Journal of Research in Mechanics of Agricultural Machinery

Shahrekord University

Research Paper

Predicting Tractor Draft Force, Wheel Slippage, and Fuel Consumption Under Field Conditions Using Adaptive Neuro-Fuzzy Inference System (ANFIS)

Kalam Babazadeh[1], Behzad Mohammadi-Alasti[*1], Mahdi Abbasgholipour[1], Asghar Mahmudi[2]

1. Department of Mechanical Engineering of Biosystems, Bon.C., Islamic Azad University, Bonab, Iran.
2. Department of Mechanical Engineering of Biosystems, Tabriz University, Tabriz, Iran.

Article History

Submited:2026/06/05

Revised: 2026/08/02

Accepted: 2026/08/16

Published online: 2026/09/23

Keywords:
Draft Force
Wheel slippage
Fuel consumption
Field conditions
ANFIS
Tillage operations

***Corresponding author email:** behzad.alasti@iau.ac.ir

ORCID: 0000-0002-2411-8068

Abstract

In this study ,the Adaptive Neuro-Fuzzy Inference System (ANFIS) was used to predict traction force, wheel slip, and tractor fuel consumption under field conditions during plowing operations with a plow and a harrow .Experiments were conducted in the fields of Iran Tractor Sazi Company using a two-tractor method. The independent variables included four tillage-depth levels (10, 20, 30, and 40 cm), three soil-moisture levels (approximately 12, 15, and 19 percent), and four forward-speed levels with heavy gears (1, 2.55, 4.40 , and 6.58 km/h.) A factorial experiment based on a randomized complete block design (RCBD) with three replications was used .Simultaneous prediction of key tractor performance indicators is one of the fundamental challenges in managing tillage operations and optimizing energy consumption because these indicators are affected by the complex and nonlinear interaction between soil properties and operating parameters ,and conventional methods do not have sufficient accuracy to describe these relationships .Therefore ,an intelligent framework based on (ANFIS) along with principal component analysis) PCA (was developed to simultaneously predict traction force ,wheel slip and fuel consumption .The results showed that increasing soil depth and forward speed increased traction force ,slip and fuel consumption ,while increasing soil moisture improved this index due to the decrease in soil mechanical strength .The proposed model with high coefficients of determination for traction force (0.99996), slip (0.9997) and fuel consumption (0.99964) and very low RMSE values was able to simulate the real behavior of the soil tractor system with good accuracy .The results showed that the developed model is not only an accurate tool for predicting tractor performance but also can be used as a decision support system in selecting optimal operating conditions to reduce fuel consumption and tillage costs , control slip and improve energy efficiency in precision agriculture.

How to cite this paper:

Babazadeh, K., Alasti, M.B., Abbasgholipour, M., and Mahmudi, A. (2026). Predicting Tractor Draft Force, Slippage, and Fuel Consumption Under Field Conditions Using an Adaptive Neuro-Fuzzy Inference System. *Journal of Research in Mechanics of Agricultural Machinery.* 40: 113-138. https://dx.doi.org/10.22034/jrmam.2026.15096.777 (In Persian)

Authors retain the copyright and full publishing rights. Published by Shahrekord University. This article is an open access article licensed under the Creative Commons Attribution 4.0 International (CC BY 4.0)

https://dx.doi.org/10.22034/jrmam.2026.15096.777

EXTENDED ABSTRACT

Introduction

Tractor energy efficiency in tillage operations remains a critical concern in sustainable agricultural engineering, given that primary tillage accounts for 25% to 40% of fuel consumption in crop production systems. Growing global food demand and the urgency to reduce greenhouse gas emissions have intensified efforts to optimize field operations, particularly plowing, which demands high draft forces and is highly sensitive to soil conditions. Key operational parameters tillage depth, forward speed, and soil moisture significantly influence draft force, slippage, and fuel consumption, yet their interactive effects are complex and often nonlinear. Traditional predictive models, such as regression or ASABE standard equations, frequently fail to capture these nonlinear dynamics under real-field variability. In this context, data-driven modeling approaches capable of handling uncertainty and fuzziness in field data offer a promising alternative. This study aims to investigate the effects of tillage depth (10 - 40 cm), soil moisture (12%, 15%, and 19%), and forward speed (1.00, 2.55, 4.40, and 6.58 km/h) on draft force, fuel consumption, and slippage during moldboard plowing, and to develop a high-accuracy predictive model using the Adaptive Neuro-Fuzzy Inference System (ANFIS). The research hypothesis posits that ANFIS, by integrating fuzzy logic and neural network learning, can outperform conventional regression models in predicting tractor performance under uncertain and nonlinear field conditions. This approach addresses a practical need for real-time decision support systems to enhance energy efficiency and reduce operational costs in precision agriculture.

Material and Methods

Field experiments were conducted at the research farm of Iran Tractor Manufacturing Company (Tabriz) on a loamy soil (48.6% sand, 29.4% silt, 22% clay). A three-bottom moldboard plow (104 cm working width) was used with two ITM399-4W tractors in a controlled two-tractor test configuration to measure draft force via a calibrated load cell (SS300, SEWHA, 100 kN capacity, ±0.01 kg accuracy). Fuel consumption was recorded using dual Overall flow sensors (supply and return lines), while slippage (%) was calculated from travel time over a 50-m test plot with and without implement load, following the RNAM standard method. The experimental design followed a Randomized Complete Block Design (RCBD) with three replications, resulting in 144 treatment combinations. Independent variables included tillage depth (four levels), soil moisture (three levels), and forward speed (four levels); dependent variables were draft force (N), fuel consumption (L/h), and slippage (%). Data were normalized using the hyperbolic tangent function to fit the [-1, 1] range. We developed ANFIS models in MATLAB, using 70% of the data for training, 20% for validation, and 10% for testing. Various membership functions were evaluated. Model performance was assessed using RMSE, R^2, Efficiency (EF), and Mean Bias Error (MBE).

Results and Discussion

Statistical analysis (ANOVA) revealed that tillage depth and soil moisture significantly affected all three output variables ($p < 0.01$), whereas forward speed significantly influenced fuel consumption and slippage but not draft force. Draft force increased with depth but decreased as soil moisture rose, likely due to reduced soil mechanical resistance in wetter conditions. Slippage exhibited a consistent upward trend with increasing depth, speed, and moisture; the highest slippage (35%) occurred at 40 cm depth, 4.40 km/h speed, and 19% moisture. Fuel consumption per hour rose with all three factors, yet consumption per unit area decreased with higher speeds under constant depth and moisture highlighting a trade-off between time efficiency and instantaneous fuel use. The ANFIS models demonstrated excellent predictive performance. For draft force, the Dsigmf membership function achieved $R^2 = 0.99992$ and RMSE = 0.0023;

for fuel consumption, Traamf yielded R^2 = 0.99964 and RMSE = 0.0174; for slippage, Dsigmf produced R^2 = 0.99993 and RMSE = 0.0023. These results significantly surpass those of existing ANN-based models reported in the literature (e.g., $R^2 < 0.99$ and RMSE > 0.004). ANFIS's high accuracy is attributed to its ability to model nonlinear, uncertain relationships without requiring explicit physical equations. Notably, the model captures complex interactions such as the non-monotonic effect of speed on slippage at high depths, demonstrating its robustness for real-world agricultural decision-making.

Conclusions

This study confirms that ANFIS is a superior tool for modeling and predicting key tractor performance indicators under variable field conditions, offering significantly higher accuracy than conventional regression or neural network approaches. The findings provide practical insights: optimizing tillage depth and operating within moderate moisture ranges can substantially reduce fuel use and slippage, thereby enhancing overall energy efficiency. From a theoretical perspective, the success of ANFIS underscores the value of hybrid soft-computing methods in agricultural systems where data uncertainty and nonlinearity are inherent. These models can be integrated into intelligent tractor management systems to control depth and speed in real time based on soil conditions, paving the way for autonomous, energy-efficient tillage. Future research should extend this framework to other implements and soil types, and explore online learning capabilities for dynamic adaptation during field operations. Ultimately, such advancements contribute to the broader goals of precision agriculture: reducing environmental impact, lowering operational costs, and improving the sustainability of food production systems.

Acknowledgements

The authors sincerely thank the staff and management of the Testing Center of Iran Tractor Manufacturing Company for their assistance in carrying out the experiments and for providing the required equipment.

Author Contributions

Author1: Writing, Visualization, Investigation, Methodology.
Author2: Validation, Supervision, Project administration, Methodology.
Author3: Validation, Methodology, Conceptualization.
Author4: review & editing, Validation, Formal analysis.

Data Availability Statement

The data thatsupport the findings of this study are available from the corresponding author upon reasonable reques.

Ethical Considerations

Adherence to ethical standards is confirmed, including avoidance of data fabrication, falsification, plagiarism, and misconduct.

Conflict of Interest

The authors declare that they have no known competing financial interests or personal relationships that could have appeared to influence the work reported in this paper.

Funding Statement

The author(s) received no specific funding for this research

نشریه پژوهش‌های مکانیک ماشین‌های کشاورزی
دانشگاه شهرکرد

مقاله پژوهشی

پیش‌بینی نیروی کششی، لغزش چرخ و مصرف سوخت تراکتور در شرایط مزرعه‌ای با استفاده از سامانه استنتاج عصبی-فازی تطبیقی (ANFIS)

کلام بابازاده[۱]، بهزاد محمدی الستی[۱*]، مهدی عباسقلی پور[۱] و اصغر محمودی[۲]

۱-گروه مهندسی مکانیک بیوسیستم، واحد بناب، دانشگاه آزاد اسلامی، بناب، ایران.
۲-گروه مهندسی مکانیک بیوسیستم، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران.

تاریخچه مقاله

دریافت:۱۴۰۵/۰۳/۱۵
بازنگری:۱۴۰۵/۰۵/۱۱
پذیرش:۱۴۰۵/۰۵/۲۵
انتشار: ۱۴۰۵/۰۷/۰۱

واژه‌های کلیدی:
نیروی کشش
لغزش چرخ
مصرف سوخت
شرایط مزرعه‌ای
سامانه استنتاج عصبی-فازی تطبیقی
عملیات خاک‌ورزی

***پست الکترونیکی نویسنده مسئول:**
behzad.alasti@iau.ac.ir

ORCID: ۰۰۰۰-۰۰۰۲-۲۴۱۱-۸۰۶۸

چکیده

در این پژوهش، از سامانه استنتاج عصبی-فازی تطبیقی (ANFIS) برای پیش‌بینی نیروی کششی، لغزش چرخ و مصرف سوخت تراکتور در شرایط مزرعه‌ای طی عملیات شخم با گاوآهن سه‌خیشه استفاده شد. آزمایش‌ها در مزارع شرکت تراکتورسازی ایران با روش دو تراکتوری انجام گردید. متغیرهای مستقل شامل چهار سطح عمق خاک‌ورزی (۱۰، ۲۰، ۳۰ و ۴۰ سانتی‌متر)، سه سطح رطوبت خاک (تقریباً ۱۲، ۱۵ و ۱۹ درصد) و چهار سطح سرعت پیشروی با دنده‌های سنگین (۱، ۲/۵۵، ۴/۴۰ و ۶/۵۸ کیلومتر بر ساعت) بودند. آزمایش فاکتوریل بر پایه طرح بلوک کامل تصادفی (RCBD) با سه تکرار استفاده شد. پیش‌بینی هم‌زمان سه شاخص کلیدی عملکرد تراکتور از چالش‌های اساسی در مدیریت عملیات خاک‌ورزی و بهینه‌سازی مصرف انرژی است، زیرا این شاخص‌ها تحت تأثیر برهم‌کنش پیچیده و غیرخطی میان ویژگی‌های خاک و عامل‌های عملیاتی قرار دارند و روش‌های متداول از دقت کافی برای توصیف این روابط برخوردار نیستند. لذا یک چارچوب هوشمند مبتنی بر (ANFIS) همراه با تحلیل مؤلفه های اصلی (PCA) برای پیش‌بینی هم‌زمان نیروی کششی، لغزش چرخ و مصرف سوخت توسعه یافت. نتایج نشان داد که افزایش عمق خاک و سرعت پیشروی موجب افزایش نیروی کششی، لغزش و مصرف سوخت شده، درحالی‌که افزایش رطوبت خاک به دلیل کاهش مقاومت مکانیکی خاک، این شاخص را بهبود می‌بخشد. مدل پیشنهادی با ضرایب تعیین بالا برای نیروی کششی (۰/۹۹۹۹۶)، لغزش (۰/۹۹۹۷) و مصرف سوخت (۰/۹۹۹۶۴) و مقادیر بسیار پایین RMSE، توانست رفتار واقعی سامانه تراکتور-خاک را با دقتی خوب شبیه‌سازی کند. نتایج نشان داد که مدل توسعه‌یافته نه‌تنها ابزاری دقیق برای پیش‌بینی عملکرد تراکتور است، بلکه می‌تواند به‌عنوان یک سامانه تصمیم یار در انتخاب شرایط بهینه عملیات، کاهش مصرف سوخت وهزینه خاک‌ورزی، واپایش لغزش و ارتقای بهره‌وری انرژی در کشاورزی دقیق مورداستفاده قرار گیرد.

نحوه استناد به این مقاله:

بابازاده، ک.، الستی، م.ب.، عباسقلی‌پور، م.، محمودی، ا.، (۱۴۰۵). پیش‌بینی نیروی کششی، لغزش و میزان مصرف سوخت تراکتور در شرایط مزرعه‌ای به کمک شبکه استنتاج عصبی سامانه فازی. *نشریه پژوهش‌های مکانیک ماشین‌های کشاورزی*، ۴۰: ۱۱۳-۱۳۸:
https://dx.doi.org/10.22034/jrmam.2026.15096.777

مقدمه

تراکتورها به‌عنوان اصلی‌ترین ماشین تولید توان در عملیات کشاورزی از خاک‌ورزی تا برداشت به شمار می‌روند. بنابراین استفاده از تراکتور در کشاورزی به‌عنوان منبع توان، غیرقابل‌انکار است. افزایش نرخ رشد جمعیت و تقاضای جهانی غذا، تمایل به استفاده هرچه بیشتر از این وسیله را به‌منظور بالابردن بازده کاری افزایش داده است. تراکتورهای مزرعه‌ای مقدار قابل‌توجهی از انرژی را طلب می‌کنند، به‌طوری که بهینه‌کردن عملکرد تراکتورهای مزرعه‌ای می‌تواند بسیاری از افت‌های انرژی در کشاورزی را کاهش دهد. انرژی موردنیاز برای عملیات خاک‌ورزی بخش قابل‌توجهی (۲۵ تا ۴۰ درصد) از کل انرژی مصرفی در تولید محصول را شامل می‌شود و کاهش این انرژی به چالشی مهم برای مهندسان کشاورزی و کشاورزان تبدیل شده است (Shafaei *et al*., 2021).

خاک‌ورزی با مهیاکردن وضعیت مناسب خاک، با جذب رطوبت و دمای کافی برای جوانه‌زنی و رشد بذر و همچنین با کاهش مقاومت به نفوذ خاک سبب رشد آسان‌تر ریشه می‌گردد. خاک‌ورزی عملیاتی زمان‌بر و هزینه‌بر است که با برنامه‌ریزی دقیق عملیات زراعی می‌توان به میزان قابل‌توجهی در مصرف سوخت، انرژی و زمان صرفه‌جویی کرد. انرژی مصرفی در عملیات خاک‌ورزی، بـه عوامل مختلفی مانند نوع خاک و شرایط آن (رطوبت و بافت خاک)، عمق خاک‌ورزی، سرعت عملیات و نحوه اتصال ادوات به تراکتور بستگی دارد. میزان مصرف سوخت به نوع ادوات، عمق خاک‌ورزی و میزان رطوبت خاک بستگی دارد. کمترین میزان مصرف سوخت مربوط به رطوبت ۸/۶ درصد بوده است(Tayel et al., 2015) . خاک‌ورزی حفاظتی دارای مزایای زیادی نسبت به خاک‌ورزی مرسوم است و از محیط‌زیست و خاک محافظت کرده و در هزینه خرید ماشین، تعمیرات و مصرف سوخت صرفه‌جویی می‌کند(Lithourgidis *et al*., 2006) . اگر در نوع عملیات خاک‌ورزی دقت شود، می‌توان تا ۸۰ درصد در مصرف سوخت و ۶۰ درصد در زمان انجام عملیات صرفه‌جویی نمود (Šarauskis *et al*., 2017).

خاک‌ورزی حفاظتی ۱/۵ تا ۲ برابر کمتر از خاک‌ورزی مرسوم سوخت مصرف می‌نماید (Kim et al., 2022) . ادوات خاک‌ورزی (کولتیواتور فنری، دیسک هارو)، بافت خاک، سرعت روبه‌جلو و عمق خاک‌ورزی بر مصرف سوخت و کیفیت خاک‌ورزی تأثیر دارد (Damanauskas & Janulevičius, 2022). با اعمال مدیریت خاک‌ورزی دقیق یا خاک‌ورزی در عمق متغیر، میزان سوخت مصرفی به میزان ۵۰ درصد کاهش می‌یابد (Soylu & Çarman, 2021).

یک سامانه واپایش لغزش خودکار مبتنی بر منطق فازی برای تراکتورهای کشاورزی توسعه‌یافته است که به طور مداوم میزان لغزش را در طول عملیات خاک‌ورزی اندازه‌گیری کرده و به‌صورت به خودکار عمق کار ادوات را تنظیم می‌کند (Han et al., 2023). بر اساس نتایج مطالعات پیشین، پیش‌نیاز طراحی و اعمال سامانه‌های کنترلی هوشمند در تجهیزات خاک‌ورزی، پیش‌بینی دقیق عامل‌های عملکردی بر اساس متغیرهای مستقل است.

روش‌های پیش‌بینی را در حالت کلی می‌توان به سه دسته معادلات رگرسیونی، مدل‌های تحلیلی و نیمه‌تحلیلی، و مدل‌های یادگیری ماشین تقسیم کرد (Falahat Nejad Mahani, & Karami, 2023; Fallah & Ghanbari Parmehr, 2023; Ghiasi *et al*., 2020). معادلات رگرسیونی متعددی برای پیش‌بینی نیروها، به‌ویژه نیروی کششی موردنیاز ابزارهای خاک‌ورزی با استفاده از داده‌های مزرعه‌ای ارائه شده‌اند (Dizaji et al., 2022). مدل ریاضی ارائه شده توسط استاندارد ASABE D497.7یکی از مهمترین و کاربردی‌ترین معادلات ریاضی در پیش‌بینی نیروی کششی موردنیاز ابزارهای خاک‌ورزی است (ASABE, 2011) .

فناوری محاسبات نرم، رویکردی میان‌رشته‌ای است که از ابزارهایی مانند یادگیری ماشین، شبکه‌های عصبی مصنوعی و منطق فازی بهره می‌گیرد. از این‌رو، روش‌های هوش مصنوعی در زمینه‌های مختلف کاربردهای کشاورزی بسیار مورداستفاده قرار گرفته است. مدل‌های هوشمند و برنامه‌های شبیه‌سازی به محققان کمک می‌کنند تا بدون انجام آزمون‌های پرهزینه و زمان‌بر مزرعه‌ای، نیروهای وارد بر ادوات را پیش‌بینی کنند. این مدل‌ها همچنین در طراحی و بهینه‌سازی ادوات کشاورزی جدید و موجود بسیار مفید هستند (Foldager *et al*., 2022) .

به دلیل ماهیت غیرخطی عامل‌های مرتبط با بر همکنش ابزار خاک‌ورزی و خاک، برخی محققان روش‌های مبتنی بر یادگیری ماشین و هوش محاسباتی مانند شبکه عصبی مصنوعی (ANN) و سامانه استنتاج فازی (FIS) را به کار گرفته‌اند (Jalilnezhad *et al*., 2023; Mohammadi, 2012) .

در یکی از جدیدترین مطالعات انجام شده، مروری به بررسی کارهای انجام شده در زمینه میزان مصرف سوخت، نیروی کشش و اندازه‌گیری سرعت تراکتور کشاورزی در حین

عملیات خاک‌ورزی پرداخته شده است (Mamkagh, 2019). سامانه استنتاج عصبی-فازی تطبیقی (ANFIS) ابزاری ترکیبی از ANN و FIS است که مزایای هر دو روش را به همراه دارد (Vesović & Jovanović, 2022). بررسی مطالعات انجام شده نشان‌دهنده توانایی بسیار بالای ANFIS به‌منظور پیش‌بینی عامل‌های مختلف مرتبط با کشاورزی است (Askari & Abbaspour-Gilandeh, 2020).

در تحقیق حاضر، ابتدا با انجام آزمایش‌های میدانی، تأثیر عمق خاک‌ورزی، رطوبت خاک و سرعت پیشروی بر نیروی کششی، لغزش چرخ و مصرف سوخت تراکتور بررسی شد. سپس با استفاده از سامانه استنتاج عصبی-فازی تطبیقی (ANFIS)، مدلی برای پیش‌بینی این عامل‌ها توسعه یافت. مطالعات پیشین با این روش ترکیبی به موضوع نگاه نکرده‌اند و یا اگر بوده به‌صورت کلی بیان شده است. بر اساس نتایج مطالعات پیشین، پیش‌نیاز طراحی و اعمال سامانه‌های کنترلی هوشمند در تجهیزات خاک‌ورزی، پیش‌بینی دقیق عامل‌های عملکردی بر اساس متغیرهای مستقل است.

فرضیه‌ای که در این پژوهش بیان می‌شود عبارت است از اینکه از کلی‌گویی در عملیات خاک‌ورزی به تشریح جزئیات و رسیدن به اهداف تعیین شده، به‌ویژه جهت تعیین‌کردن نیروی کششی، میزان اندازه‌گیری لغزش چرخ‌های عقب تراکتور و مصرف سوخت تراکتور هنگام استفاده از گاوآهن تعریف شده در عمق‌های مختلف، رطوبت‌های مختلف و سرعت‌های مختلف تراکتور و توسعه مدل ANFIS برای پیش‌بینی این متغیرها در شرایط مزرعه‌ای تعریف شده، بپردازیم. تفاوتی که پژوهش حاضر با مطالعات پیشین دارد بر این پایه استوار است که برای پیش‌بینی متغیرهای تعریف شده با جزئیات کامل آزمایشات انجام گردد.

مواد و روش‌ها

در این تحقیق برای اندازه‌گیری و مدل‌سازی عوامل مؤثر بر نیروی کششی، میزان لغزش و مصرف سوخت تراکتور آزمایش‌های مزرعه‌ای با استفاده از گاوآهن سه خیشه انجام شد. آزمایش‌ها به‌صورت به آزمون دو تراکتوری انجام گردیده و نیروی مالبندی بین دو تراکتور به‌وسیله نیروسنج (Load cell) اندازه‌گیری شد. همچنین، با محاسبه میزان لغزش، نیروی مالبندی و مقاومت غلتشی تراکتور، نیروی کششی موثر تراکتور محاسبه گردید. در خاک مزرعه مورد آزمون از آزمایش فاکتوریل بر پایه طرح بلوک کامل تصادفی (RCDB) و با سه تکرار آزمون صورت گرفت. در زمین مزرعه تحقیقاتی، رطوبت در سه سطح، سرعت پیشروی تراکتور در چهار سطح و عمق کاری در چهار سطح است.

بافت خاک در نتایج آزمایش در جدول ۱ به‌صورت خصوصیات فیزیکی و شیمیایی خاک مزرعه تحقیقاتی آمده که بافت خاک از نوع شنی رسی می‌باشد. تعیین مقدار رطوبت خاک معمولاً بر اساس وزن خشک آن صورت می‌گیرد. برای تعیین میزان رطوبت خاک، سه نمونه از هر کرت تا عمق عملیات خاک‌ورزی نمونه‌گیری شد. برای عمق کار ۲۰ سانتی‌متر، ابتدا عمق مذکور به دو قسمت از ۰ تا ۱۰ و از ۱۰ تا ۲۰ سانتی متر تقسیم شد سپس از هر کدام ۳ نمونه خاک در ظرف مخصوص درب‌دار برداشته شد. وزن خاک خشک پس از قراردادن خاک مرطوب در دمای ۱۱۰°C به مدت ۲۴ ساعت در آون برای هر آزمایش به دست آمد. تعیین رطوبت خاک هر سامانه خاک‌ورزی مورد بررسی به‌صورت به وزن‌سنجی در همان تاریخ تیمارهای خاک‌ورزی انجام شد.

دلیل انتخاب رطوبت‌های متفاوت جهت انجام آزمون، بررسی تأثیرات عملکرد رطوبت خاک در میزان لغزش چرخه‌ای تراکتور است. با افزایش رطوبت مقاومت خاک کم می‌شود. برای انتخاب عمق کار با گاوآهن، بعد از شخم زمین حین آزمون، به‌وسیله متر و با گذاشتن یک میله بر روی خاک شخم‌خورده، در چندین نقطه از طول زمین عمق را اندازه گرفته و میانگین آن را ثبت می‌کنیم. دلیل انتخاب عمق‌های متفاوت، ارزیابی و جهت رسیدن به اهداف تحقیق که اندازه‌گیری و ثبت دیتا برای متغیرهای مصرف سوخت و نیروی کششی تراکتور است. ازآنجائی‌که تراکتور مذکور دارای سرعت‌سنج نیست لذا جهت ثبت سرعت پیشروی، با انتخاب دنده‌های مختلف و در حالت دنده‌های سنگین، با ثبت زمان در طول زمین، سرعت به دست آمد. در هر کرت آزمایشی نیروی کششی ادوات خاک‌ورزی، مصرف سوخت و لغزش در خاک، برای همان رطوبت خاک طبق توضیحات بالا اندازه‌گیری شد.

آزمون‌های مزرعه‌ای در مزارع کشاورزی شرکت تراکتورسازی ایران-تبریز (طول جغرافیایی "33.231 '11 °46، عرض جغرافیایی "16.018 '3 °38 و ارتفاع از سطح دریا 1353 m) انجام گردید. سطح مزرعه عاری از هر نوع پوشش گیاهی بود و دانه‌بندی خاک با استفاده از روش دانه‌بندی و بهره‌گیری از USDA soil taxonomy مطابق جدول (۱) به دست آمد(Regassa *et al*., 2023).

جدول ۱ - خصوصیات فیزیکی و شیمیایی خاک مزرعه تحقیقاتی

خصوصیت خاک	واحد	مقدار
شن	(%)	۴۸/۶
سیلت	(%)	۲۹/۴
رس	(%)	۲۲
ماده عالی	(%)	۰/۲
ظرفیت مزرعه بر اساس وزن خشک	(%)	۱۲/۳۴
چگالی ظاهری خشک	(kg/m^3)	۱۱۵۰
میزان رطوبت بر اساس وزن خشک	(%)	۸-۱۹/۶
رطوبت بحرانی	(%)	۲۲/۵

تجهیزات موردنیاز

به‌منظور ایجاد کشش، از روش دو تراکتوری مطابق شکل (۱) حین شخم با گاوآهن سه خیشه (عرض کار ۱۰۴ سانتیمتر) استفاده گردید. در جدول ۲ مشخصات تراکتور بار (ITM399-4W+CAB) و تراکتور آزمون (ITM399-4W) مورداستفاده در روش دو تراکتوری نشان‌داده‌شده است.

جدول ۲ - مشخصات فنی تراکتورهای آزمون و بار مورداستفاده

مشخصات	واحد	ITM399-4W	ITM399-4W+CAB
توان موتور	kW	۸۲	۸۲
حداکثر دور موتور	RPM	۲۳۹۰	۲۳۹۰
حداکثر گشتاور (۱۳۰۰ RPM)	N.m	۴۴۵	۴۴۵
وزن استاتیکی روی محور جلو	kg	۱۸۸۰	۱۹۸۰
وزن استاتیکی روی محور عقب	kg	۲۰۹۰	۲۲۶۰
فشار باد چرخ عقب	bar	۱.۱	۱.۱
فاصله بین دو محور	mm	۲۶۰۰	۲۶۰۰

شکل ۱ - روش دو تراکتوری مورداستفاده برای اندازه‌گیری نیروی کششی تراکتور بار و لودسل نصب شده بر روی مجموعه

آزمون‌های مزرعه‌ای

تمامی ابزار و ادوات موردنیاز به همراه تراکتورهای بار و آزمون به مزرعه تحقیقاتی منتقل گردید. آزمون‌های مزرعه‌ای با گاوآهن سه خیشه در چهار سطح عمق کاری (۱۰، ۲۰، ۳۰ و۴۰ سانتی‌متر)، سه رطوبت متفاوت خاک (۱۲ و ۱۵ و ۱۹ درصد) و چهار سطح سرعت پیشروی با دنده‌های سنگین (۱، ۲/۵۵، ۴/۴۰ و ۶/۵۸ کیلومتر بر ساعت) اندازه‌گیری شدند.

جهت اطمینان از صحت دیتای ثبت شده موردنیاز، بدین صورت عمل می‌شود که درصورت خطا و تغییر بیش از اندازه در هرکدام از اندازه‌گیری‌ها، اندازه ثبت شده (دارای خطا) کنار گذاشته شده و مجدداً آزمون برای آن حالت تکرار می‌گردد.

برای مثال در زمین با رطوبت۱۲٪ تراکتور بار با ادوات نصب شده در شروع خط آزمون (مسافت ۱۰۰ متر) قرار گرفته و گاوآهن به‌اندازه میانگین ۱۰ سانتیمتر بوسیله پیچ تنظیم کوادرانت ثابت می‌گردد. (میانگین عمق با اندازه‌گیری عملی صحه‌گذاری شد) تراکتور آزمون‌شونده در جلو قرار گرفته و با زنجیر و لودسل نصب شده به تراکتور بار در یک خط قرار می‌گیرد و دنده آزمون را انتخاب کرده و با دور موتور نهایی، تراکتور شروع به حرکت می‌کند در این حالت زمان طی شده برای ۵۰ متر وسط که با شاخص جدا شده ثبت می‌گردد در مسافت ۵۰ متر مقادیر مصرف سوخت،نیروی کششی با لودسل اندازه‌گیری‌شده و ثبت می‌گردد و همچنین ۱۰ دور چرخ عقب اندازه‌گیری‌شده و سپس لغزش محاسبه و ثبت می‌گردد. آزمون‌ها در سه تکرار برای هر حالت اجرا و بدلیل نیاز به عدم قطعیت در محاسبات و همچنین افزایش بیش از حد داده، میانگین آنها به‌عنوان مقدار نهایی در نظر گرفته شد.

با درنظرگرفتن متغیرهای مستقل و تکرارها، در مجموع ۱۴۴ تیمار در قالب ۳ بلوک بر پایه طرح بلوک‌های کاملاً تصادفی[1] (RCBD) اعمال شد. هر بلوک ۴۸ کرت، هر کرت ۲ متر عرض و ۵۰ متر طول دارد. در آزمون‌های مزرعه‌ای، سه پارامتر شامل نیروهای کششی تحت بار، سرعت پیشروی، مصرف سوخت به‌صورت مستقیم اندازه‌گیری شدند. مدت زمان طی مسیر ۵۰ متری بدون بار تراکتور نیز جهت به دست آوردن نیروی کششی و محاسبه مقدار لغزش اندازه‌گیری شد.

عامل‌های اندازه‌گیری شده

برای اندازه‌گیری نیروی کششی از روش استاندارد دو تراکتوری طبق شکل (۱) استفاده می‌شود. لودسل کششی

[1] Randomized Complete Block Design

مدل SS300-10T ساخت کارخانه SEWHA ، با ظرفیت ۱۰۰ کیلونیوتن و بادقت اندازه‌گیری ۰/۰۱ کیلوگرم نیرو توسط یک زنجیر، بین دو تراکتور (تراکتور بار و تراکتور آزمون)، قرار گرفت. باتوجه‌به تغییرات شدید و سریع نیروی کششی، در طول هر کرت بیش از پنجاه داده ثبت و میانگین آنها به‌عنوان نیروی کششی منظور شد. باتوجه‌به قابلیت تنظیم دیتابرداری دیتالاگر، می‌توان تعداد داده‌برداری را بر حسب میلی‌ثانیه کم یا زیاد کرد.

مصرف سوخت تراکتور با استفاده از دو حسگر سنجش جریان، ساخت شرکت Ovrall ژاپن اندازه‌گیری شد (شکل ۲). یک حسگر در مسیر رفت (قبل از پمپ انژکتور) و دیگری در مسیر برگشت سوخت اضافی به مخزن کار گذاشته شدند. اختلاف بین این دو حسگر در نمایشگر رقمی سامانه سوخت سنج بیانگر میزان سوخت مصرفی است. سرعت پیشروی درون مزرعه با استفاده از یک زمان‌سنج و مسافت طی شده توسط تراکتور، اندازه‌گیری شد. برای به‌دست‌آوردن میزان لغزش W_s از روش استاندارد RNAM از معادله (۱) استفاده شد (Kepner *et al.*, 1978):

$$W_s(\%) = \left(1 - \frac{V_a}{V_t}\right) \times 100 = \left(1 - \frac{\frac{x}{t_a}}{\frac{x}{t_t}}\right) \times 100 = \left(1 - \frac{t_t}{t_a}\right) \times 100 \quad (۱)$$

که در آن t_t و t_a به ترتیب زمان (s) لازم برای طی مسیر ۵۰ متری بدون بار و با بار، V_t و V_a به ترتیب سرعت بدون بار[۲] و سرعت واقعی تراکتور با بار برحسب متر بر ثانیه و x مسیر آزمایش است. (در این آزمایش مسیر آزمایش ۵۰ متر انتخاب شده است) لذا برای محاسبه درصد لغزش کافی است زمان طی مسیر ۵۰ متری با بار و بدون بار اندازه‌گیری و از رابطه (۱) بکسوات محاسبه گردد.

شکل ۲- سوخت سنج دو حسگر Ovrall

با استفاده از مقادیر به‌دست‌آمده برای نیروی کشش مالبندی P (نیوتن)، مقاومت غلتشی[۳] چرخ‌های تراکتور R (نیوتن) و درصد لغزشِ چرخ‌های محرک (Ws)، بازده کششی[۴] برای هر آزمایش با استفاده از معادله (۲) محاسبه می‌شود:

$$T.E. = \frac{P}{P+R}(1 - W_s) \quad (۲)$$

نیروی مالبندی متناظر با حالتی که گاوآهن بر روی تراکتور نصب نباشد، نشان‌دهنده مقاومت غلتشی تراکتور است. یکی از مهم‌ترین عامل‌هایی که در این تحقیق مورد بررسی قرار گرفت، بازده انرژی کل مجموعه[۵] تراکتور-ادوات خاک‌ورزی است که طریق معادله (۳) تعریف می‌شود:

$$OEE(\%) = \frac{V_a \times P}{10.2 \times F_c} \times 3.6 \quad (۳)$$

که در آن V_a سرعت واقعی حرکت تراکتور در مزرعه (km/h) و Fc مصرف سوخت تراکتور (lit/h) است. باتوجه‌به معادله (۳) می‌توان دریافت که سرعت واقعی حرکت در مزرعه، مقاومت کششی موردنیاز ادوات خاک‌ورزی و مصرف سوخت به‌صورت به مستقیم و عوامل دیگری مانند لغزش به‌صورت به غیرمستقیم روی بازده انرژی کل تأثیر می‌گذارند. رطوبت در عمق ۲۰ cm به‌عنوان محتوی رطوبت مبنا در نظر گرفته شد و برای محاسبه آن از رابطه (۴) استفاده گردید:

$$C_m = \frac{M_{ws} - M_{ds}}{M_{ds}} \times 100 \quad (۴)$$

که در آن M_{ds} و M_{ws} به ترتیب وزن خاک خشک و وزن خاک مرطوب هستند. در این تحقیق، وزن خاک خشک پس از قراردادن خاک مرطوب در دمای ۱۱۰°C به مدت ۲۴ ساعت در آون به دست آمد. تعیین رطوبت خاک هر سامانه خاک‌ورزی مورد بررسی به‌صورت به وزن‌سنجی در همان تاریخ تیمارهای خاک‌ورزی انجام شد.

سامانه استنتاج عصبی-فازی تطبیقی (ANFIS)

اگر داده‌های ورودی، مبهم و یا دارای عدم قطعیت باشند، یک سامانه فازی مانند ANFIS بهترین انتخاب برای تحلیل آنها خواهد بود (Mohd Salleh & Hussain, 2016). مدل شبکه‌ی عصبی مصنوعی (ANNs) زمانی کارآیی بهتری از خود نشان می‌دهد که اطلاعات و داده‌های کافی وجود داشته باشد.

[2] Plow tool
[3] Rolling Resistance
[4] Traction efficieny
[5] Overall energy efficieny

سامانه استنتاج عصبی - فازی تطبیقی که توسط Jang مطرح شد از ترکیب قابلیت تولید قوانین فازی مدل FIS و قابلیت آموزش شبکه در مدل ANNs ایجاد می‌شود و به‌این‌ترتیب می‌تواند بر معایب هر یک از این مدل‌ها غلبه کند (Jang, 1993). ANFIS با محدودیت‌های کمتری نسبت به مدل‌های ANNs و FIS در زمینه‌های مختلفی که تعداد داده‌های به‌دست‌آمده کمتر بوده و داده‌ها دارای عدم قطعیت زیادی دارند، می‌تواند نتایج بهتری ارائه دهد. توابع عضویت در فرایند آموزش شبکه ANFIS تغییر می‌کند و تطبیق آنها به واسطه یک بردار گرادیان میسر خواهد بود. بردار گرادیان مقیاسی برای ارزیابی عملکرد مدل ANFIS است. طرحواره ای از مدل ANFIS با چهار متغیر مستقل ورودی و دو متغیر وابسته در خروجی در شکل ۳ نشان‌داده‌شده است.

در شبکه‌های عصبی به طور کل داده‌های در دسترس به سه مجموعه آموزش، اعتبارسنجی و آزمون طبقه‌بندی می‌شوند. مجموعه آموزش توسط الگوریتم یادگیری برای تخمین وزن‌های شبکه استفاده می‌شود و مجموعه اعتبارسنجی برای ارزیابی دقت پیش‌بینی شبکه آموزش‌دیده، مورداستفاده قرار می‌گیرند. در این مطالعه، ۷۰ درصد از داده‌ها به‌عنوان داده‌های آموزش، ۲۰ درصد از آنها جهت اعتبارسنجی و ۱۰ درصد برای آزمون مدل در نظر گرفته شد. به‌منظور بررسی اثرگذاری متغیرهای ورودی بر روی شاخص‌های کیفی، می‌توان از آزمون‌های آماری تحلیل مؤلفه اصلی[6] (PCA)، انتخاب پیشرو[7] (FC) و آزمون گاما[8] (GT) استفاده نمود. لازم به ذکر است که آزمون‌های مذکور قادر به کاهش حجم محاسبات (متغیرهای ورودی) روش‌های هوش مصنوعی می‌گردند. در تحقیق حاضر از آزمون آماری تحلیل مؤلفه اصلی برای کاهش پیچیدگی تحلیل متغیرهای اولیه مسئله و همچنین تفسیر بهتر اطلاعات استفاده شده است.

به‌منظور تعیین ساختار بهینه مدل ANFIS ، پنج نوع تابع عضویت شامل: TriMF (مثلثی)، GaussMF (گاوسی)، PiMF (پی‌شکل)، DsigMF (سیگموئید دوگانه) و TrapMF (ذوزنقه‌ای) مورد بررسی قرار گرفتند. انتخاب این توابع بر اساس کاربرد گسترده آنها در مطالعات پیشین و توانایی متفاوت آنها در مدل‌سازی و روابط غیرخطی انجام شد. برای ایجاد شرایط مقایسه یکسان، در تمامی مدل‌ها نوع تابع عضویت خروجی به‌صورت Linear در نظر گرفته شد.

تعداد توابع عضویت ورودی ها به روش آزمون خطا و باهدف دستیابی به تعادل بین دقت مدل و پیچیدگی محاسباتی تعیین گردید. پس از انجام چندین آزمایش اولیه، ساختار ۵،۳ و۴ تابع عضویت به ترتیب برای ورودی‌های اول، دوم و سوم انتخاب شد، زیرا افزایش تعداد توابع عضویت منجر به بهبود معنی‌دار شاخص‌های عملکرد نشده و در برخی موارد موجب افزایش پیچیدگی و احتمال بیش برازش گردید.

فرایند آموزش ANFIS با استفاده از الگوریتم Hybrid Learning (ترکیب حداقل مربعات و پس انتشار خطا) انجام شد. برای کاهش اثر مقداردهی اولیه تصادفی عامل‌ها و افزایش قابلیت اطمینان نتایج، هرمدل ۲۰۰ بار اجرا شد و میانگین شاخص‌های عملکرد شامل ریشه میانگین مربعات خطا (RMSE)، ضریب تعیین (R^2)، کارایی مدل (EF) و خطای اریب میانگین (MBE) محاسبه گردید. درنهایت، مدل برتر بر اساس کمترین RMSE و MBE و همچنین بیشترین R2 و EF انتخاب شد.

مطابق نتایج جدول ۷، برای متغیرهای Draft Force و Slippage، تابع عضویت DsigMF بهترین عملکرد را با کمترین RMSE و بیشترین R^2 نشان داد. برای مصرف سوخت تابع TrapMF و برای OEE تابع PiMF بهترین نتایج را ارائه کردند. بنابراین نوع تابع عضویت نهایی برای هر خروجی بر اساس مقایسه کمی شاخص‌های عملکرد انتخاب شد.

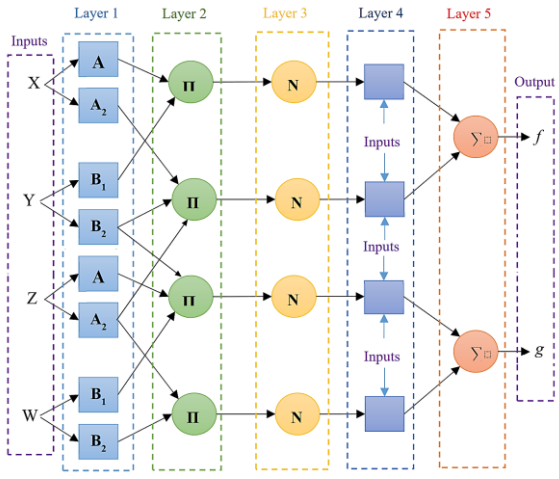

شکل ۳- ساختار ANFIS با چهار متغیر ورودی و دو خروجی

نرمالیزه‌کردن (Normalization) داده‌ها

به دلیل ماهیت متفاوت مقادیر ورودی، داده‌های مورد بررسی برای استفاده در ساختار ANFIS با استفاده از رابطه زیر بین

[6] Principle Component Analysis
[7] Forward Selection
[8] Gamma Test

اعداد 1- تا 1 نرمال شدند تا حساسیت شبکه ANFIS حفظ شود. یکی از انواع توابع تبدیل متداول که در شرط فوق صدق می‌کنند، توابع سیگموید sig(n) و تابع تانژانت هیپربولیک tanh(n) است. در این تحقیق از تابع تانژانت هیپربولیک استفاده شده است و ازآنجائی‌که خروجی این تابع بین [1 ,1-] است، لذا نرمالیزه‌سازی داده‌ها بین [1 ,1-] انجام گرفت. برای نرمالیزه‌کردن داده‌ها از رابطه (۵) استفاده شد.

$$X_{normal} = 2 \times \left(\frac{x - x_{min}}{x_{max} - x_{min}}\right) - 1 \qquad (۵)$$

معیارهای ارزیابی

مقادیر به‌دست‌آمده از مدل ANFIS بر اساس سه معیار ضریب کارایی مدل[۹] (EF)، جذر میانگین مجموع مربعات خطا[۱۰] (RMSE)، ضریب تبیین[۱۱] (R^2) و میانگین خطای انحراف[۱۲] (MBE) با داده‌های مشاهده‌ای حاصل از معادله‌های (۶) – (۹) مقایسه شد. مقادیر کمتر MBE و RMSE و مقادیر نزدیک‌تر به یک برای EF نشانه‌ی برتری مدل می‌باشد (Suresh *et al*., 2023).

$$\mathrm{EF} = \frac{\sum_{i=1}^{N}(P_i - O_i)^2}{\sum_{i=1}^{N}(O_i - \bar{O})^2} \qquad (۶)$$

$$\mathrm{RMSE} = \sqrt{\frac{1}{N}\sum_{i=1}^{N}(P_i - O_i)^2} \qquad (۷)$$

$$R^2 = \frac{[\sum_{i=1}^{N}(P_i - \bar{P})(O_i - \bar{O})]^2}{\sum_{i=1}^{N}(P_i - \bar{P})^2 \sum_{i=1}^{N}(O_i - \bar{O})^2} \qquad (۸)$$

$$\mathrm{MBE} = \frac{1}{N}\sum_{i=1}^{N}(P_i - O_i) \qquad (۹)$$

که در آن Pi، مقادیر پیش‌بینی شده توسط مدل، Oi مقادیر مشاهده شده، N تعداد داده‌ها در هر بخش از مدل، $\bar{P}$ میانگین مقادیر پیش‌بینی شده توسط مدل و $\bar{O}$ میانگین مقادیر مشاهده شده است. با بررسی تعداد لایه‌های مخفی، نرون‌ها و نوع توابع فعال‌سازی، بهترین مدل شبکه ANFIS باتوجه‌به عامل‌های ارزیابی مشخص شده است.

مدل رگرسیونی

با استفاده از روش رگرسیونی (یک روش عاملی)، در این تحقیق برای برقراری رابطه بین نهاده‌ها و عملکرد استفاده می‌شود و همچنین از تابع لگاریتمی که به تابع کاب داگلاس[۱۳] مشهور است استفاده شد (Mobtaker *et al*., 2010). شکل عمومی تابع کاب داگلاس در رابطه (۱۰) نشان‌داده‌شده است.

$$Y = f(x)\, exp(u) \qquad (۱۰)$$

که در آن $f(x)$ نهاده‌های تولیدی و u میزان مطلوبیت است. اگر از طرفین معادله (۱۰) لگاریتم گرفته شود، معادله به‌صورت به یک معادله خطی مطابق معادله (۱۱) درمی‌آید.

$$ln\, Y_i = a_0 + \sum_{j=1}^{n} a_j\, ln(X_{ij}) + e_i\,, \qquad (۱۱)$$
$$i = 1,2,\ldots,n$$

که در آن Yi مقدار خروجی، Xij مقدار عامل‌های مستقل و aj مقادیر ثابت و ei ضریب خطا است. در این مطالعه متغیرهای مستقل، عمق خاک‌ورزی، سرعت پیشروی، رطوبت و نوع گاوآهن و متغیر وابسته میزان مصرف سوخت و بازده کششی است.

مدل رگرسیونی کاب-داگلاس یکی از پرکاربردترین مدل‌های تحلیل تولید در علوم مهندسی کشاورزی می‌باشد. دلیل انتخاب آن به دلایل علمی زیر است:

الف-تفسیر آسان ضرایب در فرم لگاریتمی تابع کاب-داگلاس،ضرایب رگرسیون مستقیماً کشش تولید نسبت به نهاده‌ها را نشان می‌دهد. لذا می‌توان اثرگذاری صددرصدی هر متغیر مستقل بر متغیر وابسته را به‌سادگی تفسیر کرد. این ویژگی در مدل‌های خطی معمولی وجود ندارد.

ب-تبدیل مدل غیرخطی به فرم خطی تابع مذکور به‌صورت ذاتی غیرخطی است، اما با تبدیل لگاریتمی به یک مدل خطی تبدیل می‌شود و می‌توان عامل‌های آن را با روش حداقل مربعات معمولی برآورد نمود. این موضوع موجب سادگی محاسبات و افزایش قابلیت کاربرد مدل می‌شود.

ج-کاربرد گسترده و اعتبار تجربی مطالعات متعددی در زمینه کشاورزی، مکانیزاسیون از این مدل استفاده کرده‌اند و نتایج قابل‌اعتمادی گزارش نموده‌اند . بنابراین استفاده از این مدل امکان مقایسه نتایج با پژوهش‌های پیشین را فراهم می‌کند.

[9] Efficiency
[10] Root Mean Square Error
[11] Determination Coefficient
[12] Mean Bias Error
[13] Coob-Douglas production function

نتایج و بحث

نتایج رگرسیون

نتایج تجزیه واریانس (ANOVA) اثرات اصلی و متقابل سرعت پیشروی، عمق خاک‌ورزی و رطوبت خاک بر نیروی کششی، مصرف سوخت و لغزش در جدول ۳ ارائه شده است. نتایج نشان داد که عمق خاک‌ورزی و رطوبت خاک اثر معنی‌دار ($P \leq ۰/۰۱$) بر هر سه متغیر وابسته یعنی نیروی کششی، مصرف سوخت و میزان لغزش داشتند. همچنین سرعت پیشروی بر مصرف سوخت و لغزش اثر معنی‌دار داشت، درحالی‌که اثر آن بر نیروی کششی معنی‌دار نبود. معنی‌دار بودن اغلب اثرات متقابل نشان‌دهنده وابستگی پاسخ به ترکیب شرایط عملیاتی و ویژگی‌های خاک است. افزایش عمق خاک‌ورزی موجب افزایش نیروی کششی موردنیاز شد. این رفتار ناشی از افزایش حجم خاک جابه جا شده، افزایش سطح تماس خیش با خاک و در نتیجه افزایش مقاومت خاک در برابر حرکت ادوات است. افزایش عمق همچنین سبب افزایش بار وارده بر موتور و سامانه انتقال قدرت تراکتور شده و در نتیجه مصرف سوخت را افزایش می‌دهد. ازسوی‌دیگر، افزایش نیروی کششی موردنیاز معمولاً با افزایش لغزش چرخ‌ها همراه است، زیرا سهم بیشتری از توان تراکتور صرف غلبه بر مقاومت خاک می‌شود.

نتایج نشان داد که افزایش رطوبت خاک نیز تغییرات معنی‌داری در متغیرهای مورد بررسی ایجاد می‌کند. در محدوده رطوبتی موردمطالعه، تغییر مقاومت برشی و چسبندگی خاک سبب تغییر نیروی کششی موردنیاز و عملکرد حرکتی تراکتور شده است. افزایش رطوبت می‌تواند از یک سو مقاومت مکانیکی خاک را کاهش دهد، اما ازسوی‌دیگر در سطوح بالاتر رطوبت موجب افزایش چسبندگی و کاهش کارایی انتقال نیرو بین چرخ و خاک شود که نتیجه آن افزایش لغزش و تغییر مصرف سوخت است.

سرعت پیشروی نیز تأثیر معنی‌داری بر مصرف سوخت و لغزش داشت. با افزایش سرعت، نیاز توان لحظه‌ای افزایش یافته و در نتیجه مصرف سوخت بیشتر می‌شود. همچنین افزایش سرعت باعث کاهش زمان تماس موثر چرخ با خاک و افزایش احتمال لغزش می‌شود. بااین‌حال، عدم معنی دار بودن اثر سرعت بر نیروی کششی نشان می‌دهد که در دامنه سرعت های مورد بررسی، مقاومت اصلی خاک عامل غالب در تعیین نیروی کششی بوده است.

این نتایج با گزارش های منتشر شده در حوزه مکانیزاسیون کشاورزی همخوانی دارد؛ به‌طوری که پژوهشگران مختلف افزایش عمق خاک‌ورزی را عامل افزایش نیروی کششی، مصرف سوخت و لغزش دانسته‌اند و نقش رطوبت خاک را به‌عنوان یکی از مهم‌ترین عوامل موثر بر عملکرد کششی ترکتور معرفی کرده‌اند.

نتایج این پژوهش نشان داد که عمق خاک‌ورزی و رطوبت خاک مهم‌ترین عوامل موثر بر نیروی کششی، مصرف سوخت و لغزش هستند. افزایش عمق خاک‌ورزی از ۱۰ سانتی‌متر به ۴۰ سانتی‌متر به دلیل افزایش مقاومت خاک، موجب افزایش نیاز کششی، مصرف سوخت و لغزش شد. همچنین تغییرات رطوبت خاک از حدود۲۰٪ به ۱۲٪ به طور معنی‌داری عملکرد کششی تراکتور را تحت تأثیر قرار داد. سرعت پیشروی نیز از حدود یک کیلومتر بر ساعت به حدود ۷ کیلومتر بر ساعت اگرچه بر نیروی کششی اثر معنی‌داری نداشت، اما موجب تغییر مصرف سوخت و لغزش شد. بنابراین انتخاب ترکیب مناسب سرعت پیشروی، عمق کار و زمان انجام عملیات بر اساس شرایط رطوبتی خاک که در دو فصل مجزا انجام گرفت، می‌تواند نقش مؤثری در کاهش مصرف انرژی، بهبود کارایی مزرعه و افزایش بهره‌وری عملیات خاک‌ورزی داشته باشد.

نیروی کششی

نتایج نیروی کششی در جدول ۴ و شکل (۴) ارائه شده است. نیروی کششی با افزایش عمق خاک‌ورزی به طور معنی‌داری افزایش یافت، درحالی‌که با افزایش رطوبت خاک کاهش یافت. این کاهش به دلیل کاهش مقاومت مکانیکی خاک در شرایط مرطوب‌تر است. اثر سرعت پیشروی بر نیروی کششی معنی‌دار نبود که می‌تواند به دلیل محدوده نسبتاً نزدیک سرعت‌های موردمطالعه باشد.

لغزش چرخ

تأثیر متغیرهای آزمایشی بر لغزش چرخ در جدول ۵ و شکل (۵) نشان‌داده‌شده است. لغزش با افزایش عمق، سرعت و رطوبت خاک افزایش یافت. بیشترین مقدار لغزش (۳۵٪) در عمق ۴۰ سانتی‌متر، سرعت ۴/۴۰ کیلومتر بر ساعت و رطوبت ۱۹٪ مشاهده شد. افزایش لغزش با رطوبت را می‌توان به کاهش چسبندگی خاک به چرخ‌ها نسبت داد.

جدول ۳- تجزیه واریانس (ANOVA) اثرات سرعت پیشروی، عمق خاک‌ورزی و رطوبت خاک بر متغیرهای وابسته نیروی کششی، مصرف سوخت و میزان لغزش.

Factor	لغزش (%)		مصرف سوخت (L/h)		نیروی کششی (N)	
	F-value	AS[1]	F-value	AS[1]	F-value	AS[1]
سرعت پیشروی	۳۶۹/۵**	۳۸۳/۲	۱۴۵۰/۶۵**	۳۸۹/۸۲	۰/۴۱ns	۴۴۰۶۸۰۳۸/۷
عمق خاک‌ورزی	۱۳۰/۸**	۵۹۷/۳	۶۴/۳۵**	۲۱۵/۴۵	۲۹۷**	۳۲۵۳۵۳۹۰۱/۳
رطوبت خاک	۳۰۴/۵**	۶۸۰/۷	۵۹/۹۲**	۱۵۰/۹۸	۲۶/۰۸**	۱۰۴۹۳۱۳۰/۶
عمق×سرعت	۴۶/۲**	۱۵۳/۰	۶/۸۵**	۳/۶۵۸	۱/۳۶ns	۱۶۵۹۲۳۴۶/۶
رطوبت خاک×سرعت	۱۴۵/۲**	۳۹/۵	۲۶/۸۵**	۱۶/۳۵	۰/۵۶ns	۳۸۱۷۰۹۸/۷
عمق× رطوبت خاک	۶۵/۲**	۳۷/۹	۱۹/۸۷**	۵۳/۰۶	۲/۳۶ns	۳۲۵۹۸۸۹/۲
سرعت×عمق× رطوبت خاک	۱۲/۶**	۳۶/۴	۱۸/۹۰**	۲/۰۴	۵/۳۷**	۸۶۱۲۴۴۵۶/۲

جدول ۴- نیروی کششی به‌ازای عمق کاری، رطوبت و سرعت‌های پیشروی مختلف

رطوبت خاک	عمق شخم	سرعت	نیروی کششی(kN)				انحراف معیار	عدم قطعیت
(%)	(cm)	(km/h)	R1	R2	R3	(R1,R2,R3) میانگین	SD	UA
۱۲	۱۰	۱	۵/۴۸	۵/۹۹	۶/۰۷	۵/۸۵	۱/۹	۱/۱
		۲/۵۵	۶/۶۴	۶/۶۵	۶/۳۱	۶/۵۳	۳/۲	۱/۴
		۴/۴	۸/۶۰	۷/۶۳	۷/۶۲	۷/۹۵	۱/۱	۰/۸
		۶/۵۸	۷/۱۰	۷/۴۰	۶/۷۴	۷/۰۸	۲/۱۰	۱/۱
	۲۰	۱	۱۱/۳۷	۱۱/۸۷	۱۱/۲۰	۱۱/۴۸	۱/۸	۱
		۲/۵۵	۱۲/۹۰	۱۱/۸۲	۱۲/۲۸	۱۲/۳۳	۱/۲	۰/۸
		۴/۴	۱۲/۶۷	۱۳/۹۲	۱۴/۲۱	۱۳/۶	۰/۸	۰/۷
		۶/۵۸	۱۳/۷۶	۱۲/۷۴	۱۳/۰۴	۱۳/۱۸	۱/۲	۰/۸
	۳۰	۱	۱۸/۴۱	۱۸/۰۴	۱۸/۵۸	۱۸/۳۴	۲/۳	۱/۲
		۲/۵۵	۱۸/۷۶	۲۰/۱۳	۱۹/۳۲	۱۹/۴	۱	۰/۸
		۴/۴	۲۱/۰۲	۲۱/۸۶	۲۰/۰۸	۲۰/۹۹	۰/۸	۰/۷
		۶/۵۸	۱۹/۴	۱۹/۷۶	۱۸/۷۴	۱۹/۳	۱/۳	۰/۹
	۴۰	۱	۲۳/۶۷	۲۲/۸۹	۲۳/۱۶	۲۳/۲۴	۱/۶	۱
		۲/۵۵	۲۷/۸۵	۲۹/۶۷	۲۹/۹۷	۲۹/۱۶	۰/۵	۰/۶
		۴/۴	۳۱/۲۷	۳۳/۷۵	۳۲/۶۲	۳۲/۵۵	۰/۶	۰/۶
		۶/۵۸	۳۱/۴۹	۲۸/۶۵	۳۰/۲۸	۳۰/۱۴	۰/۵	۰/۵
۱۵	۱۰	۱	۵/۶۴	۵/۱۰	۵/۲۵	۵/۳۳	۲/۳	۱/۱
		۲/۵۵	۶/۲۰	۵/۷۸	۶/۱۱	۶/۰۳	۲/۸	۱/۳

		۴/۴	۷/۲۹	۷/۶۶	۷/۷۰	۷/۵۵	۲/۷	۱/۲
		۶/۵۸	۶/۶۶	۶/۵۹	۶/۴۹	۶/۵۸	۸/۲	۲/۲
		۱	۱۱/۳۳	۱۰/۸۳	۱۱/۵۰	۱۱/۲۲	۱/۸	۱
		۲/۵۵	۱۲/۷۴	۱۱/۴۸	۱۱/۹۹	۱۲/۰۷	۱/۱	۰/۸
	۲۰	۴/۴	۱۳/۰۶	۱۳/۷۷	۱۳/۴۶	۱۳/۴۳	۱/۹	۱/۱
		۶/۵۸	۱۲/۹۰	۱۲/۸۲	۱۳/۳۱	۱۳/۰۱	۲/۳	۱/۲
		۱	۱۸/۶۵	۱۷/۹۶	۱۷/۴۵	۱۸/۰۲	۱/۱	۰/۸
		۲/۵۵	۱۹/۰۹	۱۸/۴۶	۱۹/۶۹	۱۹/۰۸	۱/۱	۰/۸
	۳۰	۴/۴	۲۱/۶۰	۲۰/۲۹	۲۰/۱۱	۲۰/۶۷	۰/۸	۰/۷
		۶/۵۸	۱۷/۶۲	۱۹/۷۰	۱۹/۶۸	۱۹	۰/۵	۰/۵
		۱	۲۴/۰۲	۲۲/۷۳	۲۱/۸۹	۲۲/۸۸	۰/۶	۰/۶
		۲/۵۵	۲۷/۸۷	۲۹/۲۷	۲۸/۹۸	۲۸/۶۹	۰/۹	۰/۷
	۴۰	۴/۴	۳/۷۹	۳۲/۰۴	۳۱/۸۵	۳۱/۵۶	۰/۹	۰/۷
		۶/۵۸	۲۹/۷۶	۲۸/۳۰	۲۹/۴۸	۲۹/۱۸	۰/۸	۰/۷
		۱	۴/۷۳	۵/۱۹	۵/۱۴	۵/۰۲	۲/۴	۱/۲
		۲/۵۵	۵/۷۵	۵/۹۴	۵/۴۲	۵/۷	۲/۵	۱/۲
	۱۰	۴/۴	۶/۷۵	۷/۳۳	۷/۵۲	۷/۲	۱/۶	۱
		۶/۵۸	۶/۱۴	۶/۱۹	۶/۲۷	۶/۲	۱۰/۲	۲/۴
		۱	۱۰/۳۸	۱۱/۰۴	۱۱/۴۹	۱۰/۹۷	۱/۲	۰/۸
		۲/۵۵	۱۲/۶۸	۱۱/۵۵	۱۱/۲۳	۱۱/۸۲	۰/۸	۰/۷
	۲۰	۴/۴	۱۲/۶۱	۱۳/۵۲	۱۳/۴۱	۱۳/۱۸	۱/۲	۰/۸
		۶/۵۸	۱۳/۰۶	۱۲/۲۴	۱۲/۹۶	۱۲/۷۵	۱/۴	۰/۹
۱۹		۱	۱۷/۳۸	۱۷/۹۴	۱۷/۷۸	۱۷/۷	۲/۲	۱/۱
		۲/۵۵	۱۸/۷۰	۱۸/۰۷	۱۹/۵۱	۱۸/۷۶	۰/۹	۰/۷
	۳۰	۴/۴	۱۹/۷۲	۲۰/۵۰	۲۰/۸۳	۲۰/۳۵	۱/۱	۰/۸
		۶/۵۸	۱۸/۱۴	۱۸/۷۳	۱۹/۲۳	۱۸/۷	۱/۳	۰/۹
		۱	۲۳/۰۲	۲۱/۹۹	۲۲/۶۴	۲۲/۵۵	۱/۳	۰/۹
		۲/۵۵	۲۸/۵۷	۲۷/۸	۲۸/۷۷	۲۸/۳۸	۱/۲	۰/۸
	۴۰	۴/۴	۳۱/۹۲	۳۱/۲۷	۳۰/۴۴	۳۱/۲۱	۰/۹	۰/۷
		۶/۵۸	۲۸/۵۴	۲۸/۹۹	۲۸/۷۵	۲۸/۷۶	۳/۱	۱/۳

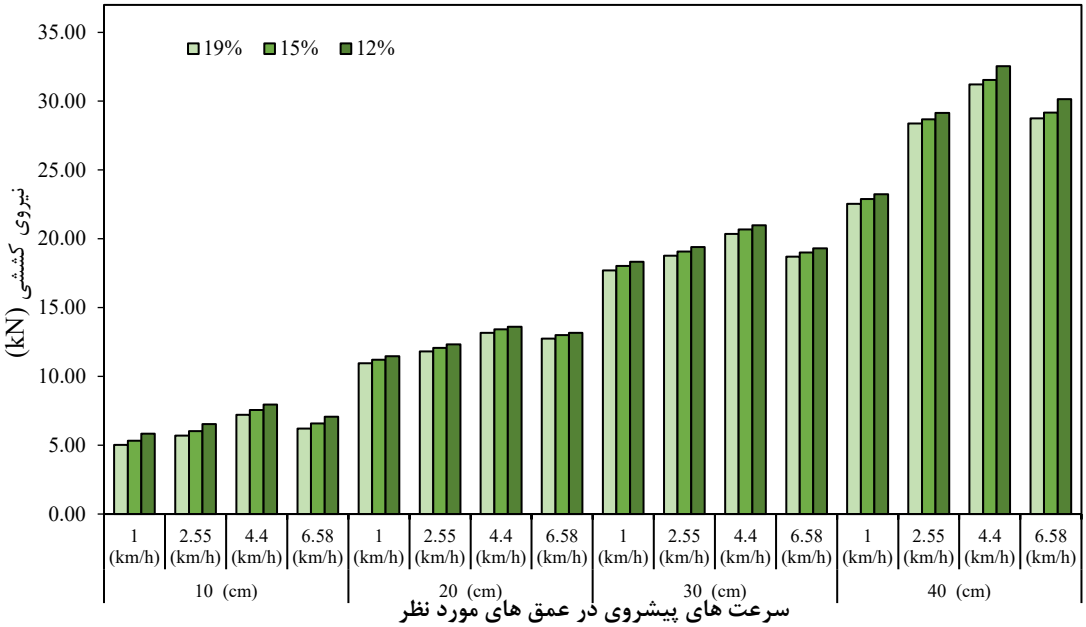

شکل ۴- تأثیر رطوبت خاک، عمق و سرعت پیشروی بر روی نیروی کششی

جدول ۵- مقادیر لغزش به‌ازای عمق کاری، رطوبت و سرعت‌های پیشروی مختلف

رطوبت خاک	عمق شخم	سرعت	لغزش(٪)			انحراف معیار	عدم قطعیت
(%)	(cm)	(km/h)	R1	R2	R3	(R1,R2,R3) میانگین	SD	UA
۱۲	۱۰	۱	۷/۵۹	۶/۸	۶/۹۱	۷/۱	۱/۴	۰/۹
		۲/۵۵	۸/۷۶	۹/۰۴	۹/۵	۹/۱	۱/۸	۱
		۴/۴	۹/۳۹	۱۰/۲	۱۰/۴۲	۱۰	۱/۱	۰/۸
		۶/۵۸	۸/۴۸	۷/۸۶	۷/۶۶	۸	۱/۵	۰/۹
	۲۰	۱	۱۳/۲۱	۱۴/۴۳	۱۴/۳۵	۱۴	۰/۹	۰/۷
		۲/۵۵	۱۷/۱۱	۱۵/۴۶	۱۵/۴۳	۱۶	۰/۶	۰/۶
		۴/۴	۲۰/۱۷	۲۰/۲۸	۱۹/۵۵	۲۰	۱/۶	۱
		۶/۵۸	۱۷/۰۲	۱۸/۵	۱۸/۴۸	۱۸	۰/۷	۰/۶
	۳۰	۱	۲۱/۷۸	۲۰/۱	۱۹/۶۳	۲۰/۵	۰/۶	۰/۶
		۲/۵۵	۲۱/۶۵	۲۲/۶۱	۲۳/۲۴	۲۲/۵	۰/۸	۰/۷
		۴/۴	۲۵/۸۵	۲۵/۹۸	۲۷/۶۷	۲۶/۵	۰/۶	۰/۶
		۶/۵۸	۲۴/۸۲	۲۵/۰۵	۲۳/۶۳	۲۴/۵	۰/۸	۰/۷
	۴۰	۱	۲۸/۲۷	۲۶/۱	۲۶/۶۴	۲۷	۰/۶	۰/۶
		۲/۵۵	۲۸/۵	۳۱/۹۸	۳۲/۵۲	۳۱	۰/۳	۰/۴
		۴/۴	۳۳/۰۱	۳۴/۰۹	۳۴/۹	۳۴	۰/۷	۰/۶
		۶/۵۸	۲۶/۹۷	۲۵/۹۷	۲۵/۰۶	۲۶	۰/۷	۰/۶

		۱	۷/۶۶	۷/۱۸	۷/۶۶	۷/۵	۲/۲	۱/۱
		۲/۵۵	۱۰/۲۹	۹/۶	۱۰/۱	۱۰	۱/۸	۱
	۱۰	۴/۴	۱۰/۴۷	۱۱/۴۹	۱۱/۶۴	۱۱/۲۲	۱	۰/۷
		۶/۵۸	۹/۳۹	۹/۷۴	۹/۳۷	۹/۵	۲/۹	۱/۳
		۱	۱۴/۷۲	۱۴/۴۹	۱۴/۲۸	۱۴/۵	۳/۲	۱/۴
		۲/۵۵	۱۷/۱۷	۱۵/۹۶	۱۶/۳۷	۱۶/۵	۱/۱	۰/۸
	۲۰	۴/۴	۲۰/۶۲	۲۰/۹۳	۱۹/۹۵	۲۰/۵	۱/۳	۰/۹
		۶/۵۸	۱۷/۴۶	۱۸/۷۸	۱۹/۲۶	۱۸/۵	۰/۷	۰/۶
۱۵		۱	۲۲/۱۹	۲۰/۴	۲۰/۴۱	۲۱	۰/۶	۰/۶
		۲/۵۵	۲۵/۲۵	۲۱/۸۶	۲۱/۸۹	۲۳	۰/۳	۰/۴
	۳۰	۴/۴	۲۶/۸۱	۲۸/۱۶	۲۶/۰۳	۲۷	۰/۶	۰/۶
		۶/۵۸	۲۴/۱۱	۲۵/۲۵	۲۵/۶۴	۲۵	۰/۸	۰/۷
		۱	۲۶/۳۶	۲۶/۶۸	۲۷/۶۶	۲۶/۹	۰/۹	۰/۷
		۲/۵۵	۳۱/۹۸	۳۰/۶۲	۳۳/۴	۳۲	۰/۵	۰/۵
	۴۰	۴/۴	۳۳/۸	۳۳/۶۹	۳۴/۵۱	۳۴	۱/۴	۰/۹
		۶/۵۸	۲۸/۸۱	۲۷/۰۲	۲۷/۸۸	۲۷/۹	۰/۸	۰/۷
		۱	۷/۹۶	۸/۰۷	۷/۶۸	۷/۹	۳/۲	۱/۴
		۲/۵۵	۹/۷۵	۱۰/۸۵	۱۰/۹	۱۰/۵	۰/۹	۰/۷
	۱۰	۴/۴	۱۱/۰۶	۱۲/۴۳	۲۵/۵۲	۱۲	۰/۷	۰/۷
		۶/۵۸	۱۰/۱۲	۹/۹۳	۹/۹۶	۱۰	۶/۱	۱/۹
		۱	۱۴/۸۶	۱۴/۳۲	۱۵/۵۳	۱۴/۹	۱/۱	۰/۸
		۲/۵۵	۱۶/۱۲	۱۷/۳۲	۱۷/۵۶	۱۷	۰/۸	۰/۷
	۲۰	۴/۴	۲۱/۷۳	۲۱/۱۱	۲۰/۴۶	۲۱/۱	۱/۱	۰/۸
		۶/۵۸	۱۸/۳۸	۱۹/۶۶	۱۹/۵۶	۱۹/۲	۰/۹	۷.۰
۱۹		۱	۲۱/۴۸	۲۱/۵۳	۲۱/۴۸	۲۱/۵	۲۰/۸	۳/۵
		۲/۵۵	۲۴/۶	۲۲/۵۱	۲۳/۳۹	۲۳/۵	۰/۶	۰/۶
	۳۰	۴/۴	۲۷/۲۱	۲۸/۶۱	۲۶/۶۸	۲۷/۵	۰/۶	۰/۶
		۶/۵۸	۲۴/۳۳	۲۵/۷۳	۲۶/۴۴	۲۵/۵	۰/۶	۰/۶
		۱	۲۷/۸۶	۲۷/۳۷	۲۶/۹۷	۲۷/۴	۱/۵	۰/۹
		۲/۵۵	۳۲/۰۹	۳۴/۱۱	۳۴/۳	۳۳/۵	۰/۵	۰/۵
	۴۰	۴/۴	۳۳/۱۶	۳۵/۲۸	۳۶/۵۶	۳۵	۰/۴	۰/۵
		۶/۵۸	۲۷/۷۹	۲۸/۴۷	۳۰/۱۴	۲۸/۸	۰/۵	۰/۶

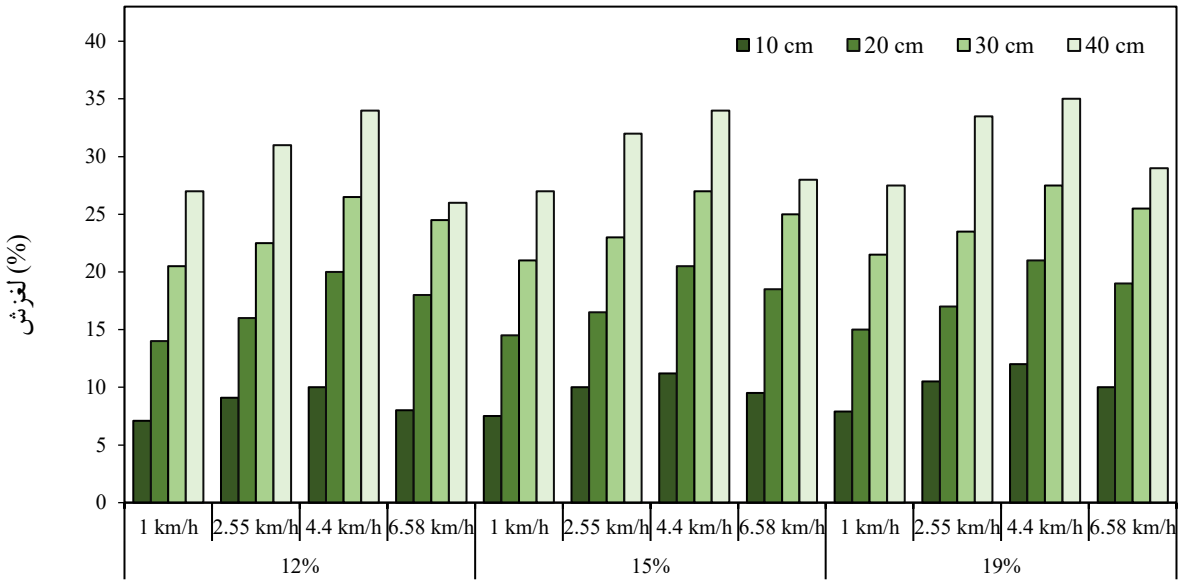

شکل ۵- تأثیر رطوبت خاک، عمق و سرعت پیشروی بر لغزش

به‌عنوان مثال نتایج نشان می‌دهد به‌ازای عمق ۱۰cm و سرعت ۶/۵۸ km/h، با افزایش رطوبت از ۱۲٪ به ۱۵٪ لغزش در حدود ۱۶٪ افزایش می‌یابد. همچنین در شرایط رطوبت ۱۵٪ و سرعت ۶/۵۸ km/h، افزایش عمق از ۱۰cm به ۳۰cm سبب بیشترشدن حدود ۶۲٪ لغزش می‌شود. با دانستن این موضوع که تأثیر عمق روی نیروی کششی بیشتر از تأثیر سرعت پیشروی است که این موضوع مطابق با نتایج جدول (۴) قابل‌مشاهده است و می‌توان تنظیمات صحیح در تراکتور را به‌منظور کاهش لغزش انجام داد .

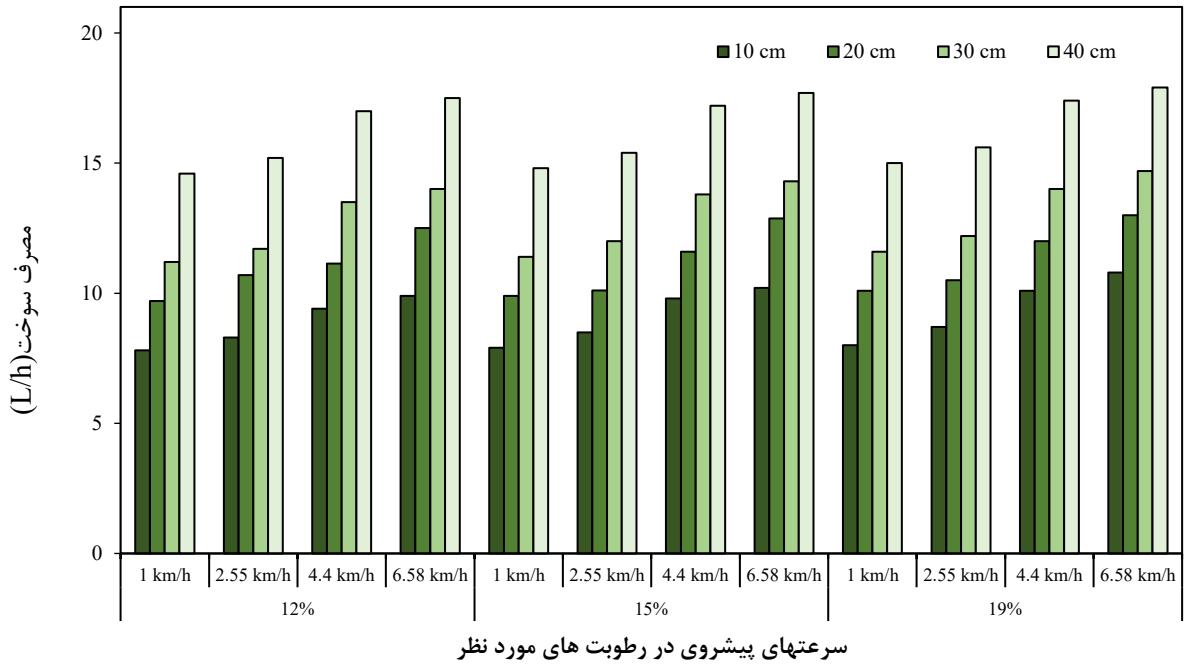

شکل ۶- تأثیر رطوبت خاک، عمق و سرعت پیشروی بر مصرف سوخت

جدول ۶- مقادیر مصرف سوخت به‌ازای عمق کاری، رطوبت و سرعت‌های پیشروی مختلف

رطوبت خاک	عمق شخم	سرعت	مصرف سوخت(L/h)			انحراف معیار	عدم قطعیت
%	cm	km/h	R1	R2	R3	(R1,R2,R3) میانگین	SD	UA
۱۲	۱۰	۱	۷/۶۳	۷/۶۷	۸/۱	۷/۸	۲/۴	۱/۲
		۲/۵۵	۸/۱۷	۸/۶۱	۱۸/۱۲	۸/۳	۲/۳	۱/۲
		۴/۴	۱۰/۱۴	۹/۰۷	۸/۹۹	۹/۴	۱	۰/۷
		۶/۵۸	۹/۸۶	۱۰/۰۲	۹/۸۳	۹/۹	۶	۱/۹
	۲۰	۱	۱۰/۱۸	۹/۵	۹/۴۲	۹/۷	۱/۵	۰/۹
		۲/۵۵	۱۰/۳۷	۱۱/۱۴	۱۰/۵۹	۱۰/۷	۱/۶	۱
		۴/۴	۱۰/۹۹	۱۱/۳	۱۱/۰۱	۱۱/۱	۳/۵	۱/۴
		۶/۵۸	۱۲/۰۹	۱۲/۵	۱۲/۹۱	۱۲/۵	۱/۷	۱
	۳۰	۱	۱۱/۴۵	۱۰/۶۷	۱۱/۴۷	۱۱/۲	۱/۳	۰/۹
		۲/۵۵	۱۱/۷۴	۱۱/۹۳	۱۱/۴۴	۱۱/۷	۲/۷	۱/۲
		۴/۴	۱۳/۵۱	۱۳/۰۲	۱۳/۹۷	۱۳/۵	۱/۵	۰/۹
		۶/۵۸	۱۴/۱۲	۱۳/۵۷	۱۴/۳۱	۱۴	۱/۷	۱
	۴۰	۱	۱۴/۸۹	۱۴/۲۲	۱۴/۷	۱۴/۶	۱/۹	۱
		۲/۵۵	۱۴/۷۲	۱۵/۱	۱۵/۷۸	۱۵/۲	۱/۲	۰/۸
		۴/۴	۱۶/۹۷	۱۷/۶۶	۱۶/۳۷	۱۷	۱/۱	۰/۸
		۶/۵۸	۱۷/۱۹	۱۸/۲۳	۱۷/۰۸	۱۷/۵	۱	۰/۷
۱۵	۱۰	۱	۷/۸۶	۷/۷۵	۸/۰۹	۷/۹	۳/۷	۱/۵
		۲/۵۵	۱۸/۷۲	۸/۶	۸/۱۹	۸/۵	۲/۳	۱/۱
		۴/۴	۱۰/۲۶	۹/۶۶	۹/۴۹	۹/۸	۱/۶	۰/۹
		۶/۵۸	۹/۷۶	۱۰/۲۶	۱۰/۵۸	۱۰/۲	۱/۶	۱
	۲۰	۱	۹	۹/۲۸	۹/۳۳	۹/۲	۳/۵	۱/۴
		۲/۵۵	۹/۵۵	۱۰/۵۹	۱۰/۱۶	۱۰/۱	۱/۳	۰/۹
		۴/۴	۱۱/۰۱	۱۲/۱۴	۱۱/۶۵	۱۱/۶	۱/۲	۰/۸
		۶/۵۸	۱۲/۸۸	۱۳/۰۶	۱۲/۷۶	۱۲/۹	۴/۴	۱/۶
	۳۰	۱	۱۱/۳۷	۱۱/۲۳	۱۱/۶	۱۱/۴	۳/۵	۱/۴
		۲/۵۵	۱۲/۰۴	۱۱/۶۴	۱۲/۳۲	۱۲	۱/۹	۱/۱
		۴/۴	۱۳/۶۹	۱۴/۲۵	۱۳/۴۶	۱۳/۸	۱/۶	۱
		۶/۵۸	۱۳/۲۳	۱۴/۹۹	۱۴/۶۸	۱۴/۳	۰/۷	۰/۶
	۴۰	۱	۱۴/۱	۱۵/۴۴	۱۴/۸۶	۱۴/۸	۱	۰/۸

		۲/۵۵	۱۶/۱۳	۱۵/۱	۱۴/۹۷	۱۵/۴	۱	۰/۷
		۴/۴	۱۸/۳۹	۱۶/۴	۱۶/۸۱	۱۷/۲	۰/۶	۰/۶
		۶/۵۸	۱۸/۷	۱۷/۳۴	۱۷/۰۶	۱۷/۷	۰/۷	۰/۶
		۱	۷/۶۵	۸/۱۳	۸/۲۳	۸	۲	۱/۱
		۲/۵۵	۸/۸۴	۸/۵۳	۸/۷۴	۸/۷	¼	۱/۵
	۱۰	۴/۴	۱۰/۵۴	۹/۶۵	۱۰/۱۲	۱۰/۱	۱/۶	۱
		۶/۵۸	۱۰/۷۶	۱۰/۳۱	۱۱/۳۳	۱۰م۸	۱/۳	۰/۹
		۱	۹/۹۸	۹/۸۵	۱۰/۴۸	۱۰/۱	۱/۹	۱
		۲/۵۵	۱۰/۶۴	۱۰/۰۱	۱۰/۸۵	۱۰/۵	۱/۴	۰/۹
	۲۰	۴/۴	۱۲/۵۴	۱۱/۸۳	۱۱/۶۴	۱۲	۱/۳	۰/۹
		۶/۵۸	۱۳/۲۸	۱۳/۲۹	۱۲/۴۳	۱۳	۱/۲	۰/۸
۱۹		۱	۱۱/۳	۱۱/۹	۱۱/۶	۱۱/۶	۲/۴	۱/۲
		۲/۵۵	۱۱/۵۴	۱۲/۶۹	۱۲/۳۷	۱۲/۲	۱/۱	۰/۸
	۳۰	۴/۴	۱۴/۵۴	۱۳/۸۳	۱۳/۶۴	۱۴	۱/۳	۰/۹
		۶/۵۸	۱۴/۴	۱۵/۱۱	۱۴/۵۹	۱۴/۷	۱/۷	۱
		۱	۱۵/۶۸	۱۴/۸۵	۱۴/۴۷	۱۵	۱	۰/۸
		۲/۵۵	۱۵/۰۳	۱۵/۶۲	۱۶/۱۵	۱۵/۶	۱/۲	۰/۸
	۴۰	۴/۴	۱۸/۱	۱۶/۸	۱۷/۳	۱۷/۴	۱	۰/۸
		۶/۵۸	۱۸/۱۲	۱۷/۵۴	۱۸/۰۴	۱۷/۹	۲	۱/۱

مصرف سوخت

نتایج مصرف سوخت در جدول ۶ و شکل (۶) ارائه شده است. مصرف سوخت در واحد زمان (L/h) با افزایش هر سه عامل (عمق، سرعت و رطوبت) افزایش یافت. بااین‌حال، مصرف سوخت در واحد سطح با افزایش سرعت کاهش یافت که این امر به دلیل کاهش زمان انجام عملیات است که با نتایج تحقیق سایر محققان همخوانی دارد (Jalali *et al*., 2015).

بیشترین مصرف سوخت در عمق ۴۰ سانتی‌متر و رطوبت ۱۹ درصد مشاهده شد (شکل ۶) که علت آن را می‌توان لغزش بیش از حد چرخ‌های محرک دانست. که در این شرایط، مقدار بیشترین مصرف سوخت برابر با ۱۷/۹ لیتر بر ساعت در سرعت ۶/۵۸ کیلومتر بر ساعت بود؛ درحالی‌که کمترین مصرف سوخت در همین عمق، برابر با ۷/۸ لیتر بر ساعت در سرعت ۱ کیلومتر بر ساعت و رطوبت ۱۲ درصد به دست آمد. براین‌اساس، می‌توان نتیجه گرفت که بسته به شرایط مزرعه، مقادیر بهینه برای عامل‌های مستقل وجود دارد که در صورت تعیین مناسب آنها می‌توان میزان مصرف سوخت را تا حد قابل‌ملاحظه‌ای کاهش داد.

پیش‌بینی نیروی کشش، مصرف سوخت و لغزش با استفاده از مدل ANFIS

به‌منظور مدل‌سازی عامل‌های مؤثر بر عملکرد شخم‌زنی از مدل شبکه ANFIS استفاده شد. شبکه ANFIS مورداستفاده در این تحقیق دارای ۳ متغیر مستقل (شامل چهار سطح عمق کاری، سه رطوبت متفاوت خاک و چهار سطح سرعت پیشروی) در ورودی و ۳ متغیر وابسته (نیروی کششی، میزان لغزش و مصرف سوخت تراکتور) در خروجی است. این شبکه‌ها قادر هستند هر رابطه بین ورودی و خروجی را بادقت مناسب تخمین بزنند. به‌منظور ارائه مدل دقیق، در جدول ۷ تأثیر توابع عضویت در ورودی و خروجی و تعداد توابع عضویت بر عامل‌های ارزیابی نشان‌داده‌شده است. بر اساس نتایج این جدول می‌توان بهترین مدل را که دارای بیشترین ضریب

تبیین (R^2) و کمترین مقدار RMSE، EF و MBE است، تعیین نمود.

این نتایج دقت بالایی را در مقایسه با مدل‌های شبکه عصبی ارائه‌شده برای نیروی کششی توسط رول و همکاران (Roul et al., 2009) نشان می‌دهد. ضریب تبیین (R^2) مدل ارائه‌شده برای نیروی کششی در این تحقیق برابر با ۰/۹۹۹۹۲ و ضریب تبیین مدل رول و همکاران برابر با ۰/۹۳۴۰۰ است که بیانگر بهبود بسیار قابل‌ملاحظه در دقت پیش‌بینی نتایج است.

همچنین، نتایج سامانه ANFIS تحقیق حاضر در مقایسه با مطالعه اکبرنیا و همکاران که میانگین خطای نسبی ۰/۵۶ را ارائه کردند مطلوب است (Akbarnia *et al*., 2014).

جدول ۷- مدل‌های مختلف ANFIS

خروجی	#	نوع توابع عضویت		شماره توابع عضویت		RMSE	R^2	EF	MBE
		ورودی	خروجی	ورودی	تکرار				
نیروی کششی	۱	Trimf	Linear	۵،۳،۴	۲۰۰	۰/۰۵۲۲	۰/۸۶۹۲۱	۰/۰۱۷۲	۰/۰۱۱۵
	۲	Gaussmf	Linear	۵،۳،۴	۲۰۰	۰/۰۱۶۵	۰/۹۳۲۶۵	۰/۰۰۳۸	۰/۰۰۰۲
	۳	Pimf	Linear	۵،۳،۴	۲۰۰	۰/۰۸۹۲	۰/۸۹۳۷	۰/۰۱۴۳	۰/۰۰۵۵
	۴	Dsigmf	Linear	۵،۳،۴	۲۰۰	۰/۰۰۲۳	۰/۹۹۹۹۲	۰/۰۰۲۳	۰/۰۰۲۱
	۵	Traamf	Linear	۵،۳،۴	۲۰۰	۰/۰۴۸۶	۰/۸۳۰۴۵	۰/۰۴۰۱	۰/۰۰۷۲
مصرف سوخت	۱	Trimf	Linear	۵،۳،۴	۲۰۰	۰/۰۲۶۵	۰/۹۸۲۷۴	۰/۰۱۲۹	۰/۰۰۲۸
	۲	Gaussmf	Linear	۵،۳،۴	۲۰۰	۰/۰۲۹۸	۰/۹۶۵۰۵	۰/۰۲۱۶	۰/۰۰۳۸
	۳	Pimf	Linear	۵،۳،۴	۲۰۰	۰/۰۳۴۸	۰/۹۱۵۸۸	۰/۰۰۸۷	۰/۰۰۳۴
	۴	Dsigmf	Linear	۵،۳،۴	۲۰۰	۰/۰۵۲۳	۰/۸۴۶۵۶	۰/۰۲۸۶	۰/۰۲۴۸
	۵	Traamf	Linear	۵،۳،۴	۲۰۰	۰/۰۱۷۴	۰/۰۹۹۹۶۴	۰/۰۱۶۹	۰/۰۰۶۲
لغزش	۱	Trimf	Linear	۵،۳،۴	۲۰۰	۰/۰۴۵۲	۰/۸۶۵۲۵	۰/۰۲۲۱	۰/۰۱۹۱
	۲	Gaussmf	Linear	۵،۳،۴	۲۰۰	۰/۰۳۴۹	۰/۸۹۳۰۷	۰/۰۱۷۶	۰/۰۱۱۲
	۳	Pimf	Linear	۵،۳،۴	۲۰۰	۰/۰۲۳۵	۰/۹۴۵۳۸	۰/۰۰۲۶	۰/۰۰۰۱
	۴	Dsigmf	Linear	۵،۳،۴	۲۰۰	۰/۰۰۲۳	۰/۹۹۹۹۳	۰/۰۰۰۲	۰/۰۰۰۱
	۵	Traamf	Linear	۵،۳،۴	۲۰۰	۰/۰۳۴۵	۰/۸۶۲۷۵	۰/۰۳۴۲	۰/۰۲۵۸
بازده انرژی کل	۱	Trimf	Linear	۵،۳،۴	۲۰۰	۰/۰۶۵۲	۰/۷۶۲۳	۰/۲۸۹۱	۰/۰۹۳۰
	۲	Gaussmf	Linear	۵،۳،۴	۲۰۰	۰/۰۴۵۲	۰/۸۹۵۲۲	۰/۰۳۰۲	۰/۰۱۹۵
	۳	Pimf	Linear	۵،۳،۴	۲۰۰	۰/۰۱۸۲	۰/۹۸۳۵۹	۰/۰۱۰۱	۰/۰۰۵۱
	۴	Dsigmf	Linear	۵،۳،۴	۲۰۰	۰/۰۹۴۵	۰/۸۶۳۸	۰/۰۴۱۸	۰/۰۰۲۲
	۵	Traamf	Linear	۵،۳،۴	۲۰۰	۰/۰۳۲۴	۰/۹۶۳۸۵	۰/۰۲۸۸	۰/۰۱۲۸

به‌منظور تعیین ساختار بهینه مدل ANFIS ، پنج نوع تابع عضویت شامل: TriMF (مثلثی)، GaussMF (گاوسی)، PiMF (Π شکل)، DsigMF (سیگموئید دوگانه) و TrapMF (ذوزنقه‌ای) مورد بررسی و ارزیابی قرار گرفتند. انتخاب این توابع بر اساس کاربرد گسترده آنها در مطالعات پیشین و توانایی متفاوت آنها در مدل‌سازی و روابط غیرخطی انجام شد. برای ایجاد شرایط مقایسه یکسان، در تمامی مدل‌ها نوع تابع عضویت خروجی به‌صورت به Linear در نظر گرفته شد. با در نظر گرفتن تابع عضویت خروجی از نوع Linear، تعداد توابع عضویت ورودی برابر با ۵ و۴ و۳ و تعداد تکرار آموزش برابر با ۲۰۰ در نظر گرفته شد. انتخاب مدل نهایی بر اساس مقایسه شاخص‌های EF,R2,RMSE,MBE صورت گرفت. به گونه‌ای که مدل دارای کمترین RMSE , MBE و بیشترین R^2 , EF به‌عنوان مدل برتر انتخاب شد. براین اساس، تابع عضویت Dsimf برای پیش‌بینی نیروی کشش و لغزش، تابع Traamf برای مصرف سوخت و تابع Pimf برای شاخص OEE بهترین عملکرد را نشان دادند.

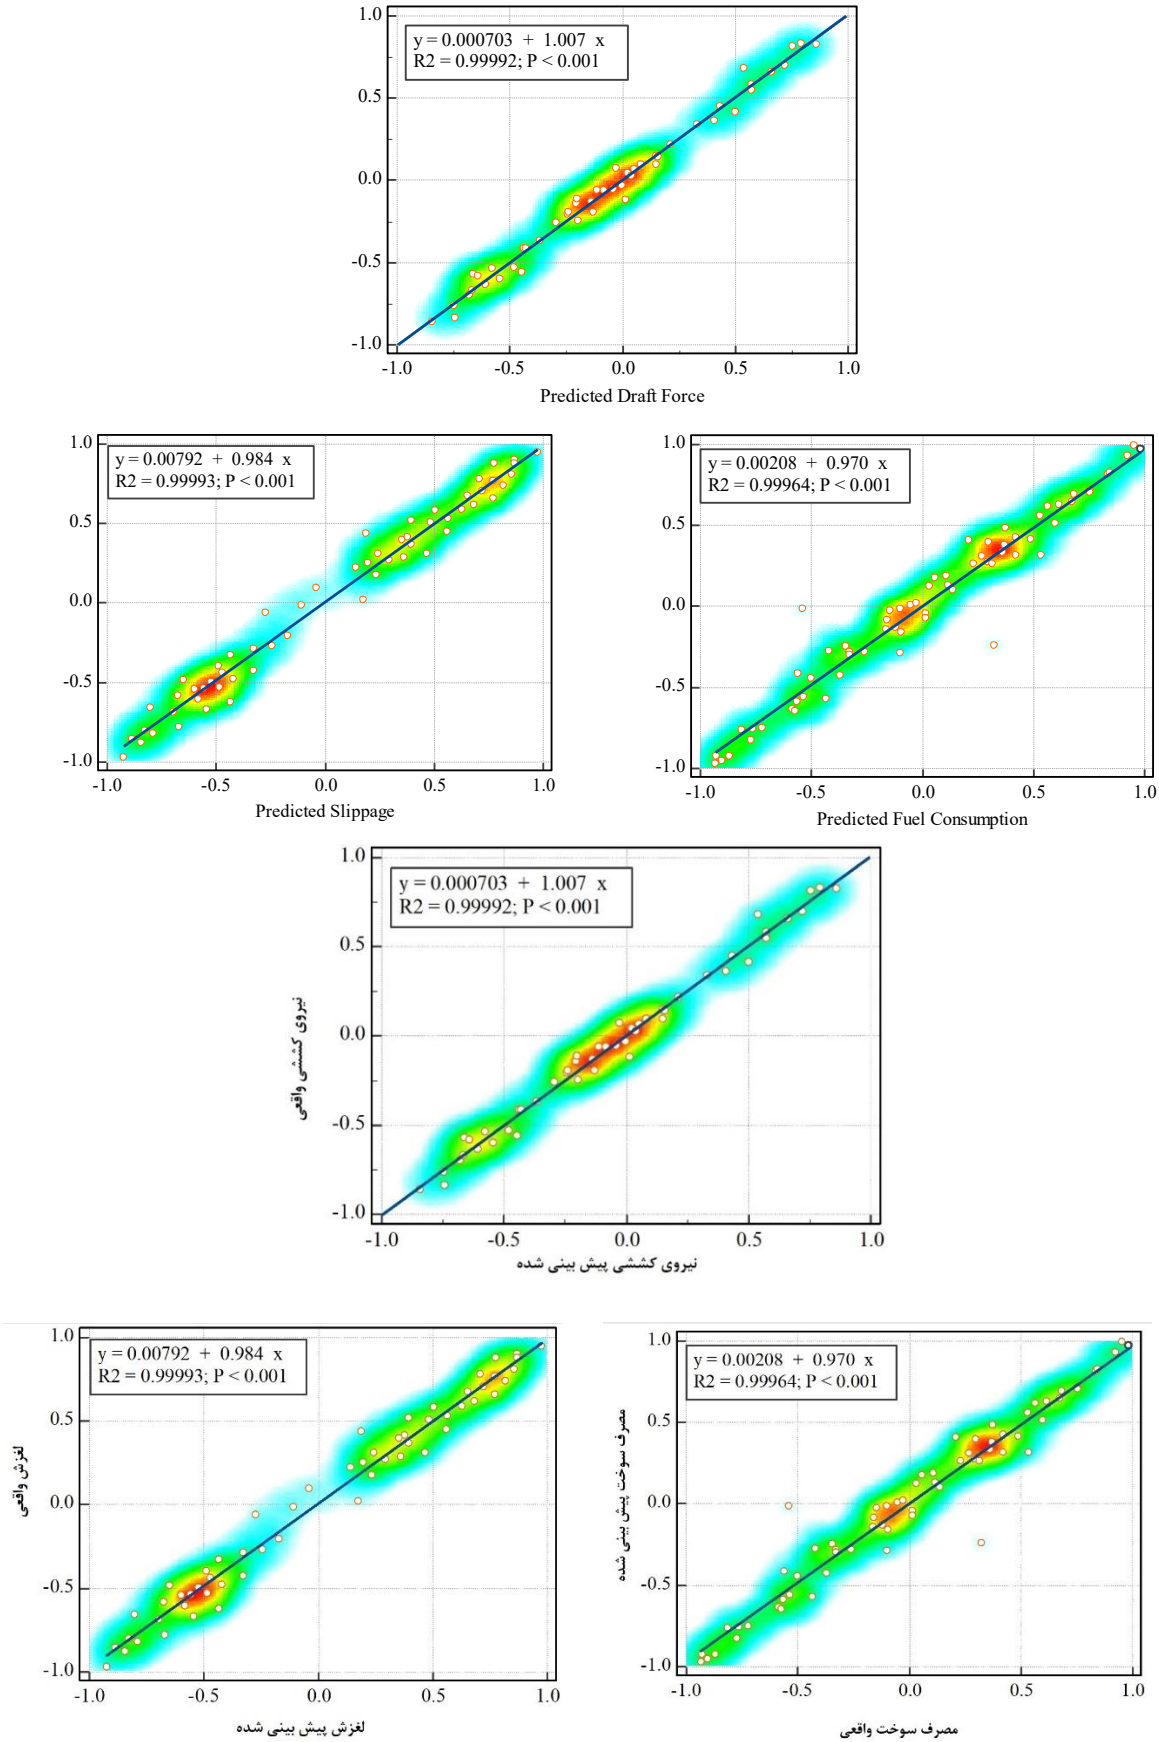

شکل ۷- همبستگی نتایج مدل ANFIS میان داده‌های پیش‌بینی شده و اندازه‌گیری شده نرمالیزه

جدول ۸- مقایسه معیارهای عملکردی آماری به‌دست‌آمده از تحقیق حاضر (برای مصرف سوخت) با نتایج شبکه‌های عصبی موجود در تخمین عامل‌های شخم‌زنی

منبع پژوهش	روش	RMSE	R^2
(Jalilnezhad *et al*., 2023)	CNN	۰/۰۰۴۹	۰/۹۷۲۹
(Almaliki *et al.*, 2016)	ANNs	۰/۰۱۳۴	۰/۹۸۹۰
(Nagar & Machavaram, 2022)	ANNs	۰/۰۰۴۱	۰/۹۰۰۰
(Abbaspour-Gilandeh *et al*., 2009)	ANNs	۰/۰۱۷۱	۰/۹۸۳۲
(Rahimi-Ajdadi & Abbaspour-Gilandeh, 2011)	ANN	-	۰/۹۳۸۰
(Borges *et al.*, 2017)	MANN	۴/۹۸۸۳	۰/۹۸۰۸
(Ziółkowski *et al*., 2021)	ANN	۰/۲۵۳۵	۰/۹۷۶۰
Proposed method	ANFIS	۰/۰۱۷۴	۰/۹۹۹۶۴

باتوجه‌به نتایج جدول (۷) مشاهده می‌شود که بهترین عملکرد مدل ANFIS برای پیش‌بینی لغزش با تابع عضویت Dsigmf (R^2=۰/۹۹۹۹۳، RMSE=۰/۰۰۲۳)، برای مصرف سوخت با Traamf (R^2=۰/۹۹۹۶۴، RMSE=۰/۰۱۷۴)، برای نیروی کششی با Dsigmf (R^2=۰/۹۹۹۹۲، RMSE=۰/۰۰۲۳) و برای بازده انرژی کل (OEE) مجموعه تراکتور و ادوات خاک‌ورزی با Pimf (R^2=۰/۹۸۳۵۹، RMSE=۰/۰۱۸۲) حاصل شد.

همچنین، باتوجه‌به نمودارهای برازش متغیرهای واقعی و پیش‌بینی شده که برای عامل‌های وابسته نیروی کششی، سوخت مصرف شده و لغزش در شکل ۷ نشان‌داده‌شده است، می‌توان مطابقت و همبستگی مناسب را در بین داده‌ها مشاهده نمود. باتوجه‌به مقادیر مناسب معیارهای عملکردی آماری و همچنین، مطابقت مناسب بین داده‌های واقعی و داده‌های پیش‌بینی شده، می‌توان گفت که شبکه ANFIS ارائه شده در این تحقیق به‌خوبی و بادقت بالایی توانست متغیرهای وابسته هدف را پیش‌بینی کند. دلیل این پیش‌بینی بادقت بالا، ماهیت این شبکه است که می‌تواند به‌خوبی رابطه‌های غیرخطی را پیش‌بینی کند.

مقایسه معیارهای عملکردی آماری R^2 و RMSE به‌دست‌آمده از مدل ارائه شده برای مصرف سوخت با نتایج شبکه‌های عصبی موجود در مقالات دیگر در جدول (۸) ارائه شده است. این مقایسه نشان‌دهنده عملکرد بسیار بالای روش این تحقیق نسبت به روش‌های متداول شبکه عصبی ارائه شده استنتایج این پژوهش تأیید کرد که ANFIS به دلیل توانایی در مدل‌سازی روابط غیرخطی و مدیریت عدم قطعیت داده‌های میدانی، دقت خوبی نسبت به مدل‌های رگرسیونی دارد. افزایش نیروی کششی با عمق و کاهش آن با رطوبت خاک با مطالعات قبلی همخوانی دارد. افزایش لغزش با رطوبت نیز پدیده‌ای شناخته‌شده است که به کاهش اصطکاک خاک-چرخ مربوط می‌شود.

مدل ANFIS با R^2 بالای ۰/۹۹۹ برای اکثر متغیرها، ابزار مناسبی برای پیش‌بینی عملکرد تراکتور در شرایط واقعی مزرعه ارائه می‌دهد و می‌تواند در توسعه سامانه‌های هوشمند مدیریت تراکتور و عملیات خوب در کشاورزی مورداستفاده قرار گیرد. اگرچه مدل ANFIS در این پژوهش مقادیر بسیار بالایی برای ضریب تعیین (R^2) و مقادیر بسیار پایین RMSE دست یافت، اما تفسیر این نتایج مستلزم احتیاط است. در مجموعه داده‌های حجم محدود، دستیابی به شاخص‌های عملکردی نزدیک به حالت ایده‌آل لزوماً به معنای توانایی بالای مدل در تعمیم به داده‌های جدید نیست و می‌تواند تا حدی ناشی از یادگیری ویژگی‌های خاص مجموعه داده مورداستفاده باشد. از این احتمال بیش برازش (Overfitting) را نمی توان صرفاً بر اساس شاخص‌های برازش رد کرد. هرچند عملکرد مدل در داده‌های آزمون نیز مطلوب بود، اما ارزیابی جامع تر پایداری مدل نیازمند استفاده از روش‌های اعتبارسنجی سخت‌گیرانه نظیر k-fold و اعتبارسنجی متقابل (Cross-validation) یا آزمون مدل بر روی مجموعه داده‌های مستقل و خارج از دامنه آموزش است.

همچنین باید توجه داشت که مقایسه مستقیم عملکرد مدل پیشنهادی با مطالعات پیشین برمبنای شاخص‌هایی نظیر R^2 و RSME دارای محدودیت‌های روش‌شناختی است. تفاوت تعداد مشاهدات، نحوه نمونه‌برداری، دامنه تغییرات متغیرهای مستقل، شرایط خک و مرزعه، تعداد نوع متغییرهای ورودی،

روش تقسیم داده‌ها و راهبردهای اعتبارسنجی می‌تواند تأثیر قابل‌توجهی بر مقادیر این شاخص‌ها داشته باشد. درنتیجه، برتری ظاهری عملکرد ANFIS نسبت به مدل‌های گزارش شده در سایر مطالعات پیشین الزاماً بیانگر برتری ذاتی این روش نیستا و ممکن است بخشی از تفاوت مشاهده شده ناشی از تفاوت در ساختار داده باشد. از منظر نظری، ANFIS به دلیل ترکیب قابلیت یادگیری شبکه‌های عصبی با سازوکار استنتاج فازی، توانایی منسبی در مدل‌سازی روابط غیرخطی و برهم‌کنش ها پیچیده بین متغیرهای موثر بر عملکرد تراکتور دارد؛ بااین‌حال، نتایج حاضر بیشتر نشان‌دهنده ظرفیت بالای این مدل در توصیف الگوهای موجود در داده‌های این پژوهش است تا اثبات قطعی قابلیت تعمیم آن به‌تمامی شرایط عملیاتی. بنابراین، اعتبار بیرونی (External Validity) مدل باید در پژوهش‌های آینده از طریق ارزیابی در شرایط مزرعه‌ای متنوع‌تر، دامنه وسیع‌تری از ویژگی‌های خاک و سطوح مختلف رطوبت و بار عملیاتی مورد بررسی قرار گیرد.

مدل ANFIS در چارچوب داده‌ها و شرایط آزمایشی این پژوهش، دقت پیش‌بینی بسیار بالایی را نشان داد. بااین‌حال، باتوجه‌به حجم داده‌ها و احتمال بروز بیش برازش در مدل‌های داده‌محور، تعمیم این نتایج بر شرایط عملیاتی گسترده تر مستلزم انجام مطالعات تکمیلی با مجموعه داده‌های مستقل، حجم نمونه بیشتر و روش‌های اعتبارسنجی جامع تر است. ازاین‌رو، نتایج حاضر باید به‌عنوان شواهدی از ظرف طت بالقوه مدل ANFIS در پیش‌بینی عملکرد تراکتور تلقی شود، نه به‌عنوان تأیید نهایی قابلیت تعمیم آن در تمامی شرایط مزرعه‌ای.

نتیجه‌گیری

هدف این مطالعه ارائه‌ی روشی دقیق به‌منظور یافتن ارتباط بین میزان لغزش، نیروی کششی و میزان مصرف سوخت در اثر مقادیر متفاوت عامل‌های مستقل شامل رطوبت خاک، سرعت پیشروی تراکتور و عمق‌های مختلف خاک است. بدین منظور، داده‌های موردنیاز از آزمون‌های مزرعه‌ای به روش دو تراکتوری و در چهار سطح عمق خاک‌ورزی، سه سطح رطوبت خاک و چهار سطح سرعت پیشروی جمع‌آوری شد و سپس دو روش رگرسیون و سامانه استنتاج عصبی-فازی تطبیقی (ANFIS) برای مدل‌سازی و پیش‌بینی متغیرهای موردمطالعه به کار گرفته شدند. نتایج نشان داد که کاهش رطوبت خاک و در نتیجه افزایش خشکی و سفتی آن، موجب افزایش نیروی مقاوم کششی و کاهش میزان لغزش چرخ می‌شود که این موضوع را می‌توان به افزایش مقاومت مکانیکی خاک و شاخص مخروطی نسبت داد.

همچنین افزایش رطوبت خاک تا یک محدوده مشخص، سبب کاهش مقاومت خاک و در نتیجه کاهش نیروی موردنیاز برای گسیختگی و جابه‌جایی آن می‌شود. بررسی اثر متقابل عوامل موردمطالعه نیز نشان داد که تغییرات عمق خاک‌ورزی، سرعت پیشروی و رطوبت خاک تأثیر معنی‌داری بر عملکرد کششی، لغزش و مصرف سوخت تراکتور دارند و انتخاب مناسب این عامل‌ها می‌تواند موجب بهبود کارایی عملیات خاک‌ورزی شود. مقایسه عملکرد مدل‌ها نشان داد که مدل ANFISبادقت بالا قادر به پیش‌بینی عامل‌های عملکردی تراکتور است؛ به‌طوری‌که برای مدل نیروی کششی مقادیر ضریب تعیین (R^2) و ریشه میانگین مربعات خطا (RMSE) به‌ترتیب برابر با ۰/۹۹۹۹۲ و ۰/۰۰۲۳ به دست آمد. همچنین نتایج مقایسه‌ای نشان داد که مدل ANFIS نسبت به روش رگرسیون و بسیاری از مدل‌های گزارش‌شده در مطالعات پیشین، عملکرد دقیق‌تر و قابلیت بیشتری در مدل‌سازی روابط غیرخطی و پیچیده میان متغیرهای خاک و ماشین دارد.

نتایج این پژوهش نشان داد که سامانه استنتاج عصبی-فازی تطبیقی (ANFIS) از توانایی خوبی در مدل‌سازی و پیش‌بینی هم‌زمان نیروی کششی،لغزش تراکتور و مصرف سوخت تحت شرایط واقعی مزرعه برخوردار است. روابط بین متغییرهای موثر بر عملکرد کششی تراکتور نظیر ویژگی خاک، شرایط عملیاتی، عمق کار، سرعت پیشروی و عامل‌های ماشین‌آلات کشاورزی ماهیتی پیچیده، غیرخطی و همراه با عدم قطعیت دارند. ازاین‌رو استفاده از ANFIS امکان استخراج این روابط را بادقت خوبی نسبت به روش‌های آماری کلاسیک فراهم ساخت. نتایج بیانگر آن است که مدل توسعه‌یافته قادر است تغییرات شاخص‌های عملکردی تراکتور را با خطای قابل‌قبول پیش‌بینی نموده و به‌عنوان ابزاری موثر در مدیریت عملیات مکانیزه کشاورزی مورداستفاده قرار گیرد.

نوآوری اصلی این پژوهش در توسعه یک چارچوب هوشمند برای پیش‌بینی هم‌زمان سه شاخص کلیدی عملکرد تراکتور شامل نیروی کششی، لغزش چرخ و مصرف سوخت در شرایط واقعی مزرعه است. در بسیاری از مطالعات پیشین، این متغیرها به‌صورت جداگانه مدل‌سازی شده‌اند، درحالی‌که در این پژوهش ارتباط متقابل آنها در قالب یک سامانه استنتاج عصبی-فازی مورد بررسی قرار گرفت. مدل‌های ANFIS به

دلیل توانایی در مدیریت عدم قطعیت داده‌های میدانی، دقت بالاتری نسبت به مدل‌های رگرسیونی سنتی نشان دادند. مدل‌های ANFIS توسعه‌یافته امکان محاسبه مستقیم خروجی‌ها را برای هر ترکیب دلخواه از متغیرهای ورودی فراهم می‌کنند.

همچنین استفاده از تحلیل مؤلفه های اصلی (PCA) پیش‌بینی از توسعه مدل، موجب کاهش ابعاد داده‌ها، حذف هم خطی میان متغیرهای ورودی و بهبود پایداری مدل گردید. این رویکرد امکان بهره‌برداری مؤثر از داده‌های مزرعه‌ای را فراهم کرده و می‌تواند به‌عنوان یک ابزار تصمیم یار در انتخاب شرایط بهینه کار تراکتور مورداستفاده قرار گیرد.

باوجود نتایج امیدوارکننده، پژوهش حاضر دارای محدودیت‌هایی است که باید در تفسیر نتایج موردتوجه قرار گیرند. نخست، داده‌های مورداستفاده از یک منطقه جغرافیایی، نوع خاصی از خاک و شرایط عملیاتی محدود جمع‌آوری شده‌اند، بنابراین بخشی از روابط استخراج شده ممکن است تحت تأثیر ویژگی‌های محلی قرار داشته باشند. دوم، تغییرات رطوبت خاک، بافت خاک، بقایای گیاهی سطح مزرعه، وضعیت تایرها و مهارت راننده از جمله عواملی هستند که می‌توانند بر نیروی کششی، لغزش و مصرف سوخت اثرگذار باشند، اما امکان اندازه‌گیری یا واپایش کامل آنها در شرایط مزرعه‌ای وجود نداشته است. سوم، ساختار ANFIS و تعداد توابع عضویت انتخاب شده ممکن است برای مجموعه داده‌های دیگر نیازمند تنظیم مجدد و بهینه‌سازی باشد.

ازنظر قابلیت تعمیم، نتایج این مطالعه بیشترین اعتبار را برای شرایطی دارند که از لحاظ نوع تراکتور، ادوات مورداستفاده، ویژگی‌های خاک و شرایط عملیاتی مشابه داده‌های آموزشی باشند. بااین‌حال، چارچوب مدل‌سازی ارائه شده قابلیت انتقال به سایر سامانه‌های مکانیزاسیون کشاورزی را دارد و می‌تواند پس از آموزش مجدد با داده‌های محلی، برای پیش‌بینی عملکرد تراکتور در مناطق و شرایط متفاوت مورداستفاده قرار گیرد. بنابراین، قابلیت تعمیم مدل بیشتر در سطح روش‌شناسی و ساختار مدل مطرح است تا مقادیر عددی حاصل از آن.

برای افزایش قابلیت و اعتبار نتایج، پیشنهاد می‌شود در مطالعات آینده اعتبارسنجی خارجی مدل با استفاده از داده‌های مستقل جمع‌آوری‌شده از مناطق مختلف، انواع خاک، شرایط رطوبتی متفاوت و کلاس‌های مختلف تراکتور و ادوات انجام شود. همچنین مقایسه عملکرد ANFIS با الگوریتم‌های پیشرفته یادگیری ماشین نظیر جنگل تصادفی (RF)، ماشین بردار پشتیبان (SVM)، گرادیان تقویتی (XGBoost) و شبکه‌های عصبی عمیق می‌تواند تصویر جامع‌تری از مزایا و محدودیت‌های هر روش ارائه دهد.

علاوه بر این توسعه مدل‌های بلادرنگ مبتنی بر حسگرهای نصب شده روی تراکتور و داده‌های اینترنت اشیا کشاورزی (IoT) می‌تواند زمینه استفاده از سامانه‌های هوشمند مدیریت انرژی، کاهش مصرف سوخت و افزایش بهره‌وری عملیات کشاورزی را فراهم سازد.

درمجموع، نتایج این پژوهش نشان می‌دهد که ANFIS ابزاری کارآمد برای پیش‌بینی شاخص‌های عملکردی تراکتور بوده و می‌تواند در طراحی سامانه‌های تصمیم یار مدیریت عملیات خاک‌ورزی، بهینه‌سازی مصرف انرژی و ارتقای بهره‌وری ماشین های کشاورزی نقش مؤثری ایفا کند. در مجموع، یافته‌های این پژوهش بیانگر توانمندی روش‌های هوشمند مبتنی بر ANFIS در پیش‌بینی شاخص‌های عملکردی تراکتور و پشتیبانی از تصمیم‌گیری در مدیریت عملیات خاک‌ورزی است. استفاده از این مدل‌ها می‌تواند زمینه توسعه سامانه‌های هوشمند مدیریت و واپایش تراکتور را فراهم کرده و از طریق کاهش مصرف سوخت، بهبود بازده انرژی و انتخاب بهینه شرایط عملیاتی، در جهت تحقق اهداف کشاورزی دقیق و پایدار مؤثر واقع شود.

سپاسگزاری

از تمامی کارکنان و مدیریت مرکز آزمون شرکت تراکتورسازی ایران که در این تحقیق همکاری نموده‌اند و در انجام آزمون‌ها و در اختیار قراردادن ابزار و تجهیزات آزمون نقش ایفا کرده‌اند به نحو مقتضی تقدیر و تشکر می‌گردد.

مشارکت نویسندگان

نحوه و میزان مشارکت نویسندگان در انجام این تحقیق به‌صورت زیر است:

نویسنده ۱: نگارش، تصویرسازی، تحقیق، روش‌شناسی.
نویسنده ۲: اعتبارسنجی، نظارت، اداره پروژه، روش‌شناسی.
نویسنده ۳: اعتبارسنجی، روش‌شناسی، مفهوم‌پردازی.
نویسنده ۴: بازنگری و ویرایش، اعتبارسنجی، تحلیل آماری.

دسترسی به داده‌ها

داده‌ها در صورت درخواست، در اختیار قرار خواهند گرفت.

اصول اخلاقی

نویسندگان اصول اخلاقی را در انجام و انتشار این اثر علمی رعایت نموده‌اند و این موضوع مورد تأیید همه آنها است.

تضاد منافع نویسندگان

نویسندگان اعلام می‌کنند که هیچ‌گونه منافع مالی رقابتی یا روابط شخصی شناخته‌شده‌ای که ممکن است بر کار گزارش‌شده در این مقاله تأثیر گذاشته باشد، ندارند.

حمایت مالی

نویسنده(ها) هیچ حمایت مالی خاصی برای انجام این پژوهش دریافت نکرده‌اند.

منابع

Abbaspour-Gilandeh, Y., Rahimi-Ajdadi, F., Asli-Ardeh, E. A., Sharabiani, V. R., & Ardabili, M. (2009). Application of artificial neural network for predicting fuel consumption of tractor. *International Agricultural Engineering Conference*, Bangkok, Thailand.

Akbarnia, A., Mohammadi, A., Alimardani, R., & Farhani, F. (2014). Simulation of draft force of winged share tillage tool using artificial neural network model. Agricultural Engineering International: CIGR Journal, 16(4), 57–65.

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.

ASABE. (2011). Agricultural machinery management data. American Society of Agricultural and Biological Engineers.

Askari, M., & Abbaspour-Gilandeh, Y. (2020). Predicting the Imposed Forces on the Tines and Tractor Fuel Consumption during Subsoiling Operation Using Adaptive Neuro-Fuzzy Inference System (ANFIS). Agricultural Mechanization and Systems Research, 21(74), 47–66. https://doi.org/10.22092/erams.2018.122163.1262

Borges, P. H. M., Mendoza, Z. M. S. H., Maia, J., Bianchini, A., & Fernándes, H. C. (2017). Estimation of fuel consumption in agricultural mechanized operations using artificial neural networks. Engenharia Agrícola, 37, 136–147. https://doi.org/10.1590/1809-4430-eng.agric.v37n1p136-147/2017

Damanauskas, V., & Janulevičius, A. (2022). Effect of tillage implement (spring tine cultivator, disc harrow), soil texture, forward speed, and tillage depth on fuel consumption and tillage quality. Journal of Agricultural Engineering, 53(3). https://doi.org/10.4081/jae.2022.1371

Dizaji, H. Z., Khorasani, M. E., Nategh, N. A., Sheikhdavoodi, M., & Andekaiezadeh, K. (2022). Specific draft modeling for combined and simple tillage implements. Agricultural Engineering International: CIGR Journal, 24(4).

Falahat Nejad Mahani, S., & Karami, A. (2023). Maize Tassel Detection and Counting Using Deep Learning Techniques. Journal of Agricultural Machinery, 13(2). https://doi.org/10.22067/jam.2022.72477.1062

Fallah, M., & Ghanbari Parmehr, E. (2023). Detection of Chilo Suppressalis using Smartphone Images and Deep Learning. Journal of Agricultural Machinery, 13(2). https://doi.org/10.22067/jam.2022.72647.1064

Foldager, F., Munkholm, L. J., Balling, O., Serban, R., Negrut, D., Heck, R. J., & Green, O. (2022). Modeling soil aggregate fracture using the discrete element method. Soil and Tillage Research, 218, 105295. https://doi.org/10.1016/j.still.2021.105295

Ghiasi, P., Masoumi, A., Hemmat, A., & Najafi, G. (2020). ANN-based Modeling of Sunflower Threshing Process and Defining the Optimal Operation Point for Separation Efficiency. Journal of Agricultural Machinery, 10(1), 73–82. https://doi.org/10.22067/jam.v10i1.76264

Han, J., Yan, X., & Tang, H. (2023). Method of controlling tillage depth for agricultural tractors considering engine load characteristics. Biosystems Engineering, 227, 95–106. https://doi.org/10.1016/j.biosystemseng.2023.01.011

Jalali, A., Mahmoudi, A., Valizadeh, M., & Skandari, I. (2015). The effect of conservation tillage forward speed and depth on farm fuel consumption. Journal of Agricultural Machinery, 5(2), 325–335. https://doi.org/10.22067/jam.v5i2.28517

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(4), 46. https://doi.org/10.3390/resources12040046

Jang, J.-S. (1993). ANFIS: adaptive-network-based fuzzy inference system. IEEE Transactions on Systems, Man, and Cybernetics, 23(3), 665–685. https://doi.org/10.1109/21.256541

Kepner, R.A., Bainer, R., & Bager, E.L. (1978). Principles of Farm Machinery (3rd ed). Westport.CT:AVI Publishing Company.

Kim, Y.-S., Lee, S.-D., Baek, S.-M., Baek, S.-Y., Jeon, H.-H., Lee, J.-H., Kim, W.-S., Shim, J.-Y., & Kim, Y.-J. (2022). Analysis of the effect of tillage depth on the working performance of tractor-moldboard plow system under various field environments. Sensors, 22(7), 2750. https://doi.org/10.3390/s22072750

Lithourgidis, A. S., Dhima, K. V, Damalas, C. A., Vasilakoglou, I. B., & Eleftherohorinos, I. G. (2006). Tillage effects on wheat emergence and yield at varying seeding rates, and on labor and fuel consumption. Crop Science, 46(3), 1187–1192. https://doi.org/10.2135/cropsci2005.09-0321

Mamkagh, A. M. (2019). Review of fuel consumption, draft force and ground speed measurements of the

agricultural tractor during tillage operations. Asian Journal of Advanced Research and Reports, 3(4), 1–9. https://doi.org/10.9734/ajarr/2019/v3i430093

Mobtaker, H. G., Akram, A., & Keyhani, A. (2010). Economic modeling and sensitivity analysis of the costs of inputs for alfalfa production In Iran: A case study from Hamedan province. Ozean Journal of Applied Sciences, 3(3), 313–319.

Mohammadi, A. (2012). Modeling of draft force variation in a winged share tillage tool using fuzzy table look-up scheme. Agricultural Engineering International: CIGR Journal, 14(4), 262–268.

Mohd Salleh, M. N., & Hussain, K. (2016). A review of training methods of ANFIS for applications in business and economics. International Journal of U- and e-Service, Science and Technology, 9(7), 165–172. http://dx.doi.org/10.14257/ijunesst.2016.9.7.17

Nagar, H., & Machavaram, R. (2022). Application of artificial intelligence for fuel consumption prediction of a tractor in different operating conditions. *2022 IEEE 7th International Conference for Convergence in Technology* (I2CT), 1–7.

Rahimi-Ajdadi, F., & Abbaspour-Gilandeh, Y. (2011). Artificial neural network and stepwise multiple range regression methods for prediction of tractor fuel consumption. Measurement, 44(10), 2104–2111. https://doi.org/10.1016/j.measurement.2011.08.006

Regassa, A., Ali, A., & Taye, G. (2023). Soil classification. In The Soils of Ethiopia (pp. 71–75). Springer.

Roul, A. K., Raheman, H., Pansare, M. S., & Machavaram, R. (2009). Predicting the draught requirement of tillage implements in sandy clay loam soil using an artificial neural network. Biosystems Engineering, 104(4), 476–485. https://doi.org/10.1016/j.biosystemseng.2009.09.004

Šarauskis, E., Vaitauskienė, K., Romaneckas, K., Jasinskas, A., Butkus, V., & Kriaučiūnienė, Z. (2017). Fuel consumption and CO2 emission analysis in different strip tillage scenarios. Energy, 118, 957–968. https://doi.org/10.1016/j.energy.2016.10.121

Shafaei, S. M., Loghavi, M., & Kamgar, S. (2021). Profound insight into tractor energy dissipation through inevitable interaction inside wheel-soil interface for the period of plowing works. Soil and Tillage Research, 211, 104998. https://doi.org/10.1016/j.still.2021.104998

Soylu, S., & Çarman, K. (2021). Fuzzy logic based automatic slip control system for agricultural tractors. Journal of Terramechanics, 95, 25–32. https://doi.org/10.1016/j.jterra.2021.03.001

Suresh, N. V. U., Sadeghi, A., & Yazdani-Asrami, M. (2023). Critical current parameterization of high temperature superconducting tapes: A novel approach based on fuzzy logic. Superconductivity, 5, 100036. https://doi.org/10.1016/j.supcon.2023.100036

Tayel, M. Y., Shaaban, S. M., & Mansour, H. A. (2015). Effect of plowing conditions on the tractor wheel slippage and fuel consumption in sandy soil. International Journal of ChemTech Research, 8(12), 151–159.

Vesović, M. V., & Jovanović, R. Ž. (2022). Adaptive neuro fuzzy Inference systems in identification, modeling and control: The state-of-the-art. Tehnika, 77(4), 439–446. https://doi.org/10.5937/tehnika2204439V

Ziółkowski, J., Oszczypała, M., Małachowski, J., & Szkutnik-Rogoż, J. (2021). Use of artificial neural networks to predict fuel consumption on the basis of technical parameters of vehicles. Energies, 14(9), 2639. https://doi.org/10.3390/en14092639