

## مدل‌سازی عملکرد کششی چرخ‌های تراکتور در خاک‌های مختلف با استفاده شبکه عصبی پیشگی

حمید جلیل‌نژاد<sup>۱</sup>، یوسف عباسپور گیلانده<sup>۲\*</sup>، ولی رسولی شربانی<sup>۲</sup> و عارف مردانی کرانی<sup>۳</sup>

### چکیده

در این تحقیق مدل‌سازی عملکرد کششی تراکتور شامل ویژگی‌های توان مالبندی، مقاومت غلتشی و بازده کششی با استفاده از شبکه عصبی پیشگی در دو نوع خاک لومی رسی شنی و رسی انجام گردید. آزمایش‌ها در داخل هر بافت خاک در قالب آزمایش فاکتوریل بر پایه طرح بلوک کامل تصادفی (RCBD) و با سه تکرار انجام شدند. در داخل هر بافت خاک، سطوح مختلف رطوبت از ۸ تا ۱۷ درصد برای خاک‌های خشک و ۱۸ تا ۴۰ درصد برای خاک‌های مرطوب، سرعت پیشروی تراکتور در چهار سطح ۱/۲، ۱/۶، ۱/۸ و ۲/۲ کیلومتر بر ساعت، عمق کار در دو سطح ۳۰ و ۵۰ سانتی‌متر، تعداد عبور تراکتور در دو سطح ۲ و ۶ بار عبور، فشار باد لاستیک تراکتور در دو سطح ۲۰ و ۲۵ پوند بر اینچ مربع انتخاب، و در داخل هر کرت آزمایشی، مشخصه‌های شاخص مخروطی، بار دینامیکی، نیروی مقاوم کششی و درصد محتوای رطوبتی اندازه‌گیری شدند. شبکه‌های طراحی شده در این تحقیق از نوع شبکه‌های پیشگی بودند. از الگوریتم‌های Adam، Sgdm و Rmsprop به منظور آموزش شبکه استفاده گردید. نتایج این تحقیق نشان داد که شبکه عصبی توسعه داده شده با الگوریتم Sgdm در مقایسه با سایر الگوریتم‌ها عملکرد بهتری دارد. بنابراین از این الگوریتم به منظور مدل‌سازی استفاده شد. از معیارهای آماری  $R^2$  و MSE به منظور ارزیابی عملکرد شبکه استفاده گردید. بهترین عملکرد شبکه پیشگی طراحی شده برای ویژگی‌های توان مالبندی، مقاومت غلتشی و بازده کششی به ترتیب دارای ضریب تبیین ۰/۹۹۵۳، ۰/۹۹۰۳ و ۰/۹۸۸۸ و میانگین مربعات خطا به ترتیب برابر با ۰/۰۰۱۶، ۰/۰۰۳۹ و ۰/۰۰۳ بودند. همچنین مقدار حداقل و حداکثر برای توان مالبندی به ترتیب برابر با ۵/۶۸ و ۱۲/۴۸ کیلووات، برای مقاومت غلتشی چرخ‌های تراکتور به ترتیب برابر ۲/۵۱ و ۴/۳۳ کیلو نیوتن و برای بازده کششی به ترتیب برابر با ۷۳/۴۲ و ۸۰/۰۵ درصد به دست آمد. نتایج نشان داد که می‌توان از این شبکه‌ها به منظور مدل‌سازی ویژگی‌ها با حذف لایه‌های پیشگی و کاهش ابعاد استفاده کرد.

**واژه‌های کلیدی:** بازده کششی، مقاومت غلتشی، توان مالبندی، یادگیری عمیق، شبکه‌های پیشگی.

ارجاع: جلیل‌نژاد ح.، عباسپور گیلانده ی.، رسولی شربانی و.، مردانی کرانی ع. ۱۴۰۳. مدل‌سازی عملکرد کششی چرخ‌های تراکتور در خاک‌های مختلف با استفاده شبکه عصبی پیشگی. نشریه پژوهش‌های مکانیک ماشین‌های کشاورزی. ۳۱: ۶۷-۵۵. <https://dx.doi.org/10.22034/JRMAM.2024.14596.682>

۱- فارغ‌التحصیل دکتری مهندسی مکانیک بیوسیستم، گروه مهندسی بیوسیستم، دانشکده کشاورزی و منابع طبیعی، دانشگاه محقق اردبیلی.

۲- استاد گروه مهندسی بیوسیستم، دانشکده کشاورزی و منابع طبیعی، دانشگاه محقق اردبیلی.

۳- دانشیار گروه مهندسی مکانیک بیوسیستم، دانشکده کشاورزی، دانشگاه ارومیه.

\* نویسنده مسئول: [abbaspour@uma.ac.ir](mailto:abbaspour@uma.ac.ir)

تاریخ دریافت: ۱۴۰۲/۰۸/۱۲ تاریخ پذیرش: ۱۴۰۲/۰۹/۲۰

## مقدمه

تراکتورهای مزرعه‌ای مقدار قابل توجهی از انرژی را طلب می‌کنند و بهینه کردن عملکرد تراکتورهای مزرعه‌ای می‌تواند بسیاری از افت‌های انرژی در کشاورزی را کاهش دهد. با توجه به اینکه بیشتر از تراکتورها در کشیدن ادوات مزرعه‌ای استفاده می‌شود، آنچه که غالباً مدنظر محققان است بحث کشش و استفاده بهینه از قدرت کششی تراکتور است.

عملکرد کششی چرخ‌های محرک تراکتور نتیجه برهمکنش تنش-کرنش بین چرخ‌های تراکتور و خاک سطحی است. این فعل و انفعالات متأثر از عوامل متعددی از جمله رفتار مکانیکی خاک سطحی، قدرت و هندسه (فاصله دو محور و ارتفاع مالبند) تراکتور، تعداد چرخ‌های محرک، بار وارد بر چرخ، لغزش چرخ، ابعاد تایر (عرض و قطر)، سختی و فشار باد لاستیک هستند. چرخ، نقش مهمی در وسایل نقلیه کشاورزی و خارج جاده‌ای ایفا می‌کند؛ زیرا همیشه با زمین در تماس است و تقریباً تمام نیروها و ممان‌های مؤثر بر تحرک وسیله نقلیه به آن وارد می‌شود. همچنین تأثیر بسیار قابل توجهی روی دینامیک ماشین دارد (Askari et al., 2021; Askari et al., 2022). از این رو، عکس‌العمل بین خاک و چرخ‌ها با توجه به نقش اساسی آنها در حرکت، فرمان‌گیری و کشش باید مورد توجه قرار گیرد. از آنجایی که تراکتور یکی از وسایل نقلیه اصلی کشاورزی است، باید توجه بیشتری به عکس‌العمل چرخ و خاک تراکتورها شود. عوامل متعددی از جمله نحوه رانندگی تراکتور، مقاومت غلتشی، لغزش، اصطکاک و فشار باد چرخ‌های تراکتور در میزان بازده کششی مؤثر هستند. مقاومت غلتشی، یک ممان وارد شده به چرخ در خلاف جهت حرکت آن است (Komandi, 1999). علاوه بر مقاومت غلتشی، فشردگی خاک، اتلاف انرژی و لغزش بیش از حد چرخ از ویژگی‌های مهم و نامطلوب در کشش ادوات است. عملکرد کششی تراکتور تأثیر زیادی بر میزان مصرف سوخت و زمان لازم برای خاک‌ورزی دارد. ویژگی‌های عملکرد کششی تراکتور نقش اساسی در مدیریت تراکتور و ماشین‌آلات کشاورزی ایفا می‌کنند. در دسترس بودن داده‌های عملکرد کششی تراکتور، کمک شایانی به مدیران کشاورزی، مشاوران، طراحان، تولیدکنندگان و مهندسان کشاورزی در انتخاب صحیح و مناسب ادوات خاک‌ورزی می‌کنند.

فناوری محاسبات نرم یکی از محبوب‌ترین روش‌ها برای مدل‌سازی و پیش‌بینی رفتار سامانه‌های غیرخطی است. این فناوری یک رویکرد تحقیقاتی میان رشته‌ای و شامل تجزیه و تحلیل داده‌ها، یادگیری ماشین، شبکه عصبی مصنوعی و تجزیه و تحلیل داده‌های فازی در علم محاسباتی به منظور تجزیه و تحلیل است. مطالعات زیادی در مورد کاربرد روش‌های مختلف محاسبات نرم برای عملکرد کششی چرخ‌ها موجود است (Marakoglu & Carman, 2010; Rahman et al., 2012; Young et al., 2013; Taghavifar & Mardani, 2013b; Taghavifar & Mardani, 2013c; Taghavifar & Mardani, 2014a). (Almalilki et al., 2016) به منظور ارزیابی عملکرد تراکتور تحت ویژگی‌های توان کششی، مصرف سوخت، مقاومت غلتشی و بازده کششی، از شبکه‌های عصبی مصنوعی استفاده کردند. در تحقیق دیگری از شبکه‌های عصبی مصنوعی به منظور پیش‌بینی ویژگی‌های عملکرد کششی (ناحیه تماس لاستیک و مقاومت غلتشی) استفاده شد. داده‌های تجربی با استفاده از یک آزمون گر تک‌چرخ در مخزن خاک با ویژگی‌های فشار باد لاستیک از ۱۰۰ کیلوپاسکال تا ۷۰۰ کیلو پاسکال، بار عمودی وارد بر لاستیک از ۱ کیلو نیوتن تا ۷ کیلو نیوتن و در دو نوع بافت خاک و دو نوع لاستیک به دست آمده بودند. نتیجه آزمایش‌ها نشان داد که شبکه‌های عصبی مصنوعی به دلیل سرعت و دقت بالا و محاسبه قابل اعتماد چند متغیره، غیرخطی و محاسبات پیچیده برای مدل‌سازی عکس‌العمل بین خاک و چرخ بسیار مناسب هستند (Taghavifar & Mardani, 2014d).

(Pentoś & Pieczarka, 2017) در یک تحقیق، اثر بافت خاک، محتوی رطوبتی، تراکم خاک، تغییر شکل افقی و بار عمودی را بر روی نیروی کششی و بازده کششی مورد بررسی قرار دادند. تجزیه و تحلیل و مدل‌سازی ریاضی توسط شبکه‌های عصبی مصنوعی انجام شده بود. ضریب تبیین برای نیروی کششی برابر با ۰/۹۴۵ و برای بازده کششی برابر با ۰/۹۶۳ به دست آمد. بافت خاک و محتوای رطوبتی، بالاترین تأثیر بر نیروی کششی و بازده کششی داشتند. بار عمودی نیز به طور قابل ملاحظه‌ای نیروی کششی را تحت تأثیر قرار داد. تغییر شکل افقی و تراکم خاک کمترین تأثیر را در متغیرهای وابسته داشتند. از الگوریتم تکاملی برای تعیین شرایط خاک و بار عمودی که نیروی کششی بالا و بازده کششی

ایجاد می‌کند، استفاده شد.

شبکه‌های یادگیری عمیق است (Yao *et al.*, 2019; Dhillon & Verma, 2020). یک شبکه عصبی پیچشی نوعی از شبکه عصبی مصنوعی است که در آن نورون‌ها، به نواحی روی هم افتاده در یک ناحیه دیداری واکنش نشان می‌دهند. این نوع شبکه‌ها از فرآیندهای زیستی الهام گرفته‌اند و گونه‌هایی از شبکه‌های پرسپترون چند لایه‌اند که با طراحی خاصی از حداقل میزان پیش پردازش بهره می‌برند. شبکه‌های عصبی پیچشی معمولاً از یک یا چند لایه پیچش (convolution)، لایه کاهش اندازه (pooling) و یا کاملاً متصل (fully connected) تشکیل می‌شوند. عملیات پیچش، استخراج ویژگی‌های مختلف از لایه ورودی است. عملیات کاهش بعد یافتن ویژگی‌های در مقیاس بزرگ و کاهش ابعاد نقشه‌های ویژگی است (Chen *et al.*, 2020; Wang *et al.*, 2020). لایه کاملاً متصل ویژگی‌های استخراج شده را برای اتصال به خروجی نهایی سازماندهی مجدد می‌کند. از مزایای این شبکه‌ها می‌توان به دقت بالا، قدرت تعمیم بالا، یادگیری خودکار ویژگی‌ها بدون نظارت، یادگیری چند لایه ویژگی‌ها، پشتیبانی سخت افزاری و نرم افزاری و قابلیت ایجاد توانمندی‌های بیشتر اشاره کرد. در سال‌های اخیر، روش یادگیری عمیق به عنوان یک ابزار رگرسیون مؤثر در زمینه کمی‌سازی خصوصیات خاک، شاهد موفقیت زیادی بوده است (Zhang *et al.*, 2019; Tsakiridis *et al.*, 2020). در یک تحقیق به منظور پیش‌بینی رطوبت خاک و تحلیل قابلیت انتقال آن بر اساس داده‌های طیفی از مدل شبکه عصبی پیچشی استفاده شد. آنها به این نتیجه رسیدند که مدل یک بعدی شبکه عصبی پیچشی یک ابزار قدرتمند برای امر پیش‌بینی است. ضریب تبیین در این تحقیق برابر با ۰/۹۸۹ به دست آمد (Chen *et al.*, 2021). همچنین این روش در حوزه‌های پیش‌بینی عملکرد، تشخیص علف هرز و تشخیص بیماری مورد استفاده قرار گرفته است (Bharman *et al.*, 2022). در یک مطالعه، یک چارچوب یادگیری عمیق و روش‌های بهینه‌سازی CNN<sup>۱</sup> و RNN<sup>۲</sup> به منظور پیش‌بینی عملکرد محصول مبتنی بر داده‌های محیطی مورد استفاده قرار گرفت. برای پیش‌بینی عملکرد ذرت و سویا مقدار RMSE به ترتیب برابر ۹ و ۸ درصد از

مدل‌سازی عملکرد کشتی به عنوان شاخصی از مقاومت غلتشی در مطالعات زیادی مورد بحث واقع شده است. روابط عملی بین چرخ و خاک توسط محققین مختلفی استخراج گردیده و نشان داده شده است که مقاومت غلتشی تحت تأثیر ویژگی‌های فشار نشست، وزن وسیله نقلیه، نشست خاک و شرایط خاک است (Bekker, 1960).

Taghavifar *et al.* (2013a)، تأثیر سرعت، فشار باد لاستیک و بار عمودی وارد بر چرخ را توسط یک آزمون گر تک چرخ روی مقاومت غلتشی در یک مخزن خاک مورد ارزیابی قرار دادند. نتایج نشان داد که مقاومت غلتشی کمتر تحت تأثیر سرعت تراکتور بوده و بیشتر تحت تأثیر فشار باد لاستیک و بار عمودی وارد بر چرخ است. نتایج نشان داد که رابطه‌ای تقریباً ثابت بین سرعت و مقاومت غلتشی وجود دارد و مقاومت غلتشی تابعی از سرعت به خصوص در سرعت‌های پایین نیست. علاوه بر این مشاهده شد که افزایش فشار باد منجر به کاهش مقاومت غلتشی گردید. همچنین افزایش بار عمودی منجر به افزایش مقاومت غلتشی می‌شود، که یک معادله چند جمله‌ای با درجه دو تخمین زده شد.

یادگیری عمیق شاخه‌ای از یادگیری ماشین و هوش مصنوعی است که در آن سعی می‌شود با استفاده از معماری‌های سلسله مراتبی، انتزاعات و ویژگی‌های سطح بالای موجود در داده‌ها فرا گرفته شود (Chollet, 2021). منظور از یادگیری عمیق، شبکه‌های عصبی چند لایه است که ویژگی‌ها را توسط چندین لایه یاد می‌گیرد. اصطلاح عمیق معمولاً به تعداد لایه‌های پنهان در شبکه عصبی اشاره دارد. در بیشتر روش‌های یادگیری عمیق از معماری شبکه عصبی استفاده می‌شود، به همین دلیل مدل‌های یادگیری عمیق اغلب تحت عنوان شبکه‌های عصبی عمیق شناخته می‌شوند. مدل‌های یادگیری عمیق با استفاده از مجموعه وسیعی از داده‌های برجسب‌دار و معماری شبکه عصبی آموزش داده می‌شوند که ویژگی‌ها را مستقیماً از داده‌ها، بدون نیاز به استخراج ویژگی‌های دستی یاد می‌گیرند. انواع مدل‌های شبکه‌های عصبی عمیق شامل شبکه خود رمزنگار، شبکه باور عمیق، شبکه عصبی پیچشی و شبکه عصبی بازگشتی است. شبکه عصبی پیچشی یکی از محبوب‌ترین و پرکاربردترین

1- Convolutional Neural Network

2- Recurrent Neural Network

۲۲۰، اراک، ایران) به عنوان عامل خاک‌ورز استفاده شد و این وسیله توسط یک تراکتور MF-285 تک محوره با قدرت ۷۵ اسب بخار (مدل MF-285، تراکتورسازی ایران، تبریز، ایران) با مشخصات لاستیک ۳۰-۱۵/۴/۱۸ (۱۰ لایه) کشیده می‌شد. تراکتور مزبور به سامانه ابزار اندازه‌گیری دقیق مجهز بود و داده‌های نیروی مقاوم کششی، سرعت پیشروی، و بار دینامیکی وارد بر چرخ‌های جلو در جریان عملیات خاک‌ورزی ثبت می‌گردید.



شکل ۱- نفوذسنج مخروطی مورد استفاده در تحقیق



شکل ۲- سامانه جمع‌آوری داده داخل اتاق راننده



شکل ۳- خروجی برنامه گزارشگر اطلاعات

سامانه اندازه‌گیری دقیق تراکتور مجهز به دینامومتر اتصال سه نقطه، حسگر اندازه‌گیری سرعت از نوع چرخ پنجم، حسگر اندازه‌گیری بار دینامیکی (شکل ۴، کرنش‌سنج‌های نصب شده بر روی محور جلوی تراکتور) و سامانه جمع‌آوری داده است. برای اندازه‌گیری مقاومت به کشش از یک دینامومتر اتصال سه نقطه با قابلیت تنظیم ارتفاع فیل‌گوش و تنظیم فاصله بین نقاط اتصال پایینی

میانگین عملکرد به دست آمد (Khaki *et al.*, 2020). در مطالعه دیگری پنج نوع بیماری برگ گوجه فرنگی با استفاده از CNN شناسایی شد. دقت این مدل برابر ۹۹/۸۴ درصد به دست آمد (Ashqar & Abu-Naser, 2018).

Zhang *et al.* (2018) در یک تحقیق به تشخیص علف‌های هرز بر روی برگ‌های پهن با استفاده از الگوریتم‌های CNN پرداختند. دقت مدل پیشنهادی آنها برابر ۹۶/۸۸ درصد به دست آمد.

تحقیقی به منظور پیش‌بینی مصرف سوخت تراکتور با استفاده از شبکه عصبی پیچشی انجام شده است. ویژگی‌های ورودی شامل رطوبت خاک، بافت خاک، شاخص مخروطی خاک، عمق کار، سرعت پیشروی تراکتور، بار دینامیکی وارد بر چرخ عقب، تعداد عبور تراکتور و فشار باد لاستیک بودند. نتایج این تحقیق دارای ضریب تبیین ۰/۹۷۲۹ برای مصرف سوخت لحظه‌ای و ۰/۹۷۳۷ برای مصرف سوخت ویژه بود (Jalilnezhad *et al.*, 2023).

هدف از تحقیق حاضر، مدل‌سازی عملکرد کششی تراکتور شامل ویژگی‌های توان مالبندی، مقاومت غلشی، بازده کششی با استفاده از شبکه عصبی پیچشی در شرایط مختلف خاک و عملیات خاک‌ورزی و ارزیابی این مدل بر اساس معیارهای آماری است.

## مواد و روش‌ها

### ادوات مورد استفاده در انجام تحقیق

از یک دستگاه نفوذسنج مخروطی دستی (CP40II، RIMIK Electronic, Rimik 1079, Ruthven St Toowoomba QLD 4350 Australia) به منظور اندازه‌گیری شاخص مخروطی در عمق صفر تا ۵۰ سانتی‌متر استفاده شد (شکل ۱). مقادیر شاخص مخروطی بر اساس نیروی اندازه‌گیری شده برای فشار دادن یک مخروط با سطح مقطع ۱۳۳ میلی‌متر مربع و زاویه نوک ۳۰ درجه به داخل خاک محاسبه گردید. سامانه جمع‌آوری داده شامل یک گزارش‌گر اطلاعات رقمی ۸ مسیره (شکل ۲ و ۳) مدل AL-8G ساخت شرکت ATRON (AL8G, Tehran, Iran) با قابلیت برنامه‌نویسی و یک رایانه کیفی در داخل اتاق راننده بود. در این تحقیق یک زیرشکن دو شاخه C شکل (تاکا، مدل

می‌دهد. خصوصیات خاک‌های مورد آزمایش در جدول ۲ آورده شده است.

جدول ۱- ویژگی‌های ورودی شبکه عصبی پیش

ویژگی‌های ورودی	واحد مقدار
بافت خاک	بدون بعد لومی رسی شنی رسی
تعداد عبور	بدون بعد 62
فشار باد لاستیک	25 20psi
عمق کار	50 30cm
شاخص مخروطی	$3/83 - 0/64 * 5/03 - 0/95MPa$
بار دینامیکی	$7/62 - 5/13 * 8/53 - 5/13kN$
رطوبت	$40 - 18 * 18 - 7\%$
سرعت پیشروی	$2/2 \ 1/8 \ 1/6 \ 1/2km \ h^{-1}$

جدول ۲- ویژگی خاک‌های مورد استفاده در تحقیق

مقدار	مورد
۵۹/۶ <sup>b</sup>	۳۲/۳ <sup>a</sup> شن (%)
۱۹/۲ <sup>b</sup>	۲۳/۲ <sup>a</sup> سیلت (%)
۲۱/۲ <sup>b</sup>	۴۴/۵ <sup>a</sup> رس (%)
۴۳۰ <sup>b</sup>	۳۳۰ <sup>a</sup> زاویه اصطکاک داخلی (°)

<sup>a</sup> رسی و <sup>b</sup> لومی رسی شنی

### محاسبه ویژگی‌ها

#### توان مالبندی

ابزارهای کششی به نقطه مالبندی تراکتور متصل می‌شوند. توان مورد نیاز برای کشیدن این ادوات را توان مالبندی می‌نامند. توان مالبندی از معادله بین نیروی کششی اندازه‌گیری شده و سرعت پیشروی واقعی به دست می‌آید (مک میلان، ۲۰۰۳):

$$P_{db} = P \times V_a \quad (1)$$

که در آن:  $P_{db}$  توان مالبندی بر حسب وات؛  $P$  نیروی کششی بر حسب نیوتن؛ و  $V_a$  سرعت پیشروی واقعی تراکتور بر حسب متر بر ثانیه است.

#### مقاومت غلته‌شی

به منظور اندازه‌گیری مقاومت غلته‌شی، تراکتور مورد آزمایش که ابزار خاک‌ورزی به آن متصل و در حالت بدون درگیری در خاک است، توسط یک تراکتور کمکی دیگر کشیده شد (RNAM, 1995). بین دو تراکتور از یک نیروسنج برای اندازه‌گیری نیروی افقی بین دو تراکتور استفاده شد (شکل ۶). آزمایش‌ها با ابزار خاک‌ورزی در

ساخته شده در گروه مهندسی مکانیک ماشین‌های کشاورزی دانشگاه محقق اردبیلی) استفاده شد (Abbaspour-Gilandeh et al., 2010).



شکل ۴- کرنش‌سنج‌های نصب شده (الف) در روی محور جلوی تراکتور (ب) کرنش‌سنج نصب شده در زیر محور جلو

دینامومتر مورد نظر دارای سه عدد مبدل انرژی (ترنسدیوسر) حلقوی نیرو با ساختار هشت وجهی و قابی به شکل U وارونه است، که بین بازوهای سامانه اتصال سه نقطه تراکتور و ادوات کشاورزی گروه‌های I و II قرار گرفته و نیروهای افقی و عمودی اتصال را نشان می‌دهد (شکل ۵). به منظور اندازه‌گیری سرعت واقعی پیشروی تراکتور از چرخ پنجم (شکل ۵) استفاده شد (Abbaspour-Gilandeh & Rashidi-Mohammadabad, 2013).



شکل ۵- تراکتور MF-285، مجهز به سامانه ابزار اندازه‌گیری دقیق

### آزمایش‌های مزرعه‌ای

آزمایش‌ها در مزرعه آموزشی و تحقیقاتی دانشکده کشاورزی دانشگاه محقق اردبیلی با دو نوع خاک لومی رسی شنی و رسی انجام شد و در داخل هر نوع خاک از آزمایش فاکتوریل بر پایه طرح بلوک کامل تصادفی (RCBD) و با سه تکرار استفاده شد. جدول ۱ ویژگی‌های ورودی شبکه پیش‌بینی به همراه مقادیر آنها را نشان

مخفی و تعداد نوروها در لایه میانی، متناسب با تعداد نوروهای لایه میانی، بر مبنای مقایسه عملکرد شبکه‌ها انتخاب شد (Abbaspour-Gilandeh *et al.*, 2013). همچنین از تابع انتقال محرک خطی به دلیل عملکرد بهتر در بین لایه‌ها استفاده شد. داده‌های ورودی و خروجی به منظور افزایش دقت و عملکرد و سرعت بین (۱ و -۱) طبق معادله زیر نرمال شدند:

$$X_n = 2 \frac{X - X_{\min}}{X_{\max} - X_{\min}} - 1 \quad (۴)$$

که در آن:  $X_n$  متغیر ورودی نرمال شده،  $X$  متغیر ورودی خام،  $X_{\min}$  و  $X_{\max}$  به ترتیب حداقل و حداکثر متغیر ورودی است. عملکرد شبکه عصبی مصنوعی آموزش دیده توسط مقایسه بین مقادیر خروجی واقعی و مقادیر خروجی پیش‌بینی شده مورد بررسی قرار گرفت. بهترین روش آموزش برای داده‌های مورد استفاده و همچنین مقایسه عملکرد شبکه‌های ساخته شده بر اساس معیارهای میانگین مربعات خطا (MSE) و ضریب تبیین ( $R^2$ ) مدل برآزش شده خطی بین داده‌های واقعی و داده‌های پیش‌بینی شده انجام می‌گردد. معادلات زیر نحوه محاسبه مقادیر آماری ذکر شده را نشان می‌دهند:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_p - y_a)^2 \quad (۵)$$

$$R^2 = \frac{\sum_{i=1}^n (y_p - y_a)^2}{\sum_{i=1}^n (y_p - y_m)^2} \quad (۶)$$

که در آن:  $y_a$  مقادیر واقعی؛  $y_p$  مقادیر پیش‌بینی شده؛  $y_m$  مقادیر میانگین مدل هستند.

### داده‌های مورد استفاده در شبکه عصبی مصنوعی

#### طراحی شده

مهم‌ترین عامل در طراحی شبکه‌های عصبی مصنوعی، انتخاب داده‌های مورد استفاده در آموزش و یادگیری شبکه است. عناصر بردارهای ورودی باید به گونه‌ای انتخاب شوند که بتوانند شرایط حاکم بر سامانه را به خوبی نشان دهند. از آنجایی که هدف از توسعه مدل شبکه عصبی مصنوعی در این تحقیق مدل‌سازی عملکرد کششی چرخ‌های تراکتور است، بنابراین بردارهای ورودی از میان ویژگی‌های مؤثر بر آنها انتخاب می‌گردند. در این تحقیق ویژگی‌های ورودی به شبکه عصبی مصنوعی بافت

عمق و سرعت‌های مورد نظر انجام شده و نیروی به دست آمده از نیروسنج، کشش ناخالص است. سپس همان آزمایش‌ها در همان سرعت‌ها و بدون درگیری ابزار خاکورزی در خاک انجام شد. نیروی اندازه‌گیری شده در این حالت مقاومت غلتشی چرخ‌های تراکتور است (Macmillan, 2003). (معادله (۲)):

$$R = H - P \quad (۲)$$

که در آن:  $R$  مقاومت غلتشی بر حسب کیلونیوتن؛  $H$  کشش ناخالص بر حسب کیلونیوتن و  $P$  نیروی کششی بر حسب کیلونیوتن است.



شکل ۶- (الف) اندازه‌گیری مقاومت غلتشی تراکتور (ب) نیروسنج سه تکی مورد استفاده بین دو تراکتور

### بازده کششی

عبارت است از قدرت ستانده از مالیند به قدرت نهاده در چرخ‌ها. عوامل متعددی در مقدار این بازده مؤثر هستند که عبارتند از نحوه هدایت تراکتور، مقاومت غلتشی، لغزش، اصطکاک و فشار باد چرخ‌های تراکتور. بازده کششی (TE) از معادله زیر به دست می‌آید (Macmillan, 2003).

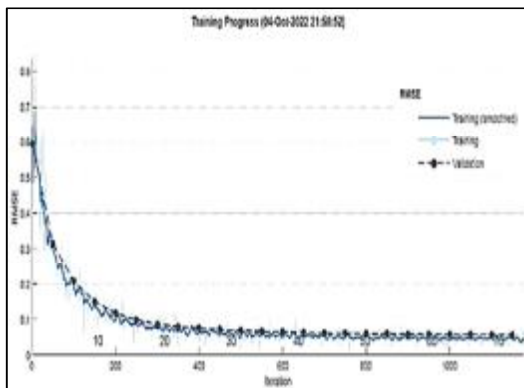
$$TE = \frac{P \times V_a}{H \times V} \quad (۳)$$

### طراحی مدل شبکه عصبی


در این مطالعه به منظور مدل‌سازی عملکرد کششی چرخ‌های تراکتور از روش یادگیری عمیق (شبکه عصبی پیچشی) واز نرم‌افزار MATLAB 2021a برای برنامه‌نویسی یادگیری عمیق مدل طراحی شده CNN استفاده شد. استفاده شد. از الگوریتم‌های Adam, Sgdm و Rmsprop به منظور آموزش شبکه استفاده گردید. اجزای مختلف مدل نشان داد که شبکه عصبی توسعه داده شده با الگوریتم Sgdm در مقایسه با سایر الگوریتم‌ها عملکرد بهتری دارد. بنابراین از این الگوریتم به منظور مدل‌سازی استفاده شد. در این تحقیق تعداد لایه‌های



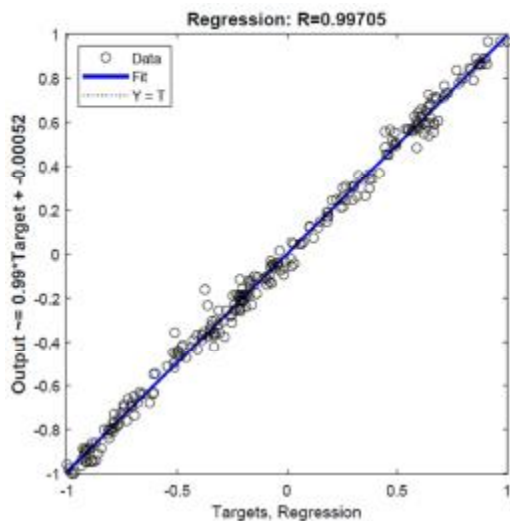
اثبات می‌کند. جدول ۳ معماری بهینه شبکه پیش‌بینی به همراه معیارهای عملکردی شبکه آورده را نشان می‌دهد.



شکل ۷- نمودار عملکرد شبکه پیش‌بینی برای نمونه‌ای از آزمایشات در مرحله آموزش



شکل ۸- خروجی شبکه پیش‌بینی در تحقیق توسط نرم‌افزار MATLAB 2021a



شکل ۹- نمودار رگرسیون بهترین شبکه عصبی پیش‌بینی برای توان مالبندی در مرحله آموزش

آوردند. آنها در یک تحقیق به پیش‌بینی توان مالبندی یک آزمون‌گر تک چرخ با داشتن ویژگی‌های لغزش، سرعت پیشروی و بار عمودی وارد بر چرخ در مخزن خاک

خاک، درصد محتوی رطوبتی خاک، سرعت پیشروی تراکتور، مقادیر شاخص مخروطی خاک، عمق نفوذ تیغه، تعداد عبور چرخ‌های تراکتور، فشار باد لاستیک و بار دینامیکی وارد بر چرخ جلو هستند. توان کششی، مقاومت غلتشی و بازده کششی ویژگی خروجی شبکه طراحی شده است. از نتایج آزمایش‌های مزرعه‌ای شرح داده شده، به عنوان داده‌های ورودی و خروجی در مدل‌سازی عملکرد کششی چرخ‌های تراکتور استفاده شد. داده‌های مورد استفاده در این تحقیق که به منظور مدل‌سازی عملکرد کششی چرخ‌های تراکتور مورد استفاده قرار گرفتند، از داده‌های آزمایشات مزرعه‌ای انجام شده به دست آمدند. انتخاب داده‌ها به نحوی بود که بتوانند تغییرات هر یک از ویژگی‌های مؤثر را در امر پیش‌بینی به خوبی بیان کرده و شرایط واقعی حاکم بر مزارع آزمایشی را به خوبی نشان دهند. از کل داده‌های مورد نظر، ۷۰ درصد برای فرآیند آموزش، ۱۵ درصد داده‌ها برای فرآیند اعتبارسنجی و ۱۵ درصد داده‌ها برای فرآیند آزمون در نظر گرفته شدند. تعداد نوروها از ۱ تا ۵۰۰ و تعداد تکرارها از ۱۰۰ تا ۲۰۰۰ تغییر داده می‌شد و عملکرد شبکه بر اساس میزان خطا مورد بررسی قرار می‌گرفت. کمترین خطا و بالاترین ضریب تبیین به عنوان عملکرد بهینه انتخاب می‌شد. بر اساس کمترین مقدار خطا، شبکه به صورت دستی یا پس از به پایان رسیدن تعداد تکرارها متوقف می‌شد. به منظور بهبود عملکرد شبکه از روش نرمال‌سازی دسته‌ای و حذف تصادفی استفاده شد.


## نتایج و بحث

شکل ۷ نمودار عملکرد شبکه عصبی پیش‌بینی در مرحله آموزش را نشان می‌دهد. همان‌طور که در شکل ۷ مشاهده می‌شود، با افزایش تعداد تکرار، میزان خطا کم می‌شود. همچنین یک انطباق رضایت‌بخشی بین داده‌های آموزش و ارزیابی وجود دارد. تصویر ۸ خروجی نرم‌افزار MATLAB را برای نمونه‌ای از آزمایشات نشان می‌دهد.


## توان مالبندی

شکل ۹ و ۱۰ نتایج بهترین مدل رگرسیون برای توان مالبندی را به ترتیب در مراحل آموزش و آزمون شبکه پیش‌بینی نشان می‌دهد. نزدیک بودن مقادیر واقعی و مقادیر مدل‌سازی شده، دقت شبکه عصبی پیش‌بینی را


نشان می‌دهد. هر چقدر داده‌ها در نمودار هیستوگرام خطا به مرکز نمودار (یعنی صفر) نزدیک باشند میزان خطا کمتر است.




شکل ۱۱- یک مقایسه بین مقادیر واقعی و مقادیر پیش‌بینی شده توان مالبندی برای تعداد آزمایشات در مرحله آموزش



شکل ۱۲- نمودار هیستوگرام خطا و نیز ریشه میانگین مربعات خطا (RMSE) برای داده‌های آموزش توان مالبندی



شکل ۱۳- یک مقایسه بین مقادیر واقعی و مقادیر پیش‌بینی شده توان مالبندی برای تعداد آزمایشات در مرحله آموزش




شکل ۱۴- نمودار هیستوگرام خطا و نیز ریشه میانگین مربعات خطا (RMSE) برای داده‌های آموزش توان مالبندی

### مقاومت غلتشی

شکل ۱۵ و ۱۶ نمودار بهترین مدل رگرسیونی برای داده‌های آموزش و آزمون را برای مقاومت غلتشی چرخ‌ها نشان می‌دهد.

پرداختند. بیش‌ترین مقدار ضریب تبیین و کم‌ترین میزان میانگین مربعات خطا را به ترتیب برابر با ۰/۹۶۷۲ و ۰/۰۲۲۴ به دست آوردند.

در این تحقیق مقدار حداقل و حداکثر برای توان مالبندی به ترتیب برابر با ۵/۶۸ و ۱۲/۴۸ کیلووات به دست آمد.



شکل ۱۰- نمودار رگرسیون بهترین شبکه عصبی پیچشی برای توان مالبندی در مرحله آزمون

جدول ۳- ویژگی‌های عملکردی برای توان مالبندی تراکتور

		Sgdm
الگوریتم آموزشی		۸-۴۹۹-۴۹۹-۱
معماری بهینه		
$R^2$	آموزش	۰/۹۹۴۱
	آزمون	۰/۹۹۵۳
MSE	آموزش	۰/۰۰۱۸
	آزمون	۰/۰۰۱۶
RMSE	آموزش	۰/۰۴۲۳
	آزمون	۰/۰۳۹۴

شکل‌های ۱۱ و ۱۳ مقایسه بین مقادیر داده‌های آزمایش و مدل‌سازی شده را برای داده‌های آزمون و آموزش و برای توان مالبندی نشان می‌دهند. این نمودارها انطباق بین مقادیر واقعی و مقادیر مدل‌سازی شده را در طول تعداد آزمایش‌ها در مرحله آزمون توسط شبکه عصبی پیچشی اثبات می‌کنند.

همچنین شکل‌های ۱۲ و ۱۴ نمودار هیستوگرام خطا و نیز ریشه میانگین مربعات خطا (RMSE) را به ترتیب برای داده‌ها در مرحله آزمون و مرحله آموزش




عصبی مصنوعی به منظور پیش‌بینی مقاومت غلتشی چرخ در مخزن خاک پرداختند. بالاترین ضریب تبیین و کمترین مقدار میانگین مربعات خطا در تحقیق آن‌ها به ترتیب برابر با ۰/۹۳۲۲ و ۰/۰۲۵۷ به دست آمد. در این تحقیق مقدار حداقل و حداکثر برای مقاومت غلتشی چرخ‌های تراکتور به ترتیب برابر ۲/۵۱ و ۴/۳۳ کیلونیوتن به دست آمد.


شکل‌های ۱۷ و ۱۹ به ترتیب نمودار انطباق برای مقادیر هدف در برابر مقادیر خروجی شبکه عصبی پیچشی را به ترتیب برای داده‌های آزمون و آموزش نشان می‌دهند. نزدیک بودن مقادیر هدف و خروجی شبکه دقت بالای شبکه عصبی پیچشی را اثبات می‌کند. شکل‌های ۱۸ و ۲۰ نمودار هیستوگرام خطا و نیز ریشه میانگین مربعات خطا را به ترتیب برای داده‌های آزمون و آموزش نشان می‌دهند.

جدول ۴- ویژگی‌های عملکردی برای مقاومت غلتشی

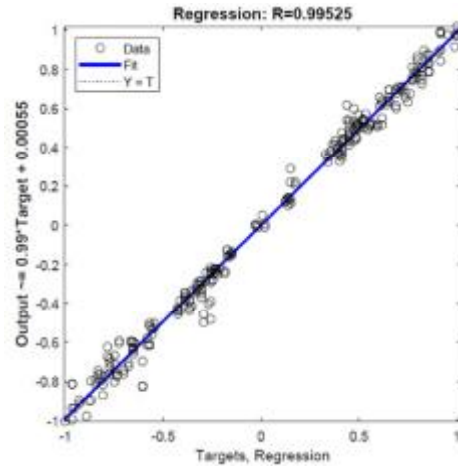
Sgdm		الگوریتم آموزشی
۸-۳۰۵-۳۰۱-۱		معماری بهینه
R <sup>2</sup>	آموزش	۰/۹۹۰۳
	آزمون	۰/۹۹۰۵
MSE	آموزش	۰/۰۰۳۹
	آزمون	۰/۰۰۳۲
RMSE	آموزش	۰/۰۵۶۹
	آزمون	۰/۰۶۲۶




شکل ۱۷- یک مقایسه بین مقادیر واقعی و مقادیر پیش‌بینی شده مقاومت غلتشی برای تعداد آزمایشات در مرحله آزمون



شکل ۱۸- نمودار هیستوگرام خطا و نیز ریشه میانگین مربعات خطا (RMSE) برای داده‌های آزمون مقاومت غلتشی




شکل ۱۵- نمودار رگرسیون بهترین شبکه عصبی پیچشی برای مقاومت غلتشی در مرحله آموزش




شکل ۱۶- نمودار رگرسیون بهترین شبکه عصبی پیچشی برای مقاومت غلتشی در مرحله آزمون

جدول ۴ معماری بهینه شبکه پیچش به همراه معیارهای عملکردی شبکه آورده را نشان می‌دهد. Almaliki *et al.*, 2016 نیز نتایج مشابهی به دست آوردند. آنها از شبکه عصبی مصنوعی به منظور پیش‌بینی مقاومت غلتشی تراکتور با داشتن ویژگی‌های سرعت موتور، سرعت پیشروی، عمق کار، فشار باد لاستیک، محتوی رطوبتی و شاخص مخروطی خاک پرداختند. بیش‌ترین مقدار ضریب تبیین در تحقیق آنها ۰/۹۲۸ به دست آمد.


Thombare (2019) تأثیر فشار باد لاستیک، بار وارد بر چرخ و سرعت بر روی مقاومت غلتشی توسط یک آزمون گر تک‌چرخ در مخزن خاک را بررسی کرد و نتایج مشابهی ارائه کرد. Taghavifar *et al.*, (2013a) از شبکه



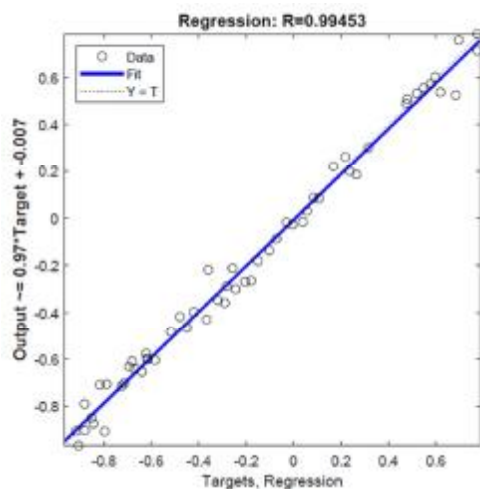
شکل ۲۱- نمودار رگرسیون بهترین شبکه عصبی پیچشی برای بازده کششی در مرحله آموزش



شکل ۱۹- یک مقایسه بین مقادیر واقعی و مقادیر پیش‌بینی شده مقاومت غلتشی برای تعداد آزمایشات در مرحله آموزش



شکل ۲۰- نمودار هیستوگرام خطا و نیز ریشه میانگین مربعات خطا (RMSE) برای داده‌های آموزش مقاومت غلتشی



شکل ۲۲- نمودار رگرسیون بهترین شبکه عصبی پیچشی برای بازده کششی در مرحله آموزش

### بازده کششی

شکل‌های ۲۱ و ۲۲ نمودار بهترین مدل رگرسیونی برای داده‌های آموزش و آزمون را برای بازده کششی نشان می‌دهند.

جدول ۵ معماری بهینه شبکه پیچشی به همراه معیارهای عملکردی شبکه آورده را نشان می‌دهد.

(Taghavifar & Mardani, 2014b) نیز نتایج مشابهی به دست آوردند. آنها از روش ANN به منظور پیش‌بینی بازده کششی یک آزمون‌گر تک چرخ در مخزن خاک با داشتن ویژگی‌های سرعت، لغزش و بار وارد بر چرخ استفاده کردند. بیشترین مقدار ضریب تبیین در تحقیق آنها برابر با ۰/۹۷۷ به دست آمد. مقدار حداقل و حداکثر برای بازده کششی در این تحقیق به ترتیب برابر با ۷۳/۴۲ و ۸۰/۰۵ درصد به دست آمد.

نمودار انطباقی بین داده‌های هدف و خروجی شبکه عصبی پیچشی برای داده‌های مراحل آزمون و آموزش به ترتیب در اشکال ۲۳ و ۲۵ آورده شده است. نزدیکی بین داده‌های هدف و خروجی مدل‌سازی شده در تصاویر نشان‌گر عملکرد خوب و دقت بالای شبکه عصبی پیچشی است.

اشکال ۲۴ و ۲۶ نمودار هیستوگرام خطا در مراحل آزمون و آموزش را برای بازده کششی نشان می‌دهند. تراکم نمودار هیستوگرام در مرکز نمودار نشان‌گر پایین بودن خطا و عملکرد بالای شبکه پیچشی است.


جدول ۵- ویژگی‌های عملکردی برای بازده کششی

		Sgdm	
		۱-۳۷۱-۳۷۱-۸	
الگوریتم آموزشی		معماری بهینه	
R <sup>2</sup>	Train	۰/۹۸۵۰	
	Test	۰/۹۸۸۸	
MSE	Train	۰/۰۰۳۱	
	Test	۰/۰۰۳۰	
RMSE	Train	۰/۰۵۶۰	
	Test	۰/۰۵۴۳	


یا دو لایه پنهان بود. بنابراین برخلاف باور عمومی که این شبکه‌ها برای تصاویر استفاده می‌شوند می‌توان از این شبکه‌ها برای مدل‌سازی و پیش‌بینی ویژگی‌ها با حذف لایه‌های پیچش و لایه‌های کاهش بعد استفاده کرد.

#### منابع


- Abbaspour-Gilandeh, Y., Jalilnezhad, H., & Mesri-Gudoshmian, T. (2013). Draft prediction of a vertical narrow tillage tool by artificial neural networks. *Journal of Agricultural Mechanization*, 1(1): 61-69. (in Persian)
- Abbaspour-Gilandeh, Y., Haghigat-Shishvan, S., Rasooli Sharabiani, V., & Fazel-Niari, Z. (2010). Design, construction and calibration of an adjustable three-point hitch dynamometer for common agricultural tractors in Iran. *Journal of Agricultural Engineering Research*, 11(2): 29-48. (in Persian)
- Abbaspour-Gilandeh, Y., & Rashidi-Mohammadabad F. (2013). Evaluation of dynamic load equations through continuous measurement of some tractor tractive performance parameters. *International Journal of Heavy Vehicle Systems*, 20(3): 222-235.
- Almaliki, S., Alimardani, R., & Omid, M. (2016). Artificial neural network-based modeling of tractor performance at different field conditions. *Agricultural Engineering International, CIGR Journal*, 18(4): 262-274.
- Ashqar, B. A. M., & Abu-Naser, S. S. (2018). Image-based tomato leaves diseases detection using deep learning. *International Journal of Academic Engineering Research*, 2(12): 10-16.
- Askari, M., Abbaspour-Gilandeh, Y., Taghinezhad, E., El Shal, A. M., Hegazy, R., & Okasha, M. (2021). Applying the response surface methodology (RSM) approach to predict the tractive performance of an agricultural tractor during semi-deep tillage. *Agriculture 2021*, 11: 1043.
- Askari, M., Abbaspour-Gilandeh, Y., Taghinezhad, E., Hegazy, R., & Okasha, M. (2022). Prediction and optimizing the multiple responses of the overall energy efficiency (OEE) of a tractor-implement system using response surface methodology. *Journal of Terramechanics 2022*, 103: 11-17.
- Bekkar, M. G. (1960). Off road locomotion. Research and development in terramechanics. Ann Arbor (MI): The University of Michigan Press.




شکل ۲۳ - یک مقایسه بین مقادیر واقعی و مقادیر پیش‌بینی شده بازده کششی برای تعداد آزمایشات در مرحله آزمون



شکل ۲۴ - نمودار هیستوگرام خطا و نیز ریشه میانگین مربعات خطا (RMSE) برای داده‌های آزمون بازده کششی



شکل ۲۵ - یک مقایسه بین مقادیر واقعی و مقادیر پیش‌بینی شده بازده کششی برای تعداد آزمایشات در مرحله آموزش



شکل ۲۶ - نمودار هیستوگرام خطا و نیز ریشه میانگین مربعات خطا (RMSE) برای داده‌های آموزش بازده کششی

#### نتیجه‌گیری

نتایج به دست آمده از این تحقیق اثبات کرد که شبکه‌های عصبی پیچشی به خوبی می‌توانند رابطه بین متغیرهای ورودی و خروجی عملکرد کششی تراکتور را آموزش ببینند. با توجه به پیچیدگی بین متغیرها و عدم وجود یک رابطه مشخص بین ویژگی‌ها، این شبکه با تعداد لایه‌های پنهان زیاد و نیز تعداد نورون بالا به خوبی می‌توانند برای پیش‌بینی و مدل‌سازی مورد استفاده قرار بگیرند. همچنین دقت این مدل بالاتر از مدل‌های پیش‌بینی شده توسط شبکه عصبی مصنوعی با یک لایه

- adaptive neuro-fuzzy inference system. *Journal of Terramechanics*, 56: 37–47.
- Taghavifar, H., & Mardani, A. (2013c). A knowledge based Mamdani fuzzy logic prediction of the motion resistance coefficient in a soil bin facility for clay loam soil. *Neural Comput Appl*, 23(1): 293-302.
- Taghavifar, H., & Mardani, A. (2014d). Application of artificial neural networks for the prediction of traction performance parameters. *Journal of the Saudi Society of Agricultural Sciences*, 13(1): 35-43.
- Taghavifar, H., Mardani, A., Karim-Maslak, H., & Kalbkhani, H. (2013). Artificial Neural Network estimation of wheel rolling resistance in clay loam soil. *Applied Soft Computing*, 13(8): 3544-3551.
- Taghavifar, H., & Mardani, A. (2014b). Applying a supervised ANN (artificial neural network) approach to the prognostication of driven wheel energy efficiency indices. *Energy*, 68: 651-657.
- Taghavifar, H., Mardani, A., & Haji Hosseinloo, A. (2015). Appraisal of artificial neural network-genetic algorithm based model for prediction of the power provided by the agricultural tractors. *Energy*, 93: 1704-1710.
- Thombare, D. G. (2019). Analysis of Effect of Tire Inflation Pressure, Inflation Fluids, Load and Speed on Tire Performance, *SAE Technical Paper*, 26, 0368.
- Tohmaz, A. S., & Hassan, A. E. (1995). Application of artificial neural networks to skidder traction performance. *Journal of Terramechanics*, 32(3): 105–114.
- Tsikiridis, N. L., Keramaris, K.D., Theocharis, J. B., & Zalidis, G. (2020). Simultaneous prediction of soil properties from VNIR-SWIR spectra using a localized multi-channel 1-D convolutional neural network. *Geoderma*, 367.
- Wang, N., Chen, F., Yu, B., & Qin, Y. (2020). Segmentation of large-scale remotely sensed images on a Spark platform: A strategy for handling massive image tiles with the MapReduce model. *ISPRS Journal of Photogrammetry and Remote Sensing*, 162: 137–147.
- Yao, G., Lei, T., & Zhong, J. (2019). A review of convolutional-neural-network-based action recognition. *Pattern Recognition Letter*, 118: 14–22.
- Young, J. S., Lin, Y. P., & Shih, P. W. (2013). Neural network approach to gain scheduling for traction control of electrical vehicles. *Applied Mechanics and Materials*, 392: 272-276.
- Bharman, P., Ahmad Saad, S., Khan, S., Jahan, I., Ray, M., & Biswas, M. (2022). Deep Learning in Agriculture: A Review. *Asian Journal of Research in Computer Science*, 13(2): 28-47.
- Chen, Y., Li, L., Whiting, M., Chen, F., Sun, Z., Song, K., & Wang, Q. (2021). Convolutional neural network model for soil moisture prediction and its transferability analysis based on laboratory Vis-NIR spectral data. *International Journal of Applied Earth Observations and Geoinformation*, 104: 102550.
- Chen, Y., Wei, Y., Wang, Q., Chen, F., Lu, C., & Lei, S. (2020). Mapping post-earthquake landslide susceptibility: a u-net like approach. *Remote Sensing*, 12(17).
- Chollet, F. (2021). Deep learning with Python. Simon and Schuster.
- Dhillon, A.; & Verma, GK. (2020). Convolutional neural network: a review of models, methodologies and applications to object detection. *Progress in Artificial Intelligence*, 9(2): 85–112.
- Khaki, S., Wang, L., & Archontoulis, S. V. (2020). A cnn-rnn framework for crop yield prediction. *Frontiers in Plant Science*, 10: 1750.
- Komandi, G. (1999). An evaluation of conception of rolling resistance. *Journal of Terramechanics*, 36(3): 159-66.
- Marakoglu, T., & Carman, K. (2010). Fuzzy knowledge-based model for prediction of soil loosening and traction efficiency in tillage. *Journal of Terramechanics*, 47(3): 173-178.
- Pentoś, K., & Pieczarka, K. (2017). Applying an artificial neural network approach to the analysis of tractive properties in changing soil conditions. *Soil & Tillage Research*, 165: 113-120.
- Rahman, A., Hossain, A., AHM, Z. A., & Rashid, M. (2012). Fuzzy knowledge-based model for prediction of traction force of an electric golf car. *Journal of Terramechanics*, 49(1): 13-25.
- RNAM. RNAM test codes and procedures for farm machinery. (1995). *In Economic and Social Commission for Asia and the Pacific, Regional Network for Agricultural Machinery*. RNAM technical publications, 12. Bangkok, Thailand
- Taghavifar, H., & Mardani, A. (2013b). Use of artificial neural networks for estimation of agricultural wheel traction force in soil bin. *Neural Comput & Applic*, 24(6): 1249–1258.
- Taghavifar, H., & Mardani, A. (2014a). On the modeling of energy efficiency indices of agricultural tractor driving wheels applying

- Zhang, W., Hansen, M. F., Volonakis, T. N., Smith, M., Smith, L., Wilson, J., Ralston, G., Broadbent, L., & Wright, G. (2018). Broad-leaf weed detection in pasture. In *2018 IEEE 3rd International Conference on Image, Vision and Computing (ICIVC), Chongqing, China, 27-29 June 2018*. IEEE., 101-105.
- Zhang, X. L., Lin, T., Xu, J. F., Luo, X., & Ying, Y. B. (2019). Deep Spectra: An end-to-end deep learning approach for quantitative spectral analysis. *Analytica Chimica Acta*, 1058: 48–57.
- Jalilnezhad, H., Abbaspour-Gilandeh, Y., Rasooli-Sharabiani, V., Mardani, A., Hernández-Hernández, J. L., Montero-Valverde, J. A., & Hernández-Hernández, M. (2023). Use of a convolutional neural network for predicting fuel consumption of an agricultural tractor. *Resources*, 12, 46. <https://doi.org/10.3390/resources12040046>
- Macmillan, R. H. (2003). The mechanics of tractor-implement performance. *Agricultural engineering international: the CIGR EJournal*. Australia: The University of Melbourne.

