Iranian Journal of Biosystem Engineering ISNN: 2423-7841
Homepage: http://ijbse.ut.ac.ir

Modelling variables affecting the yield of sugarcane fields using deep recurrent neural network

Hassan Zaki Dizaji[1]✉ |Kimia Shirini[2] | Adel Taheri Hajivand[3] | Nasim Monjezi[4]

1. Corresponding Author, Department of Biosystems Engineering, Faculty of Agriculture, Shahid Chamran University of Ahvaz, Iran. E-mail: hzakid@scu.ac.ir
2. Department of Computer Engineering, Faculty of Electrical and Computer Engineering, Tabriz University, Iran. E-mail: k.shirini@tabrizu.ac.ir
3. Department of Biosystems Engineering, Faculty of Agriculture, Tabriz University, Iran. E-mail: a.taheri@tabrizu.ac.ir
4. Department of Biosystems Engineering, Faculty of Agriculture, Shahid Chamran University of Ahvaz, Ahvaz, Iran. Email: n.monjezi@scu.ac.ir

Article Info

Article type: Research Article

Article history:

Received: July. 5, 2024

Revised: Dec. 21, 2024

Accepted: Jan. 21, 2025

Published online: Summer 2024

Keywords:
Deep Learning,
Deep Recurrent Neural Network Algorithm,
yield Prediction,
Sugarcane

ABSTRACT

In this research, one of the main goals of Khuzestan sugarcane Agro-industry companies, i.e., increasing the yield of sugarcane fields by using data mining methods, has been investigated. This research is of analytical type and includes the irrigation, drainage, soil and plant data of 1201 farms which were collected from Amirkabir Agriculture Company in 2013 to 2016 crop years. In this research, four algorithms of long Short-Term Memory (LSTM) recurrent neural network, Multilayer Neural Network Perceptron (MLP), decision tree and Support Vector Machine (SVM) were used, and two-dimension reduction methods, principal component analysis (PCA) and algorithm Independent Component Analysis (ICA) was applied using Python software. In the PCA method, the final variables including crop variety, soil texture, spraying area ratio, soil electrical conductivity, drainage and nitrogen fertilizer were identified. While in the ICA method, the final variables included product variety, soil electrical conductivity, water electrical conductivity, plant age, the number of times of irrigation and soil texture. The results showed that the LSTM recurrent neural network algorithm performed better in the PCA dimension reduction method. The values of R^2 equal to 97%, RMSE equal to 51.79, and RRMSE equal to 0.89 were obtained for this algorithm in the PCA method, compared to the ICA method, which had values of R^2 equal to 91%, RMSE equal to 62.75, and RRMSE equal to 0.798., which provided better results. This shows that PCA had a better ability to reduce the dimensionality for this model.

Cite this article: Zaki Dizaji, H., Shirini, K., Taheri Hajivand, A., Monjezi, N, (2025) Modelling variables affecting the yield of sugarcane fields using deep recurrent neural network, *Iranian Journal of Biosystem Engineering*, 55 (2),93-108. https://doi.org/10.22059/ijbse.2025.378958.665557

© The Author(s).

Publisher: The University of Tehran Press.

DOI: https://doi.org/10.22059/ijbse.2025.378958.665557

EXTENDED ABSTRACT

Introduction

The yield optimization of sugarcane fields is a primary goal for agro-industry companies in Khuzestan, Iran. In recent years, advancements in data mining and machine learning have opened new avenues for enhancing agricultural productivity. This study investigates the application of deep learning techniques, particularly the Long Short-Term Memory (LSTM) recurrent neural network, to estimate sugarcane crop yields. By leveraging the capabilities of LSTM networks, the research aims to identify the most influential factors affecting farm performance and classify farms into three performance categories. This classification can provide valuable insights for improving management practices and achieving er yields. In this context, the application of deep learning algorithms, specifically LSTM recurrent neural network, presents a promising avenue for yield estimation. LSTM networks are particularly suited for time-series data, which is prevalent in agriculture due to the seasonal nature of farming activities and the longitudinal recording of environmental and operational parameters. By leveraging LSTM's ability to capture temporal dependencies and patterns, this study aims to develop a robust model for predicting sugarcane yields.

Materials and Methods

In this article, using one of the deep learning algorithms called deep recurrent neural network LSTM, the yield estimation of sugarcane crop has been done. In this research, by using LSTM deep recurrent neural network, the most influential features in the performance of farms are selected and based on them, the performance of farms is placed in one of three categories. In this regard, available data sets such as irrigation and drainage, soil and plant data were used to determine the effect of different combinations of these factors on production performance. This research is of analytical type and its database includes records of 1201 farms. The data required for this paper were obtained from Amir Kabir Sugarcane Agriculture and Industry Company during the crop years of 2014 to 2018. The analysis was done with the help of Python software. In this research, four algorithms of LSTM recurrent neural network, Multilayer Neural Network Perceptron (MLP), decision tree and Support Vector Machine (SVM) were used, and two-dimension reduction methods of Principal Component Analysis (PCA) and independent component analysis algorithm. (ICA) was also applied.

Results and Discussion

The results showed that executive and management indicators have an effect on changing the performance level of sugarcane fields. Also, crop variety and soil electrical conductivity have appeared as the most important independent variables in modeling in both algorithms; Therefore, the obtained results can help in planning and preparing optimal conditions to reach the set goals of the production rate. The results showed that the Long Short-Term Memory (LSTM) recurrent neural network algorithm performed better in the Principal Component Analysis (PCA) dimension reduction method. The values of R^2 equal to 0.97%, RMSE equal to 51.79, and RRMSE equal to 0.89 were obtained for this algorithm in the PCA method, which compared to the ICA method, which had values of R^2 equal to 0.91%, RMSE equal to 62.75, and RRMSE equal to 0.798. The results gave a better This shows that PCA had a better ability to reduce the dimensionality for this model.

Conclusion

This research demonstrates the potential of using LSTM deep recurrent neural networks for yield estimation in sugarcane farming. The accuracy achieved by the model underscores its applicability in real-world agricultural settings. Identifying crop variety and soil electrical conductivity as major influencers provides actionable insights for farm management. The study's results can assist agro-industry companies in Khuzestan in planning and implementing optimal conditions to achieve their production goals. Future research could expand on these findings by incorporating additional variables and exploring other advanced machine learning techniques to further enhance yield prediction accuracy.

Author Contributions

For research articles with several authors, a short paragraph specifying their individual contributions must be provided. The following statements should be used “Conceptualization, Kimia Shirini and Adel Taheri Hajivand; methodology, Kimia Shirini; software, Kimia Shirini.; validation, Hassan Zaki Dizaji, Adel Taheri Hajivand; formal analysis, Hassan Zaki Dizaji; investigation, Hassan Zaki Dizaji, Kimia Shirini; resources, Hassan Zaki Dizaji. data curation, Kimia Shirini; writing—original draft preparation, Hassan Zaki Dizaji, Kimia Shirini; writing—review and editing, Adel Taheri Hajivand, Hassan Zaki Dizaji and Nasim Monjezi; visualization, Hassan Zaki Dizaji; supervision, Hassan Zaki Dizaji; project administration, Hassan Zaki Dizaji; funding acquisition, Hassan Zaki Dizaji. All authors have read and agreed to the published version of the manuscript.” Please turn to the CRediT taxonomy for the term explanation. Authorship must be limited to

those who have contributed substantially to the work re-ported.

Data Availability Statement

The data supporting the results reported in this study are available from the authors upon request. For inquiries, please contact the corresponding author.

Acknowledgements

The authors would like to appreciate the Vice Chancellor for Research and Technology of Shahid Chamran University of Ahvaz, Iran, for financial support under the special research grant number SCU.AA1402.505, and also to the R&D of Amir Kabir sugarcane Agro-Industry Company for preparing the data.

The authors would like to thank all participants of the present study.

Ethical considerations

The authors avoided data fabrication, falsification, plagiarism, and misconduct.

Conflict of interest

The author declares no conflict of interest.

مجله مهندسی بیوسیستم ایران، دوره ۵۵، شماره ۲ شاپا: ۷۸۴۱-۲۴۲۳
Homepage: http://ijbse.ut.ac.ir

مدل‌سازی متغیرهای موثر بر عملکرد مزارع نیشکر با استفاده از شبکه عصبی بازگشتی عمیق

حسن ذکی دیزجی[۱]✉ | کیمیا شیرینی[۲] | عادل طاهری حاجی‌وند[۳] | ، نسیم منجزی[۴]

۱. نویسنده مسئول، گروه مهندسی بیوسیستم، دانشکده کشاورزی، دانشگاه شهید چمران اهواز، اهواز، ایران. رایانامه: hzakid@scu.ac.ir
۲. گروه مهندسی کامپیوتر، دانشکده برق و کامپیوتر، دانشگاه تبریز، ایران. رایانامه: k.shirini@tabrizu.ac.ir
۳. گروه مهندسی بیوسیستم، دانشکده کشاورزی، دانشگاه تبریز، ایران. رایانامه: a.taheri@tabrizu.ac.ir
۴. گروه مهندسی بیوسیستم، دانشکده کشاورزی، دانشگاه شهید چمران اهواز، اهواز، ایران. رایانامه: n.monjezi@scu.ac.ir

اطلاعات مقاله

نوع مقاله: مقالهٔ پژوهشی

تاریخ دریافت: ۱۴۰۳/۴/۱۵
تاریخ بازنگری: ۱۴۰۳/۱۰/۱
تاریخ پذیرش: ۱۴۰۳/۱۱/۲
تاریخ انتشار: تابستان ۱۴۰۳

واژه‌های کلیدی:
یادگیری عمیق،
شبکه عصبی بازگشتی با حافظه‌ی طولانی کوتاه مدت،
پیش‌بینی عملکرد،
نیشکر

چکیده

در این پژوهش، یکی از اهداف اصلی شرکت‌های کشت و صنعت نیشکر خوزستان، یعنی افزایش عملکرد مزارع نیشکر با بهره‌گیری از روش‌های داده‌کاوی، مورد بررسی قرار گرفت. این پژوهش از نوع تحلیلی بوده و شامل داده‌های آبیاری، زهکشی، خاک و گیاه ۱۲۰۱ مزرعه است که در سال‌های زراعی ۱۳۹۳ تا ۱۳۹۶ از شرکت کشت و صنعت امیرکبیر گردآوری شده‌اند. تحلیل‌ها با استفاده از نرم‌افزار پایتون انجام شد. در این پژوهش، چهار الگوریتم شبکه عصبی بازگشتی حافظه طولانی کوتاه مدت (LSTM)، شبکه عصبی چندلایه پرسپترون (MLP)، درخت تصمیم و ماشین بردار پشتیبان(SVM) مورد استفاده قرار گرفت و دو روش کاهش بعد تحلیل مؤلفه‌های اصلی (PCA) و الگوریتم تحلیل مؤلفه‌های مستقل (ICA) اعمال شد. در روش PCA، متغیرهای نهایی شامل واریته محصول، بافت خاک، نسبت سطح سمپاشی، هدایت الکتریکی خاک، زهکشی و کود شیمیایی نیتروژن شناسایی شدند. با وجود این، در روشICA، متغیرهای نهایی شامل واریته محصول، هدایت الکتریکی خاک، هدایت الکتریکی آب، سن گیاه، تعداد دفعات آبیاری و بافت خاک بودند. نتایج نشان داد که الگوریتم شبکه عصبی بازگشتی حافظه طولانی کوتاه مدت (LSTM) در روش کاهش بعد تحلیل مؤلفه‌های اصلی (PCA) عملکرد بهتری داشت. مقادیر R^2 برابر با ۹۷٪، RMSE برابر با ۵۱/۷۹، و RRMSE برابر با ۰/۸۹ برای این الگوریتم در روش PCA به دست آمد که نسبت به روش ICA که مقادیر R^2 برابر با ۹۱٪، RMSE برابر با ۶۲/۷۵ و RRMSE برابر با ۰/۷۹۸ بود، نتایج بهتری ارائه داد. این نشان می‌دهد که روش PCA توانایی بهتری در کاهش ابعاد برای این مدل داشته است.

استناد: ذکی دیزجی؛ حسن، شیرینی؛ کیمیا، طاهری حاجی‌وند؛ عادل، منجزی؛ نسیم، (۱۴۰۳) مدل¬سازی متغیرهای موثر بر عملکرد مزارع نیشکر با استفاده از شبکه عصبی بازگشتی عمیق، *مجله مهندسی بیوسیستم ایران ایران*، ۵۵ (۲)، ۱۰۸-۹۳ https://doi.org/10.22059/ijbse.2025.378958.665557
ناشر: مؤسسه انتشارات دانشگاه تهران.
© نویسندگان.
DOI: https://doi.org/10.22059/ijbse.2025.378958.665557

مقدمه

نیشکر، به‌عنوان یکی از محصولات با ارزش حاصل از منابع ساکارز، اهمیت زیادی در کشاورزی دارد. در بسیاری از کشورها، تولید ساکارز به‌عنوان یکی از اهداف اصلی کشاورزی محسوب می‌شود؛ زیرا ساکارز به‌عنوان یک ماده غذایی با ارزش مطرح است. اما در کشورهایی که با مشکل تأمین انرژی مواجه هستند، کشت نیشکر به‌عنوان یک منبع انرژی نیز مورد توجه قرار می‌گیرد (ادیب‌زاده و همکاران، ۱۳۹۹). استان خوزستان با شرایط اقلیمی گرم خود، انگیزه‌ای برای کشت نیشکر فراهم می‌آورد؛ زیرا این منطقه با برداشت تقریباً ۱۲۵ تن ساقه در هر هکتار، قابلیت مناسبی برای کشت نیشکر را داراست. در این استان، نیشکر به‌صورت صنعتی تحت طرح‌های توسعه نیشکر و صنایع جانبی در ابعاد جغرافیایی گسترده‌ای کشت می‌شود (Zaki Dizaji et al., 2021). با این‌حال، عملکرد نیشکر در سال‌های اخیر به طور قابل‌توجهی نوسان داشته است. دلایل این افت شامل فشردگی خاک مزارع ناشی از تردد بیش از حد ماشین‌آلات زراعی، شوری آب رودخانه کارون، آلودگی هوا، بارندگی نامتعارف و گردوغبار در استان خوزستان است؛ همچنین، با افزایش خشکسالی و متراکم‌تر شدن خاک‌ها و عوامل تخصصی دیگر برداشت این محصول رو به نابودی است طوری که میانگین برداشت در سال ۱۴۰۱، حدوداً ۷۳ تن در هکتار بوده و این مقدار با ادامه این روند ممکن است کاهش پیدا کند. بنابراین پیش‌بینی عوامل مؤثر بر عملکرد این مزارع علاوه بر افزایش مقدار بازدهی می‌تواند از اتلاف منابع بیهوده نیز جلوگیری کند (ستاری و همکاران، ۱۴۰۲).

الگوریتم‌های یادگیری عمیق به‌عنوان ابزارهای قدرتمندی برای پیش‌بینی عملکرد و استخراج ویژگی‌ها در صنایع مختلف به شمار می‌روند (طاهری حاجیوند و همکاران، ۱۴۰۳). از جمله این الگوریتم‌ها عمیق شبکه عصبی بازگشتی با حافظه‌ی طولانی کوتاه مدت LSTM[1] و شبکه عصبی پرسپترون چند لایه MLP[2] هستند که در سال‌های اخیر به عنوان روش‌های مطمئنی برای پیش‌بینی و استخراج ویژگی‌های معنادار شناخته شده‌اند. از این الگوریتم‌ها علاوه بر کمک بسیار فراوان باعث کاهش هزینه‌ها و همچنین افزایش بهره‌وری می‌شود (Shirini et al., 2025). در زمینه به‌کارگیری روش‌های یادگیری عمیق در کشاورزی تاکنون مقاله های بسیاری انجام شده است که در ادامه به نمونه‌هایی از آن اشاره می‌شود.

پیشینهٔ پژوهش

پژوهش و مطالعات فراوانی برای پیش‌بینی عملکرد مزارع نیشکر هم در داخل کشور و هم در خارج از کشور انجام شده است و روش‌ها و نتایج مختلفی را می‌توان پیدا کرد. برخی از مطالعات برای کلاس‌بندی عملکرد این مزارع و برخی نیز برای پیش‌بینی مقدار برداشت نیشکر از مزارع است.

در پژوهشی عوامل مؤثر بر میزان تولید نیشکر با استفاده از روش‌های داده‌کاوی بررسی شد (ذکی دیزجی و همکاران، ۱۳۹۷) آن‌ها با در نظرگرفتن متغیرهای واریته محصول، کود شیمیایی نیتروژن، کود شیمیایی فسفر، سن گیاه، تعداد دفعات آبیاری، نسبت سطح سم‌پاشی محصول، بافت خاک، هدایت الکتریکی خاک و مصرف آب در هکتار، از درخت تصمیم CHAID و CART برای مدل‌سازی استفاده کردند. نتایج نشان می‌دهد که در هر دو مدل متغیر واریته محصول مهم‌ترین متغیر تأثیرگذار بر پیش‌بینی عملکرد نیشکر است. در تحقیقی دیگر به منظور مدل‌سازی متغیرهای موثر بر عملکرد نیشکر از الگوریتم‌های درخت تصمیم‌گیری استفاده شد (ذکی دیزجی و همکاران، ۱۳۹۸).

در پژوهش اولیویرا[3] و همکاران (۲۰۱۷) روشی برای پیش‌بینی میزان شکر استخراج شده از نیشکر برداشت شده در سال ۲۰۱۲–۲۰۱۱ ارائه شد. هر مشاهده مربوط به یک بلوک از زمین‌های زراعی نیشکر است. از ۵۳ ویژگی برای ساخت مدل پیش‌بینی استفاده کردند، این ویژگی‌ها در ۴ گروه شامل مواد فیزیکی و شیمیایی خاک، شرایط آب‌وهوایی، فعالیت‌های کشاورزی و اطلاعات مرتبط با محصول نیشکر است. سه تکنیک مختلف یادگیری ماشین، رگرسیون بردار پشتیبان، جنگل تصادفی و درخت‌های رگرسیون، در محیط نرم‌افزار R برای پیش‌بینی استفاده شده است. از الگوریتم ریلیف[4] برای انتخاب ویژگی استفاده شده است. نتایج نشان می‌دهد که در بین سه مدل پیش‌بینی بر اساس معیار میانگین قدرمطلق خطا، مدل ماشین بردار پشتیبان با کمترین مقدار خطا، به عنوان بهترین روش انتخاب شده است. در مطالعه ای دیگر مدلی برای پیش‌بینی عملکرد نیشکر با تمرکز بر مهندسی ویژگی‌ها، انتخاب ویژگی‌ها و تنظیم ابر پارامترها ارائه

1. Long Short-Term Memory
2. Multilayer Perceptron
3. Monique Pires Gravina de Oliveira
4. Relief

شد (Bocca and Rodrigues, 2016). زیرمجموعه‌ای از ویژگی‌ها با الگوریتم ریلیف انتخاب شده و از الگوریتم‌های ماشین بردار پشتیبان، جنگل تصادفی، درخت رگرسیون، شبکه عصبی مصنوعی، درختان رگرسیون تقویت شده استفاده شده است. تنظیم ابر پارامترها مدل با روش جست‌وجوی شبکه‌ای به همراه اعتبارسنجی متقابل با ۱۰ لایه انجام شده است. از معیار میانگین قدرمطلق خطا برای ارزیابی مدل‌ها استفاده شده است. در نهایت ۶۶ مدل از ترکیب روش‌های یادگیری و انتخاب ویژگی‌ها ایجاد شده که در بین آنها الگوریتم جنگل تصادفی بهترین عملکرد را داشته است.

با استفاده از داده‌های کارخانه شکر در تایلند، مدلی برای پیش‌بینی درجه عملکرد نیشکر بر اساس مدل‌های یادگیری ماشین ارائه شد (Charoen-Ung and Mittrapiyanuruk, 2019). این داده‌ها شامل ویژگی‌های مزرعه (نوع خاک، مساحت مزرعه، درجه عملکرد سال قبل) ویژگی‌های نیشکر (کلاس و نوع آن)، روش و میزان آبیاری، میزان بارش، روش‌های مبارزه با آفات و بیماری و میزان کوددهی است. دو الگوریتم جنگل تصادفی و درخت‌های تقویت‌کننده گرادیان برای طبقه‌بندی استفاده شدند.

در تحقیقی از الگوریتم‌های مختلف یادگیری ماشین از جمله درخت تصمیم، ماشین تقویت گرادیان، جنگل تصادفی، تقویت تطبیقی، XGBoost و شبکه عصبی برای پیش‌بینی عملکرد هیبریدهای ذرت استفاده شده است (Sarijaloo et al., 2021). نتایج نشان داد پیش‌بینی به‌دست‌آمده توسط درخت تصمیم دقیق‌تر از مدل‌های دیگر با ریشه میانگین مربع خطا برابر ۰/۵۲۴ است.

برای تخمین عملکرد محصول در ایالت راجستان هند برای پنج محصول شناسایی‌شده، از روش‌های یادگیری ماشین و یادگیری عمیق استفاده شد (Jhajharia et al., 2023). نتایج نشان داد که جنگل تصادفی با ضریب همبستگی ۰/۹۶۳، ریشه میانگین مربعات خطا ۰/۰۳۵ و میانگین مطلق خطا ۰/۰۲۵۱ بهتر از سایرین عمل کرد. همچنین در پژوهشی دیگر برای ارزیابی و عدم قطعیت پیش‌بینی عملکرد گندم از مدل پرسپترون چند لایه با رویکردهای بیزی[1] و کوپولا بیزی[2] استفاده کرده‌اند. در این تحقیق، از یک مدل پرسپترون چند لایه در حالت یادگیری پیش‌فرض و ترکیبی آن برای پیش‌بینی عملکرد گندم استفاده شده است. در حالت پیش فرض، پرسپترون چند لایه با الگوریتم پس انتشار و در حالت ترکیبی، پرسپترون چند لایه با الگوریتم حشره آبسوار (WSA)[3]، الگوریتم سینوسی کسینوس و الگوریتم ژنتیک آموزش داده شد. نتایج نشان داد که ترکیب پرسپترون چند لایه با یک الگوریتم بهینه‌سازی، پیش‌بینی عملکرد دقیق‌تری نسبت به حالت پیش‌فرض آن ارائه می‌دهد. WSA به کمترین زمان محاسباتی نیاز داشت و ترکیب آن با پرسپترون چند لایه منجر به پیش‌بینی بازده دقیق‌تری در مقایسه با سایر الگوریتم‌های بهینه‌سازی شد (Bazrafshan et al., 2022). برای محصول چای، در پژوهشی از یک رویکرد ترکیبی برای پیش‌بینی عملکرد محصول چای با استفاده از مدل‌های شبیه‌سازی و یادگیری ماشینی استفاده شد (Daoudiet et al., 2023). نتایج نشان داد که الگوریتم رگرسیون یادگیری ماشین با دقت ۹۱ درصد، بهتر از مدل شبیه‌سازی آکواکراپ سازمان ملل متحد عمل کرده و با داده‌های کمتری به پیش‌بینی عملکرد محصول پرداخت.

در پژوهش حاضر، داده‌های مربوط به مزارع نیشکر و متغیرهای مؤثر بر عملکرد این مزارع با استفاده از شبکه عصبی بازگشتی با حافظه‌ی طولانی‌مدت (LSTM) تحلیل شده و تلاش شده تا ویژگی‌های تأثیرگذارتر بر عملکرد شناسایی شوند. عوامل مختلفی مانند شرایط آب‌وهوایی، ویژگی‌های خاک، نوع کودهای مصرفی و مدیریت محصول بر عملکرد نیشکر تأثیر دارند. علاوه بر تحلیل داده‌های مربوط به مزارع نیشکر و شناسایی عوامل کلیدی مؤثر بر عملکرد این محصول با استفاده از مدل‌های یادگیری عمیق نظیر LSTM و MLP، یک تفاوت مهم و اساسی با پژوهش‌های پیشین وجود دارد: در اکثر تحقیقات گذشته، استفاده از تعداد زیادی ویژگی برای پیش‌بینی عملکرد، منجر به افزایش پیچیدگی مدل‌ها شده است. لذا در این پژوهش، با به‌کارگیری روش‌های کاهش بعد نظیر تحلیل مؤلفه‌های اصلی (PCA) و تحلیل مؤلفه‌های مستقل (ICA)، تعداد ورودی‌های مدل به میزان قابل‌توجهی کاهش یافت. این کاهش نه تنها پیچیدگی مدل را کم می کند و سرعت پردازش را افزایش می دهد، بلکه دقت پیش‌بینی را نیز در سطحی قابل‌توجه حفظ می‌نماید. مهم‌ترین دستاورد این پژوهش، ارائه مدلی کارآمد و ساده‌تر با تعداد ویژگی‌های ورودی کمتر و حفظ دقت بالا بوده است، که می‌تواند به‌عنوان راهکاری مؤثر برای مدیریت بهینه مزارع نیشکر و بهبود بهره‌وری به کار گرفته شود.

مواد و روش‌ها

1. Bayesian networks
2. Copula bayesian networks
3. Water Striders Algoritm

در این پژوهش، از داده‌های سال‌های زراعی ۱۳۹۳ تا ۱۳۹۶، مربوط به مزارع کشت و صنعت امیرکبیر که یکی از واحدهای هفت‌گانه شرکت توسعه نیشکر و صنایع جانبی بود، بهره برده شد. این شرکت در فاصله ۴۵ کیلومتری جنوب اهواز، در منطقه غربی رودخانه کارون و در مسیر شرقی جاده اهواز به خرمشهر با محدوده جغرافیایی از عرض ۴۸ درجه و ۱۲ دقیقه تا ۴۸ درجه و ۳۰ دقیقه و ارتفاع جغرافیایی از عرض ۳۱ درجه و ۱۵ دقیقه تا ۳۱ درجه و۴۰ دقیقه واقع شده است. این منطقه دارای میانگین بارش سالیانه ۱۴۷ میلی‌متر، میانگین دمای روزانه هوا۲۵ درجه سلسیوس، میانگین دمای خاک ۲۱/۲ درجه سلسیوس و ارتفاع متوسط از سطح دریا حدود ۷ متر است. مساحت این واحد کشاورزی ۱۴۰۰۰ هکتار است و پتانسیل سطح زیر کشت آن ۱۲۰۰۰ هکتار می‌باشد، باقی مانده از این مساحت شامل کانال‌ها، جاده‌ها، ساختمان‌ها و کارخانه‌ها می‌شود. این واحد دارای ۴۸۰ مزرعه با مساحت متوسط ۲۵/۲ هکتار است (ذکی دیزجی و همکاران، ۱۳۹۸).

شناخت داده‌ها

در مرحله اول تحقیق، هدف اصلی شناخت وضعیت فعلی، بررسی منابع داده و تعیین دامنه طرح است. این مرحله شامل مصاحبه با مدیران و کارشناسان، بازدید از واحدهای کشاورزی، و مطالعه مقالات و تجربیات موفق در زمینه داده‌کاوی کشاورزی می‌باشد (طاهری حاجیوند و همکاران، ۱۴۰۳). همچنین، منابع داده مرتبط با تولید نیشکر، آبیاری، هواشناسی، خاک و گیاه ارزیابی شده و محدودیت‌های موجود شناسایی گردید. در نهایت، نقشه راه مشترکی بین محققان و کارشناسان کشت و صنعت نیشکر تدوین شد. در این پژوهش، پس از شناخت و بررسی وضعیت فعلی و ارزیابی منابع داده‌های مرتبط با تولید نیشکر، مرحله دوم به آماده‌سازی و یکپارچه‌سازی داده‌ها، مدل‌سازی و ارزیابی مدل‌ها اختصاص یافت. در این مرحله، با استفاده از روش‌های داده‌کاوی و شبکه عصبی بازگشتی با حافظه‌ی طولانی کوتاه مدت (LSTM)، داده‌های مربوط به آبیاری، خاک، هواشناسی و مدیریت مزارع جمع‌آوری و پردازش شد. سپس مدل‌های پیش‌بینانه برای تخمین عملکرد مزارع توسعه یافت و متغیرهای تأثیرگذار بر عملکرد محصول شناسایی گردید. هدف نهایی این پژوهش ارائه راهکارهایی برای بهبود عملکرد و افزایش تولید نیشکر بر اساس تحلیل داده‌ها و مدل‌های یادگیری ماشینی بود. همچنین، با ارزیابی منابع داده موجود در کشت و صنعت، محدودیت و دامنه اجرایی پژوهش تعیین گردید. ارزیابی منابع داده موجود در کشت و صنعت نیز به تعیین محدودیت و دامنه اجرایی پژوهش کمک می‌کند. تأیید این مرحله منجر به ایجاد یک نقشه راه مشترک بین محققان و کارشناسان شرکت کشت و صنعت نیشکر می‌گردد.

آماده سازی و پیش پردازش داده‌ها

آمار توصیفی عملکرد مزارع نیشکر در در جدول ۱ آمده است. داده‌های استفاده شده در این تحقیق داده‌ها از ۲۲ ورودی (شامل متغیرهای پیوسته و گسسته) تشکیل شده‌اند که از ۱۲۰۱ مزرعه نیشکر در طی سال‌های۱۳۹۳ تا ۱۳۹۶ به دست آمده‌اند. این متغیرها به دو دسته متغیرهای پیش‌بینی‌کننده و متغیر هدف تقسیم شدند. متغیر عملکرد مزارع به‌عنوان متغیر هدف (متغیر وابسته) و سایر متغیرها به‌عنوان متغیرهای پیش‌بینی‌کننده (متغیر مستقل) در نظر گرفته شده‌اند. در مدل ارائه شده، داده‌های ورودی شامل: واریته محصول، ماه برداشت، کود شیمیایی (نیتروژن)، کود شیمیایی (فسفر)، سن گیاه (کشت اول یا راتون)، تعداد دفعات آبیاری مزرعه در طی فصل زراعی، نسبت سطح سم‌پاشی مزرعه (نسبت سطح سم‌پاشی شده به مساحت کل مزرعه)، بافت خاک، هدایت الکتریکی خاک (EC)، مقدار مصرف آب در هکتار، زهکشی، مدیریت مزرعه (مدیریت تولید)، طول فصل زراعی، مساحت مزرعه و عملکرد نیشکر است (ذکی دیزجی و همکاران، ۱۳۹۷). اطلاعات و توصیف داده‌های ورودی در جدول‌های ۲ و ۴ آمده است.

پیش پردازش

به‌منظور پیش‌پردازش داده‌ها، تغییرات موردنیاز برای آماده‌سازی داده‌ها و تطبیق آن‌ها با الگوریتم‌های مدل‌سازی اعمال شد. یکی از این تغییرات، کدگذاری متغیرهای کیفی است که به مدل امکان می‌دهد این متغیرها را به شکل عددی پردازش کند. برای این منظور از روش کدگذار برچسب[1] استفاده شد. برای ویژگی‌های کمی نیز، به‌منظور یکسان‌سازی مقیاس‌ها و کاهش تأثیرات نامطلوب، نرمال‌سازی داده‌ها انجام شد. در این پژوهش، از روش نرمال‌سازی کمین‌بیشین استفاده گردید که مقادیر داده‌ها را به بازه‌ای بین ۰ و ۱ نگاشت می‌کند. این روش با یکنواخت‌سازی مقیاس داده‌ها، به بهبود عملکرد مدل‌های حساس به مقیاس کمک می‌کند.

روش‌های کاهش بعد

1 Label Encoding

برای کاهش بعد داده‌ها، از دو روش تحلیل مؤلفه‌های اصلی (PCA) و تحلیل مؤلفه‌های مستقل (ICA) استفاده شد (Daffertshofer et al., 2004). این روش‌ها در نرم‌افزار پایتون پیاده‌سازی شدند. با استفاده از روش ICA، تعداد پارامترها به ۶ پارامتر اصلی شامل واریته محصول، هدایت الکتریکی خاک، هدایت الکتریکی آب، سن گیاه، تعداد دفعات آبیاری و بافت خاک کاهش یافت. در مقابل، روش PCA پارامترها را به ۶ متغیر اصلی شامل واریته محصول، بافت خاک، نسبت سطح سمپاشی، هدایت الکتریکی خاک، زهکشی و کود شیمیایی نیتروژن تقلیل داد. جزئیات پارامترهای انتخاب‌شده توسط هر روش در جدول ۳ ارائه شده است.

جدول ۱. آمار توصیفی عملکرد مزارع نیشکر در سالهای زراعی ۱۳۹۳ تا ۱۳۹۶

میزان عملکرد و بازدهی در سال	کیفی	کمی (تن در هکتار)	فراوانی نسبی (درصد)	مساحت
	خیلی کم	۴۵/۲۷–۲/۵	۴/۰۹	۵۴۴/۸
	کم	۶۲/۴۵–۸/۳	۴۲/۸۴	۵۷۰۵/۴
۱۳۹۳	متوسط	۸۰/۶۲–۵/۹	۴۴/۳۸	۵۹۱۱/۳
	زیاد	۹۸/۸۰–۱/۶	۱۱/۵۹	۱۵۴۳
	خیلی زیاد	۱۱۵/۹۸–۸/۲	۱/۱۹	۱۵۸/۶
	خیلی کم	۳۸/۱۹–۲/۵	۷/۱۶	۹۹۲/۸
	کم	۵۷/۳۸–۸/۳	۳۹/۶۶	۵۴۹۸/۴
۱۳۹۴	متوسط	۷۷/۵۷–۵/۹	۴۶/۴۵	۶۴۳۹/۳
	زیاد	۹۶/۷۷–۱/۶	۶/۲۱	۸۷۶/۲
	خیلی زیاد	۱۱۵/۹۶–۸/۲	۰/۴۱	۵۷/۴
	خیلی کم	۵۳/۳۲–۱/۹	۳/۸	۵۳۳/۷
	کم	۷۳/۵۳–۱/۲	۵۹/۲۳	۸۲۱۱
۱۳۹۵	متوسط	۹۳/۷۳–۲/۲	۳۱/۹۹	۴۴۳۵
	زیاد	۱۱۳/۹۳–۴/۳	۳/۵۵	۶۳۰
	خیلی زیاد	۱۳۳/۱۱۳–۵/۵	۰/۳	۵۲/۶
	خیلی کم	۴۹/۲۷–۸/۸	۱/۷۴	۲۴۱
	کم	۷۱/۴۹–۸/۹	۳۸/۲۵	۵۳۰۳
۱۳۹۶	متوسط	۹۳/۷۱–۸/۹	۴۹/۶۲	۶۹۷۹/۳
	زیاد	۱۱۶/۹–۰۳	۹/۸۵	۱۳۶۵/۳
	خیلی زیاد	۱۳۹–۱۱۷	۰/۵۴	۷۳/۴۳

جدول ۲. توصیف متغیرهای پیوسته ورودی مدل‌ها مورد استفاده

نام متغیر	واحد	نوع متغیر	نقش متغیر مقدار	انحراف معیار	میانگین	بیشترین مقدار	کمترین مقدار
مقدار آب مصرفی	m^3h^{-1}	پیوسته	ورودی	۱۳۰/۱۵۰	۱۳۷۸/۳۰۸	۱۷۰۴/۳۰۰	۱۰۳۰/۸۲۰
کود شیمیایی نیتروژن	h^{-1} kg	پیوسته	ورودی	۵۷/۹۸۷	۵۳۵/۰۱۸	۵۳۱/۳۳	۲۲۵/۰۰۱
مدت زمان کشت	Day	پیوسته	ورودی	۳۱/۰۳۸	۴۴۳/۵۹۳	۵۱۲/۰۰۰	۴۰۰/۰۰۰
مساحت	Ha	پیوسته	ورودی	۵/۷۸۲	۲۱/۳۹۳	۲۵/۵۰۰	۷/۰۰۰
هدایت الکتریکی خاک	dsm^{-1}	پیوسته	ورودی	۱/۸۲۵	۵/۶۳۷	۱۳/۰۰۰	۳/۴۰۰
درصد جوانه معیوب	(٪)	پیوسته	ورودی	۲/۵۲۰	۶/۵۳۹	۱۶/۵۰۰	۴/۱۰۰
تعداد قلمه	-	پیوسته	ورودی	۱۱/۰۰۶	۶۰/۷۰۰	۹۹/۰۵۰	۴۰/۶۰۰
فاصله کود اول تا کود دوم	Day	پیوسته	ورودی	۸/۶۵۱	۳۲/۸۷۵	۵۳/۰۰	۲۲/۰۰۰
فاصله آبیاری اول و قطع آب	Day	پیوسته	ورودی	۸۵/۵۷۴	۱۸۳/۰۴۶	۲۸۵/۰۰۰	۱۲/۰۰۰
میزان کود نوبت اول	-	پیوسته	ورودی	۳۴/۳۶۱	۸۰/۳۲۰	۱۸۶/۹۳۰	۵۰/۰۰۰
میزان کود نوبت دوم	-	پیوسته	ورودی	۳۲/۵۵۲	۱۴۱/۳۳۱	۲۴۱/۸۳۰	۱۰۰/۰۰۰
میزان کود نوبت سوم	-	پیوسته	ورودی	۴۸/۴۶	۱۱۸/۵۳۱	۲۱۵/۵۴۰	۰/۰۰۰
میزان کود نوبت چهارم	-	پیوسته	ورودی	۲۷/۰۴۹	۷/۸۱۲	۱۰۰/۰۰۰	۰/۰۰۰
فاصله از آخرین تعمیرات لترال	ماه	پیوسته	ورودی	۳/۱۴۹	۴/۲۱۸	۱۲/۰۰۰	۰/۰۰۰
کود شیمیایی فسفات	h^{-1} kg	پیوسته	ورودی	۱۰۸/۶۳۱	۱۶۳/۷۵۰۰۰	۲۵۰/۰۰۰	۰/۰۰۰

درصد سرنی	(٪)	پیوسته	ورودی	۳/۸۵۳	۱۵/۴۶۱	۲۷/۵۰۰	۷/۷۰۰

جدول ۳. پارامترهای انتخاب شده توسط هر یک از روش‌های کاهش بعد

روش کاهش بعد	متغیرهای نهایی انتخاب شده
تحلیل مؤلفه‌های اساسی (PCA)	واریته محصول،بافت خاک، نسبت سطح سمپاشی، هدایت الکتریکی خاک، زهکشی و کود شیمیایی نیتروژن
تحلیل مؤلفه‌های مستقل(ICA)	واریته محصول ،هدایت الکتریکی خاک، هدایت الکتریکی آب ، سن گیاه ، تعداد دفعات آبیاری و بافت خاک

همان‌طور که از جدول ۳ مشخص است پارامترهای واریته محصول، هدایت الکتریکی خاک و بافت خاک هر سه جزوه پارامترهای مهم و اساسی برای تعیین میزان عملکرد محصول نیشکر هستند. حال در ادامه با استفاده از پارامترهای مشخص شده هر یک از این الگوریتم‌ها به پیش بینی عملکرد این محصول پرداخته می شود.

جدول ۴. توصیف متغیرهای گسسته ورودی مدل‌ها

نام متغیر	نقش متغیر	نوع متغیر	مساحت	تعداد مزارع موجود در این گروه	توصیف متغیر
مدیریت مزرعه	ورودی	گسسته	۴۹/۷۹	۵۹۸	تولید اول (۶۰۰۰ هکتار)
			۵۰/۲۱	۶۰۳	تولید دوم (۶۰۰۰ هکتار)
واریته محصول	ورودی	گسسته	۱۹/۴۸	۲۳۴	**SP**۷۰-۱۱۴۳
			۱/۸۳	۲۲	**IRC**۹۹-۰۲
			۵۱/۵۴	۶۱۹	**CP**۶۹-۱۰۶۲
			۱۲/۷۴	۱۵۳	**CP**۵۷-۶۱۴
			۱۴/۴۰	۱۷۳	**CP**۴۸-۱۰۳
بافت خاک	ورودی	گسسته	۶/۳۳	۷۶	شنی لوم
			۳/۰۰	۳۶	شنی رسی لوم
			۲/۰۰	۲۴	سیلتی لوم
			۶/۱۶	۷۴	سیلتی رسی
			۲۱/۲۳	۲۵۵	سیلتی کلی لوم
			۳۴/۴۷	۴۱۴	لوم
			۲۶/۸۱	۳۲۲	کلی لوم
سن گیاه	ورودی	گسسته	۲۹/۸۹	۳۵۹	کشت اول
			۲۹/۸۱	۳۵۸	راتون اول
			۲۴/۴۰	۲۹۳	راتون دوم
			۱۵/۹۰	۱۹۱	راتون سوم
نسبت سطح سمپاشی	ورودی	گسسته	۲۲/۵۶	۲۷۱	۱
			۳۰/۸۹	۳۷۱	۲
			۲۴/۶۵	۲۹۶	۳
			۲۱/۹۰	۲۶۳	۴
عملکرد	خروجی (هدف)	گسسته	۷/۴۹	۹۰	مطلوب (x≤۱۰۰)
			۴۵/۰۵	۵۴۱	متوسط (۱۰۰ <x≥۶۵)
			۴۷/۴۶	۵۷۰	نامطلوب (۶۵>x)
ماه برداشت	ورودی	گسسته	۶/۷۴	۸۱	(مهر،اکتبر)۱۰
			۱۵/۸۲	۱۹۰	(آبان،نوامبر)۱۱
			۲۷/۳۱	۳۲۸	(آذر،دسامبر)۱۲
			۱۰/۶۶	۱۲۸	(دی،ژانویه)۱
			۲۱/۸۲	۲۲۶۲	(بهمن،فوریه)۲
			۱۴/۳۲	۱۷۲	(اسفند،مارس)۳
			۱/۶۷	۲۰	(فروردین،آوریل)۴
			۱/۶۷	۲۰	(اردیبهشت،مه)۵

انتخاب مدل و مدل‌سازی

در این پژوهش، از دو الگوریتم شبکه عصبی بازگشتی با حافظه‌ی طولانی کوتاه مدت (LSTM) و شبکه عصبی پرسپترون چند لایه

(MLP) به‌عنوان الگوریتم‌های اصلی مدل‌سازی استفاده شده است (ستاری و همکاران، ۱۴۰۲). الگوریتم LSTM به‌دلیل قابلیت‌های خاص خود در کار با داده‌های سری زمانی و توانایی مقابله با وابستگی‌های بلندمدت انتخاب شده است. این الگوریتم به‌ویژه در مواقعی که داده‌ها دارای الگوهای پیچیده و نوسانات غیرخطی هستند، عملکرد خوبی از خود نشان می‌دهد. از سوی دیگر،MLP به‌عنوان یک الگوریتم پایه در یادگیری عمیق شناخته می‌شود که در حل مسائل دسته‌بندی و رگرسیون کاربرد دارد. این الگوریتم نیز مورد بررسی قرار گرفته و با LSTM مقایسه شده است تا بهترین عملکرد بر اساس معیارهای مختلف ارزیابی شود. این مقایسه به ما کمک کرد تا نقاط قوت و ضعف هر یک از این الگوریتم‌ها را شناسایی کنیم و در نهایت، الگوریتم LSTM به‌عنوان گزینه مناسب‌تری برای مدل‌سازی داده‌ها در این پژوهش انتخاب شد.

الگوریتم شبکه عصبی بازگشتی با حافظه‌ی طولانی کوتاه مدت (LSTM)

شبکه عصبی بازگشتی با حافظه‌ی طولانی کوتاه مدت یک نوع ویژه از شبکه‌های عصبی بازگشتی (RNN) است که برای پردازش داده‌های دنباله‌ای مانند متن یا زمان سری مناسب است. این شبکه‌ها از معماری خاصی برای حفظ و استفاده از اطلاعات بلندمدت در طول دنباله استفاده می‌کنند. شبکه عصبی با حافظه طولانی‌مدت (LSTM) یک نوع خاص از شبکه‌های عصبی بازگشتی است که برای پردازش داده‌های دنباله‌ای مانند متن یا داده‌های زمانی طراحی شده است (Yu et al., 2019). این شبکه‌ها از معماری خاصی استفاده می‌کنند که امکان حفظ اطلاعات بلندمدت را فراهم می‌آورد. معماری LSTM شامل سلول حافظه است که می‌تواند اطلاعات را برای مدت‌زمان طولانی نگهداری کند و از جریان‌های ورودی و خروجی برای کنترل اطلاعات استفاده می‌کند. LSTM همچنین دارای دروازه‌های مختلفی است که به‌صورت هوشمندانه اطلاعات را فیلتر و کنترل می‌کنند. این شبکه‌ها به‌دلیل ویژگی‌های خاص خود، به‌طور گسترده در کاربردهایی نظیر ترجمه ماشینی، تولید متن و پیش‌بینی داده‌های زمانی استفاده می‌شوند. شبکه‌های عصبی LSTM شامل لایه‌هایی از نورون‌ها هستند که داده‌های ورودی را برای تولید پیش‌بینی پردازش می‌کنند. مانند سایر شبکه‌های بازگشتی، LSTM نیز دارای اتصالات بازگشتی است که وضعیت فعالیت‌های قبلی نورون را در گام‌های زمانی قبلی به‌عنوان بخشی از داده‌ها استفاده می‌کند. ساختار شبکه عصبی مصنوعی بازگشتی عمیق از نوع LSTM در شکل ۱ نشان‌داده‌شده است.

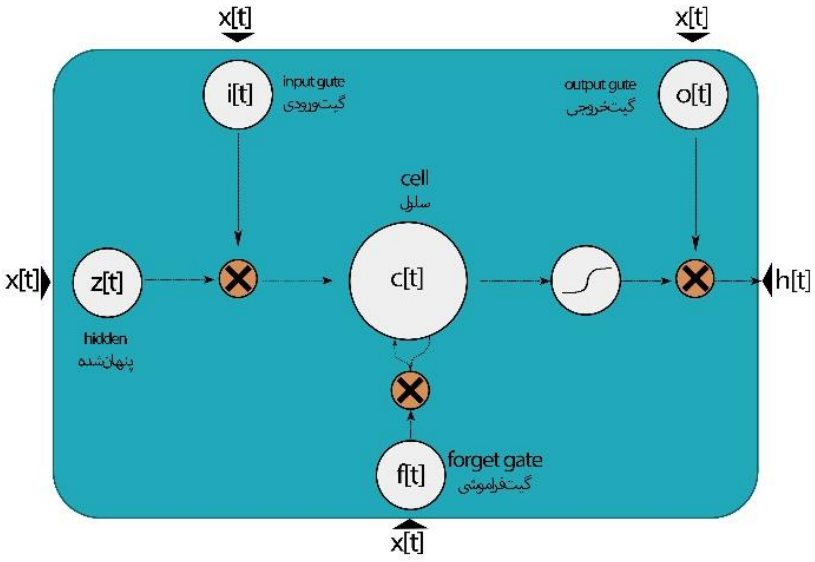

شکل ۱. ساختار شبکه عصبی مصنوعی بازگشتی عمیق از نوع LSTM

در شکل ۲ فلوچارت اجرای الگوریتم شبکه عصبی بازگشتی با حافظه‌ی طولانی کوتاه مدت ارائه شده در این مقاله نمایش‌داده‌شده است. به‌منظور مقایسه کارایی الگوریتم شبکه عصبی مصنوعی بازگشتی از یک شبکه عصبی دیگر به نام شبکهٔ عصبی مصنوعی پرسپترون چندلایه و نیز دو روش یادگیری ماشین شامل درخت تصمیم و ماشین بردار پشتیبان استفاده شد.

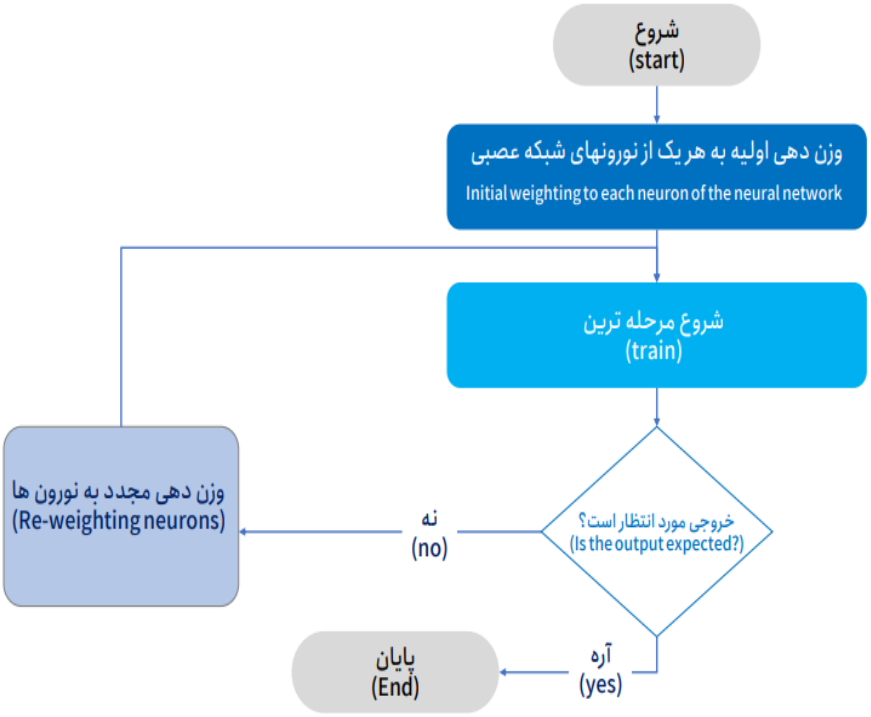

شکل ۲. فلوچارت اجرای LSTM

معیارهای ارزیابی

در این پژوهش، به‌منظور ارزیابی و مقایسه عملکرد مدل‌های پیش‌بینی، از سه معیار کلیدی شامل ضریب همبستگی (R)، جذر میانگین مربعات خطا (RMSE) و خطای نسبی ریشه میانگین مربعات (RRMSE) استفاده شده است. این معیارها به‌طور خاص برای تحلیل دقت پیش‌بینی مدل‌ها و انتخاب مدل برتر به کار گرفته شده‌اند.

یافته‌های پژوهش

در این پژوهش از نرم‌افزار پایتون برای مدل‌سازی الگوریتم‌ها و اعتبارسنجی نتایج بهـره گرفته شد. داده‌ها به دو دسته آموزشی (۷۰٪) و آزمون (۳۰٪) تقسیم شدند. یکی از ویژگی‌های شبکه‌های عصبی، عدم وجود قانون مشخص برای تعیین معماری آن‌هاست و انتخاب تعداد لایه‌ها و نورون‌ها معمولاً با استفاده از روش آزمون و خطا انجام می‌شود.

در طراحی شبکه‌های عصبی، دو پارامتر کلیدی وجود دارد: تعداد گره‌های ورودی و تعداد نورون‌های لایه پنهان. نورون‌های پنهان به کشف الگوهای غیرخطی در داده‌ها کمک می‌کنند. اگرچه از نظر تئوری محدودیتی برای تعداد نورون‌ها وجود ندارد، معمولاً این تعداد بیشتر از دوبرابر تعداد گره‌های ورودی نیست. در پژوهش حاضر برای تعیین حداقل و حداکثر تعداد بهینه نورون در لایه پنهان از رابطه $n/2+1<x<2n+1$ استفاده شده است. در این پژوهش با توجه به ۶ پارامتر ورودی، حداقل و حداکثر تعداد نورون در لایه پنهان به ترتیب ۴ و ۱۳ نورون مورد استفاده قرار گرفته است. همچنین برای لایه خروجی نیز یک نورون وابسته به طبیعت مسأله مورد نظر که پیش بینی عملکرد نیشکر می باشد، لحاظ شده است. با توجه به چیدمان مطلوب شبکه عصبی انتخاب شده برای پیش‌بینی عملکرد نیشکر که به‌صورت ۶-۹-۱ (شش نورون به ازای متغیرهای ورودی، نُه نورون در لایه پنهان و یک نورون در لایه خروجی) می‌باشد. در جدول ۵، تنظیمات ابرپارامترهای چهار الگوریتم مختلف به صورت خلاصه ارائه شده است. برای الگوریتم درخت تصمیم (Decision Tree) از معیار تقسیم جینی یا آنتروپی، عمق بهینه‌سازی‌شده درخت، حداقل نمونه‌های ۲ و ۱۰ به ترتیب برای برگ و تقسیم و هرس برای جلوگیری از بیش‌برازش استفاده شده است. در SVM، هسته‌های خطی و چندجمله‌ای با پارامتر مجازات (C) بهینه‌سازی شده و مقادیر گاما برای هسته‌های غیرخطی تنظیم شده است. در LSTM، ۲ لایه مخفی با ۵۰ واحد و الگوریتم آموزشی نزول گرادیان با مومنتوم با نرخ یادگیری ۰/۰۰۱ و تابع فعال‌سازی تانژانت هایپربولیک به‌کار گرفته شده است. برای MLP نیز، ۳ لایه مخفی با تعداد نورون‌های ۶۴، ۳۲ و ۱۶، همراه با الگوریتم لونبرگ–مارکوارت و توابع فعال‌سازی سیگموئید و ReLU تنظیم شده‌اند.

جدول ۵. تنظیمات ابرپارامترهای چهار الگوریتم مختلف به صورت خلاصه.

الگوریتم	ابرپارامتر	مقدار/توضیحات
درخت تصمیم (**Decision Tree**)	معیار تقسیم	آنتروپی
	حداقل نمونه در یک برگ	۲
	حداقل نمونه برای تقسیم	۱۰
ماشین بردار پشتیبان (**SVM**)	نوع هسته	هسته چندجمله‌ای
	نوع مسئله	مسئله دوکلاسی با استفاده از **SVM** باینری
شبکه عصبی بازگشتی (**LSTM**)	الگوریتم آموزشی	الگوریتم نزول گرادیان با مومنتوم
	تعداد لایه‌های مخفی	۱
	تعداد واحدها در هر لایه	۱۰۰
	تابع فعال‌سازی	تانژانت هایپربولیک
	نرخ یادگیری	۰/۰۰۱
	تعداد اپوک‌ها	۱۰۰
شبکه عصبی چندلایه پرسپترون (**MLP**)	تابع فعال‌سازی	سیگموئید (**Sigmoid**) و **ReLU**
	نرخ یادگیری	۰/۰۰۱

بحث

به‌طورکلی با توجه به نتایج جدول ۶، الگوریتم پرسپترون چندلایه بیش‌ترین تأثیر را در مدل‌سازی شاخص عملکرد محصول نیشکر داشته است که به‌عنوان معیار ارزیابی مورد بررسی قرار گرفته‌اند. نتایج نشان می‌دهد روش PCA یکی از روش‌های بسیار مناسب نسبت به روش ICA برای کاهش بعد ویژگی‌ها است. همچنین، با مقایسه جداول ۶ و ۷ می‌توان نتیجه گرفت که برای پیش‌بینی عملکرد محصول نیشکر، روش شبکه عصبی مصنوعی چندلایه (MLP) دقت پایین و خطای بالایی نسبت به روش‌های یادگیری ماشین مانند درخت تصمیم و SVM دارد. از طرف دیگر، روش‌هایLSTM، دقت بالایی در پیش‌بینی عملکرد نیشکر دارند. این نتایج نشان‌دهنده اهمیت انتخاب الگوریتم مناسب برای بهبود دقت پیش‌بینی در مدل‌سازی عملکرد محصولات کشاورزی است. نتایج مدل‌سازی به تفکیک داده‌های آموزشی و آزمون ارائه شده است. نتایج جداول ۶ و ۷ همچنین نشان‌دهنده مقایسه روش‌های پیشنهادی با نتایج کارهای مشابه در ادبیات موجود است. به‌ویژه در مقایسه با درخت تصمیم (Decision Tree) از نتایج تحقیق سجارلو و همکاران (2021) و ماشین بردار پشتیبان (SVM) در تحقیق دیگر (Oliveira, et al., 2017)، نتایج پژوهش حاضر به‌طور معناداری دقت بالاتری را در پیش‌بینی عملکرد نیشکر نشان می‌دهد.

جدول ۶. مقایسه روش‌های کاهش بعد در الگوریتم های یادگیری عمیق برای داده‌های آموزش.

الگوریتم‌های مورد استفاده	معیار ارزیابی	نتایج برای داده‌های آموزشی		نتایج برای داده‌های تست	
		روش کاهش بعد		روش کاهش بعد	
		PCA	ICA	PCA	ICA
LSTM	R^2	۰/۹۸	۰/۹۴	۰/۹۷	۰/۹۱
	RMSE	۳۳/۲۱	۴۲/۴۵	۵۱/۷۹	۶۲/۷۵
	RRMSE	۰/۴۱	۰/۵۵	۰/۸۹	۰/۷۹۸

				۰/۷۵۷	۰/۶۵۰
MLP	R^2	۰/۸۸۷	۰/۷۲۰		
	RMSE	۴۱/۰۰	۵۱/۵۹	۷۵/۰۰	۱۸۴/۵۹
	RRMSE	۰/۵۹۰	۰/۷۵		
				۰/۹۹۰	۰/۹۸۰
Decision Tree (sejarloo, ۲۰۲۱) (سجارلو، ۲۰۲۱)	R^2	۰/۹۷	۰/۹۱	۰/۸۷	۰/۸۳۱
	RMSE	۶۳/۰۹	۷۱/۲۳	۶۳/۰۹	۷۱/۲۳
	RRMSE	۰/۲۹	۰/۵۴	۰/۴۹	۰/۵۹
SVM (اولیویر و همکاران، ۲۰۱۷)	R^2	۰/۹۶	۰/۹۴	۰/۹۱	۰/۸۳
	RMSE	۷۷/۱۰	۹۷/۲۱	۵۷/۱۰	۵۷/۲۱
	RRMSE	۰/۴۶	۰/۵۲	۰/۶۶	۰/۵۲

جدول ۶ به بررسی مقایسه‌ای روش‌های کاهش بعد در الگوریتم‌های یادگیری عمیق برای داده‌های آموزشی می‌پردازد. این جدول شامل سه معیار ارزیابی اصلی شامل ضریب تعیین (R^2)، ریشه میانگین مربعات خطا (RMSE)، و خطای نسبی میانگین مربعات (RRMSE). نتایج نشان‌دهنده تأثیر روش‌های کاهش بعد تحلیل مؤلفه اصلی (PCA) و تحلیل مؤلفه مستقل (ICA) بر عملکرد الگوریتم‌های مختلف یادگیری عمیق هستند .برای الگوریتم شبکه عصبی حافظه کوتاه–بلند (LSTM)، استفاده از PCA منجر به بهبود قابل توجهی در عملکرد مدل شده است؛ به طوری که مقدار R^2 به ۰/۹۷ افزایش یافته و RMSE به ۵۱/۷۹ کاهش یافته است. این در حالی است که استفاده از ICA مقدار R^2 را به ۰/۹۱ و RMSE را به ۶۲/۷۵ محدود کرده است. این نتایج نشان می‌دهند که روش PCA در مقایسه با ICA دقت و کارایی بهتری را برای LSTM فراهم می‌کند. در مورد الگوریتم MLP (پرسپترون چندلایه)، مقادیر ارزیابی نیز عملکرد متفاوت روش‌ها را مشخص می‌کند. نتایج مربوط به الگوریتم SVM (ماشین بردار پشتیبانی) نیز نشان می‌دهد که مقدار R^2 به ۰/۹۴ رسیده است که توانایی بالای این روش را در توضیح تغییرات داده‌ها تأیید می‌کند. با این وجود، مقدار RMSE برابر با ۹۷/۲۱ و RRMSE برابر با ۰/۵۲ حاکی از خطای قابل توجه در مقایسه با مدل‌های بهینه‌شده LSTM و PCA می‌باشد. به‌طور کلی، نتایج جدول ۶ به وضوح تأکید می‌کند که استفاده از روش‌های کاهش بعد، به‌ویژه PCA، در بهبود دقت پیش‌بینی و کاهش خطای مدل‌های یادگیری عمیق بسیار مؤثر است. در تحلیل نهایی، PCA به عنوان بهترین روش کاهش بعد معرفی می‌شود، زیرا عملکرد بهتری نسبت به ICA در مدل‌های مختلف از خود نشان داده است.

شکل ۳ مقایسه‌ای بین مقادیر واقعی و پیش‌بینی‌شده توسط الگوریتم‌ها با استفاده از روش‌های کاهش بُعد PCA و ICA را نشان می‌دهند. در بخش اول، شکل‌های (a) تا (d) عملکرد الگوریتم‌های LSTM و MLP را با استفاده از روش‌های کاهش بُعد بررسی می‌کنند. شکل (a) مربوط به ترکیب PCA و LSTM است که مقدار R^2=۰/۹۷۴۵ دارد و نشان می‌دهد مدل توانسته است داده‌ها را با دقت بالایی پیش‌بینی کند. شکل (b) ترکیب ICA و LSTM را نشان می‌دهد که مقدار R^2=۰/۹۱۵۱ به دست آمده و اندکی پایین‌تر از مقدار مربوط به PCA است. در شکل (c)، ترکیب PCA و MLP با مقدار R^2=۰/۷۵۳۹ ارائه شده که در مقایسه با مدل LSTM دقت پایین‌تری دارد. در نهایت، شکل (d) مربوط به ترکیب ICA و MLP است که با مقدار R^2=۰/۶۵۸۹ پایین‌ترین دقت را در بین این چهار ترکیب به دست آورده است. در بخش دوم، شکل‌های (e) تا (h)، عملکرد درخت تصمیم و SVM را با استفاده از روش‌های کاهش بُعد PCA و ICA مورد ارزیابی قرار می‌دهند. شکل (e) ترکیب PCA و درخت تصمیم را نشان می‌دهد که مقدار R^2=۰/۸۲۷۴ بوده و این مدل را به‌عنوان یک مدل با دقت مناسب معرفی می‌کند. شکل (f) مربوط به ترکیب ICA و درخت تصمیم است که مقدار R^2=۰/۸۳۵ داشته و اندکی بهتر از PCA عمل کرده است. در نهایت، شکل (g) به ترکیب PCA و SVM اختصاص دارد که با R^2=۰/۹۱۶ نشان می‌دهد که مدل SVM با PCA دقت بسیار بالایی دارد. شکل (h) مربوط به ترکیب ICA و SVM است. مقدار R^2 برابر ۰/۸۳۲۳ است که اندکی پایین‌تر از PCA است.

نتیجه‌گیری و پیشنهادها

این مقاله به بررسی کارایی الگوریتم‌های یادگیری عمیق و روش‌های کاهش ابعاد در پیش‌بینی عملکرد محصول نیشکر پرداخته است. همچنین، روش پیشنهادی با کارهای تحقیقاتی پیشین مقایسه شد که توسط اولیویر و همکاران (2017) و سجارلو و همکاران (2021) انجام شده است. در این پژوهش‌ها، از الگوریتم‌های مختلف یادگیری ماشین و روش‌های کاهش بعد استفاده شده بود، اما نتایج پژوهش حاضر نشان می‌دهد که روش ترکیبی الگوریتم LSTM و کاهش بعد با تحلیل مؤلفه‌های اصلی (PCA) در پیش‌بینی عملکرد نیشکر نسبت

به سایر روش‌ها عملکرد بهتری داشته است. در تحلیل متغیرهای موثر، واریته محصول و هدایت الکتریکی خاک به‌عنوان مهم‌ترین متغیرهای مستقل و اساسی در هر دو روش کاهش بعد تحلیل مؤلفه‌های اصلی و تحلیل مؤلفه‌های مستقل شناسایی شده‌اند. در روش تحلیل مؤلفه‌های اصلی، متغیرهای نهایی انتخاب‌شده عبارت‌اند از واریته محصول، بافت خاک، نسبت سطح سمپاشی، هدایت الکتریکی خاک، زهکشی، و کود شیمیایی نیتروژن. در روش تحلیل مؤلفه‌های مستقل ، متغیرهای اصلی شامل واریته محصول، هدایت الکتریکی خاک، هدایت الکتریکی آب، سن گیاه، تعداد دفعات آبیاری، و بافت خاک هستند. نتایج نشان می‌دهد که استفاده از الگوریتم LSTM به همراه روش کاهش بعد PCA، باعث بهبود قابل توجهی در دقت پیش‌بینی عملکرد نیشکر شده است. به‌ویژه، LSTM با PCA موفق به کسب R^2 برابر با ۰/۹۷ و RMSE برابر با ۵۱/۷۹ شده است که نشان‌دهنده توانایی بالای این ترکیب در پیش‌بینی دقیق عملکرد محصول است. در مقایسه، استفاده از الگوریتم ICA منجر به کاهش دقت پیش‌بینی‌ها شده و به R^2 برابر با ۰/۹۱ و RMSE برابر با ۶۲/۷۵ انجامیده است. علاوه بر LSTM، روش‌های سنتی یادگیری ماشین مانند پرسپترون چندلایه و درخت تصمیم نیز عملکرد خوبی را نشان داده‌اند که تأکید می‌کند که این الگوریتم‌ها نیز می‌توانند در کنار روش‌های پیشرفته‌تر، نقش مؤثری در پیش‌بینی عملکرد محصولات کشاورزی ایفا کنند. نتایج به‌دست‌آمده از این تحقیق، می‌تواند به کشاورزان و محققان در بهینه‌سازی روش‌های کشت و مدیریت منابع کمک کند.

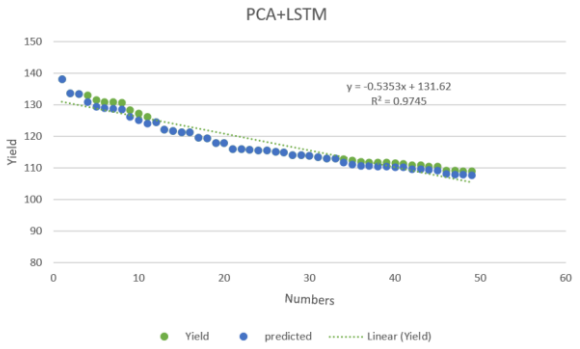

(a)

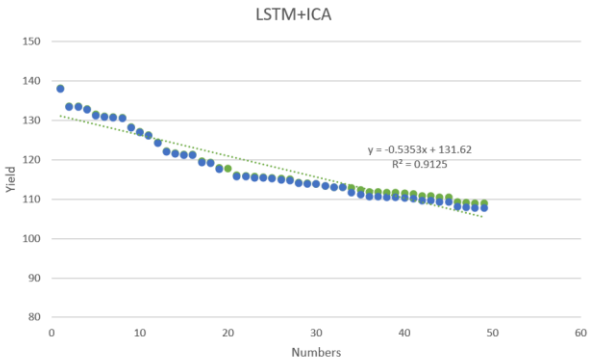

(b)

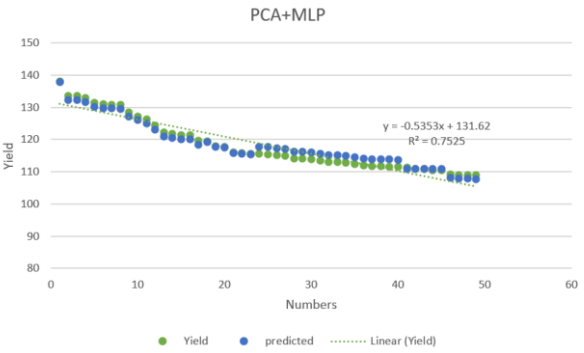

(c)

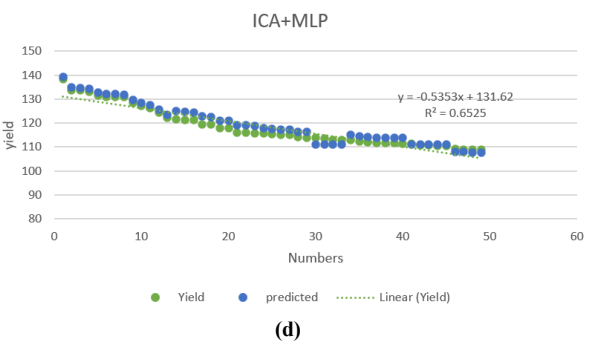

(d)

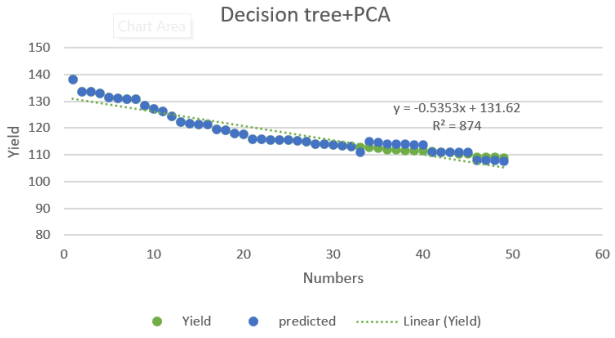

(e)

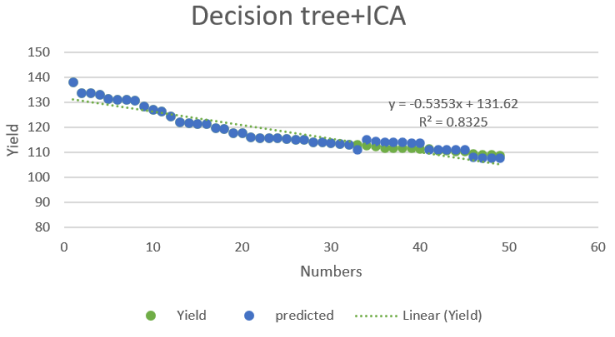

(f)

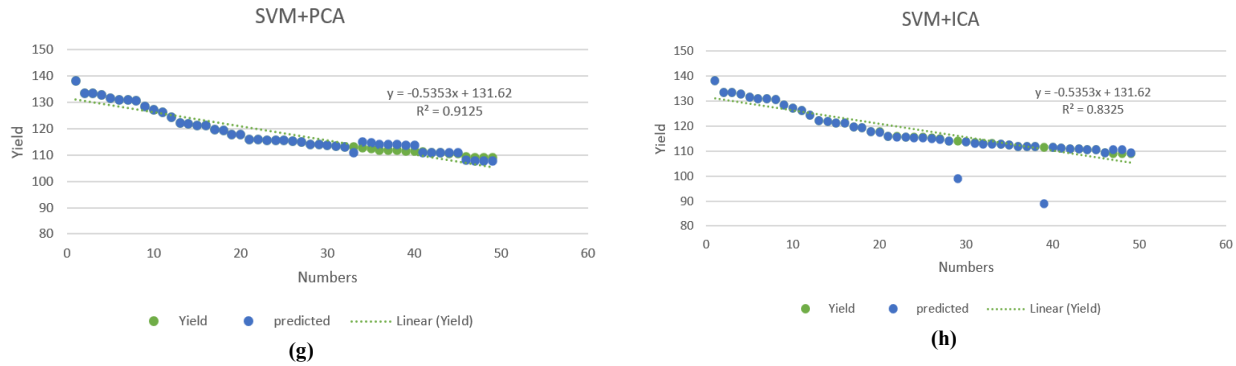

(g) (h)

شکل ۳ . نمودار مقایسه مقادیر واقعی و مقادیر پیش‌بینی شده توسط الگوریتم‌ها.

در نهایت، این مقاله برای اولین بار با استفاده از الگوریتم کاهش بعد ICA، عملکرد نیشکر را با دقت بالای ۹۰ درصد پیش‌بینی کرده است که این دستاورد می‌تواند به بهبود روش‌های پیش‌بینی و عارضه‌یابی عملکرد نیشکر کمک کند. با توجه به نتایج به‌دست‌آمده، مشخص می‌شود که ترکیب مناسب الگوریتم‌های یادگیری عمیق و روش‌های کاهش بعد می‌تواند به‌طور چشمگیری در بهبود دقت پیش‌بینی و درک بهتر از تأثیر عوامل مختلف بر عملکرد محصولات کشاورزی مؤثر باشد. برای گسترش این تحقیق، پیشنهاد می‌شود که چندین خط تحقیقاتی جدید را بررسی کرد. اولین پیشنهاد، ارزیابی و بهینه‌سازی مدل‌های یادگیری عمیق دیگر مانند شبکه‌های عصبی کانولوشنی (CNN) و شبکه‌های عصبی عمیق (DNN) برای مقایسه با نتایج به‌دست‌آمده از LSTM و MLP است. این مدل‌ها ممکن است توانایی‌های بیشتری در کشف الگوهای پیچیده‌تری در داده‌های نیشکر داشته باشند. پیشنهاد می‌شود که الگوریتم‌های کاهش بعد دیگری مانند t-SNE یا UMAP نیز به کار گرفته شوند تا عملکرد آن‌ها در مقایسه با PCA و ICA بررسی شود. این کار می‌تواند بینش‌های جدیدی درباره تأثیر روش‌های مختلف کاهش بعد بر دقت پیش‌بینی‌ها فراهم آورد. با توجه به پیشرفت‌های مستمر در یادگیری عمیق و تحلیل داده‌ها، کارهای آتی باید بر روی بهبود دقت پیش‌بینی، کاهش هزینه‌های محاسباتی و افزایش قابلیت تعمیم مدل‌ها به داده‌های جدید تمرکز کنند. این گام‌ها می‌توانند به بهبود کاربردهای عملی الگوریتم‌های یادگیری عمیق در کشاورزی و به‌ویژه در پیش‌بینی عملکرد محصولات کشاورزی مانند نیشکر کمک کنند.

سپاسگزاری

از حمایت‌های مالی معاونت پژوهشی و فناوری دانشگاه شهید چمران اهواز در قالب اعتبار پژوهانه به شماره SCU.AA1402.505 و همچنین از بخش تحقیقات و توسعه (R&D) کشت و صنعت نیشکر امیر کبیر در تهیه داده ها تشکر و قدردانی می‌گردد.

منابع

ادیب‌زاده، عبدالله، ذکی دیزجی، حسن، عقیلی ناطق، ناهید. (۱۳۹۹). امکان سنجی تشخیص واریته های مختلف نیشکر با تکنیک بینی‌الکترونیک در شربت نیشکر. مهندسی بیوسیستم ایران، ۵۱(۱)، ۱-۱۰. doi: 10.22059/ijbse.2019.287027.665209

ذکی دیزجی، حسن، بهرامی، هوشنگ، منجزی، نسیم، شیخ داودی، محمدجواد. (۱۳۹۸). مدل‌سازی متغیرهای موثر بر عملکرد نیشکر با استفاده از الگوریتم‌های درخت تصمیم‌گیری C5.0 و QUEST. ماشین های کشاورزی, ۹(۲), ۴۶۹-۴۸۴. doi: 10.22067/jam.v9i2.69712

ذکی دیزجی، حسن، منجزی، نسیم، شیخ داودی، محمدجواد. (۱۳۹۷). بررسی عوامل موثر بر میزان عملکرد تولید نیشکر با هدف افزایش تولید با استفاده از رهیافت داده‌کاوی. مهندسی بیوسیستم ایران, ۴۹(۳), ۵۰۱-۵۱۱. doi: 10.22059/ijbse.2018.248601.665021

ستاری، محمدتقی، شیرینی، کیمیا، جاویدان، سحر. (۱۴۰۳). ارزیابی کارائی روش‌های کاهش پارامترها در بهبود دقت مدل‌سازی شاخص کیفی آب در رودخانهٔ قزل اوزن با استفاده از الگوریتم‌های یادگیری ماشین. مدل سازی و مدیریت آب و خاک, ۴(۲), ۸۹-۱۰۴. doi: 10.22098/mmws.2023.12434.1241

طاهری حاجیوند، عادل، شیرینی، کیمیا، صمدی قره ورن، سینا. (۱۴۰۳). تشخیص علف های هرز در مزارع با استفاده از شبکه عصبی کانولوشنال بر اساس یادگیری عمیق. مهندسی زراعی, ۴۷(۱), ۱۲۹-۱۴۲. doi: 10.22055/agen.2024.45327.1688

REFERENCES

Adibzadeh, A., Zaki Dizaji, H., & Aghili Nategh, N. (2020). Feasibility of Detecting Sugarcane Varieties by

Electronic Nose Technique in Sugarcane Syrup. Iranian Journal of Biosystems Engineering, 51(1), 1-10. 10.22059/ijbse.2019.287027.665209. (in Persian).

Bazrafshan, O., Ehteram, M., Moshizi, Z. G., & Jamshidi, S. (2022). Evaluation and uncertainty assessment of wheat yield prediction by multilayer perceptron model with bayesian and copula bayesian approaches. Agricultural Water Management, 273: 107881. https://doi.org/10.1016/j.agwat.2022.107881

Bocca, F.F. and Rodrigues, L.H.A., 2016. The effect of tuning, feature engineering, and feature selection in data mining applied to rainfed sugarcane yield modelling. Computers and electronics in agriculture, 128, pp.67-76. https://doi.org/10.1016/j.compag.2016.08.015

Charoen-Ung, P., Mittrapiyanuruk, P. (2019). Sugarcane Yield Grade Prediction Using Random Forest with Forward Feature Selection and Hyper-parameter Tuning. In: Unger, H., Sodsee, S., Meesad, P. (eds) Recent Advances in Information and Communication Technology 2018. IC2IT 2018. Advances in Intelligent Systems and Computing, vol 769. Springer, Cham. https://doi.org/10.1007/978-3-319-93692-5_4

de Oliveira, M.P.G., Bocca, F.F. and Rodrigues, L.H.A., 2017. From spreadsheets to sugar content modeling: A data mining approach. Computers and Electronics in Agriculture, 132, pp.14-20. https://doi.org/10.1016/j.compag.2016.11.012

Daffertshofer, A., Lamoth, C.J., Meijer, O.G., & Beek, P.J. (2004). PCA in studying coordination and variability: a tutorial. Clinical biomechanics, 19(4), 415-428. doi:10.1016/j.clinbiomech.2004.01.005

Ed-Daoudi, R., Alaoui, A., Ettaki, B., & Zerouaoui, J. (2023). Improving Crop Yield Predictions in Morocco Using Machine Learning Algorithms. Journal of Ecological Engineering, 24(6) :392-400. https://doi.org/10.12911/22998993/162769

Jhajharia, K., Mathur, P., Jain, S., and Nijhawan, S. (2023). Crop yield prediction using machine learning and deep learning techniques. Procedia Computer Science, 218: 406-417. https://doi.org/10.1016/j.procs.2023.01.023

Sarijaloo, F. B., Porta, M., Taslimi, B., and Pardalos, P. M. (2021). Yield performance estimation of corn hybrids using machine learning algorithms. Artificial Intelligence in Agriculture, 5: 82-89. https://doi.org/10.1016/j.aiia.2021.05.001

Sattari, M. T., shirini, K., & javidan, S. (2024). Evaluating the efficiency of dimensionality reduction methods in improving the accuracy of water quality index modeling in Qizil-Uzen River using machine learning algorithms. Water and Soil Management and Modelling, 4(2), 89-104. doi: 10.22098/mmws.2023.12434.1241. (in Persian).

Shirini, K., Kordan, M.B. & Gharehveran, S.S. (2025) Impact of learning rate and epochs on LSTM model performance: a study of chlorophyll-a concentrations in the Marmara Sea. Journal of Supercomputing, 81, 265. https://doi.org/10.1007/s11227-024-06806-2

Taherihajivand, A., shirini, K., & samadi Gharehveran, S. (2024). Weed detection in fields using convolutional neural network based on deep learning. Agricultural Engineering, 47(1), 129-142. doi: 10.22055/agen.2024.45327.1688. (in Persian).

Yu, Y., Si, X., Hu, C., & Zhang, J. (2019). A review of recurrent neural networks: LSTM cells and network architectures. Neural computation, 31(7), 1235-1270. https://doi.org/10.1162/neco_a_01199

Zaki Dizaji, H., Bahrami, H., Monjezi, N., & Sheikhdavoodi, M. J. (2019). Modeling of the Variables that Influence Sugarcane Yield using C5.0 and QUEST Decision Tree Algorithms. Journal of Agricultural Machinery, 9(2), 469-484. doi: 10.22067/jam.v9i2.69712. (in Persian).

Zaki Dizaji, H., Monjezi, N., & Sheikhdavoodi, J. (2018). Investigating Effective Factors on Sugarcane Production Performance to Increase the Production of Sugarcane Using Data Mining. Iranian Journal of Biosystems Engineering, 49(3), 501-511. doi: 10.22059/ijbse.2018.248601.665021. (in Persian).

Zaki Dizaji, H., Adibzadeh, A. & Aghili Nategh, N. (2021). Application of E-nose technique to predict sugarcane syrup quality based on purity and refined sugar percentage. Journal of Food Science and Technology. 58, 4149–4156. https://doi.org/10.1007/s13197-020-04879-4