاهدات،  $y$  بیان‌کننده مقادیر اندازه‌گیری شده و  $\bar{y}$  نشان‌دهنده مقدار پیش‌بینی شده است. خطای نسبی، انحراف بین مقادیر پیش‌بینی شده و داده‌های اندازه‌گیری شده را نشان می‌دهد و مطلوب است که مقدار آن به صفر برسد.

### آموزش شبکه

یکی از قابلیت‌های بسیار مهم شبکه عصبی، توانایی آموزش آن است. در هر شبکه عصبی مقادیری تحت عنوان پارامترهای آزاد وجود دارند که قابل تغییر می‌باشند. تعیین مقدار صحیح این مقادیر تضمین‌کننده‌ی عملکرد مناسب شبکه در حل مسئله موردنظر می‌باشد؛ بنابراین آموزش یک شبکه عصبی پرسپترون چندلایه (Multilayer perceptron) یا اصطلاحاً (MLP) به این معنی است پارامترهای آزاد شبکه (وزن‌ها و بایاس‌ها) توسط الگوریتم‌های آموزش و بر اساس داده‌های آموزشی (شامل بردارهای ورودی و هدف) به‌گونه‌ای بهینه شوند که مقدار خطای بین خروجی شبکه و پارامتر هدف به حداقل مقدار ممکن خود برسد. به‌طور کلی دو نوع آموزش شامل آموزش با ناظر و آموزش بدون ناظر وجود دارد. معمولاً برای آموزش شبکه‌های عصبی با ناظر، یک تابع هزینه تعریف می‌شود و از مجموعه‌ای از داده‌های تجربی به نام داده‌های آموزشی برای تعیین وزن‌های شبکه عصبی استفاده می‌شود در این نوع آموزش، وزن‌های شبکه به‌نحوی تنظیم می‌شود که تابع هزینه بر اساس داده‌های آموزشی کمینه شود (Boghosial, 2006). روش یادگیری پس‌انتشار خطا<sup>4</sup> یک روش آموزش با ناظر و مبتنی

1- Mean squared error

2- Fit

3- Mmean absolute percentage error

4- Back propagation (BP)

5- Over fitting

چسبندگی بیشتر خاک در رطوبت‌های بالاتر و قابلیت فشرده شدن بیشتر ذرات خاک به یکدیگر توجیه کرد. می‌توان این‌گونه بیان کرد که افزایش محتوای رطوبتی خاک موجب کاهش ظرفیت تحمل بار (Kondo and Junior, 1999) و کاهش فشار مجاز وارده به خاک می‌شود به‌صورتی که در محتوای رطوبتی پایین خاک، حتی بارهای بزرگ نیز توان تغییر شکل خاک در عمق‌های بیشتر از چندین سانتی‌متر را ندارند درحالی‌که در محتوای رطوبتی بالاتر مقدار بار مجاز بسیار پایین‌تر است (Medvedev and Cybulko, 1995). بیشترین مقدار میانگین جرم مخصوص ظاهری در رطوبت 22٪ به مقدار  $1326/57 \text{ kgm}^{-3}$  و کمترین آن در رطوبت 11٪ و با مقدار  $1270/89 \text{ kgm}^{-3}$  به‌دست آمد. همچنین بررسی‌ها نشان داد که در تمامی سطوح رطوبت، در همه سرعت‌ها با افزایش عمق از میزان تراکم در خاک کاسته می‌شود. زیرا خاک در لایه‌های سطحی فشار بیشتری را متحمل می‌شود، بر همین اساس است که تحت اثر بار مشخص لایه‌های سطحی متراکم‌تر از لایه‌های عمقی خاک می‌شوند. البته در لایه سطحی تراکم تا عمق مشخصی افزایش یافته و سپس با افزایش عمق به لایه‌های زیرین تراکم با افزایش عمق کاهش نشان می‌دهد. با توجه به اینکه در این تحقیق تراکم در لایه 20-40 cm اندازه‌گیری شده است روند ذکر شده برای لایه سطحی مشاهده نشد و روند کاهش تراکم در لایه زیرین ایجاد شد. بیشترین تراکم خاک به‌طور معمول در مسیر تردد و در لایه‌های بالایی مشاهده می‌شود (Balbuena et al., 2000). بیشترین مقدار میانگین جرم مخصوص در عمق 20 سانتی‌متر با مقدار  $1322/25 \text{ kgm}^{-3}$  و کمترین آن مربوط به عمق 40 سانتی‌متر با مقدار میانگین  $1272/14 \text{ kgm}^{-3}$  به‌دست آمد. نتایج آزمایشات نشان داد که با افزایش سرعت پیشروی از میزان تراکم در تمامی سطوح عمق و رطوبت کاسته می‌شود. کاهش سرعت پیشروی وسیله موجب افزایش میزان جرم مخصوص ظاهری و شاخص مخروطی در خاک می‌شود (Vomocil et al., 1958). زیرا افزایش سرعت عبور یا بارگذاری موجب کاهش مدت‌زمان بارگذاری و کاهش نیروی اعمالی به خاک از طرف وسیله می‌شود. بر همین اساس و مطابق با نتایج تحقیقات (Carman, 1994) بیشترین مقدار میانگین جرم مخصوص ظاهری در سرعت پیشروی 1 کیلومتر بر ساعت با مقدار  $1317/68 \text{ kgm}^{-3}$  و کمترین آن مربوط به سرعت پیشروی 5 کیلومتر بر ساعت با مقدار میانگین  $1277/5 \text{ kgm}^{-3}$  می‌باشد.

شکل‌های 5 تا 7 اثرات متقابل دوتایی را نشان می‌دهند. در اثر متقابل سرعت و رطوبت، در تمامی سطوح سرعت، با افزایش رطوبت جرم مخصوص ظاهری به‌طور معنی‌داری افزایش می‌یابد. همچنین در تمامی سطوح رطوبت، با افزایش سرعت کاهش معنی‌دار جرم مخصوص ظاهری خاک دیده می‌شود. تغییرات جرم مخصوص خاک تحت اثر متقابل رطوبت در عمق نیز معنی‌دار می‌باشد، بدین‌صورت

اعتبارسنجی مورداستفاده قرار گرفتند. این داده‌ها در واقع بخشی از داده‌های آموزشی هستند. بدین ترتیب که حین آموزش شبکه در بازه‌های منظم از روند بهینه‌سازی، داده‌های حاصل از شبکه با استفاده از داده‌های اعتبارسنجی موردبررسی قرار می‌گیرند. در این مورد آموزش شبکه تا زمانی که خطای بهینه‌سازی مربوط به داده‌های ارزیابی شروع به افزایش کند، ادامه می‌یابد و به‌محض اینکه این خطا تا میزان و تکرار مشخصی افزایش یابد، آموزش شبکه متوقف می‌شود (Beale et al., 2010). درنهایت 15 درصد مابقی داده‌ها به‌عنوان داده‌های آزمایشی (test data) و برای آزمون عملکرد شبکه پس از آموزش مورداستفاده قرار گرفتند. از داده‌های آزمایشی طی آموزش شبکه استفاده نمی‌شود ولی برای مقایسه میزان خطا، مورداستفاده قرار می‌گیرند. تقسیم‌بندی داده‌ها برای سه دسته فوق به‌صورت تصادفی انجام شد زیرا در این حالت داده‌های هر دسته از قسمت‌های مختلف مجموعه داده‌ها انتخاب شده و تمام خصوصیات را در برمی‌گیرند و به‌علاوه از میل کردن خصوصیات داده‌های هر دسته به سمت مجموعه خاصی از داده‌ها ممانعت به‌عمل می‌آید. الگوریتم لونیگ-مارکوارت یک تکنیک پیشرفته غیرخطی است که به‌جای تکنیک گرادینان نزولی<sup>1</sup> و به‌منظور بهبود سرعت و عملکرد عمومی پس‌انتشار خطا استفاده می‌شود. این الگوریتم از سال 1993 تاکنون به‌عنوان یکی از سریع‌ترین روش‌های آموزش شبکه‌های عصبی شناخته شده است. بر همین اساس در این پژوهش این الگوریتم برای آموزش شبکه طراحی شده، به‌کار گرفته شد، به‌گونه‌ای که آموزش شبکه پس از 61 تکرار آموزشی و به دلیل افزایش خطای داده‌های ارزیابی از خروجی شبکه، متوقف شد.

## نتایج و بحث

### نتایج تجزیه واریانس

بر اساس تجزیه واریانس داده‌های جرم مخصوص ظاهری ضریب تغییرات داده‌ها 5/24٪ به‌دست آمد که این مقدار صحت آزمایشات را تأیید می‌کند. نتایج بیانگر معنی‌داری تأثیر هر سه عامل اصلی در سطح احتمال 1٪ بر میزان جرم مخصوص ظاهری بود (جدول 2). همچنین اثرات متقابل رطوبت در عمق، رطوبت در سرعت، عمق در سرعت و رطوبت در سرعت در عمق بر جرم مخصوص ظاهری خاک در سطح احتمال 1٪ معنی‌دار تشخیص داده شدند. مقایسه میانگین‌های سطوح مختلف سه عامل اصلی توسط آزمون چند دامنه‌ای دانکن در جدول 3 نشان داده شده است. افزایش رطوبت در تمام سرعت‌های پیشروی و عمق موجب افزایش در میزان جرم مخصوص ظاهری خاک شد. علت این امر را می‌توان به‌صورت

نتایج حاصله از مقایسه میانگین اثرات متقابل سه‌گانه (رطوبت در سرعت پیشروی در عمق) بر مقدار میانگین جرم مخصوص خاک نشان داد که بیشترین مقدار میانگین جرم مخصوص ظاهری خاک ( $1362 \text{ kg m}^{-3}$ ) به بالاترین سطح رطوبت (رطوبت بحرانی 22٪)، حداقل سرعت پیشروی معادل سرعت  $1 \text{ km h}^{-1}$  و حداقل عمق (عمق 20 سانتی‌متری) اختصاص دارد.

که در همه سطوح رطوبت، با افزایش عمق شاهد کاهش جرم مخصوص و در همه سطوح عمق، با افزایش رطوبت افزایش معنی‌دار جرم مخصوص مشاهده می‌شود. معنی‌دار بودن اثر متقابل سرعت در عمق نشان می‌دهد که در همه سطوح سرعت، با افزایش عمق تغییرات جرم مخصوص به‌طور معنی‌داری کاهش یافته است و همچنین در همه سطوح عمق نیز با افزایش سرعت تغییرات جرم مخصوص کاهش می‌یابد.

**جدول 2- تجزیه واریانس داده‌های مربوط به اندازه‌گیری جرم مخصوص در آزمایشات مزرعه‌ای**

**Table 2-** Analysis of variance of obtained data on bulk density during field experiments

منبع تغییرات Source of variations	درجه آزادی Degree of freedom	مجموع مربعات	میانگین مربعات Mean squares	F
تکرار Replication	2	40.469	20.235	1.085 ns
رطوبت Moisture	4	151253.376	37813.344	2027.163**
سرعت Speed	4	76949.269	19237.317	1031.307**
عمق Depth	4	121443.483	30360.871	1627.638**
رطوبت × سرعت Moisture×Speed	16	5888.544	368.034	19.73**
رطوبت × عمق Moisture×Depth	16	2661.931	166.371	8.919**
سرعت × عمق Speed×Depth	16	1985.904	124.119	6.654**
رطوبت × سرعت × عمق Moisture×Speed×Depth	64	4217.749	65.902	3.533**
خطا Error	248	4663.333	18.64	-
کل Total	374	589369063	-	-

\*\* معنی‌دار در سطح احتمال 1٪، ns معنی دار نبودن

**جدول 3- نتایج مقایسه میانگین اثرات پارامترهای اصلی بر جرم مخصوص خاک در سطح احتمال 5٪**


**Table 3-** Comparing results of the means of the main parameters effect on the bulk density at P<5%

عمق (cm) Depth	جرم مخصوص ظاهری ( $\text{kg m}^{-3}$ ) Bulk density	سرعت پیشروی ( $\text{km h}^{-1}$ ) Speed	جرم مخصوص ظاهری ( $\text{kg m}^{-3}$ ) Bulk density	محتوای رطوبتی (%) Moisture content	جرم مخصوص ظاهری ( $\text{kg m}^{-3}$ ) Bulk density
20	1322.25 <sup>a</sup>	1	1317.68 <sup>a</sup>	11	1270.89 <sup>a</sup>
25	1307.41 <sup>b</sup>	2	1302.82 <sup>b</sup>	13.5	1279.19 <sup>b</sup>
30	1292.4 <sup>c</sup>	3	1294.29 <sup>c</sup>	16	1290.65 <sup>c</sup>
35	1281.09 <sup>d</sup>	4	1282.98 <sup>d</sup>	19	1308.01 <sup>d</sup>
40	1282.14 <sup>e</sup>	5	1277.52 <sup>e</sup>	22	1326.57 <sup>e</sup>


حروف مختلف نشان‌دهنده معنی‌دار بودن اختلاف می‌باشد

Similar letters show that there was no significant difference






شکل 5- اثر متقابل سرعت پیشروی در رطوبت بر جرم مخصوص خاک  
 Fig. 5. Binary effect of forward speed and moisture on the soil bulk density



شکل 6- اثر متقابل رطوبت در عمق بر جرم مخصوص خاک  
 Fig. 6. Binary effect of moisture and depth on the soil bulk density



شکل 7- اثر متقابل سرعت پیشروی در عمق بر جرم مخصوص خاک  
 Fig. 7. Binary effect of forward speed and depth on the soil bulk density

سرعت پیشروی در تمامی عمقها سبب کاهش معنی دار در میزان جرم مخصوص خاک می شود؛ همچنین با افزایش عمق در همه سطوح رطوبت و تمامی سرعتها، میزان جرم مخصوص کاهش


همچنین حداقل مقدار آن نیز (1234/5 kg m<sup>-3</sup>) متعلق به حداقل رطوبت (رطوبت 11٪)، حداکثر سرعت (5 km h<sup>-1</sup>) و حداکثر عمق (عمق 40 سانتی متری) خاک است. در همه سطوح رطوبت، افزایش

تمامی عمق‌ها با افزایش میزان رطوبت افزایش میزان تراکم مشاهده می‌شود، حد نهایی میزان تراکم خاک در حداقل عمق و حداکثر محتوای رطوبتی مشاهده شد. در تمامی سطوح عمق با افزایش سرعت پیشروی و در تمامی سطوح سرعت با افزایش عمق از میزان تراکم خاک کاسته می‌شود. حداکثر مقدار تراکم ایجاد شده در خاک در حداقل سرعت و عمق‌های سطحی تر اتفاق افتاد. با بررسی مدل‌ها مشخص شد که در تمامی سطوح سرعت با افزایش محتوای رطوبتی بر میزان تراکم خاک افزوده می‌شود. همچنین افزایش در سرعت پیشروی در تمامی سطوح رطوبت موجب کاهش میزان نهایی تراکم ایجاد شده در خاک می‌شود. منطبق بر نتایج تجربی حداکثر میزان تراکم در حداقل سرعت و بیشترین مقدار محتوای رطوبتی اتفاق افتاد.


یافت. حال آنکه افزایش میزان رطوبت خاک موجب افزایش میزان جرم مخصوص در تمامی سطوح عمق و سرعت پیشروی شد. به‌طور کلی با افزایش رطوبت و کاهش عمق و کاهش سرعت پیشروی وسیله تراکم خاک بیشتر شده و با کاهش رطوبت، افزایش عمق و سرعت پیشروی بالا تراکم خاک کمتر می‌گردد.

### تحلیل و بررسی نتایج حاصل از مدل‌سازی

نتایج مدل‌ها در شکل‌های 8 تا 9 نشان می‌دهند که مشابه با نتایج تجربی در یک سطح رطوبت با افزایش عمق از میزان تراکم خاک کاسته می‌شود. این روند در تمامی سطوح رطوبت صادق است؛ اما محتوای رطوبتی بالا در مقایسه با رطوبت کمتر میزان تراکم بیشتری حتی در عمق‌های بیشتر خاک نشان می‌دهد. همچنین در



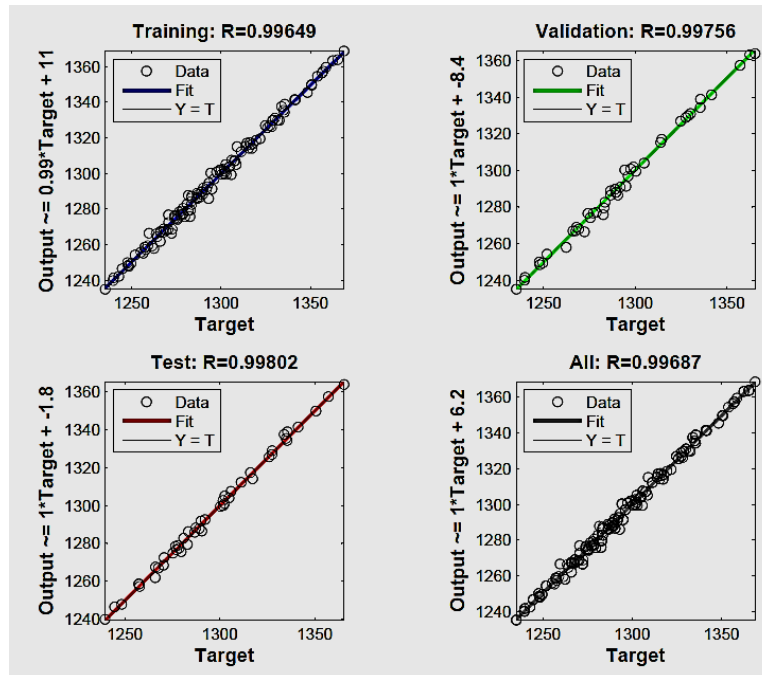
شکل 8- نمودار تغییرات جرم مخصوص ظاهری خاک با تغییر رطوبت و عمق (راست) و با تغییرات عمق و سرعت پیشروی (چپ)  
**Fig. 8.** Variation of the soil bulk density with soil moisture and depth (right) also with depth and the tractor velocity



شکل 9- نمودار تغییرات جرم مخصوص ظاهری خاک با تغییرات رطوبت و سرعت پیشروی  
**Fig. 9.** Variation of the soil bulk density with moisture and the tractor velocity change

در نهایت تمامی داده‌ها به ترتیب برابر 0/993، 0/995 و 0/996 و 0/993 به دست آمد که نشان‌دهنده توانایی بالای شبکه‌های عصبی مصنوعی در مدل‌سازی سیستم‌های پیچیده است.

نتایج رگرسیون خطی بین مقادیر تجربی و مدل شبکه عصبی در شکل 10 آورده شده است. ضریب تبیین ( $R^2$ ) بین داده‌های تجربی و مدل شبکه عصبی برای داده‌های آموزشی، اعتبارسنجی و ارزیابی و



شکل 10- نتایج رگرسیون خطی بین مقادیر تجربی و مدل شبکه عصبی مصنوعی

Fig. 10. Linear regression relationship between experimental data and predicted data by artificial neural network

از میزان رطوبت خاک زمینه‌های مدیریت صحیح به‌منظور کاهش آسیب به ساختمان خاک، کاهش هزینه‌ها و افزایش تولیدات کشاورزی را موجب خواهد شد. همچنین با افزایش عمق خاک، میزان تراکم در تمامی سطوح سرعت و رطوبت کاهش معنی‌داری را نشان می‌دهد. در لایه‌های زیرین با توجه به رابطه معکوس فشار وارده با عمق، با افزایش عمق فشار وارده و در نتیجه تراکم کاهش یافت. افزایش سرعت پیشروی سبب کاهش تراکم ایجاد شده در خاک می‌شود. در این تحقیق استفاده از شبکه عصبی MLP با یک‌لایه پنهان شامل پنج نورون با تابع سیگموئید در لایه میانی و یک نورون با تابع انتقال خطی در لایه خروجی دقیق و مؤثر تشخیص داده شد به‌صورتی که ضریب همبستگی ( $R^2$ ) بین داده‌های تجربی و مدل شبکه عصبی برای تمامی داده‌ها برابر 0/996 به دست آمد. همچنین درصد میانگین مطلق خطای سیستم و مقدار میانگین مربعات خطا برای مدل توسعه داده‌شده به ترتیب برابر 1/4 درصد و 0/008 به دست آمد.

میانگین قدرمطلق خطا برای آموزش، تست و ارزیابی به ترتیب برابر 1/07، 2/32 و 1/96 محاسبه گردید و درصد خطا برای پارامترهای ذکر شده برابر 0/08، 0/017 و 0/1 درصد بود. میانگین قدرمطلق خطا برای شبکه توسعه داده شد برابر 1/4 به دست آمد. همچنین درصد میانگین مطلق خطای سیستم برای نتایج شبکه عصبی برابر 0/008 درصد به دست آمد.

### نتیجه‌گیری

ساختار سیستم‌های طبیعی به‌واسطه کثرت عوامل مؤثر در رفتار سیستم، شامل پیچیدگی‌های فراوانی است. به همین دلیل نتایج اکثر پژوهش‌های انجام‌شده در این زمینه تنها می‌توانند رفتار سیستم را در محدوده مورد بررسی و شرایط خاص بیان کنند. مشاهدات آزمایشگاهی و نتایج حاصله از مدل‌ها نشان داد که با افزایش محتوای رطوبتی خاک تا حد بحرانی رطوبت، میزان تراکم اعمال شده در خاک به‌واسطه تردد افزایش می‌یابد. به عبارت دیگر افزایش محتوای آبی خاک موجب کاهش ظرفیت تحمل بار می‌شود. به همین دلیل آگاهی

## References

1. Akker, J., J. H. Van den, and A. Canarache. 2001. Two European concerted actions on subsoil compaction. *Landnutz Und Landentwickl*, 42 (1): 15-22.
2. Allmaras, R., V. A. Fritz, F. L. Pflieger, and S. M. Copeland, 1998. Common root rot of pea (*Pisum sativum* L.): oat pre-crop and traffic compaction effects in fine-textured mollisols. In *Root Demographics and Their Efficiencies in Sustainable Agriculture, Grasslands and Forest Ecosystems* (pp. 285–294). Springer.
3. Anderson, J. A., and E. Rosenfeld. 1990. *Neurocomputing* (Vol. 2). MIT press
4. Balbuena, R. H., A. M. Terminiello, J. A. Claverie, J. P. Casado, and R. Marlats. 2000. Soil compaction by forestry harvester operation: evolution of physical properties. *Revista Brasileira de Engenharia Agricola E Ambiental* 4 (3): 453-459.
5. Battiti, R. 1992. First-and second-order methods for learning: between steepest descent and Newton's method. *Neural Computation* 4 (2): 141-166.
6. Beale, M. H., M. T. Hagan, and H. B. Demuth. 2010. *Neural Network Toolbox 7. User's Guide*, MathWorks.
7. Benjamin, J. R., and C. A. Cornell. 2014. *Probability, statistics, and decision for civil engineers*. Courier Dover Publications.
8. Boghosial, A. 2006. Predicting consumption of petroleum products: Compare econometric equation systems and neural networks (In Persian). *Energy Economics Studies* 3 (3): 47-67.
9. Bouwman, L. A., and W. Arts. 2000. Effects of soil compaction on the relationships between nematodes, grass production and soil physical properties. *Applied Soil Ecology* 14 (3): 213-222.
10. Carder, J., and J. Grasby. 1986. A framework for regional soil conservation treatments in the medium and low rainfall agricultural district. Department of Agriculture, PP. 128.
11. Carman, K. 1994. Tractor forward velocity and tire load effects on soil compaction. *Journal of Terramechanics* 31 (1): 11-20.
12. Demuth, H., and M. Beale. 1993. *Neural network toolbox for use with MATLAB*. The MathWorks Inc., 840p.
13. Engelbrecht, A. P. 2007. *Computational intelligence: an introduction*. John Wiley & Sons, 650p.
14. Ferrara, C., P. M. Barone, and L. Salvati. 2015. Toward a socioeconomic profile for areas vulnerable to soil compaction? A case study in Mediterranean country, *Geoderma*, 247-248, 97-107.
15. Flowers, M., and R. Lal. 1998. Axle load and tillage effects on soil physical properties and soybean grain yield on a mollic ochraqualf in northwest Ohio. *Soil and Tillage Research* 48 (1): 21-35.
16. Geshlaghi, F., and A. Mardani. 2015. Predicting the wheel rolling resistance regarding important motion parameters using the artificial neural network. *Journal of Agricultural Machinery* 6 (1): 259-270. (In Farsi).
17. Günaydn, O. 2009. Estimation of soil compaction parameters by using statistical analyses and artificial neural networks. *Environmental Geology* 57 (1): 203-215.
18. Hagan, M. T., H. B. Demuth, and M. H. Beale, 1996. *Neural network design* (Vol. 1). Pws Boston, 1012p.
19. Hamza, M. A., and W. K. Anderson. 2005. Soil compaction in cropping systems: a review of the nature, causes and possible solutions. *Soil and Tillage Research* 82 (2): 121-145.
20. Haykin, S., and N. Network. 2004. *A comprehensive foundation. Neural Networks*, Second Edition, McMaster University Hamilton, Ontario, Canada, 823p.
21. Hecht-Nielsen, R. 1987. Kolmogorov's mapping neural network existence theorem. In *Proceedings of the international conference on Neural Networks* (Vol. 3, pp. 11–14). New York: IEEE Press.
22. Hewitson, B. C., and R. G. Crane. 1994. *Neural Nets: Applications in Geography*. Kluwer Academic Publishers, Dordrecht.
23. Johari, A., A. Javadi, and G. Habibagahi, 2011. Modelling the mechanical behaviour of unsaturated soils using a genetic algorithm-based neural network. *Computers and Geotechnics* 38 (1): 2-13.
24. Lam, D., and C. Pupp. 1993. Expert system and modeling for state of environment reporting. In *2nd International Conference on Integrating GIS and Environmental Modeling* (pp. 26-30).
25. Levine, E. R., D. S. Kimes, and V. G. Sigillito. 1996. Classifying soil structure using neural networks. *Ecological Modelling* 92 (1): 101-108.

26. Mason, E. G., A. W. J. Cullen, and W. C. Rijkse. 1988. Growth of two *Pinus radiata* stock types on ripped and ripped/bedded plots at Karioi forest. *New Zealand Journal of Forestry Science* 18 (3): 287-296.
27. McClelland, J. L., and D. E. Rumelhart, 1989. Explorations in parallel distributed processing: A handbook of models, programs, and exercises. MIT press, 333p.
28. Medvedev, V. V., and W. G. Cybulko. 1995. Soil criteria for assessing the maximum permissible ground pressure of agricultural vehicles on Chernozem soils. *Soil and Tillage Research* 36 (3): 153-164.
29. Menhaj, M. 2005. *Fundamentals of Neural Networks* (third edit). Amirkabir University Press, 715p. (In Farsi).
30. Minasny, B., A. B. McBratney, and K. L. Bristow. 1999. Comparison of different approaches to the development of pedotransfer functions for water-retention curves. *Geoderma* 93 (3): 225-253.
31. Navabian, M., A. M. Liaghat, and M. Homayi. 2004. Neural network for fast estimation of saturated hydraulic conductivity. Prediction of Electrical conductivity with neural networks. The second National water and soil conference, Tehran, Iran.
32. Kondo, M. K., and D. Junior, 1999. Soil compressibility of three latosols (oxisols) as a function of moisture and use. *Revista Brasileira de Ciencia Do Solo* 23 (2): 211-218.
33. Onwubolu, G. 2009. Hybrid Computational Intelligence and GMDH Systems. In *Hybrid Self-Organizing Modeling Systems* (pp. 1-26). Springer.
34. Panayiotopoulos, K. P., C. P. Papadopoulou, and A. Hatjioannidou. 1994. Compaction and penetration resistance of an Alfisol and Entisol and their influence on root growth of maize seedlings. *Soil and Tillage Research* 31 (4): 323-337.
35. Raper, R. L. 2005. Agricultural traffic impacts on soil. *Journal of Terramechanics* 42 (3-4): 259-280.
36. Schaap, M. G., F. J. Leij, and M. T. van Genuchten. 1998. Neural network analysis for hierarchical prediction of soil hydraulic properties. *Soil Science Society of America Journal* 62 (4): 847-855.
37. Tardieu, F. 1994. Growth and functioning of roots and of root systems subjected to soil compaction. Towards a system with multiple signaling. *Soil and Tillage Research* 30 (2): 217-243.
38. Taylor, S. A., and G. L. Ashcroft. 1972. *Physical edaphology. The physics of irrigated and nonirrigated soils*. San Francisco, 533p.
39. Vomocil, J. A., E. R. Fountaine, and Reginato. 1958. The influence of speed and drawbar load on the compacting effect of wheeled tractors. *Soil Science Society of America* 22 (2): 178-180.

## Modeling of Soil Compaction Beneath the Tractor Tire using Multilayer Perceptron Neural Networks

Gh. Shahgoli<sup>1\*</sup> - H. Ghafouri Chiyaneh<sup>2</sup> - T. Mesri Gundoshmian<sup>3</sup>

Received: 15-09-2016

Accepted: 30-01-2017

### Introduction

Soil compaction is one of the most destructive effects of machine traffic. Compaction increases soil mechanical strength and reduces its porosity, plant rooting and ultimately the yield. Nowadays, agricultural machinery has the maximum share on soil compaction in modern agriculture. The soil destruction may be as surface deformation or as subsurface compaction. Any way machine traffic destructs soil structure and as result has unfavorable effect on the yield. Hence, soil compaction recognition and its management are very important. In general, soil compaction is the most destructive effect of machine traffic. Modeling of ecological systems by conventional modeling methods due to the multitude effective parameters has always been challenging. Artificial intelligence and soft computing methods due to their simplicity, high precision in simulation of complex and nonlinear processes are highly regarded. The purpose of this research was the modeling of soil compaction system affected by soil moisture content, the tractor forward velocity and soil depth by multilayer perceptron neural network.

### Materials and Methods

In order to carry out the field experiments, a tractor MF285 which was equipped with a three-tilt moldboard plough was used. Experiments were conducted at the Agricultural research field of University of Mohagheh Ardabili in five levels of moisture content of 11, 14, 16, 19 and 22%, forward velocity of 1, 2, 3, 4 and 5 km/h, and soil depths of 20, 25, 30, 35 and 40 cm as a randomized complete block design with three replications. In this study, perceptron neural network with five neurons in the hidden layer with sigmoid transfer function and linear transfer function for the output neuron was designed and trained.

### Results and Discussion

Field experiments showed three main factors were significant on the bulk density ( $P < 0.01$ ). The mutual effect of moisture on depth and mutual binary effect of moisture on velocity and depth on velocity were significant ( $P < 0.01$ ). Mutual triplet effect of moisture on velocity on depth was significant ( $P < 0.05$ ). Maximum bulk density of  $1362 \text{ kg/m}^3$  was obtained at the highest moisture of 22% and the lowest forward velocity of 1 km/h at the depth of 20 cm. Whilst the minimum value of  $1234.5 \text{ kg/m}^3$  was related to the moisture, forward velocity and depth of 11%, 5 km/h and depth of 40 cm, respectively. Compaction increased as soil moisture content increased up to 22% which was critical moisture. In contrast, soil compaction decreased as the tractor velocity and soil depth increased. A comparison of neural network output and experimental results indicated a high determination coefficient of  $R^2 = 0.99$  between them. Also, the mean square error of the model was 0.174, in addition, mean absolute percentage error of the system (MAPE) was equal to %0.29 which showed high accuracy of neural network to model soil compaction.

### Conclusions

It was concluded that soil compaction increased as soil moisture content increased up to a critical value. Increasing soil moisture act as lubricant and soil layers compacted together. Hence knowledge of soil moisture can help us to manage soil compaction during agricultural operations. Increasing the tractor forward velocity reduced soil compaction. However, agricultural operations should be conducted at certain speeds to carry out the duty properly and increasing speed more that value decreases the efficiency of work.

Neural network of MLP with 5 neurons in hidden layer and sigmoid function in middle layer and one neuron with linear transfer function was found the most accurate and precise in prediction of the soil bulk density. A high determination coefficient of  $R^2 = 0.99$  was found between measured and predicted values.

**Keywords:** Artificial neural network, Modeling, Multilayer perceptron, Soil compaction

1, 2- Associate Professor of Department of Biosystem Engineering, Faculty of Agriculture and Natural Resources, University of Mohagheh Ardabili, Ardabil, Iran

3- M.Sc. of Mechanics of Biosystem, Faculty of Agriculture and Natural Resources, University of Mohagheh Ardabili, Ardabil, Iran

(\*- Corresponding Author Email: gshahgoli@yahoo.com)