



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

F. Nashmil¹, A. Mardani^{1*}, A. Hosainpour¹, B. Golbanbari¹

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., & Golbanbari, B. (2025). Prediction of Rut Depth in Soil Caused by Wheels Using Artificial Neural Networks. *Journal of Agricultural Machinery*, (in Press). (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://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

مقاله پژوهشی

جلد ۱۵، شماره ۲، ۹۹، ص ۹-۱۵

پیش‌بینی عمق شیار ایجادشده 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 روبکدهای 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 پس‌انشار، برای پیش‌بینی عمق شیار مورد استفاده قرار گرفت و مدل به دست آمده با داده‌های تجربی اعتبارسنجی شد. علاوه بر این، از روش آزمون-خطا برای بهینه‌سازی فرآپارامترهای شبکه عصبی استفاده شد. پیکربندی بهینه برای شبکه پرسپترون چندلایه با تکانه ۰/۹ و نرخ یادگیری ۰/۳۵ به خطای جذر میانگین مربعات ۱۰/۰ دست یافت. شبکه عصبی تابع شعاعی پایه، با پهنای تابع گوسی برابر ۳/۹۰ و نرخ نرمال‌سازی برابر ۰/۰۲، جذر میانگین مربعات خطای برابر ۱۲/۰ را نشان داد. در حالی که 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 بلاذرنگ 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 چندگانه

(Machuga *et al.*, 2023; Sadeghi, Solgi, & Tsioras, 2022; Toivio *et al.*, 2017)

شیارهای ایجادشده بر اثر عبور وسایل نقلیه می‌تواند به طور 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 فشردنی خاک افزایش یافته و در نتیجه عمق شیار با تکرار عبور بیش‌تر می‌شود (Calleja-Huerta, Lamandé, Green, & Munkholm, 2023; Vennik, Keller, Kukk, Krebsstein, & 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 به عنوان یک عامل مؤثر در عمق شیار ایجادشده 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, 2020; Mardani, Hosainpour, & Taghavifar, 2025). این افزایش

مقدمه

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 ایجادشده 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 ایجادشده تأثیر دارند. تعامل پیچیده این عوامل، عمق و شکل شیارهای ایجادشده را

- گروه مهندسی مکانیک بیوپریستم، دانشکده کشاورزی، دانشگاه ارومیه، ایران
(*)- نویسنده مسئول: (Email: a.mardani@urmia.ac.ir)

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

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 قابل توجهی برای قدرت تخمین شبکه‌های عصبی ارائه کرد (Pento & 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 روبکردهای مبتنی بر یادگیری ماشین، مدلی ارائه دهد که قادر به پیش‌بینی عمق فرورفتگی خاک به طور دقیق تری 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.

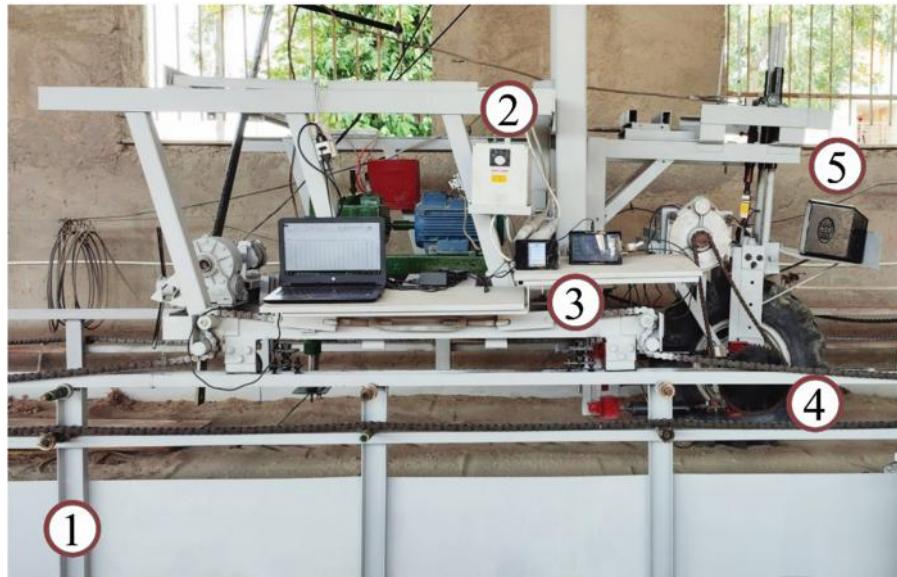
مواد و روش‌ها

آزمایش‌های میدانی و تحصیل داده

برای انجام آزمایش‌ها به منظور 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 به صورت یک سازه فلزی بر روی سطح زمین قرار گرفته و محیط خاک کاملاً به صورت 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 ۲۶ متر است. عرض کانال ۲ متر و عمق لایه خاک ۰/۸ متر است. این انباره خاک مجهز به آزمونگر تک چرخ باقابیت نصب انواع چرخ است. استفاده از انباره خاک در آزمایش‌ها امکان کنترل کامل شرایط آزمایش را فراهم می‌سازد. شما کلی سیستم در شکل ۱ نمایش داده شده است.

زمان تماس منجر به تغییر شکل بیشتر خاک و در نتیجه، افزایش عمق شیار می‌گردد (Mardani & Golbanbari, 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 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 طباطبایی کلور (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 به ترتیب باعث افزایش ۳۱٪، ۴۷٪ 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 تاکید شد (Vennik, Kukk, Krebsstein, Reintam, & Keller, 2019).

استفاده از روش‌های یادگیری ماشین در پرداختن به چالش‌های پیش روی وسایل نقلیه برون‌جاده‌ای در زمین‌های غیرمتعارف به دلیل توانایی آن در پردازش داده‌ها، تشخیص الگوهای و پیش‌بینی روابط پیچیده در تعاملات چرخ و خاک بسیار مهم است (Golbanbari, 2024) در سال‌های Mardani, Hosainpour, & Taghavifar, 2024) 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 بومتر و پیش‌بینی پارامترهای خاک با شبکه عصبی مورد بررسی قرار گرفت (Golbanbari et al., 2024). نتایج این تحقیق نشان داد تغییر در سرعت نفوذ صفحات باعث تغییر در پارامترهای فیزیکی و مکانیکی



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

امکان انجام همه‌ی آزمایش‌ها با یک بار 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.

خاک مورداستفاده 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 چنگه‌زنی و تسطیح خاک بود. طول و عرض مناسب انباره خاک

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%	
لای Silt	22%	Golanbari and Mardani, 2024
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 داخلى Angle of internal friction	32	

حاصل شود که خاک به حداقل نشست خود تحت بارگذاری‌های مختلف برسد. عامل کشش مورد استفاده یک چرخ تراکتور لاستیکی با

پارامترهای آزمایش شامل ۱۵ سطح عبور، ۳ سطح بار عمودی ۲، ۳ و ۴ کیلونیوتون و ۳ سطح سرعت پیشروی ۱، ۲ و ۳ کیلومتر در ساعت می‌شود. دلیل انتخاب ۱۵ سطح عبور این بود که اطمینان

جمع آوری داده‌ها

برای اندازه‌گیری داده‌ها پس از عبور چرخ، عمق شیار ایجادشده توسط چرخ، توسط یک کولیس ساعتی با دقیقه ۰/۰۲ میلی‌متر اندازه‌گیری شد (شکل ۲). برای اطمینان از صحت داده‌های ثبت شده، اندازه‌گیری عمق شیار سه نقطه در انباره خاک و در مسیر حرکت انتخاب شد، در هر بار عبور عمق شیار در این سه نقطه اندازه‌گیری و ثبت شد و در نهایت میانگین اندازه‌گیری‌های ثبت شده در این سه نقطه، به عنوان عمق شیار در تردد مشخص ثبت گردید. داده‌های ثبت شده به منظور تجزیه و تحلیل به نرم‌افزار متلب انتقال داده شد.

مشخصات Barez 8.25-16 P.R HL ساخت ایران هست که توسط یک شفت فولادی و دو یاتاقان در دو سر به قاب چرخ متصل می‌شود (شکل ۱)، نیروی محرکه برای جایه‌جایی حامل توسط یک عدد الکتروموتور با توان ۲۲ کیلووات (۳۰ اسب بخار)، تأمین می‌شود. به منظور کنترل سرعت دورانی الکتروموتور که سرعت پیش روی حامل را تعیین می‌کند، از یک عدد اینورتر با نام تجاری LS ساخت شرکت LG محصول کشور کره‌جنوبی با محدوده فرکانس ۰ تا ۵۰ هرتز با گام تغییر ۰/۰۱ هرتز استفاده شد.



شکل ۲- اندازه‌گیری عمق شیار ایجادشده توسط چرخ

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

استفاده شد. این شاخص‌ها جزو شاخصه‌ای متداول در بررسی عملکرد شبکه عصبی هستند. جذر میانگین مربعات خطای یک معیار رایج برای ارزیابی دقیق مدل پیش‌بینی، به‌ویژه در تحلیل رگرسیون است. این شاخص میانگین بزرگی خطاهای بین مقادیر پیش‌بینی شده و 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، \hat{y} مقدار واقعی متغیر هدف برای مشاهده i ام است و y_i مقدار پیش‌بینی شده متغیر هدف برای مشاهده i ام 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.

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 به وجود آمده است. پیش‌بینی این تعاملات با ورودی‌ها (متغیرهای مستقل) با شبکه‌های عصبی مصنوعی دارای مزیت غیرقابل انکاری نسبت به روش‌های مرسوم است. روابط غیرخطی بین متغیرهای وابسته و متغیرهای مستقل را می‌توان با دقیقیت بالایی توسط شبکه‌های عصبی مصنوعی استخراج کرد. در این مطالعه از یک شبکه عصبی پرسپترون چندلایه^۱ با الگوریتم پس انتشار^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 خطای ضریب تعیین و میانگین قدر مطلق خطای

1- Multi-layer perceptron

2- Backpropagation algorithm

3- Radial basis function

الگوریتم آموزش استفاده گردید که کمترین جذر میانگین مربعات خطای عکس‌برداری را محاسبه کرد. این مقدار 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 0.05 برای هر مقدار تعداد نورون‌ها لایه پنهان افزایش یافت. بعد از بدست آمدن مقادیر بهینه فرآپارامترها شبکه عصبی در 500 دوره و 300 تکرار آموزش داده شد.

شبکه عصبي شعاعي پايه

شیکه‌های 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 به طور معمول دارای یک لایه پنهان هستند که تعداد نوروون‌های 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 تاثیر 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 خطأ انجام شد. پارامترهای نرخ نرمال‌سازی در بازه $10/0$ تا $100/0$ با گام $0/005$ و پهنای تابع گوسی برای شبکه عصبی در بازه $1/0$ تا $10/0$ با گام $0/10$ افزایش یافت. شبکه با 100 تکرار، برای هر مقدار از پارامترهای نرخ نرمال‌سازی و پهنای تابع گوسی آموزش داده شد.

نتائج و بحث

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

ارزیابی عملکرد شبکه عصبی پرسپترون چندلایه

نمودار شکل ۳ ارتباط بین تکانه و نرخ یادگیری با جذر میانگین مربعات خطای دیگر شبکه عصبی پرسپترون چندلایه را نمایش می‌دهد. تغییرات در مقادیر جذر میانگین مربعات خطای 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

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

SS_r مجموع مجدد باقیماندها است که خطای کل مدل رگرسیون و SS_e مجموع مجددات 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، به طور میانگین، چقدر با مقدار واقعی اختلاف دارد. میانگین قدر مطلق خطا همیشه غیرمنفی است و مقدار کمتر آن به معنای عملکرد بهتر مدل است و از رابطه^(۳) محاسبه می‌شود.

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

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

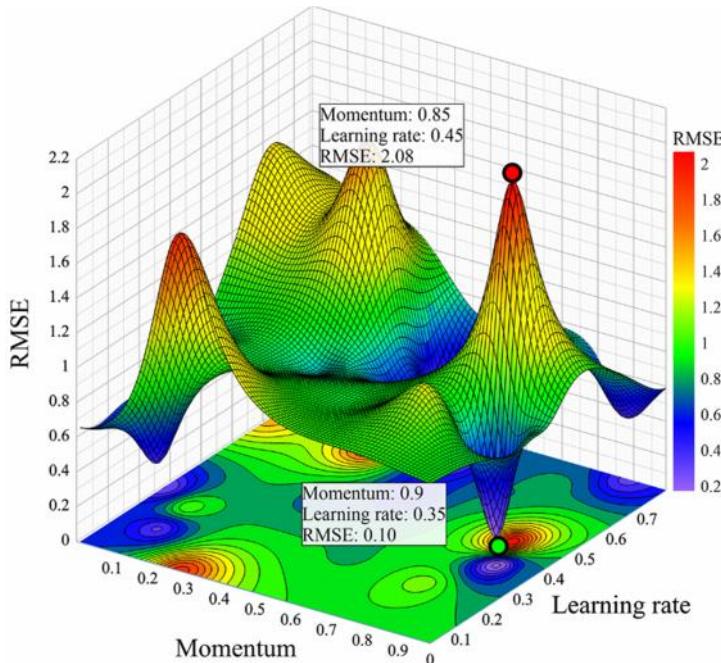
فرایارامترهای شبکه عصبی پرسپترون چندلایه شامل تعداد نورون‌های لایه پنهان، تکانه^۱ و نرخ یادگیری^۲ و فرایارامترهای شبکه عصبی شعاعی پایه شامل پهنه‌ای تابع گوسی^۳ و نرخ نرمال سازی^۴ است. برای تنظیم مناسب و بهینه فرایارامترها هر دو شبکه از روش آزمون و خطا استفاده شد. پس از انتخاب بهترین معماری از نظر کمترین مقدار جذر میانگین مربیات خطا انتخاب و به عنوان معماری شبکه انتخاب شد. ورودی‌های شبکه شامل سرعت پیشروی چرخ، بار عمودی روی تایر و تعداد تردد است. از طرفی خروجی شبکه عمق شیا، ابجاده شده است.

شیکہ عصبی پرسپترون چند لایه

معماری شبکه عصبی پرسپترون چندلایه استفاده شده در این مطالعه شامل یک شبکه با دو لایه پنهان بود که در آن از تابع انتقال سیگموید برای نگاشت داده‌ها از لایه‌های پنهان استفاده شد. تعداد کل داده‌های اندازه‌گیری شده برای عمق شبیار برابر ۱۳۵ داده بود که از این بین، یک مجموعه داده جدا شد و به عنوان داده‌های دیده نشده 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 به عنوان

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

پارامترها می‌توانند تأثیرات متفاوتی بر عملکرد شبکه عصبی داشته باشند و بهینه‌سازی این پارامترها اهمیت بالایی در بهبود دقت و



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

منجر شده است. در مقابل بهترین عملکرد شبکه عصبی با تکانه $0/9$ و نرخ یادگیری $0/35$ با خطای جذر میانگین مربعات $0/10$ و میانگین قدر مطلق خطا $0/08$ بهدست آمد.

یک پارامتر اساسی مؤثر بر عملکرد شبکه عصبی پرسپترون چندلایه انتخاب یک الگوریتم یادگیری مناسب است. برای شناسایی مناسب‌ترین الگوریتم یادگیری پس انتشار، سه الگوریتم یادگیری پس انتشار 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.

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 تعییر 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 کمک می‌کند تا از تاریخچه گرادیان برای بهروزرسانی وزن‌ها استفاده کند، به طوری که تعییرات 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 $0/85$ و نرخ یادگیری $0/45$ است که به خطای جذر میانگین مربعات $2/08$

جدول ۲- توابع انتقال و الگوریتم‌های آموزشی پس انتشار 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
لونبرگ-مارکوارت پس انتشار Levenberg-Marquardt backpropagation (trainlm)	0.999982	0.10	0.08
پس انتشار ارجاعی Resilient backpropagation (trainrp)	0.999501	0.71	0.43
پس انتشار بیزی Bayesian regularization backpropagation (trainbr)	0.999969	0.17	0.10

در جدول ۳، معماری ۱۲-۱-۳-۱۴ با خطای جذر میانگین مربعات برابر 0.08 و میانگین قدر مطلق خطا 0.008 ، با کمترین مقدار خطای جذر، در بین سایر معماری‌ها بهترین عملکرد را در کاهش خطای داشته است. همچنین ضریب تعیین با مقدار برابر 0.9984 نشان می‌دهد که مدل می‌تواند به خوبی روند داده‌های تجربی را شناسایی و پیش‌بینی کند.

ارزیابی عملکرد شبکه عصبی شعاعی پایه

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

نمودار شکل ۳ نشان‌دهنده رابطه بین پهنانی تابع گوسی و پارامتر نرمال‌سازی با جذر میانگین مربعات خطای شبکه عصبی شعاعی پایه است. عملکرد بهینه شبکه عصبی با اندازه پهنانی $3/90$ و نرخ نرمال‌سازی 0.02 به دست آمد که منجر به خطای جذر میانگین مربعات 0.08 و میانگین قدر مطلق خطا 0.008 شد. شکل ۴ عملکرد شبکه عصبی را به‌ازای مقادیر مختلف فراپارامترها نشان می‌دهد.

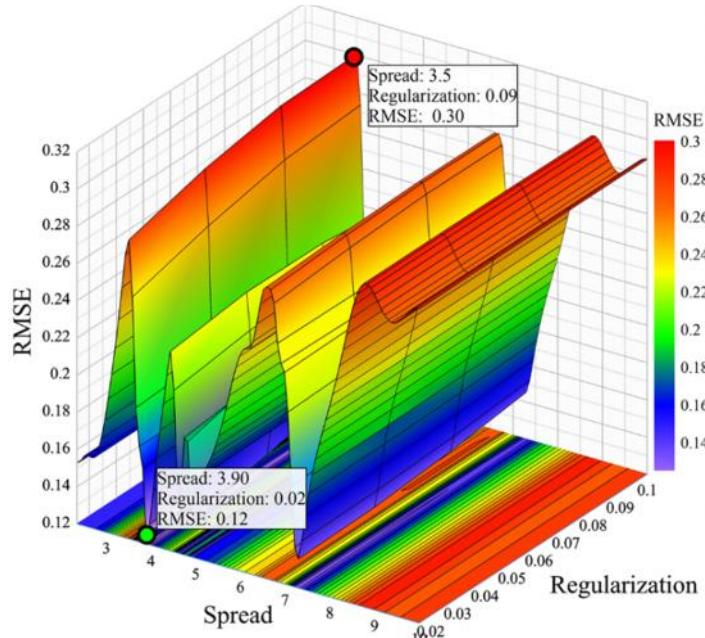
همان‌طور که از جدول ۳ مشاهده می‌شود از بین الگوریتم‌های یادگیری پس انتشار، الگوریتم یادگیری لونبرگ-مارکوارت با خطای جذر میانگین مربعات معادل 0.13 ، ضریب تعیین برابر 0.99834 و میانگین قدر مطلق خطا برابر 0.08 بهترین عملکرد را داشت؛ بنابراین به عنوان الگوریتم یادگیری انتخاب شد.

جدول ۳ نشان‌دهنده نتایج آموزش با چیدمان بهینه شبکه عصبی پرسپترون چندلایه و فراپارامترها است. در معماری بهینه، مقادیر مربوط به نرخ یادگیری، تکانه، جذر میانگین مربعات خطای و ضریب تعیین در جدول ارائه شده‌اند.

جدول ۳- ویژگی‌های به دست آمده در آموزش پرسپترون چندلایه با پیکره‌بندی بهینه شده

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 خطای RMSE	0.10
ضریب تعیین R-square	0.999982
میانگین قدر مطلق خطا MAE	0.08



شکل ۴- تأثیر پارامترهای پهنانی 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

مقایسه نتایج رگرسیون در شبکه‌های عصبی پرسپترون چندلایه و شعاعی پایه

عملکرد نهایی شبکه‌های عصبی، مستلزم بررسی پیش‌بینی عمق 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 تعیین مدل را فراهم می‌کند و اطمینان حاصل می‌کند که مدل به جای تطبیق بیش از حد 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.

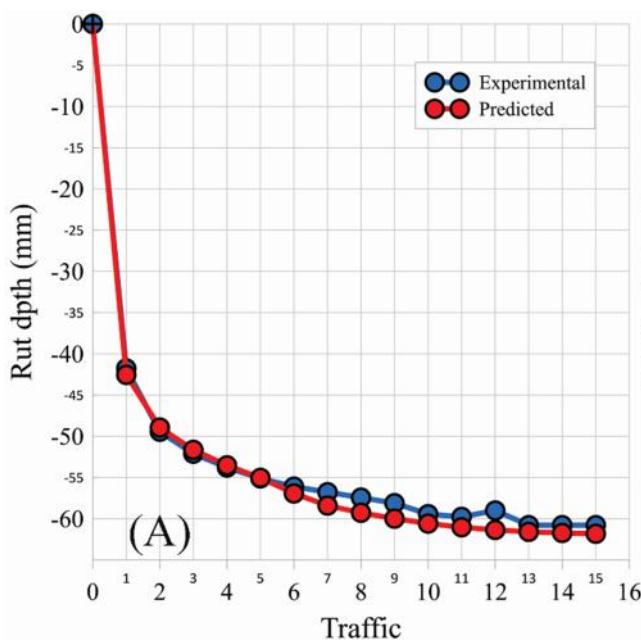
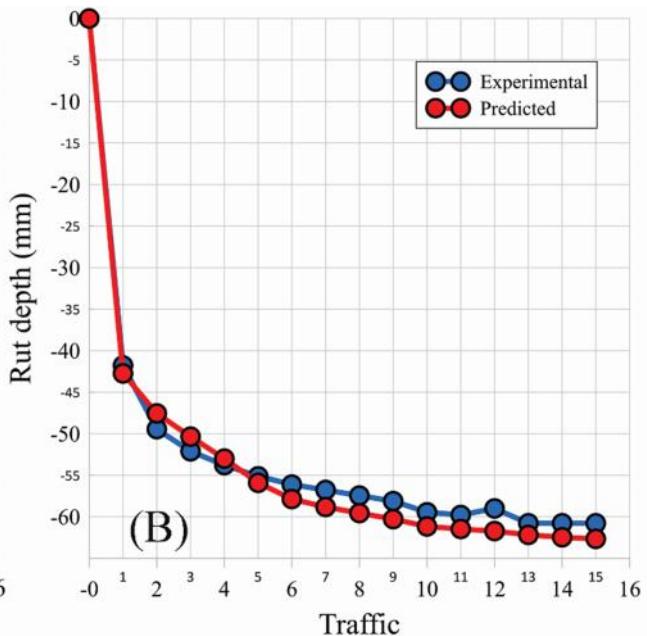


Fig.5. Comparison of experimental data and predicted values of rut depth obtained from (A) MLP and (B) RBF models

است؛ بنابراین توانایی شبکه برای پیش‌بینی دقیق این تغییرات اولیه از اهمیت قابل توجهی برخوردار است. شکل ۵-ب پیش‌بینی تغییرات عمق شیار ایجاد شده توسط عوامل کششی با استفاده از شبکه عصبی شعاعی پایه را نشان می‌دهد. مشاهدات نشان می‌دهد که این شبکه عصبی نیز به طور مؤثر فرآیند

در نمودار شکل ۴ دو نقطه خاص برجسته شده‌اند. اولین نقطه در پهنهای تابع گوسی برابر $3/50$ و نرخ نرمال‌سازی برابر $0/09$ قرار دارد که در آن مقدار جذر میانگین مربعات خطأ برابر $0/3$ است. این مقدار جذر میانگین مربعات خطأ نشان می‌دهد که تنظیمات فرایانترهای شبکه در این نقطه منجر به عملکرد ضعیفتری شده است. این می‌تواند به این معنا باشد که مدل به دلیل مقادیر نامناسب فرایانترهای دچار بیش‌برازش یا کم‌برازش شده است. نقطه دوم که در پهنهای تابع گوسی برابر $3/90$ و نرخ نرمال‌سازی برابر $0/02$ قرار دارد، جذر میانگین مربعات خطأ برابر $0/12$ را نشان می‌دهد که مقدار بسیار کمتری است. این مقدار کم جذر میانگین مربعات خطأ بیانگر دقت بیشتر مدل و تنظیم بهینه‌تر این دو پارامتر است. با توجه به ساختار نمودار شکل ۴ می‌توان مشاهده کرد که مقدار پهنهای تابع گوسی به تنها یک نمی‌تواند تعیین کننده اصلی دقت مدل باشد. تعامل بین پهنهای تابع گوسی و نرخ نرمال‌سازی نقش کلیدی در کاهش خطأ و بهبود عملکرد شبکه ایفا می‌کند.

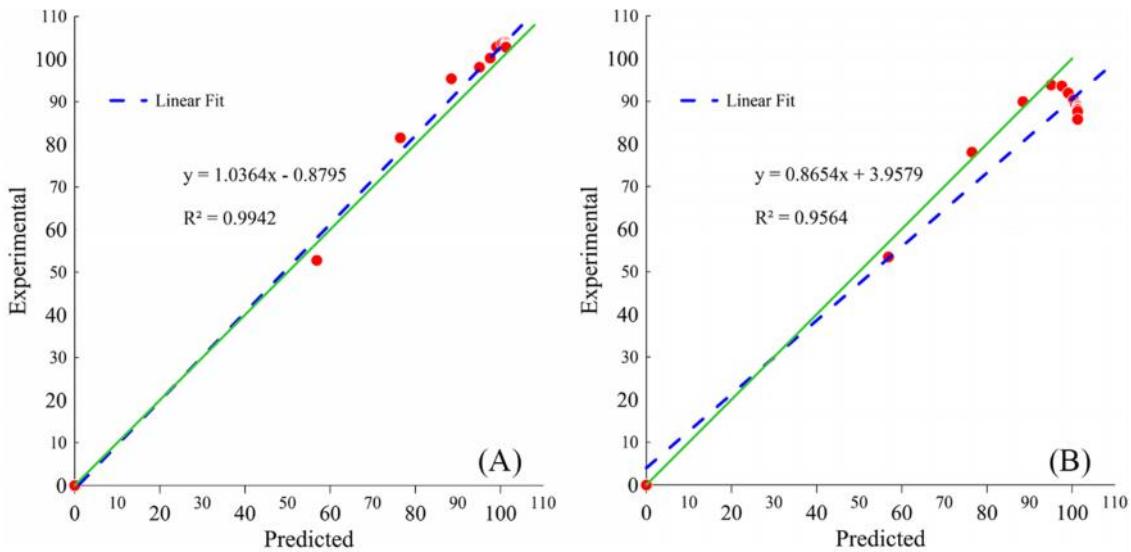


شکل ۵- مقایسه داده‌های تجربی و مقادیر پیش‌بینی شده از عمق شیار به دست‌آمده از مدل‌های شبکه عصبی

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 به طور مؤثر تغییرات در داده‌های تجربی را ردیابی می‌کند. ترددات اولیه بسیار مهم هستند زیرا با بالاترین سطوح تغییر شکل خاک، مقاومت در برابر غلتتش چرخ و فشردنگی خاک همراه

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.

تغییرات در عمق شیار را یاد می‌گیرد و عملکرد مناسب را روی 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 بالادرنگ مناسب‌تر می‌کنند.



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

پیش‌بینی تشکیل عمق شیار ناشی از تردد وسایل نقلیه خارج از جاده ارائه می‌کند. دو معماری شبکه عصبی متمازی، پرسپترون چندلایه و تابع پایه شعاعی، با استفاده از داده‌های تجربی به دست‌آمده 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 توسط تایرهای کشاورزی لاستیکی را فراهم می‌کند. عملکرد شبکه‌های عصبی آموزش‌دیده با استفاده از جذر میانگین مربعات خطأ 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 بالادرنگ که در آن سرعت پاسخ بسیار مهم است به ابزار مناسب‌تری تبدیل می‌کند. قابلیت‌های تعمیم 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 کشن مختص مختلف تأیید کرد. این مطالعه خلوفیت روش‌های

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 خطأ 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 Kashaninejad, Dehghani, & Kashiri, 2009) کاشانی‌نژاد و همکاران، همخوانی دارد.

نتیجه‌گیری

این مطالعه یک تحقیق جامع در مورد کاربرد روش‌های یادگیری ماشین، به ویژه شبکه‌های عصبی مصنوعی، برای مدل‌سازی و

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،
ویرایش متن
بهزاد گلعتبری: روش‌شناسی، مشاوره فنی، تحلیل آماری،
تصویرسازی نتایج، ویرایش متن

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 نویسنده‌گان

نشمیل فرهادی: روش‌شناسی، مفهوم‌سازی، جمع‌آوری داده‌ها،

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., Padhiari, 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. Golombokbari, 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. Golombokbari, 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. Golombokbari, 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. Golombokbari, 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., Kuvík, 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., & Golombokbari, 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. Pento, 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. Tabatabaeikoloor, R. (2016). *Field evaluation of soil sinkage under different moisture content, traffic and loading rate*.
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-Illomäki, 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., Krebstein, 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., Krebstein, 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>