

Research Article

Vol. 15, No. 2, 2025, p. 263-274

Prediction of Rut Depth in Soil Caused by Wheels Using Artificial Neural Networks

F. Nashmil¹, A. Mardani^{1*}, A. Hosainpour¹, B. Golanbari¹

1- Department of Mechanics Engineering of Biosystems, Urmia University, Urmia, Iran

(*- Corresponding Author Email: a.mardani@urmia.ac.ir)

Received: 16 October 2024

Revised: 04 November 2024

Accepted: 11 November 2024

Available Online: 24 February 2025

How to cite this article:Nashmil, F., Mardani, A., Hosainpour, A., & Golanbari, B. (2025). Prediction of Rut Depth in Soil Caused by Wheels Using Artificial Neural Networks. *Journal of Agricultural Machinery*, 15(2), 263-274. (in Persian with English abstract).
<https://doi.org/10.22067/jam.2024.90273.1295>

Introduction

The formation of ruts induced by vehicle traffic poses a significant challenge for agricultural soils due to soil compaction both at the surface and deeper layers. This phenomenon compromises vehicle performance increases energy consumption, and leads to long-term environmental degradation, such as soil erosion and fertility reduction. To enhance vehicle performance and reduce soil damage, it is crucial to accurately predict how factors such as vehicle speed, vertical load, and the number of passes impact rut depth. The findings of this study hold significant practical implications, facilitating the development for the creation of more efficient agricultural practices, while simultaneously minimizing environmental impact. The complexity of these interactions necessitates using machine learning models, especially artificial neural networks (ANNs), to predict rut depth based on input parameters. In this study, two machine learning models, namely the multilayer perceptron (MLP) and the radial basis function (RBF) networks, were employed to predict rut depth.

Materials and Methods

Experiments were conducted using a soil bin that allows for precise control of independent parameters, measuring 24 meters in length, 2 meters in width, and 0.8 meters in depth. The soil used was agricultural soil, comprising 35% sand, 22% silt, and 43% clay, with a moisture content of 8%. The tests included three independent parameters: vertical load (2, 3, and 4 kN), forward speed (1, 2, and 3 km h⁻¹), and number of wheel passes (up to 15). Two types of traction devices, including a rubber wheel and a track wheel, were tested. A caliper was used to measure the rut depth after each pass with an accuracy of 0.02 mm. The data collected from soil bin tests were used to train neural network models in MATLAB 2021-b software. The MLP model had a topology with two hidden layers and included three inputs and one output. In the RBF model, the network topology had a single hidden layer. The trial-and-error method was used to adjust the hyperparameters of the neural networks, including the number of neurons in the hidden layers, the learning rate, and momentum for the MLP network, as well as the spread rate and regularization rate for the RBF network.

Results and Discussion

Experimental data confirmed that increasing the vertical load and the number of passes resulted in deeper ruts. Conversely, an increase in speed led to a reduction in rut depth, particularly during the initial pass. Both artificial neural network (ANN) models accurately predicted rut depth, with the multilayer perceptron (MLP) neural network outperforming the radial basis function (RBF) neural network. Specifically, the root mean square error (RMSE) for the optimal MLP model, which utilized a learning rate of 0.001 and a momentum of 0.67, was 0.10. In contrast, the optimal RBF model, with an expansion rate of 0.23456, yielded an RMSE of 0.12. The findings indicate that the MLP artificial neural network model surpasses the RBF neural network model in terms of accuracy and overall performance. However, the RBF neural network exhibits a faster response time, making it particularly suitable for real-time applications.

©2025 The author(s). This is an open access article distributed under [Creative Commons Attribution 4.0 International License \(CC BY 4.0\)](https://creativecommons.org/licenses/by/4.0/).<https://doi.org/10.22067/jam.2024.90273.1295>

Conclusion

This study demonstrates the efficacy of machine learning techniques, particularly artificial neural networks (ANNs), in predicting rut depth caused by off-road vehicle traffic. Both multilayer perceptron (MLP) and radial basis function (RBF) neural networks exhibited robust predictive capabilities, with the MLP model providing slightly superior accuracy and the RBF model offering better computational efficiency. These findings highlight the potential of machine learning in modeling complex interactions between soil and vehicles, which can enhance vehicle performance, mitigate soil erosion, and guide the design of off-road vehicles. Future research directions could include investigating additional soil parameters, various vehicle configurations, and the real-world implementation of autonomous off-road vehicles to promote more environmentally sustainable operations.

Keywords: Multiple passes, Soil bin, Terramechanics, Vertical load, Vehicle speed

پیش‌بینی عمق شیار ایجاد شده توسط چرخ بر روی خاک با استفاده از شبکه‌های عصبی مصنوعی

نشمیل فرهادی^۱، عارف مردانی^{۱*}، عادل حسین پور^۱، بهزاد گل‌عنبری^۱

تاریخ دریافت: ۱۴۰۳/۰۷/۲۵

تاریخ پذیرش: ۱۴۰۳/۰۸/۲۱

چکیده

پرداختن به چالش‌های وسایل نقلیه خارج از جاده در زمین‌های غیرمتعارف، مدل‌های پیش‌بینی بر پایه‌ی یادگیری ماشین را برای تعاملات چرخ و خاک ضروری می‌کند. علی‌رغم علاقه فزاینده به یادگیری ماشین برای مطالعات تعامل چرخ و خاک، پژوهش‌های محدودی بر روی استفاده از رویکردهای مبتنی بر شبکه‌های عصبی مصنوعی برای پیش‌بینی تشکیل شیار ناشی از چرخ متمرکز شده است. هدف اصلی پژوهش حاضر پیش‌بینی تأثیر تایرهای بادی کشاورزی تحت بارها، سرعت‌ها و عبورهای متعدد بر تشکیل شیارهای خاک در شرایط انبارهای خاک کنترل شده است. در این تحقیق شبکه‌های عصبی مصنوعی با الگوریتم پس‌انتشار، برای پیش‌بینی عمق شیار مورد استفاده قرار گرفت و مدل به‌دست‌آمده با داده‌های تجربی اعتبارسنجی شد. علاوه بر این، از روش آزمون-خطا برای بهینه‌سازی فرآیندهای شبکه عصبی استفاده شد. پیکربندی بهینه برای شبکه پرسپترون چندلایه با تکانه ۰/۹ و نرخ یادگیری ۰/۳۵ به خطای جذر میانگین مربعات ۰/۱۰ دست یافت. شبکه عصبی تابع شعاعی پایه، با پهنای تابع گوسی برابر ۳/۹۰ و نرخ نرمال‌سازی برابر ۰/۰۲، جذر میانگین مربعات خطا برابر ۰/۱۲ را نشان داد. درحالی‌که شبکه پرسپترون چندلایه دقت بالایی را نشان داد، شبکه تابع شعاعی پایه هزینه‌های محاسباتی کمتر و زمان پاسخ‌دهی سریع‌تری را ارائه می‌دهد که آن را برای کاربردهای بلادرنگ مناسب می‌سازد. شبکه‌های عصبی بر روی داده‌های تجربی نادیده اعتبارسنجی شدند و قابلیت‌های قوی و تعمیم آن‌ها را تایید کردند.

واژه‌های کلیدی: انبارهای خاک، بار عمودی، ترامکانیک، سرعت وسیله نقلیه، عبور چندانگانه

مقدمه

شیارهای ایجاد شده بر اثر عبور وسایل نقلیه می‌تواند به‌طور مستقیم بر عملکرد وسیله نقلیه تأثیرگذار باشد. عمق شیار تحت تأثیر تعداد دفعات عبور وسیله نقلیه از روی خاک قرار دارد، به‌گونه‌ای که با تکرار عبور از یک مسیر مشخص، میزان فشردگی خاک افزایش یافته و در نتیجه عمق شیار با تکرار عبور بیشتر می‌شود (Calleja-Huerta, Lamandé, Green, & Munkholm, 2023; Vennik, Keller, Kuk, Krebstein, & Reintam, 2017). وزن وسایل نقلیه از دیگر عوامل تأثیرگذار بر عمق شیار ایجاد شده بر روی خاک است (Mardani, 2014; Taghavifar & Mardani, 2014).

سرعت حرکت وسایل نقلیه به‌عنوان یک عامل مؤثر در عمق شیار ایجاد شده در سطح خاک شناخته می‌شود. در مطالعات قبلی رابطه‌ی معکوسی بین سرعت حرکت و عمق شیار مشاهده شده است به این صورت که با کاهش سرعت وسیله نقلیه، مدت زمان تماس و اعمال نیرو توسط چرخ‌ها بر سطح خاک افزایش می‌یابد (Golanbari, Mardani, Hosainpour, & Taghavifar 2025). این افزایش زمان تماس منجر به تغییر شکل بیشتر خاک و در نتیجه، افزایش عمق شیار می‌گردد (Mardani & Golanbari, 2024). مطالعه‌ای که توسط کالجا-هورتا و همکاران (Calleja-Huerta et al., 2023) به بررسی تأثیر بار و تعداد عبور یک ربات خودکار سبک وزن بر

در اثر تردد وسایل نقلیه خارج جاده بر سطوح نرم از جمله خاک، نیروهای کششی و عمودی ناشی از تعامل چرخ-زمین منجر به ایجاد شیارهایی در بستر خاک می‌گردد. شیار ایجاد شده توسط چرخ که به فرورفتگی چرخ معروف است، نتیجه تغییر شکل پلاستیک خاک تحت تأثیر تنش‌های برشی و فشاری اعمال شده توسط وسیله نقلیه هست (Cambi, Certini, Neri, & Marchi, 2015).

پارامترهایی مانند وزن وسایل نقلیه، سرعت حرکت آن، مشخصات هندسی و مکانیکی چرخ‌ها (قطر، عرض و فشار باد)، تعداد عبور مکرر از یک مسیر مشخص و خصوصیات فیزیکی خاک (میزان رطوبت، تراکم‌پذیری و مقاومت برشی) روی شیار ایجاد شده تأثیر دارند. تعامل پیچیده این عوامل، عمق و شکل شیارهای ایجاد شده را تعیین می‌کند (Machuga et al., 2023; Sadeghi, Solgi, & Tsioras, 2022; Toivio et al., 2017).

۱- گروه مهندسی مکانیک بیوسیستم، دانشکده کشاورزی، دانشگاه ارومیه، ارومیه، ایران

(Email: a.mardani@urmia.ac.ir)

*- نویسنده مسئول:

 <https://doi.org/10.22067/jam.2024.90273.1295>

(Pieczarka, 2017).

با وجود مطالعات مختلفی که به استفاده از روش‌های یادگیری ماشین در زمینه‌ی تعامل وسیله نقلیه با خاک پرداخته‌اند، هنوز مطالعات بسیار محدودی به بررسی و پیش‌بینی عمق شیار ایجادشده توسط این تعامل، با استفاده از این روش‌ها، اختصاص داده شده است. در این راستا، هدف از این تحقیق پیش‌بینی عمق شیار ناشی از عبور وسیله نقلیه بر روی خاک با استفاده از شبکه‌های عصبی تحت شرایط مختلف از بار عمودی، تعداد عبور و سرعت حرکت است. با توجه به اهمیت موضوع، این تحقیق تلاش می‌کند تا شکاف‌های موجود در روش‌شناسی‌های فعلی را پر کند و با استفاده از رویکردهای مبتنی بر یادگیری ماشین، مدلی ارائه دهد که قادر به پیش‌بینی عمق فرورفتگی خاک به‌طور دقیق‌تری باشد. نتایج این تحقیق می‌تواند کاربردهای گسترده‌ای در زمینه‌های مختلف، از جمله کشاورزی و صنایع داشته باشد و به توسعه مدل‌هایی کارآمدتر برای پیش‌بینی رفتار خاک در برابر عبور وسیله نقلیه کمک کند.

مواد و روش‌ها


آزمایش‌های میدانی و تحصیل داده

برای انجام آزمایش‌ها به‌منظور ارزیابی اثر متغیرهای تعداد عبور، بار عمودی و سرعت پیش‌روی بر روی عمق شیار ایجادشده توسط چرخ از یک واحد انباره خاک استفاده شد. انباره خاک مورد استفاده از نوع ثابت است که به‌صورت یک سازه فلزی بر روی سطح زمین قرار گرفته و محیط خاک کاملاً به‌صورت جدا از سطح زمین و در قالب یک کانال خاک طراحی شده است. انباره خاک شامل شاسی، کانال خاک، حامل، سامانه‌های کنترل و واحد تولید توان برای حرکت حامل است. این کانال دارای طولی معادل ۲۴ متر است. عرض کانال ۲ متر و عمق لایه خاک ۰/۸ متر است. این انباره خاک مجهز به آزمونگر تک‌چرخ باقابلیت نصب انواع چرخ است. استفاده از انباره خاک در آزمایش‌ها امکان کنترل کامل شرایط آزمایش را فراهم می‌سازد. شمای کلی سیستم در شکل ۱ نمایش داده شده است.

خاک مورد استفاده در انباره خاک از خاک‌های کشاورزی منطقه جمع‌آوری شد و بعد از انتقال به انباره خاک مراحل آماده‌سازی آن برای آزمایش‌ها انجام شد. این آماده‌سازی به دلیل فراهم کردن شرایط نسبتاً یکنواخت و همگن برای محیط آزمایش است که شامل چنگ‌زنی و تسطیح خاک بود. طول و عرض مناسب انباره خاک امکان انجام همه‌ی آزمایش‌ها با یک‌بار آماده‌سازی خاک را فراهم کرد. برای این منظور کل فضای انباره خاک به ۹ کرت تقسیم شد. مشخصات خاک مورد استفاده پس از آماده‌سازی در جدول ۱ آمده است.

ویژگی‌های فیزیکی خاک شنی-لومی پرداخته است، تأثیر تعداد عبور و بارگذاری مکرر بر روی خاک را روشن نموده است. نتایج نشان داد که عمق شیار با افزایش تعداد عبورهای ربات افزایش می‌یابد. همچنین، تخلخل مؤثر هوا و قابلیت نفوذپذیری هوا با افزایش تعداد عبورها کاهش می‌یابد. تحقیق انجام‌شده توسط طباطبایی‌کلور (Tabatabaekoloor, 2016) به بررسی تأثیر رطوبت خاک، تعداد عبور و وزن تراکتور بر فرورفتگی خاک پرداخته است؛ نتایج این مطالعه نشان داد که افزایش وزن تراکتور، تعداد عبور و رطوبت خاک به‌ترتیب باعث افزایش ۴۷٪، ۳۱٪ و ۲۸٪ در میزان فرورفتگی خاک می‌شود. در مطالعه‌ای توسط لیو و همکاران (Liu, Ayers, Howard, & Anderson, 2010)، اثر پنج تیمار شامل بافت خاک، رطوبت، نوع وسیله نقلیه، شعاع و سرعت چرخش، بر روی تشکیل عمق شیار مورد بررسی قرار گرفت، نتایج نشان داد که تمامی پارامترهای وسیله نقلیه (نوع وسیله نقلیه، وزن، سرعت و شعاع گردش) و پارامترهای خاک (بافت خاک و رطوبت) از نظر آماری بر تشکیل شیارها معنی‌دار هستند. در یک مطالعه دیگر، اثر تعداد عبور بر روی عمق شیار ایجادشده توسط وسیله نقلیه مورد بررسی قرار گرفت. در این مطالعه عمق شیار در تردد اول و دهم اندازه‌گیری شد. نتایج نشان داد که بیشترین تغییر شکل خاک در تردد اول ایجاد می‌شود، همچنین در این مطالعه به ضرورت انجام تحقیقات بیشتر بر روی رفتار مکانیکی خاک به‌ویژه خاک‌های نرم در اثر عبور وسیله نقلیه تأکید شد (Vennik, Kuk, Krebstein, Reintam, & Keller, 2019).

استفاده از روش‌های یادگیری ماشین در پرداختن به چالش‌های پیش‌روی وسایل نقلیه برون‌جاده‌ای در زمین‌های غیرمتعارف به دلیل توانایی آن در پردازش داده‌ها، تشخیص الگوها و پیش‌بینی روابط پیچیده در تعاملات چرخ و خاک بسیار مهم است (Golanbari, Mardani, Hosainpour, & Taghavifar, 2024). در سال‌های اخیر مطالعاتی با روش‌های مبنی بر یادگیری ماشین در مطالعات تعامل وسیله نقلیه با خاک انجام شده است. در یک مطالعه تأثیر نرخ نفوذ صفحات بر ویژگی‌های مکانیکی خاک با ابزار بوامتر و پیش‌بینی پارامترهای خاک با شبکه عصبی مورد بررسی قرار گرفت (Golanbari et al., 2024). نتایج این تحقیق نشان داد تغییر در سرعت نفوذ صفحات باعث تغییر در پارامترهای فیزیکی و مکانیکی خاک در این روش می‌شود، با این حال شبکه عصبی با دقت بالایی قادر به پیش‌بینی پارامترهای مکانیکی خاک بود. در تحقیق دیگری برای بررسی اثرات بافت خاک، رطوبت، فشردگی خاک و همچنین تغییر شکل افقی و بار عمودی بر نیروی کششی و راندمان کششی، از شبکه‌های عصبی مصنوعی استفاده شد. یافته‌های این مطالعه نتایج قابل‌توجهی برای قدرت تخمین شبکه‌های عصبی ارائه کرد (Pentós



شکل ۱- انباره خاک و اجزای آن: ۱- شاسی، ۲- اینورتر، ۳- سیستم جمع‌آوری اطلاعات، ۴- عامل کشش، ۵- بار عمودی استاتیک
Fig.1. Soil bin and its components: 1- Chassis, 2- Inverter, 3- Data logger, 4- Traction device, and 5- Static vertical load

جدول ۱- مشخصات فیزیکی و مکانیکی خاک مورد استفاده در انباره خاک.

Table 1- Physical and mechanical characteristics of the soil in soil bin.

فاکتور Parameter	مقدار Value	منبع Reference
شن Sand	35%	Golanbari and Mardani, 2024
لای Silt	22%	
رس Clay	43%	
محتوای رطوبت Moisture content	8%	اندازه‌گیری شده
چگالی ظاهری Bulk density	1460 kg cm ⁻³	
مدول یانگ Young's modulus	0.3 MPa	
ضریب پواسون Poisson's ratio	0.29	Golanbari and Mardani, 2024
ضریب اصطکاک داخلی Angle of internal friction	32	

می‌شود (شکل ۱). نیروی محرکه برای جابه‌جایی حامل توسط یک عدد الکتروموتور با توان ۲۲ کیلووات (۳۰ اسب بخار)، تأمین می‌شود. به‌منظور کنترل سرعت دورانی الکتروموتور که سرعت پیشروی حامل را تعیین می‌کند، از یک عدد اینورتر با نام تجاری LS ساخت شرکت LG محصول کشور کره جنوبی با محدوده فرکانس ۰ تا ۵۰ هرتز با گام تغییر ۰/۰۱ هرتز استفاده شد.

پارامترهای آزمایش شامل ۱۵ سطح عبور، ۳ سطح بار عمودی ۲، ۳ و ۴ کیلونیوتن و ۳ سطح سرعت پیشروی ۱، ۲ و ۳ کیلومتر در ساعت می‌شود. دلیل انتخاب ۱۵ سطح عبور این بود که اطمینان حاصل شود که خاک به حداکثر نشست خود تحت بارگذاری‌های مختلف برسد.

عامل کشش مورد استفاده یک چرخ تراکتور لاستیکی با مشخصات Barez 8.25-16 (8) P.R HL ساخت ایران هست که توسط یک شفت فولادی و دو یاتاقان در دو سر به قاب چرخ متصل

جمع‌آوری داده‌ها

انتخاب شد، در هر بار عبور عمق شیار در این سه نقطه اندازه‌گیری و ثبت شد و در نهایت میانگین اندازه‌گیری‌های ثبت‌شده در این سه نقطه، به‌عنوان عمق شیار در تردد مشخص ثبت گردید. داده‌های ثبت شده به‌منظور تجزیه و تحلیل به نرم‌افزار متلب انتقال داده شد.

برای اندازه‌گیری داده‌ها پس از عبور چرخ، عمق شیار ایجادشده توسط چرخ، توسط یک کولیس ساعتی با دقت ۰/۰۲ میلی‌متر اندازه‌گیری شد (شکل ۲). برای اطمینان از صحت داده‌های ثبت‌شده، اندازه‌گیری عمق شیار سه نقطه در انباره خاک و در مسیر حرکت



شکل ۲- اندازه‌گیری عمق شیار ایجادشده توسط چرخ

Fig.2. Measuring the rut depth caused by the wheel

مقادیر واقعی در یک مجموعه داده را محاسبه می‌کند که از رابطه (۱) محاسبه می‌شود.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (1)$$

n تعداد کل مشاهدات در مجموعه داده است، y مقدار واقعی متغیر هدف برای مشاهده نام است و \hat{y} مقدار پیش‌بینی شده متغیر هدف برای مشاهده نام است.

ضریب تعیین نشان‌دهنده نسبت واریانس در متغیر وابسته شاخص دیگر مورد استفاده است که توسط متغیرهای مستقل در مدل توضیح داده می‌شود. مقدار ضریب تعیین از ۰ تا ۱ متغیر است، مقادیر بالاتر نشان‌دهنده تناسب بهتر مدل است که از رابطه (۲) محاسبه می‌شود.

$$R^2 = 1 - \frac{SS_{res}}{SS_{tot}} \quad (2)$$

SS_{res} مجموع مجذور باقی‌مانده‌ها است که خطای کل مدل رگرسیون و SS_{tot} مجموع مجذورات است که کل تغییرات متغیر وابسته را نشان می‌دهد.

میانگین قدر مطلق خطا به میانگین تفاوت‌های مطلق بین مقادیر واقعی و پیش‌بینی شده مدل اشاره دارد و نشان می‌دهد که مدل، به‌طور میانگین، چقدر با مقدار واقعی اختلاف دارد. میانگین قدر مطلق خطا همیشه غیرمنفی است و مقدار کمتر آن به معنای عملکرد بهتر

معرفی شبکه‌های عصبی

در سال‌های اخیر، علاقه فزاینده‌ای به استفاده از روش‌های مبتنی بر هوش مصنوعی، از جمله شبکه‌های عصبی مصنوعی، برای مطالعات تعامل چرخ-خاک به‌وجود آمده است. پیش‌بینی این تعاملات با ورودی‌ها (متغیرهای مستقل) با شبکه‌های عصبی مصنوعی دارای مزیت غیرقابل‌انکاری نسبت به روش‌های مرسوم است. روابط غیرخطی بین متغیرهای وابسته و متغیرهای مستقل را می‌توان با دقت بالایی توسط شبکه‌های عصبی مصنوعی استخراج کرد. در این مطالعه از یک شبکه عصبی پرسپترون چندلایه^۱ با الگوریتم پس‌انتشار^۲ و همچنین از شبکه عصبی شعاعی پایه^۳ در نظر گرفته شده است.

در این تحقیق برای ارزیابی عملکرد شبکه‌های عصبی از شاخص جذر میانگین مربعات خطا، ضریب تعیین و میانگین قدر مطلق خطا استفاده شد. این شاخص‌ها جزو شاخصه‌های متداول در بررسی عملکرد شبکه عصبی هستند. جذر میانگین مربعات خطا یک معیار رایج برای ارزیابی دقت یک مدل پیش‌بینی، به‌ویژه در تحلیل رگرسیون است. این شاخص میانگین بزرگی خطاهای بین مقادیر پیش‌بینی شده و

- 1- Multi-layer perceptron
- 2- Backpropagation algorithm
- 3- Radial basis function

مدل است و از رابطه (۳) محاسبه می‌شود.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3)$$

برای آموزش شبکه عصبی نیاز است که فرآپارامترهای شبکه تنظیم شود. فرآپارامترها تنظیماتی هستند که شبکه آن‌ها را از داده‌ها یاد نمی‌گیرد بلکه قبل از شروع فرآیند آموزش توسط کاربر مشخص می‌شوند. اهمیت فرآپارامترها در تأثیر آن‌ها بر عملکرد، همگرایی و توانایی تعمیم شبکه‌های عصبی است.

فرآپارامترهای شبکه عصبی پرسپترون چندلایه شامل تعداد نورون‌های لایه پنهان، تکانه^۱ و نرخ یادگیری^۲ و فرآپارامترهای شبکه عصبی شعاعی پایه شامل پهنای تابع گوسی^۳ و نرخ نرمال‌سازی^۴ است. برای تنظیم مناسب و بهینه فرآپارامترها هر دو شبکه از روش آزمون و خطا استفاده شد. پس از انتخاب بهترین معماری از نظر کمترین مقدار جذر میانگین مربعات خطا انتخاب و به‌عنوان معماری شبکه انتخاب شد. ورودی‌های شبکه شامل سرعت پیشروی چرخ، بار عمودی روی تایلر و تعداد تردد است. از طرفی خروجی شبکه عمق شیار ایجاد شده است.

شبکه عصبی پرسپترون چندلایه

معماری شبکه عصبی پرسپترون چندلایه استفاده شده در این مطالعه شامل یک شبکه با دو لایه پنهان بود که در آن از تابع انتقال سیگموئید برای نگاشت داده‌ها از لایه‌های پنهان استفاده شد. تعداد کل داده‌های اندازه‌گیری شده برای عمق شیار برابر ۱۳۵ داده بود که از این بین، یک مجموعه داده جدا شد و به‌عنوان داده‌های دیده‌نشده بعد از آموزش شبکه عصبی برای بررسی تعمیم‌پذیری شبکه به کار برده شد. از کل داده‌های باقی‌مانده ۷۰ درصد برای داده‌های آموزش، ۱۵ درصد برای داده‌های اعتبارسنجی و ۱۵ درصد برای داده‌های آزمون مورد استفاده قرار گرفت. همچنین از ۳ تابع آموزشی به‌عنوان الگوریتم آموزش استفاده گردید که کمترین جذر میانگین مربعات خطا به‌عنوان بهترین عملکرد تابع آموزش برای شبکه برگزیده شد. همچنین از روش آزمون و خطا برای تعیین تعداد بهینه نورون‌ها در لایه‌های پنهان و همچنین پارامترهای تکانه و نرخ یادگیری برای شبکه عصبی استفاده شد. بدین منظور تعداد نورون‌ها از ۱ تا ۱۵ نورون به ترتیب افزایش یافت و همچنین نرخ یادگیری و تکانه در بازه صفر تا یک با گام ۰/۰۵ برای هر مقدار تعداد نورون لایه پنهان افزایش یافت. بعد از به‌دست آمدن مقادیر بهینه فرآپارامترها شبکه عصبی در ۵۰۰ دوره و ۳۰۰ تکرار آموزش داده شد.

شبکه عصبی شعاعی پایه

شبکه‌های عصبی تابع شعاعی پایه مدل‌های قدرتمندی هستند که به دلیل توانایی خود در تقریب توابع پیچیده و مدیریت روابط غیرخطی در داده‌ها شناخته شده‌اند. شبکه‌های عصبی شعاعی پایه به‌طور معمول دارای یک لایه پنهان هستند که تعداد نورون‌های لایه پنهان آن توسط خود شبکه در هر تکرار تنظیم می‌شود. با این حال، عملکرد شبکه‌های شعاعی پایه به انتخاب مناسب فرآپارامترها مانند پهنای تابع گوسی و نرخ نرمال‌سازی بستگی دارد. پارامتر پهنای تابع گوسی توابع پایه شعاعی، پهنای تأثیر آن‌ها بر خروجی شبکه را کنترل می‌کند، درحالی‌که پارامتر نرمال‌سازی پیچیدگی و ظرفیت مدل را تعیین می‌کند. بهینه‌سازی نرخ نرمال‌سازی و پهنای تابع گوسی شبکه عصبی تابع پایه شعاعی با استفاده از روش آزمون و خطا انجام شد. پارامترهای نرخ نرمال‌سازی در بازه ۰/۰۱ تا ۰/۱۰ با گام ۰/۰۰۵ و پهنای تابع گوسی برای شبکه عصبی در بازه ۱ تا ۱۰ با گام ۰/۱۰ افزایش یافت. شبکه با ۱۰۰ تکرار، برای هر مقدار از پارامترهای نرخ نرمال‌سازی و پهنای تابع گوسی آموزش داده شد.

نتایج و بحث

شبکه‌های عصبی مصنوعی، شامل مدل‌های پرسپترون چندلایه و تابع شعاعی پایه، برای پیش‌بینی عمق شیار بر اساس پارامترهای ورودی (سرعت وسیله نقلیه، بار عمودی و عبورهای متعدد)، توسعه و آموزش داده شدند. عملکرد مدل‌های شبکه عصبی با استفاده از معیارهای ارزیابی مانند جذر میانگین مربعات خطا و ضریب تعیین مورد ارزیابی قرار گرفت.

ارزیابی عملکرد شبکه عصبی پرسپترون چندلایه


نمودار شکل ۳ ارتباط بین تکانه و نرخ یادگیری با جذر میانگین مربعات خطا در یک شبکه عصبی پرسپترون چندلایه را نمایش می‌دهد. تغییرات در مقادیر جذر میانگین مربعات خطا بر اساس تنظیمات مختلف تکانه و نرخ یادگیری نمایانگر پیچیدگی تأثیر این دو پارامتر کلیدی بر فرآیند بهینه‌سازی شبکه عصبی است. هر کدام از این پارامترها می‌توانند تأثیرات متفاوتی بر عملکرد شبکه عصبی داشته باشند و بهینه‌سازی این پارامترها اهمیت بالایی در بهبود دقت عملکرد مدل دارد.

نرخ یادگیری، سرعت به‌روزرسانی وزن‌ها در هر گام از فرآیند آموزش را نشان می‌دهد. اگر نرخ یادگیری بسیار بالا باشد، مدل به سرعت وزن نورون‌ها را تغییر می‌دهد و ممکن است از مقدار بهینه عبور کند و شبکه به جواب جهانی همگرا نشود. در مقابل، اگر نرخ یادگیری خیلی پایین باشد، فرآیند یادگیری آهسته‌تر شده و شبکه ممکن است در حداقل‌های محلی گرفتار شود. تکانه به الگوریتم

- 1- Momentum
- 2- Learning Rate
- 3- Spread
- 4- Regularization

یک پارامتر اساسی مؤثر بر عملکرد شبکه عصبی پرسپترون چندلایه انتخاب یک الگوریتم یادگیری مناسب است. برای شناسایی مناسب‌ترین الگوریتم یادگیری پس‌انتشار، سه الگوریتم یادگیری پس‌انتشار مختلف مورد آزمایش قرار گرفتند. عملکرد شبکه عصبی با هر الگوریتم یادگیری مورد ارزیابی قرار گرفت. جدول ۲ معیارهای عملکرد شبکه عصبی را برای الگوریتم‌های یادگیری مختلف ارائه می‌دهد.

کمک می‌کند تا از تاریخچه گرادینان برای به‌روزرسانی وزن‌ها استفاده کند، به طوری که تغییرات در وزن‌ها به تدریج انجام شده و از نوسانات زیاد جلوگیری شود. اگر تکانه به درستی تنظیم نشود، ممکن است شبکه دچار نوسانات شدید شود. بدترین عملکرد شبکه با تکانه ۰/۸۵ و نرخ یادگیری ۰/۴۵ است که به خطای جذر میانگین مربعات ۲/۰۸ منجر شده است. در مقابل بهترین عملکرد شبکه عصبی با تکانه ۰/۹ و نرخ یادگیری ۰/۳۵ با خطای جذر میانگین مربعات ۰/۱۰ و میانگین قدر مطلق خطا ۰/۰۸ به دست آمد.



شکل ۳- تأثیر تکانه و نرخ یادگیری بر میزان خطای جذر میانگین مربعات در مدل یادگیری شبکه پرسپترون چندلایه
Fig.3. The effect of momentum and learning rate on the RMSE in the MLP learning model

جدول ۲- توابع انتقال و الگوریتم‌های آموزشی پس‌انتشار در شبکه عصبی مصنوعی پرسپترون چندلایه

Table 2- Transfer functions and backpropagation training algorithms in the multilayer perceptron artificial neural network

الگوریتم آموزشی Training algorithm	R ²	RMSE	MAE
لونیبرگ-مارکوارت پس‌انتشار Levenberg-Marquardt backpropagation (trainlm)	0.999982	0.10	0.08
پس‌انتشار ارتجاعی Resilient backpropagation (trainrp)	0.999501	0.71	0.43
پس‌انتشار بی‌بی Bayesian regularization backpropagation (trainbr)	0.999969	0.17	0.10

به‌عنوان الگوریتم یادگیری انتخاب شد. جدول ۳ نشان‌دهنده نتایج آموزش با چیدمان بهینه شبکه عصبی پرسپترون چندلایه و فرآیندها است. در معماری بهینه، مقادیر مربوط به نرخ یادگیری، تکانه، جذر میانگین مربعات خطا و ضریب

همان‌طور که از جدول ۳ مشاهده می‌شود از بین الگوریتم‌های یادگیری پس‌انتشار، الگوریتم یادگیری لونیبرگ-مارکوارت با خطای جذر میانگین مربعات معادل ۰/۱۳، ضریب تعیین برابر ۰/۹۹۸۳۴ و میانگین قدر مطلق خطا برابر ۰/۱۰ بهترین عملکرد را داشت؛ بنابراین

تعیین در جدول ارائه شده‌اند.

که مدل می‌تواند به‌خوبی روند داده‌های تجربی را شناسایی و پیش‌بینی کند.

جدول ۳- ویژگی‌های به‌دست‌آمده در آموزش پرسپترون چندلایه با پیکره‌بندی بهینه‌شده


Table 3- Features obtained in multi-layer perceptron training with optimized topology

پیکره‌بندی Topology	3-14-12-1
نرخ یادگیری Learning Rate	0.35
تکانه Momentum	0.90
جذر میانگین مربعات خطا RMSE	0.10
ضریب تعیین R-square	0.999982
میانگین قدر مطلق خطا MAE	0.08

ارزیابی عملکرد شبکه عصبی شعاعی پایه
پهنای تابع گوسی بر نحوه تأثیرگذاری هر نود (نورون) در لایه مخفی شبکه بر داده‌های ورودی تأثیرگذار است. مقادیر کمتر پهنای باعث می‌شود که هر نورون فقط به محدوده کوچکی از ورودی‌ها حساس باشد و این ممکن است موجب ایجاد مدل‌های پیچیده‌تر و بیش‌برازش شبکه شود. پارامتر نرمال‌سازی به کنترل پیچیدگی مدل کمک می‌کند. نرمال‌سازی از بیش‌برازش مدل به داده‌های آموزشی جلوگیری می‌کند.

نمودار شکل ۳ نشان‌دهنده رابطه بین پهنای تابع گوسی و پارامتر نرمال‌سازی با جذر میانگین مربعات خطا در شبکه عصبی شعاعی پایه است. عملکرد بهینه شبکه عصبی با اندازه پهنای ۳/۹۰ و نرخ نرمال‌سازی ۰/۰۲ به‌دست آمد که منجر به خطای جذر میانگین مربعات ۰/۱۲ و میانگین قدر مطلق خطا ۰/۱۱ شد. شکل ۴ عملکرد شبکه عصبی را به‌ازای مقادیر مختلف فرآپارامترها نشان می‌دهد.

در جدول ۳، معماری ۳-۱۴-۱۲-۱ با خطای جذر میانگین مربعات برابر ۰/۱۰ و میانگین قدر مطلق خطا ۰/۰۸، با کمترین مقدار خطا، در بین سایر معماری‌ها بهترین عملکرد را در کاهش خطا داشته است. همچنین ضریب تعیین با مقدار برابر ۰/۹۹۹۸۴ نشان می‌دهد



شکل ۴- تأثیر پارامترهای پهنای تابع گوسی و نرخ نرمال‌سازی بر میزان خطای جذر میانگین مربعات در مدل یادگیری شبکه تابع شعاعی

Fig.4. The effect of spread and regularization rate on the RMSE in the RBF network learning model

شبکه در این نقطه منجر به عملکرد ضعیف‌تری شده است. این می‌تواند به این معنا باشد که مدل به دلیل مقادیر نامناسب فرآپارامترها دچار بیش‌برازش یا کم‌برازش شده است. نقطه دوم که در پهنای تابع گوسی برابر ۳/۹۰ و نرخ نرمال‌سازی برابر ۰/۰۲ قرار دارد، جذر

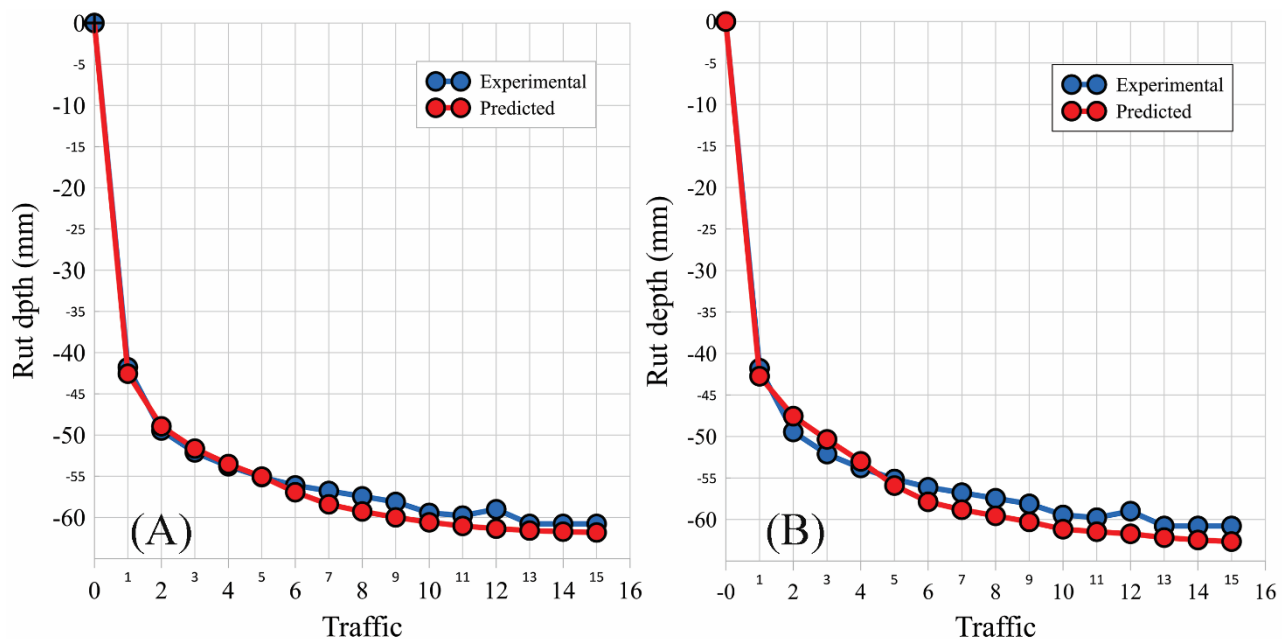
در نمودار شکل ۴ دو نقطه خاص برجسته شده‌اند. اولین نقطه در پهنای تابع گوسی برابر ۳/۵۰ و نرخ نرمال‌سازی برابر ۰/۰۹ قرار دارد که در آن مقدار جذر میانگین مربعات خطا برابر ۰/۳ است. این مقدار جذر میانگین مربعات خطا نشان می‌دهد که تنظیمات فرآپارامترهای

شیار وابسته به عملکرد شبکه‌های عصبی روی داده‌های دیده‌نشده است. داده‌های دیده‌نشده، اشاره به داده‌هایی دارند که در مرحله آموزش استفاده نمی‌شوند. این امکان ارزیابی تعمیم مدل را فراهم می‌کند و اطمینان حاصل می‌کند که مدل به جای تطبیق بیش‌ازحد با داده‌های آموزشی، الگوهای اساسی را یاد گرفته است. علاوه بر این، ارزیابی مدل بر روی داده‌های آزمایشی دیده‌نشده، معیارهای عملکردی شبکه را ارائه می‌کند که برای کاربردی بودن مدل در دنیای واقعی و اطمینان از آمادگی استقرار قوی ضروری است. در شکل ۵ عمق شیار اندازه‌گیری شده در آزمایش‌های میدانی و پیش‌بینی شده توسط شبکه عصبی پرسپترون چندلایه و شعاعی پایه نمایش داده شده است.

میانگین مربعات خطا برابر $0/12$ را نشان می‌دهد که مقدار بسیار کمتری است. این مقدار کم جذر میانگین مربعات خطا بیانگر دقت بیشتر مدل و تنظیم بهینه‌تر این دو پارامتر است. با توجه به ساختار نمودار شکل ۴، می‌توان مشاهده کرد که مقدار پهنای تابع گوسی به‌تنهایی نمی‌تواند تعیین‌کننده اصلی دقت مدل باشد. تعامل بین پهنای تابع گوسی و نرخ نرمال‌سازی نقش کلیدی در کاهش خطا و بهبود عملکرد شبکه ایفا می‌کند.

مقایسه نتایج رگرسیون در شبکه‌های عصبی پرسپترون چندلایه و شعاعی پایه

عملکرد نهایی شبکه‌های عصبی، مستلزم بررسی پیش‌بینی عمق



شکل ۵- مقایسه داده‌های تجربی و مقادیر پیش‌بینی شده از عمق شیار به‌دست‌آمده از مدل‌های شبکه عصبی

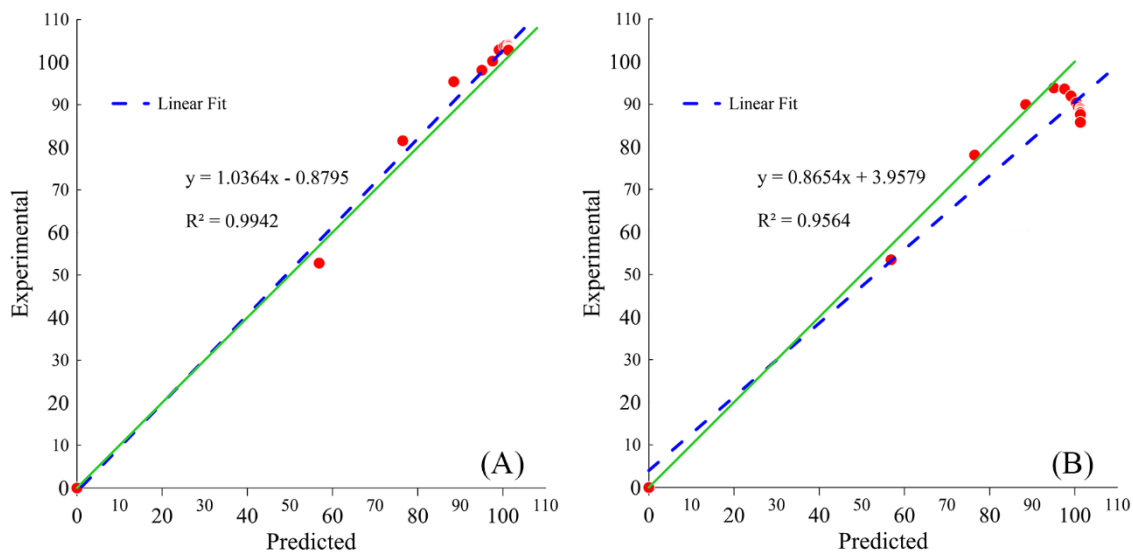
Fig.5. Comparison of experimental data and predicted values of rut depth obtained from (A) MLP and (B) RBF models

داده‌های دیده‌نشده ارائه می‌دهد. اگرچه شبکه عصبی پرسپترون چندلایه پیش‌بینی‌های کمی دقیق‌تر ارائه می‌دهد، با این حال شبکه عصبی شعاعی پایه هزینه‌های محاسباتی کمتر و زمان‌های پاسخ سریع‌تری دارد. این ویژگی‌ها شبکه عصبی شعاعی پایه را برای کاربردهای بلادرنگ مناسب‌تر می‌کند.

ارزیابی عملکرد رگرسیون بین شبکه‌های عصبی پرسپترون چندلایه و تابع پایه شعاعی مشخص می‌کند کدام شبکه عصبی قابلیت بهتری در پیش‌بینی عمق شیار ارائه می‌دهد. شکل ۶ نمایش رگرسیون داده‌های دیده‌نشده را بعد از آموزش شبکه‌های عصبی پرسپترون چندلایه (الف) و شعاعی پایه (ب) نمایش می‌دهد.

شکل ۵-الف پیش‌بینی تغییرات در عمق شیار را با استفاده از شبکه عصبی پرسپترون چندلایه نشان می‌دهد. شکل ۵ نشان می‌دهد که شبکه عصبی به‌طور مؤثر تغییرات در داده‌های تجربی را ردیابی می‌کند. تردد‌های اولیه بسیار مهم هستند زیرا با بالاترین سطوح تغییر شکل خاک، مقاومت در برابر غلتش چرخ و فشردگی خاک همراه است؛ بنابراین توانایی شبکه برای پیش‌بینی دقیق این تغییرات اولیه از اهمیت قابل توجهی برخوردار است.

شکل ۵-ب پیش‌بینی تغییرات عمق شیار ایجادشده توسط عوامل کششی با استفاده از شبکه عصبی شعاعی پایه را نشان می‌دهد. مشاهدات نشان می‌دهد که این شبکه عصبی نیز به‌طور مؤثر فرآیند تغییرات در عمق شیار را یاد می‌گیرد و عملکرد مناسب را روی



شکل ۶- نتایج رگرسیون برای داده‌های دیده‌نشده شبکه‌های عصبی پرسپترون چندلایه و تابع شعاعی پایه
Fig.6. Regression results for unseen data of (A) MLP and (B) RBF neural networks

توسط تایرهای کشاورزی لاستیکی را فراهم می‌کند. عملکرد شبکه‌های عصبی آموزش‌دیده با استفاده از جذر میانگین مربعات خطا و ضریب تعیین ارزیابی شد. هر دو شبکه پرسپترون چندلایه و شعاعی پایه دقت بالایی در پیش‌بینی عمق شیار نشان دادند. شبکه پرسپترون چندلایه عملکرد کمی بهتری از شبکه شعاعی داشت. از طرفی، شبکه شعاعی پایه هزینه‌های محاسباتی کمتر و زمان پاسخ سریع‌تر را نشان داد که آن را برای کاربردهای بلادرنگ که در آن سرعت پاسخ بسیار مهم است به ابزار مناسب‌تری تبدیل می‌کند. قابلیت‌های تعمیر و استحکام شبکه‌های عصبی با ارزیابی عملکرد آن‌ها بر روی داده‌های تجربی دیده‌نشده تأیید شد. نتایج کارایی مدل‌های آموزش‌دیده را در گرفتن الگوهای زیربنایی و پیش‌بینی دقیق تشکیل عمق شیارها در شرایط کشتش مختلف تأیید کرد. این مطالعه ظرفیت روش‌های یادگیری ماشین، به‌ویژه شبکه‌های عصبی مصنوعی، در مدل‌سازی دقیق و پیش‌بینی تعاملات خاک و خودرو را نشان می‌دهد. این یافته‌ها به درک دینامیک تشکیل شیار کمک می‌کند و پایه‌ای برای بهینه‌سازی عملکرد خودرو، کاهش فرسایش و تراکم خاک و بهبود طراحی خودروهای برون‌جاده را فراهم می‌کند.

مشارکت نویسندگان

نشمیل فرهادی: روش‌شناسی، مفهوم‌سازی، جمع‌آوری داده‌ها، پردازش داده‌ها، استخراج و تهیه متن اولیه
 عارف مردانی: نظارت و مدیریت، مفهوم‌سازی، روش‌شناسی، اعتبارسنجی، ویرایش متن
 عادل حسین پور: نظارت و مدیریت، مفهوم‌سازی، اعتبارسنجی،

نمودار رگرسیون شبکه عصبی پرسپترون چندلایه و شبکه عصبی شعاعی پایه به ترتیب با ضریب تعیین $0/9942$ و $0/9564$ همبستگی بالایی را بین مقادیر تجربی و پیش‌بینی شده نشان می‌دهد، همان‌طور که با مقدار ضریب تعیین نشان داده شده است. این همبستگی مناسب نشان می‌دهد که پیش‌بینی‌های مدل دقیق هستند. معادله خطوط رگرسیون از این نتیجه‌گیری پشتیبانی می‌کنند.

عملکرد شبکه عصبی MLP و RBF بستگی به نوع مسئله دارد. شبکه عصبی پرسپترون چندلایه از نظر مقدار ضریب تعیین و جذر میانگین مربعات خطا دقت پیش‌بینی، از شبکه تابع پایه شعاعی بهتر عمل می‌کند. یافته‌های این مطالعه از نظر عملکرد شبکه عصبی با یافته‌های چامپاتی و همکاران (Champati *et al.*, 2023) و کاشانی‌نژاد و همکاران (Kashaninejad, Dehghani, & Kashiri, 2009)، همخوانی دارد.

نتیجه‌گیری

این مطالعه یک تحقیق جامع در مورد کاربرد روش‌های یادگیری ماشین، به‌ویژه شبکه‌های عصبی مصنوعی، برای مدل‌سازی و پیش‌بینی تشکیل عمق شیار ناشی از تردد وسایل نقلیه خارج از جاده ارائه می‌کند. دو معماری شبکه عصبی متمایز، پرسپترون چندلایه و تابع پایه شعاعی، با استفاده از داده‌های تجربی به‌دست‌آمده از آزمایش‌های انباره خاک، توسعه و آموزش داده شدند. انباره خاک امکان ارزیابی سازمان‌یافته اثرات مولفه‌های مختلف، از جمله سرعت وسیله نقلیه، بار عمودی و عبورهای متعدد، بر تشکیل عمق شیارها

References

1. Calleja-Huerta, A., Lamandé, M., Green, O., & Munkholm, L. J. (2023). Impacts of load and repeated wheeling from a lightweight autonomous field robot on the physical properties of a loamy sand soil. *Soil and Tillage Research*, 233, 105791. <https://doi.org/10.1016/j.still.2023.105791>
2. Cambi, M., Certini, G., Neri, F., & Marchi, E. (2015). The impact of heavy traffic on forest soils: A review. *Forest Ecology and Management*, 338, 124-138. <https://doi.org/10.1016/j.foreco.2014.11.022>
3. Champati, B. B., Padihari, B. M., Ray, A., Jena, S., Sahoo, A., Mohanty, S., Patnaik, J., Naik, P. K., Panda, P. C., & Nayak, S. (2023). Implementation of multilayer perceptron (MLP) and radial basis function (RBF) neural networks for predicting Shatavarin IV content in *Asparagus racemosus* accessions. *Industrial Crops and Products*, 191, 115968. <https://doi.org/10.1016/j.indcrop.2022.115968>
4. Golanbari, B., & Mardani, A. (2024). An analytical model for stress estimation at the soil-tire interface using the dynamic contact length. *Journal of Terramechanics*, 111, 1-7. <https://doi.org/10.1016/j.jterra.2023.08.006>
5. Golanbari, B., Mardani, A., Farhadi, N., & Reina, G. (2024). Machine learning applications in off-road vehicles interaction with terrain: An overview. *Journal of Terramechanics*, 116, 101003. <https://doi.org/10.1016/j.jterra.2024.101003>
6. Golanbari, B., Mardani, A., Hosainpour, A., & Taghavifar, H. (2024). Modeling Soil Deformation for Off-Road Vehicles Using Deep Learning Optimized by Grey Wolf Algorithm. *Journal of Agricultural Machinery*, 14(1), 69-82. <https://doi.org/10.22067/jam.2023.84339.1188>
7. Golanbari, B., Mardani, A., Hosainpour, A., & Taghavifar, H. (2025). Predicting terrain deformation patterns in off-road vehicle-soil interactions using TRR algorithm. *Journal of Terramechanics*, 117, 101021. <https://doi.org/10.1016/j.jterra.2024.101021>
8. Kashaninejad, M., Dehghani, A. A., & Kashiri, M. (2009). Modeling of wheat soaking using two artificial neural networks (MLP and RBF). *Journal of Food Engineering*, 91(4), 602-607. <https://doi.org/10.1016/j.jfoodeng.2008.10.012>
9. Liu, K., Ayers, P., Howard, H., & Anderson, A. (2010). Influence of soil and vehicle parameters on soil rut formation. *Journal of Terramechanics*, 47(3), 143-150. <https://doi.org/10.1016/j.jterra.2009.09.001>
10. Machuga, O., Shchupak, A., Styranivskiy, O., Krilek, J., Helexa, M., Kováč, J., Kuvik, T., Mancel, V., & Findura, P. (2023). Field and Laboratory Research of the Rut Development Process on Forest Roads. *Forests*, 15(1), 74. <https://doi.org/10.3390/f15010074>
11. Mardani, A. (2014). On-the-move monitoring of tire rut depth on deformable soil using an instrumented inclinometer. *Transactions of the ASABE*, 57(5), 1291-1295. <https://doi.org/10.13031/trans.57.10563>
12. Mardani, A., & Golanbari, B. (2024). Indoor measurement and analysis on soil-traction device interaction using a soil bin. *Scientific Reports*, 14(1), 10077. <https://doi.org/10.1038/s41598-024-59800-2>
13. Pentoś, K., & Pieczarka, K. (2017). Applying an artificial neural network approach to the analysis of tractive properties in changing soil conditions. *Soil and Tillage Research*, 165, 113-120. <https://doi.org/10.1016/j.still.2016.08.005>
14. Sadeghi, S., Solgi, A., & Tsioras, P. A. (2022). Effects of traffic intensity and travel speed on forest soil disturbance at different soil moisture conditions. *International Journal of Forest Engineering*, 33(2), 146-154. <https://doi.org/10.1080/14942119.2022.2055442>
15. Tabatabaekoloo, R. (2016). *Field evaluation of soil sinkage under different moisture content, traffic and loading rate*. International Conference on Agricultural Engineering, CIGR- AgEng 2016, Aarhus, Denmark, 26- 29 June.
16. Taghavifar, H., & Mardani, A. (2014). Effect of velocity, wheel load and multipass on soil compaction. *Journal of the Saudi Society of Agricultural Sciences*, 13(1), 57-66. <https://doi.org/10.1016/j.jssas.2013.01.004>
17. Toivio, J., Helmisaari, H. S., Palviainen, M., Lindeman, H., Ala-Ilomäki, J., Sirén, M., & Uusitalo, J. (2017). Impacts of timber forwarding on physical properties of forest soils in southern Finland. *Forest Ecology and Management*, 405, 22-30. <https://doi.org/10.1016/j.foreco.2017.09.022>
18. Vennik, K., Keller, T., Kukk, P., Krestein, K., & Reintam, E. (2017). Soil rut depth prediction based on soil strength measurements on typical Estonian soils. *Biosystems Engineering*, 163, 78-86. <https://doi.org/10.1016/j.biosystemseng.2017.08.016>
19. Vennik, K., Kukk, P., Krestein, K., Reintam, E., & Keller, T. (2019). Measurements and simulations of rut depth due to single and multiple passes of a military vehicle on different soil types. *Soil and Tillage Research*, 186, 120-127. <https://doi.org/10.1016/j.still.2018.10.011>