

مدل سازی بازده کششی تراکتور با استفاده از شبکه عصبی مصنوعی

سید رضا موسوی سیدی^{۱*}، مهدی علی جانی^۲، رمضان هادی پور رکنی^۳

^۱ استادیار، گروه مکانیک بیوسیستم، دانشگاه علوم کشاورزی و منابع طبیعی ساری

^۲ دانش‌آموخته کارشناسی ارشد، دانشگاه علوم کشاورزی و منابع طبیعی ساری

^۳ کارشناس ارشد، گروه مکانیک بیوسیستم، دانشگاه علوم کشاورزی و منابع طبیعی ساری

*نویسنده مسئول:

پست الکترونیکی: Mousavi22@yahoo.com

دریافت: ۱۳۹۵/۰۵/۱۰ پذیرش: ۱۳۹۵/۱۱/۰۳

چکیده

در این مطالعه آزمایش‌های مزرعه‌ای در شرایط متفاوت عمق شخم، سرعت پیشروی و میزان وزنه‌های متصل به تراکتور انجام شد. در این تحقیق، عمق شخم در چهار سطح ۵، ۱۰، ۱۵ و ۲۰ سانتی‌متر، سرعت‌های پیشروی در چهار سطح ۲/۵، ۳/۵، ۴/۵ و ۵/۵ کیلومتر بر ساعت و میزان سنگین‌کننده نیز در چهار سطح ۰، ۴۰، ۸۰ و ۱۲۰ کیلوگرم قرار گرفت. شبکه‌های عصبی مدل‌سازی شده در این تحقیق که به منظور پیش‌بینی بازده کششی تراکتور مورد استفاده قرار گرفتند از نوع شبکه‌های چند لایه پس‌انتشار برگشتی بودند. نتایج این تحقیق نشان داد که شبکه عصبی توسعه داده شده با الگوریتم LM نسبت به الگوریتم SCG عملکرد بهتری دارد. مقدار خطای RMSE و ضریب تبیین R^2 به دست آمده در این مطالعه برای بازده کششی به ترتیب عبارت است از ۰/۰۱۰۸۲۸ و ۰/۹۹۱۶۳. نتیجه مدل‌سازی نشان داد که داده‌های پیش‌بینی شده توسط شبکه عصبی مصنوعی خیلی نزدیک به داده‌های واقعی به دست آمده از آزمایش‌های مزرعه‌ای می‌باشد. بنابراین می‌توان مدل به دست آمده را در مواقعی که امکان اندازه‌گیری وجود نداشته باشد، به خدمت گرفت.

واژه‌های کلیدی: نیروی کششی، بازده کششی، شبکه عصبی، الگوریتم پس‌انتشار

۱- مقدمه

محدودیت درگیری مناسب چرخ‌های محرک با خاک،

کم‌بازده‌ترین آن‌ها می‌باشد. بازده کششی تراکتور، مهمترین عامل در ارزیابی و تعیین عملکرد تراکتور محسوب می‌شود (Naghdiyan and Abdollahpour, 2014). محققان زیادی با استفاده از شبکه عصبی مصنوعی، انرژی و نیروی کشش مورد نیاز ادوات خاکورزی را تخمین زدند. تقوی‌فر و مردانی (۲۰۱۴) در

متداول‌ترین کاربرد تراکتورها در کشاورزی ایران،

استفاده از توان مالبندی آن‌ها در اجرای عملیات خاکورزی و مخصوصاً شخم توسط گاواهن برگرداندار است. در میان روشهای مختلف بهره‌برداری از توان تراکتور و توان کششی متداول‌ترین آن‌هاست، ولی عموماً به علت نامناسب بودن شرایط فیزیکی خاک و یا

مطالعه‌ی خود به تحلیل و بررسی پارامترهای عملکردی کشش پرداختند. آن‌ها در مطالعه‌ی خود سطح تماس تایر و مقاومت غلتشی را پیش‌بینی کردند. به علت پیچیده و غیر خطی بودن تعامل بین خاک و چرخ از شبکه عصبی مصنوعی استفاده کردند. با استفاده از داده‌های تجربی به دست آمده، شبکه عصبی پیشخور با الگوریتم پس انتشار توسعه داده شد. آن‌ها برای ارزیابی عملکرد شبکه از ضریب رگرسیون، محاسبه پراکندگی، میانگین مربعات خطا و سادگی مدل استفاده کردند. شبکه با ساختار عصبی ۲-۶-۴ در مدل‌سازی سطح تماس و مقاومت غلتشی بهترین دقت را ایجاد نمود. به طوری که ضریب رگرسیون برابر با ۰/۹۹۸ و ۰/۹۹۹، مقدار T برابر با ۰/۹۹۶ و میانگین مربعات خطا برابر با $(10^{-12} \times 25)$ به دست آمد. در پایان آن‌ها به این نتیجه رسیدند که شبکه عصبی مصنوعی به دلیل سرعت، دقت بالا و اطمینان در محاسبه مسائل پیچیده، غیر خطی و چند متغیره برای مدل‌سازی تعامل بین خاک و چرخ بسیار مناسب می‌باشد. الحامد و همکاران (۲۰۱۳) به منظور تخمین کشش و انرژی مورد نیاز گاوآهن بشقابی از شبکه عصبی مصنوعی استفاده کردند. شبکه عصبی ایجاد شده توسط آن‌ها دارای ۱۰ پارامتر ورودی شامل عمق و سرعت شخم، بافت خاک، رطوبت خاک، قطر و زاویه بشقاب، زاویه انحراف دیسک و دانسیته خاک بود. پارامترهایی که توسط شبکه تخمین زده شدند شامل کشش، کشش واحد و انرژی مورد نیاز گاوآهن بشقابی بود. شبکه عصبی توسعه داده شده دارای یک لایه پنهان و ۸ نرون در لایه پنهان بود که بر اساس داده‌های تجربی به دست آمده آموزش داده

شد. نتایج نشان داد که مقدار ضریب همبستگی برای داده‌های تست به ترتیب برای کشش، کشش واحد و انرژی مورد نیاز شخم ۰/۹۳۳، ۰/۹۳۴ و ۰/۹۱۵ می‌باشد. این نتایج بیانگر آن است که شبکه عصبی ایجاد شده می‌تواند به عنوان یک روش قابل اعتماد و قابل اجرا در تخمین عملکرد گاوآهن بشقابی تحت شرایط مختلف مزرعه‌ای به کار گرفته شود. آلتینیسک و همکاران (۲۰۱۲) به منظور تحلیل و ارزیابی نیروی کشش تراکتور در عملیات مزرعه‌ای از شبکه عصبی مصنوعی استفاده کردند. برای این منظور سه مدل (مدل ۱، مدل ۲ و مدل ۳) از شبکه عصبی توسعه داده شد. عملیات مزرعه‌ای در سرعت و عمق شخم متفاوت انجام گرفت. به منظور دست یافتن به مدل بهینه از میان سه مدل شبکه عصبی، از آزمون اعتبار سنجی متقابل استفاده شد. مقایسه نتایج نشان داد که مدل ۱ دارای بهترین عملکرد بود. در این تحقیق، سه مدل ارائه شده برای شبکه عصبی، دارای ساختار و الگوریتم یادگیری یکسان بودند و تفاوت آن‌ها در تعداد و نوع پارامترهای ورودی و خروجی بود. مدل ۱ دارای دقت ۹۰ درصد بود که بهترین عملکرد را در بین سه مدل از خود نشان داد. عباسپور گیلانده و همکاران (۲۰۱۳) در تحقیق خود آزمایش‌های مزرعه‌ای را در دو نوع خاک لومی رسی و رسی لومی به منظور پیش‌بینی مقاومت به کشش با استفاده از شبکه عصبی مصنوعی با داشتن برخی پارامترهای نوع و شرایط خاک، پارامترهای ابزار و پارامترهای عملیاتی و مقایسه دقت مدل به دست آمده با مدل‌های رگرسیونی به انجام رساندند. شبکه‌های طراحی شده در این تحقیق از نوع شبکه‌های چند لایه

پس انتشار برگشتی بودند. از سه روش الگوریتم گرادیان نزولی با مومنتوم، الگوریتم لونبرگ-مارکوارت و الگوریتم گرادیان نزولی مزدوج مقیاسی به منظور آموزش شبکه استفاده گردید. نتایج نشان داد که الگوریتم لونبرگ-مارکوارت با میانگین دقت شبیه‌سازی ۹۵/۰۵ درصد و ضریب همبستگی ۰/۹۹۳۵ نسبت به سایر الگوریتم‌ها عملکرد بهتری دارد.

لغوی و ملاصادقی (۲۰۰۲) بازده کششی دو تراکتور مسی فرگوسن (MF285) و یونیورسال (U650) را در عملیات شخم توسط گاواهن برگرداندار ارزیابی و مقایسه کردند. تیمارهای آزمایش شامل سه وضعیت تراکتور از نظر میزان سنگین‌کننده و سه سطح عمق شخم سطحی، متوسط و عمیق بود. سرعت اجرای شخم در تمامی تیمارها ثابت و برابر چهار کیلومتر در ساعت بود. پارامترهای مورد اندازه‌گیری در این مطالعه شامل نیروی کشش مال‌بندی، مقاومت کششی، درصد لغزش چرخ‌های محرک و بازده کششی تراکتور بود. نتایج نشان داد که میانگین درصد لغزش در سه سطح شخم برای تراکتور یونیورسال ۶۵۰، کمترین مقدار برابر با (۱۲/۶ درصد) و در تراکتور مسی فرگوسن ۲۸۵ بدون سنگین‌سازی چرخ‌ها بیشترین مقدار برابر با (۲۷ درصد) بود که با سنگین‌سازی چرخ‌های محرک به ۱۷/۷ درصد کاهش یافت. با افزایش عمق شخم، تغییرات معنی‌داری در بازده کششی تراکتور یونیورسال ۶۵۰ حاصل نگردید و با میانگین بازده ۷۳/۸ درصد دارای عملکرد مطلوبی بود. در حالیکه بازده کششی تراکتور مسی فرگوسن ۲۸۵ سنگین‌سازی نشده که در شرایط شخم سطحی بیش از ۷۵ درصد بود، با افزایش عمق شخم به ۴۶

درصد کاهش یافت. سنگین‌سازی چرخ‌های محرک تراکتور مسی فرگوسن ۲۸۵ با افزایش عمق روند نزولی بازده کششی را به طور چشم‌گیری بهبود بخشید. نتایج این پژوهش نشان داد که تراکتور مسی فرگوسن ۲۸۵ چنانچه سنگین‌سازی نگردد، تنها در انجام عملیات خاکورزی سطحی بازده مطلوب دارد و برای شخم متوسط و عمیق باید از تراکتور یونیورسال ۶۵۰ و یا مسی فرگوسن ۲۸۵ سنگین‌شده استفاده نمود.

رحمان و همکاران (۲۰۱۱) مدلی از شبکه عصبی را توسعه دادند تا با استفاده از آن انرژی مورد نیاز برای ابزار خاکورزی را با استفاده از داده‌های آزمایشگاهی پیش‌بینی کنند. شبکه عصبی مدل‌سازی شده بر اساس پارامترهای ورودی محتوی رطوبت خاک، عمق خاکورزی و سرعت رو به جلوی عملیات خاکورزی آموزش داده شد و مورد آزمون قرار گرفت. پارامتر خروجی اندازه‌گیری شده در این مطالعه، انرژی مورد نیاز برای ابزار خاکورزی بود. نتایج به دست آمده توسط آن‌ها نشان داد که اختلاف بین داده‌های حاصل از آزمون تجربی و داده‌های به دست آمده از مدل‌سازی با استفاده از شبکه عصبی بسیار اندک می‌باشد. کارمن و تانر (۲۰۱۲) به بررسی رابطه بین کاهش پیشروی و عملکرد کششی تایر پرداختند. آن‌ها در مطالعه خود دقت و کارایی شبکه عصبی مصنوعی را در تخمین این پارامترها نیز بررسی کردند. شبکه عصبی با ساختار ۲-۴-۶ و الگوریتم یادگیری پس انتشار توسعه داده شد. پارامترهای خروجی، شبکه ضریب کشش و بازده کششی بودند. رابطه بین پارامترها با استفاده از رگرسیون غیر خطی و شبکه عصبی مورد تجزیه و

تحلیل قرار گرفت. نتایج مقایسه دو سری آنالیز داده‌ها نشان داد که مدل شبکه عصبی به طور ثابت و پایدار تخمین بهتری نسبت به مدل رگرسیون غیر خطی ارائه داده است. بر اساس نتایج حاصل شده آن‌ها به این نتیجه رسیدند که شبکه عصبی یک تکنیک قابل اعتماد به منظور پیش‌بینی عملکرد کششی تایر است.

هدف از این تحقیق، پیش‌بینی بازده کششی تراکتور آروید ۳۵۴ سه سیلندر ساخت کشور ایران با استفاده از شبکه عصبی مصنوعی می‌باشد. این تراکتور نیروی مورد نیاز خود را از طریق تراکتور ۳۱۴۰ جاندیر تأمین می‌کند و با داشتن پارامترهای سرعت، عمق و وزنه‌های سنگین کننده، پیش‌بینی‌های لازم انجام می‌شود.

۲- مواد و روش‌ها

۲-۱- آزمون مزرعه‌ای


آزمون‌های مزرعه‌ای در دانشگاه علوم کشاورزی و منابع طبیعی ساری انجام گردید. تا جایی که امکان داشت هر گونه کاه و کلش از سطح زمین جمع‌آوری شد. در این آزمون تأثیر سه متغیر مستقل مورد ارزیابی قرار گرفت. یکی از آن‌ها حالت یا وضعیت تراکتور از نظر میزان سنگین‌کننده است که در چهار وضعیت بدون سنگین کننده، وزنه ۴۰ کیلوگرم، وزنه ۸۰ کیلوگرم و وزنه ۱۲۰ کیلوگرم بررسی شد. پارامتر مستقل دیگر سرعت پیشروی است که در این آزمون از چهار سطح سرعت پیشروی ۲/۵، ۳/۵، ۴/۵ و ۵/۵ کیلومتر بر ساعت استفاده شده است و پارامتر مستقل سوم عمق شخم می‌باشد که ۴ سطح عمق شخم ۵، ۱۰، ۱۵ و ۲۰

سانتی‌متر مورد ارزیابی قرار گرفت. میانگین رطوبت خاک در عمق صفر تا ۲۰ سانتی‌متر به عنوان رطوبت مینا در نظر گرفته شد و برای محاسبه آن از رابطه (۱) استفاده گردید:

$$W(\%) = \left(\frac{W_t - W_s}{W_s} \right) \times 100 \quad (1)$$

در این رابطه W رطوبت خاک بر پایه خشک بر حسب درصد، W_t وزن کل نمونه بر حسب گرم و W_s وزن ذرات جامد نمونه بر حسب گرم می‌باشد. میانگین رطوبت به دست آمده برابر با ۱۰/۵ درصد بر مبنای وزن خشک و ۲/۵ درصد بر مبنای وزن تر اندازه گیری شد. در این مطالعه به منظور اندازه‌گیری شاخص مخروطی خاک از دستگاه نفوذسنج دستی مدل ویکس برگ به ظرفیت ۱۰۰ کیلوگرم با حساسیت ۰/۱ کیلوگرم به ازای هر درجه و زاویه مخروط ۳۰ درجه استفاده شد. شاخص مخروطی خاک در عمق‌های ۱۰ و ۲۰ سانتی‌متر اندازه‌گیری شد و در هر کرت برای هر عمق ۳ بار نمونه‌برداری انجام گرفت. شاخص مخروطی میانگین حاصل از داده‌ها برابر با ۲/۳۲۵ مگا پاسکال به دست آمد.

پارامترهای اصلی مورد اندازه‌گیری در طی آزمون نیروی کشش مالبندی، نیروی مقاومت غلتشی چرخ‌های تراکتور و درصد لغزش چرخ‌های محرک تراکتور می‌باشند که برای این منظور همانند شکل ۱ از روش کشش دو تراکتوری هنگام شخم با گاواهن برگرداندار دو خیشه به روش استاندارد RNAM استفاده شد.



شکل ۱. روش دو تراکتوری جهت اندازه‌گیری کشش

Fig. 1. Dual tractor method for measuring traction

۲۲ درصد شن، ۴۳ درصد رس و ۳۵ درصد سیلت بود که در مجموع دارای بافتی رسی بود. با توجه به تغییرات شدید و سریع مقاومت کششی ادوات در طول کرت، بیش از ۱۵ داده به صورت متوالی ثبت و میانگین آن‌ها به عنوان مقاومت کششی منظور شد. درصد لغزش چرخ‌های محرک با استفاده از رابطه (۲) محاسبه گردید:

$$S(\%) = \left\{ \frac{(A-B)}{A} \right\} \times 100 \quad (2)$$

که در آن S درصد لغزش چرخ‌های محرک، A سرعت تنوری یا بدون لغزش می‌باشد و B سرعت واقعی با لغزش می‌باشد. به منظور اندازه‌گیری این سرعت‌ها، مسافت و زمان پیمایش تراکتور در حین کشش در ۱۰ دور اندازه‌گیری شد و همچنین در شرایط بدون کشش و روی آسفالت نیز سرعت واقعی بدون لغزش در شرایط مشابه به دست آمد.

در پایان بازده کششی در تمامی ترکیب‌های مختلف سرعت، عمق و میزان سنگین‌کننده با استفاده از رابطه (۳) محاسبه گردید.

$$TE = \left[\frac{H}{H+R} \right] \times (1 - S) \quad (3)$$

که در این رابطه TE بازده کششی بر حسب درصد، H کشش خالص مالبندی (نیوتن)، R مقاومت غلتشی (نیوتن) و S لغزش چرخ‌های محرک می‌باشد.

تراکتور مورد آزمایش، تراکتور آروید ۳۵۴ سه سیلندر با توان ۲۵/۸ کیلو وات و تراکتور کشنده، جان‌دیر ۳۱۴۰ شش سیلندر با توان ۷۱ کیلو وات بود و برای اندازه‌گیری نیروی کششی از نیروسنج دیجیتالی مدل UU ساخت شرکت Sewha کره جنوبی با ظرفیت تحمل بار ۱۰ تن استفاده شد. اساس کار این نیروسنج بر پایه تغییرات مقاومت الکتریکی کرنش‌سنج‌ها به عنوان عنصر حساس به نیرو می‌باشد. به منظور ثبت داده‌های به دست آمده از نیروسنج، از ثبت دیجیتالی مدل DN10 ساخت شرکت Dacell کره جنوبی استفاده شد که خروجی این ثبت بر حسب کیلوگرم نیرو می‌باشد. جهت محاسبه نیروی مقاومت غلتشی تراکتور حامل ادوات، تراکتور مذکور در حالت خلاص به وسیله تراکتور کشنده در خاک مزرعه مورد آزمایش کشیده شد. با استفاده از دستگاه کشش‌سنج، نیروی مقاومت غلتشی در نقاط مختلف مزرعه اندازه‌گیری شد. در این پژوهش یک دستگاه گاوآهن برگرداندار دو خیش سوار شونده با عرض کار ۶۰ سانتی‌متر ساخت شرکت صالح شمال- ایران مورد استفاده قرار گرفت. فاصله بین دو خیش این گاوآهن ۵۲ سانتی‌متر و حداکثر عمق شخم ۲۰ سانتی‌متر می‌باشد.

به منظور تعیین بافت خاک در این مطالعه از روش هیدرومتری استفاده شد. خاک مورد آزمون دارای

۲-۲- شبکه عصبی مصنوعی

به منظور تحلیل و بررسی داده‌های حاصل از آزمون تجربی در شبکه عصبی، قبل از هر عملی باید داده‌های وارد شده به محیط شبکه عصبی را نرمالیزه نمود. نرمالیزه نمودن داده‌ها معمولاً بین $[0,1]$ یا $[-1,1]$ انجام می‌شود. جهت محاسبه حساسیت‌ها برای نرون‌های لایه‌های مختلف در شبکه MLP به مشتق‌گیری از توابع تبدیل نرون‌ها احتیاج می‌باشد. از این رو بایستی توابعی مورد استفاده قرار گیرند که دارای مشتق باشند. یکی از انواع توابع تبدیل متداول که در شرط فوق صدق می‌کنند، توابع سیگموئید (تابع سیگموئید $\text{sig}(n)$ و تابع تانژانت هیپربولیک $\tanh(n)$ می‌باشد. در این تحقیق از تابع تانژانت هیپربولیک استفاده شده است و از آنجایی که خروجی این تابع بین $[-1,1]$ است، لذا نرمالیزه‌سازی داده‌ها بین $[-1,1]$ انجام گرفت. برای نرمالیزه کردن داده‌ها از رابطه (۴) استفاده شده است:

$$nv_i = 2 \times \left(\frac{v_{min} - v_i}{v_{min} - v_{max}} \right) - 1 \quad (4)$$

که در این رابطه، nv_i برابر با خروجی نرمالیزه شده، v_{min} کوچکترین داده، v_{max} بزرگترین داده و v_i داده‌ای که باید نرمالیزه شود، می‌باشد.

شبکه عصبی برای طراحی نیازمند به سه دسته داده آموزشی، اعتبار سنجی و آزمون می‌باشد. در این مطالعه از ۷۰ درصد داده‌ها برای آموزش، ۱۵ درصد برای اعتبارسنجی و ۱۵ درصد هم برای آزمون شبکه استفاده گردید. از آنجایی که شرایط مختلف آزمون تجربی متشکل از ۴ سرعت مختلف، ۴ سطح عمق و ۴ وضعیت سنگین کننده می‌باشد، لذا تعداد کل داده‌های

تجربی به دست آمده برابر با ۶۴ حالت می‌باشد که از این تعداد ۴۴ داده برای آموزش، ۱۰ داده برای اعتبارسنجی و ۱۰ داده برای آزمون شبکه استفاده شد. تعداد نرون‌های لایه میانی با توجه به شرایط مسئله مورد بررسی یعنی تعداد پارامترهای ورودی، تعداد پارامترهای خروجی و تعداد کل داده‌های تجربی بر اساس آزمون و خطا به دست می‌آید. در این مطالعه با توجه به شرایط حاکم بر مسئله مورد بررسی، تعداد نرون‌های لایه میانی بین ۷ تا ۱۵ نرون تغییر پیدا کرد. مرحله بعدی در شکل‌گیری ساختار شبکه عصبی، تعیین تابع انتقال برای لایه میانی و لایه خروجی می‌باشد. معیار انتخاب تابع انتقال، پیوسته و مشتق‌پذیر بودن تابع است. در این تحقیق، در لایه میانی از تابع انتقال تانژانت هیپربولیک (رابطه ۵) و برای لایه خروجی از تابع خطی استفاده شده است:

$$F(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (5)$$

در این بررسی به منظور دستیابی به شبکه با بالاترین عملکرد و کمترین مقدار خطا از دو الگوریتم لونیگ-مارکوارت (LM) و گرادیان مزدوج مقیاسی (SCG) استفاده گردید. نحوه انتخاب داده‌ها توسط شبکه و همچنین مقداردهی اولیه وزن‌ها و بایاس‌ها به شبکه به طور تصادفی انجام گرفت. در جدول ۱ داده‌های آماری به دست آمده از شبکه مربوط به بازده کششی برای دو الگوریتم یادگیری نشان داده شده است. در این مطالعه از شبکه پرسپترون چند لایه با الگوریتم پس انتشار خطا استفاده گردید و اجرای شبکه عصبی مصنوعی در محیط نرم‌افزار متلب انجام گرفت. مبنای تصمیم‌گیری برای انتخاب بهترین شبکه در هر بار اجرای برنامه،

$$R^2 = 1 - \left(\frac{\sum_j (t_j - o_j)^2}{\sum_j (o_j)^2} \right) \quad (۶)$$

ضریب تبیین R^2 ریشه میانگین مربعات خطا RMSE می‌باشد که در رابطه‌های (۶) و (۷) نشان داده شده‌اند؛

$$RMSE = \left(\frac{1}{p} \sum_j |t_j - o_j|^2 \right)^{1/2} \quad (۷)$$

به طوری که t برابر با مقدار هدف، o مقدار خروجی شبکه و p تعداد الگوهای مورد آزمایش می‌باشد.

جدول ۱. داده‌های به دست آمده به وسیله شبکه عصبی برای دو الگوریتم آموزشی

Table 1. The neural network data output for two training algorithm

داده‌های آموزش		تعداد نرون در لایه میانی		نوع الگوریتم آموزشی
R^2	RMSE	R^2	RMSE	
۰/۹۶۹۰	۰/۰۳۲۲۸۲	۰/۹۳۸۵	۰/۰۴۰۱۹۲	۷ LM
۰/۹۹۱۱	۰/۰۱۵۷۱۰	۰/۹۷۸۶	۰/۰۳۰۰۳۷	۸ LM
۰/۹۳۷۰	۰/۰۶۲۵۵۶	۰/۹۹۰۵	۰/۰۲۴۷۹۰	۹ LM
۰/۸۳۲۶	۰/۰۹۵۹۱۹	۰/۹۲۳۴	۰/۰۵۶۴۳۱	۱۰ LM
۰/۹۹۱۶	۰/۰۱۰۸۲۸	۰/۹۹۲۲	۰/۰۰۱۱۰۰	۱۱ LM
۰/۸۵۵۱	۰/۰۴۴۵۲۳	۰/۹۲۲۷	۰/۰۴۱۱۷۳	۱۲ LM
۰/۴۱۷۰	۰/۰۱۱۲۸۴	۰/۹۸۴۸	۰/۰۲۷۹۳۲	۱۳ LM
۰/۸۸۵۶	۰/۰۸۶۲۳۰	۰/۹۷۴۱	۰/۰۴۵۵۹۳	۱۴ LM
۰/۹۵۸۷	۰/۰۵۴۳۸۶	۰/۹۷۵۶	۰/۰۳۳۴۷۴	۱۵ LM
۰/۹۴۷۷	۰/۰۵۲۰۳۱	۰/۹۴۲۷	۰/۰۵۳۶۸۵	۷ SCG
۰/۹۰۱۹	۰/۰۶۴۱۰۱	۰/۸۹۲۲	۰/۰۶۷۶۲۱	۸ SCG
۰/۸۱۸۳	۰/۰۹۴۴۶۴	۰/۸۰۵۴	۰/۰۹۶۵۲۸	۹ SCG
۰/۹۶۸۹	۰/۰۴۱۵۵۴	۰/۹۶۷۷	۰/۰۴۵۶۹۸	۱۰ SCG
۰/۹۳۳۱	۰/۰۷۰۱۱	۰/۹۳۲۳	۰/۰۷۲۴۸۳	۱۱ SCG
۰/۸۵۳۴	۰/۰۹۰۶۹۷	۰/۸۵۳۲	۰/۰۹۲۱۵۶	۱۲ SCG
۰/۹۸۳۹	۰/۰۲۹۴۸۱	۰/۹۷۲۴	۰/۰۳۸۹۶۵	۱۳ SCG
۰/۹۶۷۴	۰/۰۳۳۶۲۶	۰/۹۶۴۶	۰/۰۴۸۶۵۹	۱۴ SCG
۰/۹۶۹۰	۰/۰۳۲۲۸۲	۰/۹۷۱۲	۰/۰۳۹۷۵۶	۱۵ SCG


۳- نتایج و بحث

هدف از به کارگیری مدل شبکه عصبی به عنوان یک رویکرد عملی، سنجش توانایی این روش به منظور پیش‌بینی بازده کششی تراکتور در شرایط مختلف عمق شخم، سرعت پیشروی و وضعیت تراکتور از نظر سنگین‌کننده می‌باشد. مقادیر حاصل از مدل‌سازی شبکه عصبی مصنوعی با مقادیر حاصل از آزمون تجربی مقایسه شدند و قابلیت اعتماد شبکه مورد بررسی قرار گرفت. به منظور آموزش شبکه از دو الگوریتم گرادیان

در آزمون تجربی سه پارامتر مستقل وجود داشت که در نتیجه شبکه دارای سه ورودی است. پارامتر نهایی محاسبه شده در آزمون تجربی، بازده کششی می‌باشد. در نتیجه شبکه دارای یک خروجی است. بهترین عملکرد مدل بر اساس معیار R^2 ، مقدار ۱ و بر اساس معیار RMSE، مقدار صفر را به همراه دارد که نشان‌دهنده نزدیک‌تر بودن مقادیر محاسبه و پیش‌بینی شده به یکدیگر و دقیق‌تر بودن جواب‌ها در هر مرحله است.


مزدوج مقیاسی (SCG) و لونبرک-مارکوارت (LM) استفاده گردید. تعداد نرون ها برای هر دو الگوریتم یادگیری از ۷ تا ۱۵ متغیر بود. با توجه به جدول ۱ برای الگوریتم LM بهترین نتیجه که نشان دهنده کمترین مقدار RMSE و بیشترین مقدار R^2 می باشد، زمانی به دست آمد که شبکه در لایه میانی خود ۱۱ نرون دارد. مقادیر RMSE و R^2 برای آموزش شبکه در این حالت به ترتیب عبارتند از ۰/۰۰۱۱ و ۰/۹۹۸۹ و

برای مرحله آزمون شبکه مقادیر به دست آمده برای پارامترهای RMSE و R^2 به ترتیب عبارتند از ۰/۱۰۸۲۸ و ۰/۹۹۸۶۳. در شکل ۲ و ۳ مقایسه الگوهای به دست آمده حاصل از آزمون تجربی و شبکه عصبی مصنوعی با الگوریتم یادگیری LM و تعداد ۱۱ نرون در لایه میانی، برای دو حالت آموزش و آزمون شبکه نشان داده شده است.



شکل ۲. الگوهای به دست آمده به وسیله شبکه عصبی با ساختار LM-11 و داده های حاصل از آزمون تجربی برای آموزش


Fig. 2. Patterns obtained from Neural Networks with LM-11 structure and data obtained from experimental test for training mode




شکل ۳. الگوهای به دست آمده به وسیله شبکه عصبی با ساختار LM-11 و داده های حاصل از آزمون تجربی برای حالت آزمون

Fig. 3. Patterns obtained from Neural Networks with LM-11 structure and data obtained from experimental test for Testing mode

همچنین مقایسه‌ی رگرسیونی داده‌های حاصل از به ترتیب برای حالت آموزش و آزمون شبکه در آزمون تجربی و داده‌های مربوط به شبکه عصبی با شکل‌های ۴ و ۵ نشان داده شده است. الگوریتم یادگیری LM و تعداد ۱۱ نرون در لایه میانی




شکل ۴. رگرسیون بین داده‌های تجربی و شبکه مربوط به حالت آموزش شبکه با ساختار LM-11
Fig. 4. Regression between experimental and network data for network training mode with LM-11 structure



شکل ۵. رگرسیون بین داده‌های تجربی و شبکه مربوط به حالت آزمون شبکه با ساختار LM-11
Fig. 5. Regression between experimental and network data for network testing mode with LM-11 structure


زمانی که شبکه عصبی با الگوریتم (SCG) آموزش دید، بهترین نتایج که نشان‌دهنده کمترین مقدار RMSE و بالاترین مقدار R^2 می‌باشد با وجود ۱۳ نرون در لایه میانی به دست آمد. در این حالت مقادیر R^2 و به ترتیب برای حالت آموزش شبکه عبارتند از ۰/۰۳۸۹۶ و ۰/۹۷۲۳۹. همچنین برای حالت آزمون این مقادیر به ترتیب عبارتند از ۰/۰۲۹۴۸ و ۰/۹۸۳۹۴. در شکل‌های ۶ و ۷ به ترتیب مقایسه

الگوهای به دست آمده از شبکه عصبی و داده های شبکه با الگوریتم SCG و تعداد ۱۳ نرون در لایه میانی حاصل از آزمون تجربی برای حالت آموزش و آزمون نشان داده شده است.



شکل ۶. الگوهای به دست آمده به وسیله شبکه عصبی با ساختار SCG-13 و داده های حاصل از آزمون تجربی برای حالت آموزش


Fig. 6. Patterns obtained from Neural Networks with SCG-13 structure and data obtained from experimental test for training mode



شکل ۷. الگوهای به دست آمده به وسیله شبکه عصبی با ساختار SCG-13 و داده های حاصل از آزمون تجربی برای حالت آزمون


Fig. 7. Patterns obtained from Neural Networks with SCG-13 structure and data obtained from experimental test for Testing mode

مقایسه رگرسیونی داده‌های به دست آمده از شبکه عصبی و داده‌های حاصل از آزمون تجربی برای شبکه با الگوریتم یادگیری SCG و تعداد ۱۳ نرون در لایه میانی انجام شد. نمودارهای مربوط به حالت آموزش و آزمون شبکه به ترتیب در شکل‌های ۸ و ۹ نشان داده شده است. با مقایسه داده‌های به دست آمده از دو الگوریتم آموزشی و تعداد نرون‌های متفاوت در لایه میانی آن‌ها، مشخص گردید که الگوریتم یادگیری لوبز-مارکوارت با تعداد ۱۱ نرون در لایه میانی بالاترین دقت را در مدل‌سازی بازده کششی تراکتور داشته است.



شکل ۸. رگرسیون بین داده‌های تجربی و شبکه مربوط به حالت آموزش شبکه با ساختار SCG-13


Fig. 8. Regression between experimental and network data for network training mode with structure SCG-13



شکل ۹. رگرسیون بین داده‌های تجربی و شبکه مربوط به حالت آزمون شبکه با ساختار SCG-13

Fig. 9. Regression between experimental and network data for network testing mode with SCG-13 structure


میانگین نیروی کشش خالص بدست آمده در عمق های مختلف برای آزمون تجربی و میانگین نیروی کشش خالص تخمین زده شده به وسیله شبکه عصبی در شکل ۱۰ نشان داده شده است. با توجه به شکل مشاهده می شود که با افزایش عمق شخم، نیروی کشش خالص افزایش معنی داری دارد و شبکه عصبی نیز توانسته است افزایش نیروی کشش با افزایش عمق را با دقت بالایی پیش بینی کند.



شکل ۱۰. مقایسه میانگین نیروی کشش خالص در عمق های مختلف
Fig. 10. Compare the average net traction force in different depth

چرخ های محرک به سبب افزایش نیروی مقاوم در برابر غلتش، زیاد می شود، می توان دریافت که با افزایش عمق شخم، میزان لغزش تراکتور زیاد می گردد. اسماعیل و همکاران (۱۹۸۱) نیز در این مورد نتایج مشابهی را گزارش کردند. با توجه به شکل ۱۱ مشاهده می شود که شبکه عصبی مصنوعی توانسته است این الگو را به خوبی پیش بینی کند.

در شکل ۱۱ مقدار میانگین درصد لغزش به دست آمده برای آزمون تجربی و مقدار میانگین آن برای داده های حاصل از شبکه عصبی مصنوعی در عمق های مختلف شخم نشان داده شده است. مشاهده می شود که در آزمون تجربی با افزایش عمق شخم، درصد لغزش افزایش می یابد. با توجه به اینکه افزایش عمق شخم، باعث افزایش نیروی لازم برای کشش گاوآهن می گردد و از طرفی با افزایش نیروی مقاومت کششی، درصد لغزش




شکل ۱۱. مقایسه میانگین درصد لغزش در عمق‌های مختلف

Fig. 11. Compare the average slip percent in different depth

میانگین داده‌های حاصل از آزمون تجربی و میانگین داده‌های به دست آمده از شبکه عصبی مصنوعی مشاهده می‌شود که شبکه عصبی از دقت تخمین بالایی برخوردار است. لغزش چرخ‌های محرک عامل مهمی در بازده کششی است. با افزایش عمق خاک‌ورزی، درصد لغزش چرخ‌های محرک تراکتور افزایش می‌یابد و لغزش بیشتر در عمق بیشتر از بازده کششی می‌کاهد.

در شکل ۱۲ میانگین بازده کششی تراکتور در سطوح مختلف عمق شخم برای داده‌های تجربی و داده‌های به دست آمده از شبکه عصبی نشان داده شده است. همانطور که از شکل مشخص است با افزایش عمق شخم، میانگین بازده کششی تراکتور کاهش پیدا می‌کند. به طوری که کمترین میزان میانگین بازده کششی در عمق ۲۰ سانتی‌متر و بیشترین مقدار آن در عمق ۵ سانتی‌متر به دست آمده است. با مقایسه



شکل ۱۲. مقایسه میانگین بازده کششی در عمق‌های مختلف

Fig. 12. Compare the average traction efficiency in different depth

مصنوعی یک بستر دقیق و ساده را برای آنالیز نیرو و بازده کششی تراکتور فراهم کرده است.

۴- نتیجه گیری

نتایج این تحقیق نشان داد که شبکه عصبی با الگوریتم LM نسبت به الگوریتم SCG عملکرد بهتری دارد. مقدار خطای RMSE و ضریب تبیین R^2 به دست آمده در این مطالعه برای بازده کششی به ترتیب ۰/۱۰۸۲۸ و ۰/۹۹۱۶۳ بدست آمدند. همچنین داده های پیش بینی شده توسط شبکه عصبی مصنوعی خیلی نزدیک به داده های واقعی به دست آمده از آزمایش های مزرعه ای می باشند. بنابراین می توان مدل به دست آمده را در مواقعی که امکان اندازه گیری وجود نداشته باشد، به کار گرفت.

در این مطالعه به بررسی و تخمین بازده کششی تراکتور با استفاده از شبکه عصبی مصنوعی پرداخته شده است. نتایج حاصل از آنالیز رگرسیونی نشان می دهد که شبکه عصبی مصنوعی در پیش بینی بازده کششی تراکتور در شرایط مختلف عمق شخم، سرعت پیشروی و وضعیت تراکتور از نظر میزان سنگین کننده موفق بوده است. در این مطالعه از الگوریتم های آموزشی LM و SCG استفاده شده است. بهترین نتیجه برای بازده کششی شبکه با الگوریتم آموزشی LM و ۱۱ نرون در لایه میانی می باشد که بهترین عملکرد را از خود نشان داد. از آنجایی که ماهیت مسأله پیچیده و چند متغیره می باشد، احتمال اینکه الگوریتم های ریاضی و عددی ناکارآمد باشند وجود دارد، در حالی که به نظر می رسد شبکه عصبی مصنوعی بهتر عمل می کند. لذا می توان چنین نتیجه گیری نمود که شبکه عصبی

۵- فهرست منابع

1. Abbaspour-Gilandeh, Y., Jalilnejhad, H. and Mesri Gundoshmian, T. 2013. Draft prediction of a vertical narrow tillage tool by artificial neural networks. Journal of Agricultural Mechanization. 1(1): 27-36. (In Farsi).
2. AL-Hamed, S.A., Wahby, M.F., Al-Saqr, S.M., Aboukarima, A.M. and Sayedahmed Ahmed, A. 2013. Artificial neural network model for predicting draft and energy requirements of a disk plow J. Anim. Plant Sci. 23(6): 1714-1724.
3. Altinisk, A., Terzioglu, H., Saglam, H. and Altinisk, K. 2012. Analysis of tractor traction force with artificial neural network in cultivation, The 16Th International Research/Expert Conference "Trends in the Development of Machinery and Associated Technology" TMT, Dubai
4. Ismail. S.M., Singh, G. and Gee-Clough, D. 1981. A preliminary investigation of a combined slip and draught control for tractor. J. Agr. Eng. Res. 26(4): 293-306.
5. Karman, K. and Taner, A. 2012. Prediction of tire tractive performance by using artificial neural networks. Math. Comput. Appl. 17(3): 182-192.

6. Loghavi, M. and Molasadeghi, A. 2002. Tractive efficiency evaluation and comparison of Massey Ferguson (MF285) and Universal (U 650) tractor in the implementation of the moldboard plow. Journal of Science and Technology of Agriculture and Natural Resources. 6(2): 67-77. (In Farsi)
7. Naghdiyan, M., Abdollahpour, Sh. 2014. Analysis of moldboard plowing performance parameters effect on driving wheels slip, draft and traction efficiency. Journal of Agricultural Mechanization. 1(2): 45-58. (In Farsi)
8. Rahman, A., Kushawaha, R.L., Ashrafizadeh, S.R. and Panigrahi, S. 2011. Prediction of energy requirement of a tillage tool in a soil bin using artificial neural network. ASABE Paper No. 111112. St. Joseph, Michigan, USA.
9. Taghavifar, H. and Mardani, A. 2014. Application of artificial neural networks for the prediction of traction performance parameters, J. Saudi Soc. Agr. Sci. 13: 35– 43.

Modeling of Tractor Traction Efficiency Using Artificial Neural Networks

S. R. Mousavi Seyedi ^{1*}, M. Alijani ², R. Hadipour Rokni ³

¹ Assistance Professor, Department of Mechanics of Biosystem Engineering, Sari Agricultural Sciences and Natural Resources University, Sari, Iran

² M.Sc graduated, Sari Agricultural Sciences and Natural Resources University, Sari, Iran

³ M.Sc graduated, Department of Mechanics of Biosystem Engineering, Sari Agricultural Sciences and Natural Resources University, Sari, Iran

*Corresponding author E-mail: Mousavi22@yahoo.com

Received: 2016-07-31

Accepted: 2017-01-22

Abstract

In this study, field experiments were carried out at different plow depths, forward travel speeds and tractor ballast weights. Plowing was performed at four depths (5, 10, 15 and 20 cm), four travel speeds (2.5, 3.5, 4.5 and 5.5 km/h) and four of ballast weights (0, 40, 80 and 120 kg). An artificial neural model (ANN) that has been used for predicting tractor traction efficiency, was recurrent multi-layer back propagation network. Two LM and SCG algorithms were used for network training purposes. Results showed that the LM-based ANN outperformed the SCG-based ANN. RMSE and R^2 values for tractive efficiency were 0.010828 and 0.99163, respectively. The results showed that predicted data were similar to field measurements. The model could be employed where field experiments are not available.

Key words: Traction, Tractive efficiency, Neural Network, Back propagation Algorithm