



پیش‌بینی نیروی کششی و انرژی خاک‌ورزی عملیات زیرشکنی با استفاده از مدل شبکه عصبی مصنوعی (۲۵۲)

یوسف عباسپور گیلاندَه^۱، رضا علیمردانی^۲، احمد خلیلیان^۳، علیرضا کیهانی^۴، سیدحسین ساداتی^۵

چکیده

رد و توسعه شبکه عصبی مصنوعی در زمینه مدل کردن خصوصیات فیزیکی و دینامیکی خاک و همچنین مطالعه امکان پذیری ارتباط این سیستم با روش اجزاء محدود، روز به روز در حال توسعه می‌باشد و انتظار می‌رود که استفاده از شبکه عصبی مصنوعی نتایج موفقی را بخصوص در شیوه‌سازی عملکرد ادوات خاک‌ورزی و رفتار دینامیکی خاک در مقابل ابزار ارائه نماید. دلیل استفاده از شبکه عصبی در این کارها قدرت پیش‌بینی بالای این روش و همچنین عدم وجود رابطه ریاضی مشخص بین متغّرّهای مستقل و وابسته می‌باشد. در این تحقیق به منظور توسعه مدل پیش‌بینی نیروی کششی و انرژی خاک‌ورزی عملیات زیرشکنی، پارامترهایی سرعت پیشروی تراکتور، عمق خاک‌ورزی و پارامترهای مختلف خاک (شاخص مخروطی، محتوی رطوبتی، هدایت الکتریکی، درصد رس، درصد شن و ...) مورد استفاده قرار گرفتند. آزمایش‌هایی به منظور جمع آوری داده‌های مورد نیاز در سه نوع خاک جلگه‌ای ساحلی متفاوت در منطقه جنوب شرقی آمریکا انجام شد. شبکه‌های عصبی مصنوعی طراحی شده در این تحقیق که به منظور پیش‌بینی نیروی کششی و انرژی مورد عملیات خاک‌ورزی مورد استفاده قرار گرفتند، از نوع شبکه چند لایه پس انتشار برگشتی بودند که به منظور آموزش شبکه از سه الگوریتم گرادیان نزولی با مومنتم، الگوریتم لونبرگ-مارکوات و الگوریتم گرادیان نزولی مقایسه استفاده گردید. انتخاب بهترین الگوریتم آموزشی براساس مقایسه عملکرد شبکه‌های ساخته شده (در مرحله آموزش و آزمون داده‌ها) انجام گردید. با توجه به دقت پیش‌بینی بالا (۹۵/۸٪) و دقت شیوه‌سازی بالاتر (۹۷/۶٪) استفاده از الگوریتم لونبرگ-مارکوات (با دو لایه میانی با تعداد ۱۲ عدد نرون در لایه ول و ۱۰ عدد نرون در لایه دوم) در مقایسه با سایر الگوریتم‌های آموزشی به منظور پیش‌بینی نیروی کششی و انرژی خاک‌ورزی موردنیاز مناسب تشخیص داده شد. نمودارهای نقطه‌ای بدست آمده ضریب تبیین مدل $R^2 = ۰/۹۶$ در آموزش شبکه و ضریب تبیین مدل $R^2 = ۰/۹۷$ در جریان تست شبکه بین داده‌های واقعی و داده‌های بدست آمده از شبکه عصبی برای این حالت را نشان می‌دهند. همچنین به منظور ارزیابی مدل‌های شبکه عصبی مصنوعی، داده‌های بدست آمده از این مدل‌ها با داده‌های مدل‌های رگرسیونی (مدل ارائه شده توسط انجمن مهندسین کشاورزی آمریکا و مدل گارنر) مورد مقایسه قرار گرفتند. مقایسه نتایج بدست آمده از مدل شبکه عصبی مصنوعی و مدل‌های رگرسیونی به منظور پیش‌بینی نیروی کششی مورد نیاز عملیات زیرشکنی نشان داد که مدل شبکه عصبی مصنوعی داده‌های بسیار نزدیکتری به داده‌های واقعی در مقایسه با سایر مدل‌های رگرسیونی ارائه کرد.

کلیدواژه: انرژی خاک‌ورزی، نیروی کششی، زیرشکن، شبکه عصبی مصنوعی، الگوریتم مارکوات-لونبرگ

۱- استادیار، گروه مهندسی مکانیک ماشین‌های کشاورزی، دانشگاه محقق اردبیلی، اردبیل، ایران

۲- استاد، گروه مهندسی مکانیک ماشین‌های شاورزی، دانشکده مهندسی بیوپسیستم کشاورزی، دانشگاه تهران، کرج، ایران

۳- استاد، گروه مهندسی کشاورزی و بیوپسیستم، دانشکده اورزی، دانشگاه کامسون، کارولینای جنوبی، ایالات متحده آمریکا

۴- داشیار، گروه مهندسی مکانیک ماشین‌های کشاورزی، دانشکده مهندسی بیوپسیستم کشاورزی، دانشگاه تهران، کرج، ایران

۵- استادیار، گروه مهندسی مکانیک، دانشکده فنی، دانشگاه خواجه نصیرالدین طوسی، تهران، ایران



مقدمه

نتایج بسیاری از تحقیقات نشان می دهد که اثرات خصوصیات فیزیکی خاک روی نیروی کششی لازم برای کشیدن ادوات خاک رزی و انرژی مورد نیاز، امری کاملاً اثبات شده می باشد. خصوصیات و پارامترهای خاک که بر نیروی کششی و انرژی مورد نیاز ادوات تاثیرگذار می باشد عبارتند از: محتوی رطوبتی خاک، جرم مخصوص ظاهری، شاخص مخروطی و بافت خاک [۲۱ و ۲۲]. اثرات این پارامترهای مؤثر در نیروی کششی توسعه بسیاری از محققان بررسی شده است. همچنین اثرات شکل هندسی ابزار و طریقه شکست خاک با استفاده از آنالیز ابعادی و سایر روش‌های تحلیلی مورد مطالعه قرار گرفته است. [۲۳ و ۱۵].

در سالهای اخیر تمایل روزافزونی به کاربرد و توسعه شبکه عصبی مصنوعی در زمینه مدل کردن خصوصیات فیزیکی و دینامیکی خاک و همچنین مطالعه امکانپذیری ارتباط این سیستم با روش اجزاء محدود ایجاد شده است و انتظار می رود که استفاده از شبکه عصبی مصنوعی نتایج موقوفی را بخصوص در شیوه سازی عملکرد ادوات خاک ورزی و رفتار دینامیکی خاک در مقابل ابزار ارائه نماید. شبکه عصبی مصنوعی یک سیستم غیرخطی می باشد که بدون داشتن اطلاعات کامل از نحوه ارتباط پارامترها و قوانین حاکم بین آنها سیستم خاک را شیوه سازی نماید [۱۱ و ۱۵]. بنابراین استفاده از این سیستم غیر خطی می تواند بسیاری از مشکلات روش‌های تحلیلی و روش اجزاء محدود را مرتفع سازد و مطابق با شرایط فعلی و شرایط حاکم بر سیستم خاک با استفاده از داده‌های واقعی آموزش بینند و برای کاربردهای بعدی تعمیم داده شود.

با پیدایش روش اجزاء محدود^۱، این روش توانست مقداری از محدودیتهای روش‌های تحلیلی را جبران نماید و حداقل این روش توانست به روش نظری توزیع تنش، عکس العمل بین خاک و ابزار و همچنین نیروی کششی را پیش‌بینی نماید. این پیش‌بینی‌ها در مواردی که بحث دینامیک خاک و بحث حرکت مطرح می‌گردد، بهدلیل تعییرات بسیار در خاک‌های کشاورزی نتوانست دقّت بالایی را ارائه نماید و شرایط واقعی و دینامیکی خاک و ابزار را توصیف نماید [۲۳ و ۱۵].

کو (۱۹۹۵) امکانپذیری مطالعه سیستم‌های غیرخطی و سیستم‌هایی که تحت تأثیر پارامترهای مختلف قرار دارند را مورد بررسی قرار داد. نمونه‌ای از سیستم‌های غیرخطی که در تحقیق آنها مطالعه شده است، می‌توان به مدل کردن ادهای شاخص مخروطی در داخل خاک اشاره کرد که توسط شبکه پس انتشار برگشتی انجام گرفته است. نمونه‌ای دیگری از کاربردهای ذکر شده در این مقاله برای شبکه عصبی مصنوعی در زمینه مطالعات خاک رزی، می‌توان به پیش‌بینی نیروی کششی اشاره کرد که بر حسب سرعت پیشروی انجام گرفته است. محققان در این تحقیق ازتابع پایه شعاعی^۲ برای مدل کردن نیروی کششی استفاده کردند. باید توجه داشت که این مدل در داخل یک نوع خاک توسعه داده شده و پارامترهای خاک که نشان دهنده وضعیت خاک و در حقیقت هدف مطالعه دینامیکی خاک می باشد در این مدل وارد نشده است [۱۲].

کوشواها و همکاران (۱۹۹۸) استراتژی دیگری را ارائه نمودند که از ترکیب روش اجزاء محدود و شبکه عصبی می‌توان به منظور طراحی کامپیوترا ادوات خاک ورزی استفاده کرد. با این هدف، شبکه عصبی مصنوعی به منظور پیش‌بینی خصوصیات دینامیکی خاک بدون نیاز به تجزیه و تحلیل تنش و کرنش در داخل خاک بکار می‌رود و روش اجزاء محدود محاسبه نیروی کششی، تنش‌ها و جابجایی‌ها را در داخل خاک محاسبه می‌نماید. بدین ترتیب از ترکیب این دو روش می‌توان به منظور طراحی و تجزیه و تحلیل سه بعدی تنش‌ها و نیروهای وارد بر ادوات خاک ورزی استفاده کرد که در اکثر موارد با توجه به تعییرات بسیار زیاد در داخل خاک از لحاظ خصوصیات فیزیکی و دینامیکی، روش اجزاء محدود نتایج قابل قبولی را در این زمینه ارائه نکرده است [۲۳ و ۱۵].

تحقیقات دیگری نیز در زمینه شیوه سازی رفتار خاک، مدل کردن تنش و کرنش در داخل خاک و همچنین طبقه‌بندی ساختار خاک با استفاده از شبکه عصبی مصنوعی انجام گرفته است [۱۶ و ۱۱] و تمامی این تحقیقات نتایج بسیار موفق است. از شبکه‌های عصبی مصنوعی را در این تحقیقات و بخصوص در کارهای پیش‌بینی و مدل کردن فرآیندهای پیچیده آشکار می‌سازد. هدف این تحقیق توسعه مدل پیش‌بینی نیروی کششی و انرژی مورد نیاز عملیات زیرشکنی با استفاده از مدل شبکه عصبی مصنوعی می‌باشد. پارامترهایی که برای پیش‌بینی انرژی مورد نیاز خاک ورزی مورد استفاده قرار می‌گیرند شامل سرعت پیروی تراکتور، عمق خاک ورزی و پارامترهای مختلف خاک (از جمله شاخص مخروطی، محتوی رطوبتی، هدایت الکتریکی و درصد رس

¹ - Finite Elements Method
² - Radial Basis Function



و شن) خواهند بود که در مطالعات مختلف اثرات این پارامترها روی انرژی خاک زی و نیروی کششی مورد بررسی قرار گرفته است [۲۰ و ۱۹ و ۳].

مواد و روشها

ادوات مورد استفاده در انجام تحقیق

از یک دستگاه فروسنچ مجهز به سیستم مکان‌یاب جهانی تفاضلی^۱ (DGPS) که روی یک تراکتور شش چرخ نصب شده بود، به منظور اندازه‌گیری مقاومت به نفوذ خاک استفاده گردید [۱۴]. مقادیر شاخص مخروطی بر اساس نیروی اندازه‌گیری شده برای فشار دادن یک مخروط با سطح مقطع^۲ ۱۳۰ mm^۲ و زاویه نوک ۳۰ درجه به داخل خاک مطابق با استاندارد ASAE محاسبه شد [۴].

به منظور بدست آوردن نقشه هدایت الکتریکی^۳ (EC) مزرعه مورد آزمایش، از یک دستگاه سنجش هدایت الکتریکی خاک با نام تجاری وریس^۴ ۳۱۰۰ استفاده شد [۱۷]. این دستگاه مجهز به ۶ الکترود بشتابی می‌باشد که یک جفت از این بشتابها جریان الکتریکی را در داخل خاک ایجاد می‌کنند در حالیکه بقیه بشتابها (الکت دها) به منظور اندازه‌گیری افت ولتاژ بین جفت بشتاب مورد استفاده قرار می‌گیرند. این سیستم، هدایت الکتریکی خاک را در لایه‌های خاک به ضخامت ۳۰ و ۹۰ سانتی‌متر اندازه‌گیری می‌کند.

از یک تراکتور جاندیر کمک جلو با توان مشخصه ۱۰۵ اسب بخار و مجهز به ابزار ازه‌گیر به منظور جمع‌آوری اده‌های مریبوط به نیروی کششی و انرژی خاک‌ورزی در جریان انجام عملیات خاک‌ورزی استفاده گردید. سیستم ابزار اندازه‌گیری تراکتور مجهز به دینامومتر اتصال سه نقطه، سوخت سنج، حسگر مازه‌گیری دور موتور (RPM)، حسگرهای مختلف اندازه‌گیری سرعت (سیستم رادار^۵، چرخ پنجم و حسگر صوتی^۶، سیستم مکان‌یاب جهانی تفاضلی، واحد جمع کننده داده^۷ و همچنین حسگر نوری می‌باشد که از آن حسگر برای مشخص کردن ابتدا و انتهای کرت آزمایشی مورد استفاده قرار می‌گیرد [۱۳].

از یک سیستم کنترل عمق مجهز به سیستم مکان‌یاب جهانی تفاضلی به منظور کنترل عمق کاری زیرشکن مطابق با عمق و ضخامت لایه فشرده شده (که از روی اده‌های شاخص مخروطی بدست می‌آید) در این تحقیق مورد استفاده قرار گردید. این سیستم کنترل عمق می‌تواند عمق خاک‌ورزی را به طور پیوسته و در حال حرکت از سه طریق نقشه فشرده‌گی خاک، داده‌های ساقه مجهز به ابزار اندازه ری و یا از طریق ارده کردن مقدار عمق در کامپیوتر داخل بین راننده کنترل نماید [۱۴].

آزمایش‌های مزرعه‌ای

آزمایش‌های مزرعه‌ای در داخل یک مزرعه با سه نوع بافت خاک در مرکز تحقیقات و ترویج دانشگاه کلمبیا در نزدیکی شهر بلکویل^۸ ایالت کارولینای جنوبی آمریکا (۲۱° ۳۳' شمالي و ۸۱° ۱۸' غربي) انجام شد. مزرعه آزمایشی به وسعت ۲/۵ هکتار دارای سه نوع بافت لومی شنی فیسویل^۹، شنی لومی فوکی^۹ و شنی لیک لند^{۱۰} بود. جدول ۱ خصوصیات بافت‌های خاک مزرعه آزمایشی را ارائه می‌کند.

^۱ - Differential Geographical Positioning System (DGPS)

^۲ - Electrical Conductivity

^۳ - Veris 3100

^۴ - Radar

^۵ - Ultrasonic

^۶ - Data logger

^۷ - Blackville

^۸ - Faceville

^۹ - Fuquay

^{۱۰} - Lakeland



جدول ۱ - طبقه‌بندی خاک‌های مزرعه آزمایشی و میانگین محتوی رطوبتی خاک در جریان آزمایش

شوابط مربوط	شرایط خشک	میانگین درصد رطوبت خاک بر پایه وزن خشک در عمق cm ۴۶-۰	درصد رس	درصد شن	طیقه‌بندی خاک بر اساس خانواده خاک		نوع خاک
					طیقه‌بندی خاک بر اساس خانواده خاک		
۱۳/۵	۹/۹	۱۲/۵	۷۸/۳	Clayey-kaolinitic - thermic, Typic Paleudults		فیسیول (لومی شنی)	
۱۷/۶	۶/۷	۸/۹	۸۵/۵	Loamy-siliceous-thermic, Arenic Plinthic Paleudults		فوکسی (شنی لومی)	
۷/۶	۵/۳	۶/۳	۸۹/۵	Siliceous-thermic-coated, Typic Quartzipsamments		لیک لند (شنی)	

قبل از انجام آزمایشهای مزرعه‌ای و بدست آوردن داده‌های انرژی خاک‌ورزی، ندازه‌گیری مقادیر هدایت الکتریکی به منظور بررسی تغییرات بافت خاک و ناحیه‌بندی مزرعه انجام گردید. نتایج نشان داد که تغییرات بسیار زیادی از لحاظ تغییرات هدایت الکتریکی در داخل مزرعه وجود دارد. سپس مزرعه آزمایشی به کرت‌های 15×4 متر تقسیم شد. بعد از آن نمونه‌های خاک از هر کرت به منظور بدست آوردن بافت خاک جمع‌آوری گردید.

یک سری کامل از داده‌های شاخص مخروطی با استفاده از یک فروسنچ مخروطی مجهز به GPS در سرتاسر مزرعه بدست آمد. در هر کرت آزمایشی مقادیر شاخص مخروطی برای ۹ نقطه به فاصله ۱/۵ متر از یکدیگر بدست آمد. این مقادیر برای عمق صفر تا ۴۶ سانتی‌متری از سطح خاک و در دو شرایط رطوبتی ذکر شده در جدول ۱، بدست آمد.

بعد از بدست آوردن نقشه‌های هدایت الکتریکی، شاخص مخروطی، محتوی رطوبتی خاک و نوع بافت خاک در کرت‌های اختصاص داده شده به منظور دازه‌گیری انرژی مورد نیاز عملیات زیرشکنی، عملیات خاک‌ورزی در مزرعه آزمایشی و در داخل هر سه نوع خاک ذکر شده در جدول ۱ انجام گردید.

انرژی مورد نیاز برای عملیات زیرشکنی از طریق رابطه (۱) بدست آمد.

(۱)

$$E = t \cdot E_{PTO}$$

که در این فرمول:

$$E = \text{انرژی مورد نیاز (kW.h)}$$

$$t = \text{زمان لازم به منظور انجام عملیات زیرشکنی مورد نظر در داخل کرت آزمایشی (h)}$$

$$E_{PTO} = \text{توان مصرفی معادل محور توانده‌ی تراکتور به منظور انجام عملیات خاک‌ورزی (kW)}$$

زمان مورد نیاز به منظور انجام عملیات زیرشکنی در داخل کرت آزمایشی از روی مدت زمان لازم برای عبور از ابتدا به انتهای کرت آزمایشی (ابتدا و انتهای کرت آزمایشی توسط حسگر نوری مشخص می‌گردد) بدست آمد. توان مصرفی معادل محور توانده‌ی تراکتور (E_{PTO}) با تقسیم توان مالبندی تراکتور (P_{db}) به عدد ثابت (۰/۸۵) بدست آمد. این عدد ثابت بر اساس شرایط خاکی مزرعه و نوع تراکتور مورد استفاده، مطابق با استاندارد ASAE انتخاب شده است [۴] (۱۳).

توان مالبندی مورد نیاز (P_{db}) بر اساس رابطه (۲) بدست می‌آید:

(۲)

$$P_{db} = \frac{D.S}{3.6}$$

که در این فرمول:

$$P_{db} = \text{توان مالبندی مورد نیاز به منظور انجام عملیات خاک‌ورزی (kW)}$$

$$D = \text{نیروی کششی کل اندازه‌گیری شده توسط دینامومتر اتصال سه نقطه تراکتور (kN)}$$



= سرعت پیشروی تراکتور موقع انجام عملیات خاکورزی (km/h)

طراحی مدل شبکه عصبی مصنوعی

شبکه های طراحی شده در این تحقیق که به منظور پیش بینی نیروی کششی و انرژی مورد عملیات زیرشکنی مورد استفاده قرار گرفتند، از نوع شبکه چند لایه پس انتشار برگشتی می باشند. از سه روش الگوریتم گرادیان نزولی با مومنتوم، الگوریتم لونبرگ - مارکووات و الگوریتم گرادیان نزولی مقایسه به منظور آموزش شبکه استفاده گردیده است.

شبکه های چند لایه در کارهای پیش بینی قابلیت بسیار خوبی را از خود نشان می دهند به شرطی که نرون کافی در لایه مخفی وجود داشته باشد. اما باید به این نکته توجه داشت که تعداد نرونها بیشتر در لایه مخفی ممکن است شبکه را دچار آموزش بیش از حد^۱ کرده و ممکن است شبکه قابلیت تعمیم خود را از دست دهد. در حالت کلی نمی توان در مورد تعداد لایه های مخفی و نیز تعداد مناسب نرونها لایه مخفی اظهار نظر قطعی کرد و انتخاب تعداد نرونها لایه میانی به صورت سعی و خطأ انجام می گیرد. در این تحقیق نیز تعداد لایه های مخفی و تعداد نرونها در لایه میانی (یا لایه های میانی) متناسب با تعداد نرونها لایه میانی بر مبنای مقایسه عملکرد شبکه ها انتخاب شد. همچنین در این تحقیق از توابع تبدیل تانزانت هیپربولیک، سیگمویدی و تابع محرک خطی بین لایه های شبکه استفاده گردید.

بهترین روش آموزش برای داده های مورد استفاده و همچنین مقایسه عملکرد شبکه های ساخته شده بر اساس معیارهای میانگین مربعات خطأ^۲ (MSE)، مجموع مربعات خطأ^۳ (SSE) و ضریب تبیین^۴ (R^2) مدل برآش شده خطی بین داده های واقعی و داده های پیش بینی شده انجام گردید. به منظور مقایسه آماری میزان دقّت شبکه های طراحی شده، از معیار دقّت پیش بینی مدل استفاده گردید [۱۰ و ۱۸] که میزان دقّت پیش بینی مدل^۵ (P.A.) نسبت اختلاف بین داده های واقعی با داده های پیش بینی شده به داده های واقعی تعریف می گردد.

داده های مورد استفاده در شبکه عصبی مصنوعی طراحی شده

از آنجا که هدف از توسعه مدل شبکه عصبی مصنوعی در این تحقیق پیش بینی نیروی کششی و انرژی موردنیاز خاکورزی می باشد، باید بردارهای ورودی از میان پارامترهای مؤثر بر آنها انتخاب گردد. در این تحقیق پارامترهای ورودی به شبکه عصبی مصنوعی سرعت پیشروی تراکتور، پارامترهای خصوصیات فیزیکی و دینامیکی خاک (درصد شن و رس خاک، هدایت الکتریکی خاک، محتوی رطوبتی خاک، شاخص مخروطی) و همچنین عمق خاکورزی خواهد بود. داده های مورد نیاز از قسمتهای مختلف مزرعه با سه نوع بافت خاک متفاوت انتخاب گردید. انتخاب داده ها بنحوی بود که بتوانند تعییرات هر یک از پارامترهای سهیم در کار پیش بینی را به خوبی بیان کرده و شرایط حاکم بر مزرعه آزمایشی را به خوبی بیان کنند.

به منظور آموزش شبکه های طراحی شده و همچنین تست شبکه لازم بود که داده های مورد استفاده به دو فایل مجزا تقسیم شوند. برای انجام این کار کلیه داده های مورد استفاده در داخل هر خاک در داخل مزرعه به یک کاربرگ^۶ در صفحه گسترشده^۷ اکسل^۸ منتقل شدند. در این کاربرگ تمامی داده های مربوط به یک نقطه در مزرعه آزمایشی در یک ردیف و داده های پارامترهای مختلف در یک ستون قرار داده شد. داده ها در کاربرگ شامل کلیه داده های ورودی و خروجی می شد. پس از انتقال داده ها به کاربرگ، به هر ردیف داده یک عدد تصادفی در محدوده [۰+۱] نسبت داده شد. سپس ردیف های داده ها بر مبنای ستون اعداد تصادفی مرتب گردیدند. با این عمل در واقع ترتیب داده ها به هم زده شد و آنها به طور کاملاً تصادفی به دنبال یکدیگر قرار گرفتند. این عمل برای هر نوع خاک با بافت متفاوت انجام گردید.

¹ - Overtraining

² - Mean Square Error

³ - Sum Square Error

⁴ - Coefficient of Determination

- Prediction Accuracy^۵

- Worksheet^۶

- Excel^۷

- Spreadsheet^۸



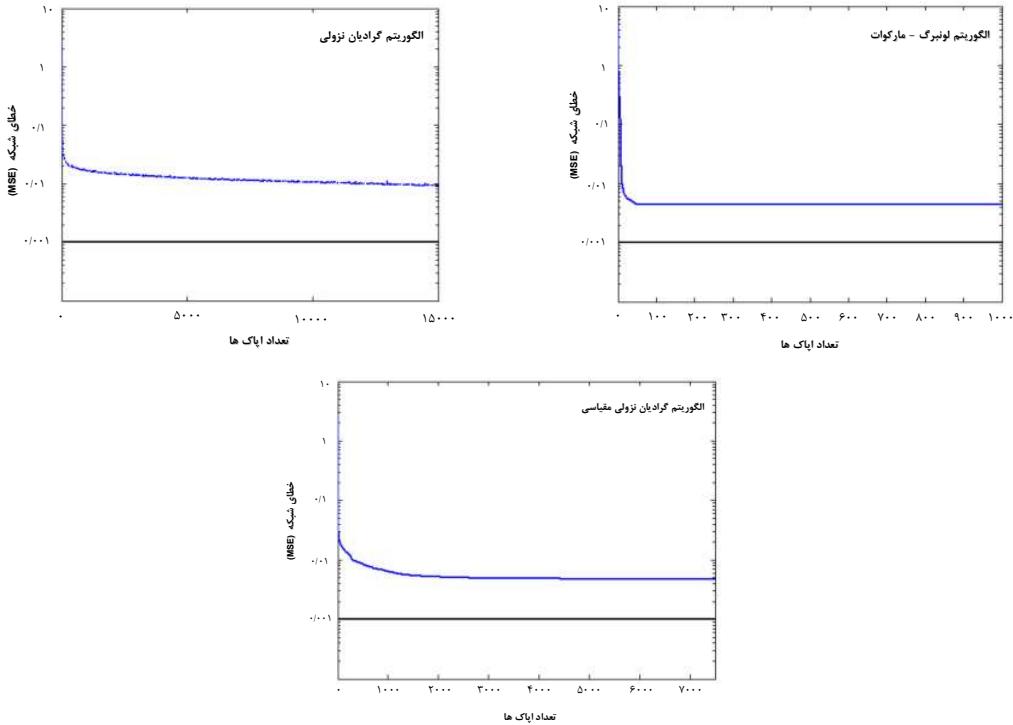
به منظور تهییه فایل‌های آموزش و تست شبکه ۸۵ درصد از داده‌ها در داخل هر نوع خاک در یک فایل Tillagetrain.txt و ۱۵ درصد بقیه در فایلی به نام Tillagetest.txt ذخیره شدند. از فایل Tillagetrain.txt برای آموزش و یادگیری شبکه از فایل Tillagetest.txt به عنوان فایل مورد استفاده در ارزیابی شبکه استفاده گردید.

نتایج و بحث

در این تحقیق به منظور آموزش شبکه عصبی مصنوعی جهت پیش‌بینی نیروی کششی و انرژی موردنیاز عملیات خاک‌ورزی از سه الگوریتم آموزشی گرادیان نزولی با مومتنم، الگوریتم لوبنبرگ – مارکوات و الگوریتم گرادیان نزولی مقیاسی استفاده گردید. بررسی‌های اولیه نشان داد که شبکه‌های ساخته شده با استفاده از الگوریتم لوبنبرگ – مارکوات بعد از طی ۳۰۰ اپاک^۱ (تعداد تکرارهای شبکه به منظور رسیدن به حداقل خطأ و همچنین برای رسیدن به حداکثر پایداری شبکه) در مقدار خطای MSE شبکه کاهش چندانی مشاهده نمی‌شود. ولی به منظور حصول اطمینان بیشتر از رسیدن به حداقل خطأ و حداکثر پایداری، شبکه‌های ساخته شده با استفاده از این الگوریتم تا ۱۰۰۰ تکرار ادامه ه شد. مقدار حداقل تعیین شده برای MSE و SSE در این تحقیق به ترتیب برابر ۰/۰۰۱ و ۰/۰۳ بود. در مورد الگوریتم آموزشی گرادیان نزولی با توجه به اینکه این الگوریتم آموزشی از مقدادر کوچک نرخ یادگیری نسبت به الگوریتم لوبنبرگ – مارکوات برای رسیدن به همگرای استفاده می‌کند تعداد تکرارهای لازم برای رسیدن به خطای حداقل، ۱۰۰۰۰ تکرار مشاهده گردید. به گونه‌ای که پس از ۱۰۰۰۰ بار تکرار الگوریتم در مقدار MSE شبکه کاهش چندانی مشاهده نگردید. ولی در مورد این الگوریتم آموزشی هم به منظور اطمینان بیشتر از رسیدن به حداکثر پایداری و رسیدن به حداقل خطأ، شبکه تا ۱۵۰۰۰ تکرار ادامه ه شد. به همین ترتیب تعداد اپاک‌های مورد نیاز برای الگوریتم گرادیان نزولی مقیاسی ۷۵۰۰ تکرار در نظر گرفته شد. شکل ۱ روند کاهش MSE برای شبکه‌های ساخته شده با استفاده از سه الگوریتم آموزشی فوق الذکر را نشان می‌دهد.

انتخاب تعداد مناسب لایه‌های میانی و همچنین تعداد نرونها در لایه‌های میانی، بر مبنای مقایسه عملکرد شبکه‌های با تعداد نرون متفاوت در لایه میانی و همچنین تعداد متفاوت لایه‌های میانی انجام گرفته است. جدول ۳ نمونه‌ای از نتایج بدست آمده برای شبکه‌های ساخته شده با استفاده از الگوریتم لوبنبرگ – مارکوات با یک لایه میانی و تعداد نرون‌های متفاوت در لایه میانی را نشان می‌دهد. نوع تابع انتقال بکار گرفته شده بین لایه ورودی و لایه میانی از نوع تانزانت سیگموید و بین لایه میانی و لایه خروجی از نوع خطی می‌باشد. بطوریکه در جدول ۳ مشخص می‌باشد شبکه‌ای که دارای کمترین خطای MSE و بالاترین دقّت شبیه‌سازی، مربوط به شبکه‌ای با تعداد ۲۲ عدد نرون در لایه میانی است که خطای شبیه‌سازی ۲/۹۱٪ را در آموزش شبکه عصبی مصنوعی ارائه می‌دهد. این مطلب نشان‌گر یادگیری خوب و کارآمد شبکه با استفاده از الگوریتم آموزشی موردنظر و داده‌های ارائه شده به شبکه می‌باشد. جداول مشابهی برای سایر الگوریتم‌های آموزشی ذکر شده با تغییر تعداد لایه‌های میانی (حداکثر دو لایه میانی) و همچنین تغییر تعداد نرونها در لایه‌های میانی مشابه جدول ۳ بدست آمده است. با افزایش تعداد نرونها در لایه میانی MSE شبکه و همچنین دقّت شبیه‌سازی شبکه برای دو الگوریتم آموزشی لوبنبرگ – مارکوات و گرادیان نزولی مقیاسی کاهش پیدا می‌کرد. این مطلب بوضوح در جدول ۳ مشاهده می‌گردد. ولی با افزایش تعداد نرونها در شبکه‌های ساخته شده با استفاده از الگوریتم گرادیان نزولی با مومتنم الگوی کاهشی در مقدار MSE شبکه با افزایش تعداد نرونها مشابه آنچه که در دو الگوریتم دیگر وجود داشت مشاهده نگردید و بهترین ساختار با تعداد ۲ لایه میانی که در هر لایه ۲۰ عدد نرون وجود داشت، مشاهده شد.

¹ - Epoch



شکل ۱: روند کاهش MSE برای شبکه های آموزش دیده با سه الگوریتم آموزشی مورد استفاده در تحقیق

جدول ۴ خلاصه نتایج شبکه های ساخته شده با استفاده از سه الگوریتم آموزشی فوق الذکر و مقایسه دقّت شبیه سازی و مقایسه پارامترهای آماری بدست آمده برای شبکه ها را نشان می دهد. مشخصات ارائه شده شامل نوع شبکه، الگوریتم های آموزشی مورد استفاده، ساختار شبکه (تعداد لایه های میانی و تعداد نرون ها در لایه میانی)، پارامترهای شبکه (ترخ یادگیری، مومنتوم و اپاک) می باشد. بطوريکه در جدول ۴ مشاهده می گردد شبکه پس انتشار برگشتی با الگوریتم آموزشی لونبرگ - مارکووات نتایج بهتری را نسبت به سایر الگوریتم های آموزشی در شبیه سازی داده ا و آموزش شبکه عصبی مصنوعی ارائه می کند. در مورد استفاده از الگوریتم آموزشی لونبرگ - مارکووات با یک لایه میانی، تعداد ۲۲ عدد نرون لازم است که MSE شبکه به مقدار ۰/۰۰۱ (تعیین شده توسط کاربر) رسد. این تعداد نرونها در مورد استفاده از الگوریتم لونبرگ - مارکووات با تعداد دو لایه میانی به ترتیب به ۱۲ و ۱۰ نرون در لایه اول میانی و لایه دوم میانی می رسد. ولی باید به این نکته توجه داشت که با استفاده از دو لایه میانی در شبکه دقّت شبیه سازی شبکه به ۹۷/۶٪ افزایش می یابد و همچنین SSE پایین تری را نسبت به استفاده از یک لایه میانی ارائه می نماید. بنابراین با توجه به نتایج شبیه سازی ارائه در جدول ۴ مناسب ترین الگوریتم آموزشی از بین الگوریتم های آموزشی مورد استفاده در این تحقیق، الگوریتم آموزشی لونبرگ - مارکووات می باشد که استفاده از دو لایه میانی با ساختار ۲-۱۲-۱۰ پایین ترین خطای شبکه و بالاترین دقّت شبیه سازی ارائه دهد. شکل های ۲ و ۳ نمودارهای نقطه ای (داده های واقعی نسبت به داده های شبیه سازی شده) نتایج شبیه سازی را برای الگوریتم آموزشی لونبرگ - مارکووات با دو لایه میانی را نشان می دهند.



جدول ۳: شاخص های کمی ارزیابی شبکه های ساخته شده با استفاده از الگوریتم آموزشی لونبرگ - مارکوات

ضریب همبستگی	میانگین دقت شبیه سازی شبکه (%)	پارامترهای آماری شبکه		پارامترهای شبکه		تعداد نمونهها
		MSE	SSE	مومنتم	نرخ بادگیری	
۰/۹۱۲	۸۱/۱	۰/۰۲۷۰	۴۳/۲۲	۰/۴	۰/۳	۲
۰/۹۵۳	۸۶/۶	۰/۰۱۴۸	۲۳/۸۰	۰/۴	۰/۳	۴
۰/۹۵۳	۸۷/۸	۰/۰۱۴۷	۲۳/۶۱	۰/۴	۰/۳	۶
۰/۹۸۱	۹۱/۶	۰/۰۰۵۹	۹/۵۰	۰/۴	۰/۳	۸
۰/۹۸۶	۹۱/۹	۰/۰۰۴۴	۷/۰۹	۰/۴	۰/۳	۱۰
۰/۹۹۰	۹۴/۰۰	۰/۰۰۳۱	۵/۰۶	۰/۴	۰/۳	۱۲
۰/۹۹۷	۹۵/۳	۰/۰۰۲۳	۳/۸۰	۰/۴	۰/۳	۱۴
۰/۹۹۳	۹۵/۵	۰/۰۰۲۱	۳/۳۶	۰/۴	۰/۳	۱۶
۰/۹۹۶	۹۶/۵	۰/۰۰۱۲	۱/۹۶	۰/۴	۰/۳	۱۸
۰/۹۹۴	۹۵/۳	۰/۰۰۱۹	۳/۰۴	۰/۴	۰/۳	۲۰
۰/۹۹۷	۹۷/۱	۰/۰۰۱	۱/۵۶	۰/۴	۰/۳	۲۲



جدول ۴: ساختار بهینه و پارامترهای آماری شبکه های ساخته شده با استفاده از سه الگوریتم وزشی

ضریب همبستگی	میانگین دقت شبیه سازی شبکه (%)	پارامترهای آماری شبکه		پارامترهای شبکه			ساختار بهینه شبکه	مدل شبکه عصبی مصنوعی و الگوریتم آموزشی
		MSE	SSE	اپاک	مومنت	نرخ یادگیری		
۰/۹۷۹	۹۰/۹	۰/۰۰۶۷	۱۱/۰۸۳	۱۵۰۰	۰/۴	۰/۳	*۱-۲۶	پس انتشار برگشتی گرادیان نزولی با مومنت
۰/۹۸۳	۹۲/۱	۰/۰۰۵۳	۸/۶۳۵	۱۵۰۰	۰/۴	۰/۳	*۲-۲۰-۲۰	پس انتشار برگشتی گرادیان نزولی با مومنت
۰/۹۹۷	۹۷/۱	۰/۰۰۱	۱/۵۶۶	۱۰۰۰	۰/۴	۰/۳	۱-۲۲	پس انتشار برگشتی لوبنبرگ - مارکوات
۰/۹۹۷	۹۷/۶	۰/۰۰۱	۰/۹۹۲	۱۰۰۰	۰/۴	۰/۳	۲-۱۲-۱۰	پس انتشار برگشتی لوبنبرگ - مارکوات
۰/۹۹۷	۹۶/۹	۰/۰۰۱	۱/۵۲۹	۷۵۰۰	۰/۴	۰/۳	۱-۴۶	پس انتشار برگشتی گرادیان نزولی مقیاسی
۰/۹۹۷	۹۶/۹	۰/۰۰۱	۰/۸۶۳	۷۵۰۰	۰/۴	۰/۳	۲-۲۰-۲۰	پس انتشار برگشتی گرادیان نزولی مقیاسی

*- منظور از ۱-۲۶ در ساختار بهینه شبکه، تعداد یک عدد لایه میانی و ۲۶ عدد نرون در لایه میانی می باشد.

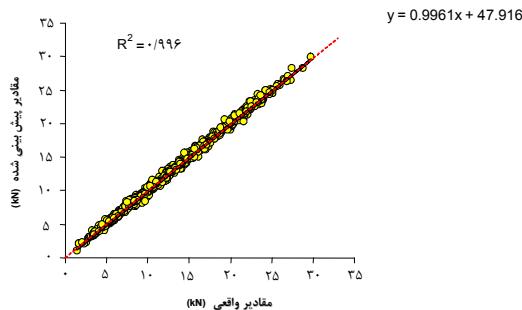
*- منظور از ۲-۲۰-۲۰ در ساختار بهینه شبکه تعداد دو عدد لایه میانی و ۲۰ عدد نرون در هر لایه میانی می باشد.

همانطوریکه قبل از بدان اشاره گردید ۱۵٪ از کل داده های بدست آمده از مزرعه آزمایشی (جهت استفاده در شبکه عصبی مصنوعی) به منظور تست شبکه های ساخته شده مورد استفاده قرار گرفتند. داده های مورد استفاده در تست شبکه از کرت هایی انتخاب شدند که داده های مربوط به آن کرت ها در جریان آموزش شبکه به هیچ وجه وارد مدل شبکه عصبی مصنوعی نشده اند. همچنین این داده ها به تعداد مساوی از داخل هر بافت خاک انتخاب شدند.

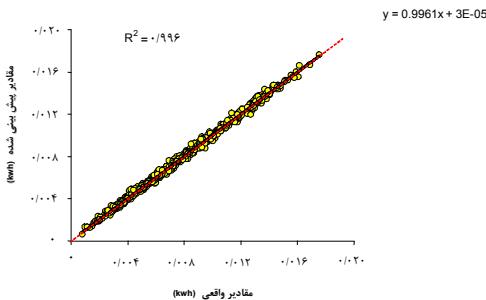
نتایج تست شبکه های ساخته شده با استفاده از سه الگوریتم آموزشی را نشان داد که الگوریتم گرادیان نزولی مقیاسی با وجود دقت شبیه سازی پایین تر نسبت به الگوریتم لوبنبرگ - مارکوات ، دقت پیش بینی بهتری را نسبت به آن ارائه می دهد. با وجودیکه این اختلاف جزئی بوده و قابل صرفنظر کردن می باشد. البته باید به این نکته توجه کرد که الگوریتم گرادیان نزولی مقیاسی با تعداد اپاک ۷۵۰۰ و تعداد نرونها دو برابر در لایه میانی نسبت به الگوریتم لوبنبرگ - مارکوات این نتایج را ارائه می دهد و مدت زمان لازم برای رسیدن به همگرایی و MSE تعیین شده بسیار بالاتر از مدت زمان لازم برای الگوریتم لوبنبرگ - مارکوات می باشد. با توجه به اینکه تعداد نرونها کمتر در لایه میانی و همچنین تعداد اپاک های کمتر در طراحی ساختار شبکه عصبی مصنوعی مورد



نظر می‌باشد و با توجه به اینکه الگوریتم لونبرگ - مارکوات با دو لایه میانی دقت تقریباً مشابهی با الگوریتم گرادیان نزوی مقیاسی ارائه می‌دهد، با توجه به دقت پیش‌بینی و شبیه‌سازی بالا استفاده از الگوریتم لونبرگ - مارکوات (با دو لایه میانی) در مقایسه با سایر الگوریتم‌های آموزشی مورد استفاده در تحقیق توصیه می‌گردد.



شکل ۲: نتایج شبیه‌سازی شبکه برای داده‌های نیروی کششی مورد نیاز عملیات خاکورزی



شکل ۳: نتایج شبیه‌سازی شبکه برای داده‌های انرژی مورد نیاز عملیات خاکورزی

به منظور ارزیابی مدل شبکه عصبی مصنوعی، داده‌های مدل‌های رگرسیونی موجود به منظور پیش‌بینی نیروی کششی مورد نیاز عملیات خاکورزی مورد مقایسه قرار گرفتند. مدل‌های رگرسیونی که در این تحقیق مورد استفاده قرار گرفتند شامل مدل ارائه شده توسط انجمن مهندسین کشاورزی آمریکا (ASAE) به منظور پیش‌بینی نیروی کششی مورد نیاز ادوات خاکورزی و همچنین مدل گارنر و همکاران (۱۹۸۷) می‌باشد. مدل گارنر و همکاران برای خاک‌های مناطق جلگه‌ای ساحلی ارائه گردیده است و لازم به ذکر است که این محققان آزمایشات خود را در مرکز تحقیقات و ترویج ادیستوی دانشگاه کلمبیا در نزدیکی شهر بلک ویل انجام داده‌اند [۸ و ۵].

در مورد استفاده از فرمولهای گارنر و همکاران (۱۹۸۷) نیز باید به این نکته توجه داشت که این مدلها فقط برای خاک‌های شنی و شنی‌لومی ارائه گردیده است و برای خاک فیسیویل (لومی‌شنی) توسط این محققان مدلی به منظور نیروی کششی مورد نیاز عملیات خاک‌ورزی (زیرشکنی) ارائه نگردیده است. داده‌های بدست آمده برای خاک فیسیویل (لومی‌شنی) در این تحقیق تنها با مدل ASAE مورد مقایسه قرار گرفته است. علاوه بر آن این مدلها برای یک وسیله خاک‌ورزی (زیرشکن) ۴ ساقه ارائه شده است و به منظور محاسبه نیروی کششی مورد نیاز برای زیرشکن دو ساقه باید نصف عدد بدست آمده از این مدل در نظر گرفته شود. جدول ۵ مقایسه داده‌های بدست آمده برای نیروی کششی مورد نیاز عملیات خاک‌ورزی در خاک لیکلند (شنی) توسط مدل شبکه عصبی مصنوعی را با داده‌های واقعی و مدل‌های رگرسیونی ASAE و مدل گارنر ارائه می‌کند. بطوریکه ملاحظه می‌گردد



تمامی داده های بدست آمده برای مزرعه آزمایشی در شرایط خشک و مرطوب خاک، به استثنای داده نیروی کششی خاک ورزی در عمق ۲۸cm در شرایط مرطوب خاک، در محدوده پیش بینی شده توسط فرمول ASAE قرار گرفته است و همچنین مدل شبکه عصبی مصنوعی داده های بسیار نزدیکتری به داده های واقعی در مقایسه با سایر مدل های رگرسیونی ارائه کرده است. در مورد استفاده از فرمول ASAE باید به این نکته توجه داشت که در مدل ASAE شرایط رطوبتی خاک در نظر گرفته نشده است و برای یک خاک با بافت مشخص این مدل تنها محدوده نیروی کششی را ارائه می دهد. همچنین مدل گارنر با توجه به شرایط رطوبتی خاک مقدار پایین تری نسبت به داده های واقعی ارائه کرده است. لازم بذکر است که در مدل گارنر نیروی کششی تابعی از عمق خاک ورزی در نظر گرفته شده است و سایر پارامترهای مؤثر بر نیروی کششی از قبیل سرعت پیشروی و پارامترهای خاک در نظر گرفته نشده است.

جدول ۶ نتایج بدست آمده از مدل شبکه عصبی مصنوعی و مدل های رگرسیونی پیش بینی نیروی کششی مورد نیاز عملیات زیرشکنی در کنار داده های واقعی برای خاک فوکی (شنی لومی) ارائه می نماید. بطوریکه ملاحظه می گردد تمام داده های نیروی کششی بدست آمده برای عمق های مختلف خاک ورزی (داده های واقعی) در محدوده اعداد بدست آمده از استاندارد ASAE قرار گرفته است و در این خاک نیز همانند خاک لیک لند (شنی) مدل شبکه عصبی مصنوعی داده های نزدیکتری به داده های واقعی نسبت به سایر مدل های رگرسیونی ارائه کرده است. در مورد استفاده از مدل های گارنر و همکاران برای خاک فوکی (شنی لومی) و مقایسه داده های بدست آمده از مدل شبکه عصبی مصنوعی با این مدلها ذکر این نکته ضروری است که شرایط خاک فوکی (درصد رس و شن خاک) مایبن خاک دانن^۱ (شنی و می) و نورفولک^۲ (شنی لومی) قرار می گیرد و هنگام مقایسه مدل های با یکدیگر باید به این نکته توجه داشت. ولی در حالت کلی و با توجه به شرایط رطوبتی خاک در خاک فوکی نیز همانند خاک لیک لند مدل گارنر داده های کوچکتری نسبت به داده های واقعی ارائه می نماید.

در مورد خاک فیسویل (لومی شنی) همانطور که قبل از اشاره گردید گارنر و همکاران برای خاک لومی شنی هیچ مدلی را به منظور پیش بینی نیروی کششی مورد نیاز برای این نوع خاک و یا خاک مشابه دیگر ارائه نکرده اند و داده های بدست آمده از مدل شبکه عصبی مصنوعی برای این نوع خاک تنها با مدل ASAE مقایسه گردیده است. بطوریکه در جدول ۷ مشاهده می گردد در هر دو حالت شرایط مرطوب و شرایط خشک داده های مزرعه ای در محدوده اعداد بدست آمده از مدل ASAE قرار دارد و همچنین مدل شبکه عصبی مصنوعی همانند سایر خاک های اشاره شده در بالا، داده های بسیار نزدیکتری به اعداد واقعی ارائه کرده است.



جدول ۵: مقایسه داده های بدست آمده برای نیروی کششی خاک ورزی توسط مدل شبکه عصبی با داده های مدل های رگرسیونی
در خاک لیک لند (شنی)

مقادیر نیروی کششی برای یک زیرشکن دو ساقه در عمق مشخص				(kN)
۴۶ cm	۳۸ cm	۲۸ cm	منابع داده	
۵/۷۰-۱۷/۱۰	۴/۷۱-۱۴/۱۳	۲/۴۷-۱۰/۴۱	خاک با بافت سیک (شنی)	استاندارد ASAE
۷/۶۶	۶/۰۶	۳/۳۷	شرط مطابق (M.C.=۷/۶%)	داده های بدست آمده از آزمایش های مزرعه ای برای خاک لیکلند (شنی)
۱۰/۴۶	۸/۱۳	۵/۷۷	شرط خشک (M.C.=۵/۳%)	
۷/۷۴	۵/۷۶	۳/۳۴	شرط مطابق (M.C.=۷/۶%)	داده های بدست آمده از مدل شبکه عصبی
۱۰/۲۱	۸/۱۸	۵/۶۰	شرط خشک (M.C.=۵/۳%)	
۹/۱۰	۷/۰۰	۴/۳۸	شرط خشک (M.C.=۴/۹%)	داده های بدست آمده از مدل گارنر و همکاران ^۲ برای خاک شنی

- ۱- محتوی رطوبتی خاک بر پایه وزن خشک خاک محاسبه شده است.
- ۲- مدل ارائه شده توسط گارنر و همکاران (۱۹۸۷) به صورت $y = -5.9 + 52.4x$ می باشد که در آن x عمق خاک ورزی بر حسب متر و y نیروی کششی مورد نیاز خاک ورزی بر حسب کیلو نیوتون می باشد. این مدل برای زیرشکن دارای ۴ ساقه ارائه شده است و به منظور محاسبه نیروی کششی برای زیرشکن دو ساقه عدد بدست آمده باید تقسیم بر عدد ۲ شود.



جدول ۶: مقایسه آمده برای نیروی کششی خاک ورزی توسط مدل شبکه عصبی با آمده های مدل های رگرسیو نی
برای خاک فوکی (شنی لومی)

مقادیر نیروی کششی برای یک زیرشکن دو ساقه در عمق مشخص (kN)				منابع آمده
۴۶ cm	۴۱ cm	۲۸ cm		
۸/۸۷-۲۶/۶۱	۷/۹۰-۲۳/۷۲	۵/۴-۱۶/۲	خاک با یافته متوسط (شنی لومی)	استاندارد ASAE
۱۲/۷۰	۱۲/۶۲	۶/۱۹	شرایط مرطوب (M.C.= ۱۱/۶٪)	آمده های بدست آمده از آزمایش های
۱۴/۱۷	۱۵/۵۸	۶/۹۳	شرایط خشک (M.C.= ۶/۷٪)	مزرعه ای برای خاک فوکی (شنی لومی)
۱۲/۵۸	۱۲/۵۶	۶/۱۰	شرایط مرطوب (M.C.= ۱۱/۶٪)	آمده های بدست آمده از مدل شبکه عصبی
۱۴/۰۲	۱۵/۵۰	۶/۸۸	شرایط خشک (M.C.= ۶/۷٪)	
۱۳/۸۱	۱۱/۸۶	۶/۸۰	شرایط خشک خاک داتن (Dothan) - شنی لومی (M.C.= ۷/۸۴٪)	آمده های بدست آمده از مدل گارنر و همکاران ^۲ برای خاک شنی لومی
۱۴/۴۹	۱۱/۹۳	۵/۲۶	شرایط خشک خاک نورفولک (Norfolk) - شنی لومی (M.C.= ۵/۹۱٪)	

- ۱- محتوی رطوبتی خاک بر پایه وزن خشک خاک محاسبه شده است.
- ۲- مدل ارائه شده توسط گارنر و همکاران (۱۹۸۷) برای خاک داتن (Dothan) - شنی لومی به صورت $x = -8.2 + 77.9x - 18.2 + 102.6y$ و برای خاک نورفولک (Norfolk) - شنی و می به صورت $x = -8.2 + 77.9x - 18.2 + 102.6y$ می باشد که در آن x عمق خاک ورزی بر حسب متر و y نیروی کششی مورد نیاز خاک ورزی بر حسب کیلونیوتون می باشد. این مدلها برای زیرشکن دارای ۴ ساقه ارائه شده است و به منظور محاسبه نیروی کششی برای زیرشکن دو ساقه عدد بدست آمده باید تقسیم بر عدد ۲ شود.



جدول ۷: مقایسه آمده برای نیروی کششی خاکورزی توسط مدل شبکه عصبی با آمده های مدل های رگرسیونی
برای خاک فیسوبیل (لومی شنی)

مقادیر نیروی کششی برای یک زیرشکن دو ساقه در عمق مشخص (kN)				منابع آمده
۴۶ cm	۳۰ cm	۲۰ cm		
۱۲/۶۷-۳۸/۰۲	۸/۲۶۵-۲۴/۷۹	۵/۵۱-۱۶/۵۳	خاک با بافت سنگین	استاندارد ASAE
۸/۸۷-۲۶/۶۱	۷/۹۰-۲۳/۷۲	۳/۸۵-۱۱/۵۷	خاک با بافت متوسط	
۲۰/۲۲	۹/۹۲	۵/۵۰	شرایط مرطوب ^(M.C.=۱۳/۵%)	داده های بدست آمده از آزمایش های مزرعه ای برای خاک فیسوبیل (لومی شنی)
۲۲/۵۶	۱۲/۰۰	۷/۱۸	شرایط خشک ^(M.C.= ۹/۹%)	
۲۰/۱۷	۹/۷۸	۵/۳۱	شرایط مرطوب ^(M.C.= ۱۲/۵%)	داده های بدست آمده از مدل شبکه عصبی
۲۲/۶۸	۱۲/۱۶	۷/۰۵	شرایط خشک ^(M.C.= ۹/۹%)	
هیچ مدلی برای خاک لومی شنی توسط گارنر و همکاران ارائه نشده است.				داده های بدست آمده از مدل گارنر و همکاران برای لومی شنی

۱- محتوى رطوبتی خاک بر پایه وزن خشک خاک محاسبه شده است.

نتیجه گیری

۱- در این تحقیق به منظور توسعه مدل پیش بینی نیروی کششی و انرژی موردنیاز خاکورزی (زیرشکنی) پارامترهایی سرعت پیشروی تراکتور، عمق خاکورزی و پارامترهای مختلف خاک (از جمله شاخص مخروطی، محتوى رطوبتی، هدایت الکتریکی و درصد رس و شن) مورد استفاده قرار گرفتند.

۲- شبکه پس انتشار برگشتی با الگوریتم آموزشی لونبرگ - مارکوات نتایج بهتری را نسبت به سایر الگوریتم های آموزشی در شبیه سازی آموزش شبکه عصبی مصنوعی ارائه کرد. استفاده از دو لایه میانی با تعداد ۱۲ عدد نرون در لایه اول و ۱۰ عدد نرون در لایه دوم پایین ترین خطای شبکه و بالاترین دقّت شبیه سازی را نسبت به سایر الگوریتم های آموزشی و همچنین الگوریتم آموزشی لونبرگ - مارکوات با یک لایه میانی نشان داد.

۳- الگوریتم گرادیان نزولی مقیاسی با وجود دقّت شبیه سازی پایین تر نسبت به الگوریتم لونبرگ - مارکوات، دقّت پیش بینی بهتری را نسبت به آن ارائه داد. با وجودیکه این اختلاف جزئی بوده و قبل صرفنظر کردن می باشد.

۴- با توجه به دقّت پیش بینی بالا (۸/۹۵٪) و دقّت شبیه سازی بالاتر (۶/۹۷٪) استفاده از الگوریتم لونبرگ - مارکوات (با دو لایه میانی) در مقایسه با سایر الگوریتم های آموزشی به منظور پیش بینی نیروی کششی و انرژی خاکورزی موردنیاز توصیه می گردد.

۵- مقایسه نتایج بدست آمده از مدل شبکه عصبی مصنوعی و مدل های رگرسیونی به منظور پیش بینی نیروی کششی موردنیاز عملیات زیرشکنی نشان داد که محدوده نیروی ارائه شده توسط مدل ASAE (با دقّت $\pm ۵\%$) بر آمده های واقعی بدست آمده از مزرعه آزمایشی منطبق می باشد. همچنین مدل گارنر و همکاران داده های کوچکتری را نسبت به آمده های واقعی نیروی کششی



ارائه می‌نماید. مدل شبکه عصبی مصنوعی داده‌های بسیار نزدیکتری به داده‌های واقعی در مقایسه با سایر مدل‌های رگرسیونی ارائه کرد.

منابع

- ۱- عباسپور گیلانده، ی.، ا. خلیلیان، ر. علیمردانی، ع. کیهانی و س.ح. سادati. ۱۳۸۵. مقایسه انرژی مورد دنیاز خاک‌ورزی در عمق یکنواخت و متغیر، تحت تأثیر سرعت پیشروی و رطوبت خاک. مجله علوم کشاورزی ایران. ج ۳۷، ش ۴، ص ۴۷۳-۴۸۳.
2. Abbaspour-Gilandeh, Y., A. Khalilian, R. Alimardani, A.R. Keyhani, S.H. Sadati. 2005. Energy savings with variable-depth tillage. Proceedings of the 2005 Southern Conservation Tillage Systems Conference, Florence, South Carolina, USA.
 3. Adamchuk, V.I., M.T. Morgan, and H.S. Sumali. 2001. Mapping of spatial and vertical variation of soil mechanical resistance using linear pressure model. Presented at the 2001 ASAE Annual International Meeting, Paper No.01-1019, American Society of Agricultural Engineers. 2950 Niles Road, St. Joseph, MI 49085-9659, USA.
 4. ASAE Standards, 2004a. ASAE S313.3 FEB04: soil cone penetrometer. In: Hahn, R.H., Purschwitz, M.A., Rosentreter, E.E. (Eds.), and ASAE Standards 2004.ASAE, St. Joseph, MI.
 5. ASAE Standards. 2001a. ASAE D497.4: Agricultural machinery management data. American Society of Agricultural Engineers. St. Joseph, MI 49085-9659, USA.
 6. ASAE Standards. 2001b. ASAE EP496.2: Agricultural machinery management. American Society of Agricultural Engineers. St. Joseph, MI 49085-9659, USA.
 7. Cheung, W.H. 1997. Neural network aided activation fuel consumption modeling. M.S. thesis in civil engineering. Virginia polytechnic Institute and State University.
 8. Garner, T.H., W.R. Reynolds, H.L. Musen, G.E. Miles, J.W. Davis, Dam Wolf, and U.M. Peiper. 1987. Energy requirement for subsoiling coastal plain soils. Transactions of the ASAE 30(2): 343-349.
 9. Garner, T.H., H.L. Musen, and R.B. Dodd. 1986. Management data for primary tillage of Coastal Plain soils. 1986 Proceedings, Beltwide Cotton Production Research Conferences, pp.465-466, January 4-9 1986, Las Vegas, Nevada.
 10. Gautam, R.K., S. Panigrahi, D. Franzen. 2003. Neural network models for soil nitrate prediction using imagery and non-imagery information. ASAE Paper No. 033065. ASAE, St. Joseph, MI.
 11. Ghaboussi, J., J.H. Garrett Jr, and X. Wu. 1991. Knowledge-based modeling of material behavior with neural networks. Journal of Engineering Mechanics 117(1):132-153.
 12. Goh ATC. 1995. Back-propagation neural network for modeling complex systems. Artificial Intelligence in Engineering; 9:143-151.
 13. Gorucu, S., A. Khalilian, Y.J. Han, R.B. Dodd, F.J. Wolak, and M. Keskin. 2001. Variable depth tillage based on geo-referenced soil compaction data in Coastal Plain region of South Carolina. ASAE Paper No. 011016. St. Joseph, Mich.: ASAE.
 14. Khalilian, A., Y. J. Han, R. B. Dodd, Mike J. Sullivan, S. Gorucu and M. Keskin. 2002. A Control System for Variable Depth Tillage. ASAE Paper No. 021209. St. Joseph, Mich.: ASAE.



15. Kushwaha, R.L., Z. X. Zhang. 1998. Evaluation of factors and current approaches related to computerized design of tillage tools: a review. *Journal of Terramechanics*: 35 (1998) 69-86.
16. Levine, E.R., D.S. Kimes and V.G. Sigillito. 1996. Classifying soil structure using neural networks. *Ecological modelling* 92: 101-108.
17. Lund, E.D., C.D. Christy, and P.E. Drummond. 1999. Practical applications of soil electrical conductivity mapping. p. 771-779. In J.V. Stafford (ed.) *Precision Agriculture '99- Proc. of the 2nd Eur. Conf. on Precision Agriculture*. Denmark, 11-15 July 1999. SCI, Sheffield, UK.
18. MATLAB. 1994. Neural Network TOOLBOX. Natick, MA: The Mathworks Inc.
19. Sudduth, K.S., N.R. Kitchen, and S.T. Drummond. 1998. Soil conductivity sensing on claypan soils: comparison of electromagnetic induction and direct methods. P. 979-990. Proc. 4th Intl. Conf. On Precision Agriculture, St. Paul, MN. ASA, CSSA, and SSSA, Madison, WI.
20. Taylor, H.M., L.F. Locke, and J.E. Box. 1964. Pans in the southern Great Plains soils: III. Their effect on yield of cotton and grain sorghum. *Agronomy Journal*. 56:542-545.
21. Upadhyaya S.K., T.X. Ma, W.J. Chancellor, and Y.M. Zhao. 1987. Dynamics of soil-tool interaction. *Soil & Tillage Research*. 9(1): 187-206.
22. Upadhyaya, S. K., T.H. Williams, L. J. Kemble and N. E. Collins. 1984. Energy requirement for chiseling in coastal plain soils. *Transactions of the ASAE* 36(5): 1267-1270.
23. Zhang, Z.X. and Kushwaha, R.L. 1999. Application of neural network to simulate soil-tool interaction and soil behavior. *Canadian Agric. Eng.* 41: 119-125.