



A Novel Approach for Manning's Roughness Coefficient Estimation in Furrow Irrigation Phases Using Image Processing and Machine Learning

Hadi Rezaei Rad¹ | Hamed Ebrahimian² | Abdolmajid Liaghat³ | Mahmoud Omid⁴

1. Corresponding Author. Nuclear Agriculture Research School, Nuclear Science and Technology Research Institute (NSTRI), Karaj, Iran. E-mail: Hadi.rezaii@ut.ac.ir

2. Department of Irrigation & Reclamation Engineering, College of Agriculture and Natural Resources, University of Tehran, Karaj, Iran. E-mail: Ebrahimian@ut.ac.ir

3. Department of Irrigation & Reclamation Engineering, College of Agriculture and Natural Resources, University of Tehran, Karaj, Iran. E-mail: Liaghat@ut.ac.ir

4. Department of Agricultural Machinery Engineering, College of Agriculture and Natural Resources, University of Tehran, Karaj, Iran. Email: omid@ut.ac.ir

Article Info

ABSTRACT

Article type: Research Article

Article history:

Received: Dec. 26, 2024

Revised: Feb. 1, 2025

Accepted: Feb. 25, 2024

Published online: June. 2025

Keywords:

Manning Roughness Coefficient,
Furrow Irrigation,
Image Processing,
Machine Learning,
Advance Phase,
Storage Phase.

This study investigates the effectiveness of combining image processing techniques and machine learning methods to estimate the Manning roughness coefficient in furrow irrigation during the advance and storage phases. For this purpose, various input discharge values, irrigation cycles, phases, and soil texture types were considered. Images of the furrow surface were captured before and after each irrigation event, and the roughness coefficient in the advance and storage phases was estimated using the SIPAR_ID model and the Manning equation, respectively. Based on this data, an algorithm was developed that integrated image processing techniques with machine learning methods and was tested in three different scenarios. The results showed that the algorithm, when using either images or field data separately, could not be properly trained and had very low accuracy, as some features were only accessible from images and others from field data. The results also revealed that the algorithm, when combining images with certain field data such as flow cross-section and discharge, performed very well in estimating the Manning roughness coefficient during both the advance and storage phases. In this scenario, the Random Forest and CART methods, with precision, recall, and F1-score values of 95%, 96%, and 95% respectively, outperformed other machine learning methods in estimating the Manning roughness coefficient. Finally, it was suggested that similar studies be conducted considering other factors affecting roughness under different conditions, and that the algorithm be retrained accordingly to improve its performance and comprehensiveness.

Cite this article: Rezaei Rad, H., Ebrahimian H., Liaghat, A.M., & Omid, M. (2025) A Novel Approach for Manning's Roughness Coefficient Estimation in Furrow Irrigation Phases Using Image Processing and Machine Learning, *Iranian Journal of Soil and Water Research*, 56 (4), 1011-1039. <https://doi.org/10.22059/ijswr.2025.387670.669860>

© The Author(s).

Publisher: The University of Tehran Press.

DOI: <https://doi.org/10.22059/ijswr.2025.387670.669860>





EXTENDED ABSTRACT

Introduction

Efficient water management in furrow irrigation is significantly influenced by various parameters, such as soil texture, furrow geometry, slope, and especially Manning's roughness coefficient. Accurate estimation of this coefficient is essential for simulating water flow. However, its temporal and spatial variability presents challenges, as it is influenced by factors like water infiltration into the soil, changes in soil composition, and the presence of vegetation. Traditional methods often estimate roughness with limited accuracy, overlooking these temporal and spatial variations and assuming the coefficient remains constant during irrigation. Such assumptions can lead to significant errors in flow simulation in surface irrigation. In this study, we propose an integrated approach that combines image processing and machine learning methods to provide accurate and rapid estimation of Manning's roughness coefficient in both the advance and storage stages.

Materials and Methods

In this study, we developed an algorithm that combines image processing techniques and machine learning methods, including Logistic Regression (LR), Linear Discriminant Analysis (LDA), k-Nearest Neighbor (KNN), Decision Tree (CART), Random Forest (RF), Support Vector Machine (SVM), and Multilayer Perceptron (MLP), to estimate the Manning roughness coefficient in furrow irrigation. This algorithm is specifically designed for the advance and storage phases of irrigation in bare furrows. The accuracy of Manning roughness coefficient estimation was evaluated using the developed algorithm under three scenarios: (i) using image data alone, (ii) using only field data, and (iii) combining both image and field data.

To achieve this, six different inflow rates were tested across two categories, low and high flow, with average flow rates of 0.27 and 0.53 L/s, respectively. Additional parameters included three irrigation events (first to third), two irrigation phases (advance and storage), two irrigation intervals (5 and 10 days), and two soil textures. Images of the furrow surface were taken from a height of 100 cm above the soil under controlled lighting conditions before and after each irrigation event. The Manning roughness coefficient was determined for the advance and storage phases using the SIPAR_ID model and Manning equation, respectively.

Results and Discussion

In the first step, Manning's roughness coefficient values were determined for the advance and storage phases, yielding accurate results that supported their use in the algorithm. In terms of numerical accuracy, the model's R^2 values for the advance phase ranged between 0.91 and 1.0, with a mean of 0.995, indicating strong predictive power. The root mean square error (RMSE) for this phase was between 0.2 and 2.6 minutes, with an average of 0.36 minutes, while the relative error (RE) remained consistently low, below 4.24%. For the storage phase, Manning's roughness coefficient values averaged 0.073 in field E and 0.041 in field F, demonstrating a decline in roughness as successive irrigation events smoothed the soil surface. These results, which aligned with physical observations, confirmed the high accuracy of the initial estimates and justified their use in the developed algorithm. Following this validation, the performance of the algorithm was evaluated under three scenarios. The hybrid approach that integrated both image and field data outperformed the other two scenarios, achieving the highest accuracy in estimating Manning's roughness coefficient. Using only image data resulted in lower accuracy, with Random Forest achieving an accuracy of 60%, recall of 60%, and precision of 55%, underscoring the necessity of combining data sources. In the hybrid scenario, Random Forest provided the best classification results, achieving a precision of 95%, recall of 96%, and F1-score of 95%. The CART model also showed competitive performance, with accuracy and precision metrics closely following those of Random Forest. These findings indicate that the combined approach of image and field data provides a more reliable and precise estimation of Manning's roughness coefficient across different irrigation conditions and phases.

Conclusion

This study introduces a novel method for estimating the Manning roughness coefficient in furrow irrigation systems by combining image processing and machine learning techniques. This approach provides a more efficient and precise solution, particularly in furrows without vegetation. Future work should include additional parameters, such as lighting conditions, image angles, as well as various hydraulic and field conditions, to refine the algorithm and enhance its applicability under diverse real-world situations. This research advances the development of automated, precise estimation methods for improved irrigation

management and water use efficiency.

Author Contributions

HRR, HE, AL, and MO conceptualized the research topic and formulated the objectives and methodology of the research. HRR carried out the field experiments as well as the data curation of the research work. HRR and MO developed the algorithm. HRR, HE, MO, and AL participated in the writing of the manuscript. All the authors read and approved the final manuscript for publication.

All authors contributed equally to the conceptualization of the article and writing of the original and subsequent drafts.

Data Availability Statement

All data generated and analyzed during this study are included in this article.

Acknowledgements

The authors would like to acknowledge the financial support of University of Tehran Science and Technology Park for this research under grant number 5888656.

Ethical considerations

The study was approved by the Ethics Committee of the University of ABCD (Ethical code: IR.UT.RES.2024.500). The authors avoided data fabrication, falsification, plagiarism, and misconduct.

Conflict of interest

The author declares no conflict of interest.

رویکردی نوین در تخمین ضریب زبری مانینگ در فازهای مختلف آبیاری جویچه‌ای با بهره‌گیری از پردازش تصویر و یادگیری ماشین

هادی رضایی راد^۱ | حامد ابراهیمیان^۲ | عبدالمجید لیاقت^۳ | محمود امید^۴

۱. پژوهشکده کشاورزی هسته‌ای، پژوهشگاه علوم و فنون هسته‌ای، سازمان انرژی اتمی، کرج، ایران. رایانامه: Hadi.rezaii@ut.ac.ir

۲. گروه مهندسی آبیاری و آبادانی، دانشکده‌گان کشاورزی و منابع طبیعی، دانشگاه تهران، کرج، ایران. رایانامه: Ebrahimian@ut.ac.ir

۳. گروه مهندسی آبیاری و آبادانی، دانشکده‌گان کشاورزی و منابع طبیعی، دانشگاه تهران، کرج، ایران. رایانامه: Aliaghat@ut.ac.ir

۴. گروه مهندسی ماشین‌های کشاورزی، دانشکده‌گان کشاورزی و منابع طبیعی، دانشگاه تهران، کرج، ایران. رایانامه: Omid@ut.ac.ir

چکیده

اطلاعات مقاله

این تحقیق به بررسی کارایی استفاده تلفیقی از تکنیک‌های پردازش تصویر و روش‌های یادگیری ماشین برای تخمین ضریب زبری مانینگ در آبیاری جویچه‌ای در فازهای پیشروی و ذخیره پرداخته است. برای این منظور، مقادیر مختلف دبی ورودی، نوبت، مرحله و دوره‌های متفاوت آبیاری در دو نوع بافت خاک در نظر گرفته شد. تصاویری از سطح جویچه‌ها قبل و بعد از هر آبیاری ثبت گردید و ضریب زبری در فازهای پیشروی و ذخیره به ترتیب با استفاده از مدل SIPAR_ID و معادله مانینگ تخمین زده شد. سپس با استفاده از این داده‌ها، الگوریتمی بر مبنای استفاده تلفیقی از تکنیک‌های پردازش تصویر و روش‌های یادگیری ماشین در سه سناریوی مختلف توسعه یافت. نتایج نشان داد که الگوریتم با استفاده از تصاویر یا داده‌های مزرعه‌ای به صورت مجزا نمی‌تواند به درستی آموزش ببیند و دقت بسیار پایینی دارد؛ چراکه برخی از ویژگی‌ها صرفاً از تصاویر و برخی دیگر از داده‌های مزرعه‌ای قابل دسترسی هستند. نتایج همچنین بیانگر دقت بسیار مناسب الگوریتم در تخمین ضریب زبری مانینگ در فازهای پیشروی و ذخیره با استفاده از تلفیق تصاویر و برخی داده‌های مزرعه‌ای نظیر سطح مقطع جریان و دبی، بود. در سناریوی منتخب، روش جنگل تصادفی و CART با شاخص‌های recall، precision و F1-score برابر با ۹۵، ۹۶ و ۹۵ درصد، بهترین عملکرد را در تخمین ضریب زبری مانینگ نسبت به دیگر روش‌های یادگیری ماشین داشتند. در نهایت پیشنهاد شد که تحقیقات مشابهی با در نظر گرفتن سایر عوامل مؤثر بر زبری (نظیر پوشش گیاهی) و در شرایط متفاوت مزرعه‌ای (نظیر بافت و ساختمان خاک متفاوت) صورت پذیرد و الگوریتم متناسب با آن مجدداً آموزش ببیند تا کارایی و جامعیت آن ارتقا یابد.

نوع مقاله: مقاله پژوهشی

تاریخ دریافت: ۱۴۰۳/۱۰/۰۶

تاریخ بازنگری: ۱۴۰۳/۱۱/۱۳

تاریخ پذیرش: ۱۴۰۳/۱۲/۰۷

تاریخ انتشار: تیر ۱۴۰۴

واژه‌های کلیدی:

ضریب

زبری مانینگ،

پردازش تصویر،

یادگیری ماشین،

فاز پیشروی و ذخیره.

استناد: رضایی راد؛ هادی، ابراهیمیان؛ حامد، لیاقت؛ عبدالمجید، امید؛ محمود، (۱۴۰۴) رویکردی نوین در تخمین ضریب زبری مانینگ در فازهای مختلف آبیاری جویچه‌ای با بهره‌گیری از پردازش تصویر و یادگیری ماشین، مجله تحقیقات آب و خاک ایران، ۵۶ (۴)، ۱۰۱۱-۱۰۳۹.



<https://doi.org/10.22059/ijswr.2025.387670.669860>

© نویسنده‌گان.

ناشر: مؤسسه انتشارات دانشگاه تهران.

DOI: <https://doi.org/10.22059/ijswr.2025.387670.669860>

مقدمه

کاربرد بهینه و توزیع مناسب آب در آبیاری جویچه‌ای به پارامترهایی نظیر جریان ورودی، بافت خاک، شیب جویچه، نفوذپذیری خاک، پوشش گیاهی، ضریب زبری و مدیریت آبیاری بستگی دارد (Amiri et al., 2016) که از این بین پارامترهای نفوذ و ضریب زبری با توجه به تغییرات مکانی و زمانی خاک و کاربرد فراوان آن در مدل‌های شبیه سازی آبیاری سطحی، از اهمیت ویژه‌ای برخوردار اند (Bautista et al., 2018; Miao et al., 2015; Gillies & Smith, 2015; Schlegel, 2017). برای تفسیر زبری از ضرایبی که در معادلات مختلف مثل شری، مانینگ، داری و غیره وجود دارد می‌توان استفاده نمود اما سهولت کاربرد و دقت قابل قبول در استفاده از معادله مانینگ، موجب انتخاب این معادله به عنوان معادله مرسوم در مجاری روباز و آبیاری سطحی توسط مهندسين هیدرولیک گردیده است (عباسی و ابراهیمیان، ۱۴۰۲؛ عباسی، ۱۳۹۱).

ضریب زبری مانینگ (n) شدت افت انرژی را نشان می‌دهد و بیان‌کننده نیروهای مقاوم در مقابل جریان بوده و اعتقاد بر این است که کلیه عوامل مقاوم بر روی جریان را در خود دارد (Sepaskhah & Bondar, 2002). تعیین ضریب زبری در مزارع آبیاری خصوصاً مزارع تحت کشت آبیاری جویچه‌ای (که رایج ترین سیستم آبیاری سطحی در دنیا است) به سادگی تعیین در بسترهای سخت و لخت مثل کانال‌های آبیاری نیست (Maheshwari, 1992) چراکه نفوذ آب در خاک از یک طرف و تغییرات ویژگی‌های خاک در نقاط مختلف مزرعه از طرف دیگر سبب می‌شود تا ضریب زبری تغییرات مکانی و زمانی زیادی داشته باشد (Mailapalli et al., 2008). علاوه بر این، با توجه به اینکه مقدار دبی در جویچه‌ها کم است، تغییرات در عمق و سرعت آب در جویچه‌ها زیاد شده و تعیین ضریب زبری را دشوارتر می‌سازد (Li & Zhang, 2001; Sedaghatdoost & Ebrahimian, 2015). تخمین دقیق ضریب زبری زمانی به وقوع می‌پیوندد که شناخت کاملی از پارامترهای مؤثر بر ضریب زبری وجود داشته باشد تا امکان محاسبه مقدار زبری فراهم گردد. ضریب زبری در مزارع آبیاری به طور مستقیم یا غیر مستقیم تحت تأثیر عوامل مختلفی از جمله بافت خاک، نوع و تراکم پوشش گیاهی، مرحله رشد گیاه، روش و نوبت آبیاری، دبی و عمق جریان، شیب مزرعه، ناهمواری‌های موجود در مسیر جریان، مقدار رسوبات و غیره قرار دارد (Díaz, 2005; Maheshwari, 1992; Mauricio et al., 2015; Mwendera & Feyen, 1992; Segeren & Trout, 1991; Sepaskhah & Bondar, 2002; Trout, 1992) که تعیین و تخمین میزان تأثیر همه این عوامل در ضریب زبری بسیار دشوار و شاید غیر ممکن است. اما می‌بایست با استفاده از روش‌های مختلف، سعی شود تا این ضریب با کم‌ترین خطا و بیش‌ترین دقت و با در نظر گرفتن اکثر پارامترهای مؤثر بر آن، تخمین زده شود. چرا که اگر مقدار ضریب زبری مانینگ به درستی تخمین زده نشود، می‌تواند منجر به بروز خطاهای قابل توجهی در میزان دبی ورودی و شبیه سازی هیدرولیک جریان آب در آبیاری جویچه‌ای گردد (Clemmens et al., 2001).

پیشینه پژوهش

محققین با استفاده از روش‌های مختلف تحقیقات بسیاری را برای تخمین ضریب زبری مانینگ انجام داده اند (Amiri et al., 2016; Bautista & Schlegel, 2017; Capra & Scicolone, 2002; Dong et al., 2018; Esfandiari & Maheshwari, 1998; Kamali et al., 2018; Mailapalli et al., 2008; Mauricio et al., 2015; Mazarei et al., 2021; Ramezani Etedali et al., 2011; Seyedzadeh et al., 2019) که برخی از این تحقیقات منجر به توسعه مدل‌هایی نظیر SIPAR_ID, EVALUE و WinSRFR برای تخمین ضریب زبری مانینگ، شده است (Rodríguez & Martos, 2010; Strelkoff et al., 1999; Walker, 2003). برخی دیگر با استفاده از این مدل‌ها مقادیری برای ضریب زبری مانینگ در شرایط مختلف مزرعه‌ای ارائه نموده اند (Kamali et al., 2019; Seyedzadeh et al., 2011, 2012; W.-B. Nie et al., 2018; Ramezani Etedali et al., 2011, 2012) و در دیگر تحقیقات ضریب زبری با استفاده از روش‌های تحلیلی یا استفاده مستقیم از معادله مانینگ تخمین زده شده است (Harun-ur-Rashid, 1990; Li & Zhang, 2001; Mailapalli et al., 2008). بررسی این تحقیقات نشان می‌دهد، تخمین ضریب زبری مانینگ نیازمند جمع‌آوری داده‌های مختلف مزرعه‌ای است که تخمین زبری را زمان بر و پرهزینه می‌کند. این موضوع سبب شده تا مقدار این ضریب غالباً به صورت تخمینی و با استفاده از جداول و روابط تجربی و البته ثابت فرض شود و در بیش‌تر مدل‌های شبیه‌سازی به عنوان داده ورودی در نظر گرفته شود. این در حالی است که مقدار زبری طی یک رخداد آبیاری به دلایل مختلف تغییر می‌کند. این پیچیدگی در تخمین سبب شده تا روش‌های مختلفی طی سالیان اخیر توسط محققین ارائه گردد؛ اما یافتن روشی سریع و با دقتی نسبتاً مناسب و از طرف دیگر جامع و قابل توصیه بودن این روش در سایر مزارع همچنان نیاز به بررسی و انجام مطالعات مختلف دارد.

سیستم‌های بینایی ماشین که از تکنیک‌های پردازش تصویر و یادگیری ماشین استفاده می‌کنند، می‌توانند یک جایگزین امیدوارکننده



باشند. این سیستم‌ها به طور گسترده در صنایع مختلف استفاده می‌شوند و به تدریج در علوم کشاورزی نیز کاربرد فراوان یافته‌اند (Brosnan & Sun, 2004). در این سیستم‌ها، ابتدا ویژگی‌های مختلفی از تصاویر با استفاده از تکنیک‌های پردازش تصویر استخراج می‌شود. در مرحله بعد، با استفاده از روش‌های یادگیری ماشین (مانند: رگرسیون لجستیک (LR) (Berkson, 1944)، تحلیل تشخیص خطی (LDA) (Blei et al., 2003)، K-نزدیک‌ترین همسایه (KNN) (Cover & Hart, 1967)، درخت تصمیم (CART) (Breiman et al., 1984)، جنگل تصادفی (RF) (Breiman, 1984)، ماشین بردار پشتیبان (SVM) (Boser et al., 1992)، شبکه‌های عصبی چندلایه (Rumelhart & McClelland, 1986) (MLP) و بیز ساده (NB Gaussian) (Friedman et al., 1997)، یک رابطه بین این ویژگی‌ها و مقادیر پارامتر مورد بررسی ایجاد می‌شود و بدین ترتیب امکان تخمین پارامتر مورد نظر بر اساس رابطه استخراج‌شده فراهم می‌شود.

این تکنیک‌ها امکان استخراج اطلاعات مفیدی مانند: اندازه و تعداد کلوخه‌ها (Rahimi-Ajdadi et al., 2016)، میزان رطوبت خاک سطحی و نفوذ آب در خاک (Adab et al., 2020; Angelaki et al., 2018; Rahimi-ajdadi et al., 2018; Taneja et al., 2021)، وجود یا عدم وجود گیاه در بستر (Ansari et al., 2021; Sabzi et al., 2017; Teimouri et al., 2018)، شکاف‌های خاک (Gilliot et al., 2017; Peng et al., 2006; Riegler-Nurscher et al., 2019; Sauzet et al., 2017; Shit et al., 2015)، مشخصات فیزیکی و شیمیایی خاک (Chung et al., 2012; Kumar et al., 2014; Sudarsan et al., 2016)، زبری سطح خاک (Gilliot et al., 2017; Riegler-Nurscher et al., 2019) و غیره را فراهم می‌کنند. با توجه به موفقیت ترکیب تکنیک‌های یادگیری ماشین و پردازش تصویر در تشخیص اندازه و تعداد کلوخه‌ها، نوع خاک، زبری سطح و سایر ویژگی‌های مرتبط، به احتمال زیاد این تکنیک‌ها نیز می‌توانند به طور موثری در تخمین ضریب زبری مانینگ به کار روند. این امر به ویژه از آن جهت مهم است که بسیاری از این پارامترها، به صورت مستقیم یا غیرمستقیم، بر ضریب زبری مانینگ تأثیر می‌گذارند.

در پاسخ به پیچیدگی تخمین ضریب زبری مانینگ، این تحقیق یک رویکرد نوین پیشنهاد می‌کند که از تکنیک‌های پردازش تصویر و یادگیری ماشین برای تخمین ضریب زبری مانینگ در آبیاری جویچه و در فازهای پیشروی و ذخیره، استفاده می‌کند. برخلاف روش‌های قدیمی که زمان‌بر، پرهزینه و نیازمند تخصص ویژه بودند، این رویکرد سریع‌تر، مقرون‌به‌صرفه‌تر و تکرارپذیر است. روش پیشنهادی به ورودی‌هایی مانند تصاویر سطح خاک و برخی پارامترهای هیدرولیکی نیاز دارد که پس از توسعه کامل (با استفاده از جمع‌آوری داده‌های مختلف در شرایط گوناگون هیدرولیکی و مزرعه‌ای)، برای کاربرانی با سطوح مختلف تخصص قابل دسترسی خواهد بود. با استفاده از تصاویر و الگوریتمی پیشرفته، این روش چارچوب دقیق‌تر و انعطاف‌پذیرتری برای پیش‌بینی تغییرات زبری ارائه می‌دهد و به شکاف‌های موجود در روش‌های قبلی پاسخ می‌دهد.

این تحقیق فرض می‌کند که استفاده هم‌زمان از تکنیک‌های پردازش تصویر و یادگیری ماشین می‌تواند ضریب زبری مانینگ را در آبیاری جویچه‌ای در فازهای پیشروی و ذخیره به طور دقیق تخمین زند. این چنین فرض شده است که ضریب زبری مانینگ می‌تواند در فاز ذخیره به صورت مستقیم توسط معادله مانینگ و در فاز پیشروی با استفاده از مدل SIPAR_ID (با توجه به اینکه این مدل از داده‌های سرعت ورودی، پیشروی جریان و عمق جریان در یک نقطه مشخص و در بازه‌های زمانی متفاوت برای تخمین پارامترهای نفوذ و ضریب زبری مانینگ استفاده می‌کند (Rodríguez & Martos, 2010))، با بالاترین دقت ممکن تخمین زده شود. هدف اصلی این مطالعه، ارزیابی عملکرد روش پیشنهادی در تخمین ضریب زبری مانینگ در آبیاری جویچه‌ای در هر دو فاز پیشروی و ذخیره بود. برای ساده‌سازی فرآیند جمع‌آوری داده‌ها و آموزش الگوریتم، برخی متغیرها مانند پوشش گیاهی که می‌توانستند جمع‌آوری داده‌ها را پیچیده کنند و عواملی نظیر شرایط نوری متغیر در طول تصویربرداری، حذف شدند. همچنین به منظور ساده‌سازی، مقادیر پیوسته ضریب زبری مانینگ، کلاس بندی (طبقه بندی) شدند. بنابراین، جویچه‌های خالی و بدون پوشش گیاهی تحت شرایط نوری یکنواخت برای تحلیل مورد استفاده قرار گرفتند. در این مطالعه، بر ارزیابی عملکرد روش‌های پردازش تصویر و یادگیری ماشین با استفاده از تصاویر برداشت شده از سطح جویچه‌ها و برخی پارامترهای هیدرولیکی و مزرعه‌ای به صورت جداگانه و یا ترکیبی از آن‌ها تمرکز شد. بدین منظور سناریوهای مختلفی (سناریوها شامل ترکیب‌های مختلفی از داده‌های ورودی الگوریتم بودند) در نظر گرفته شد و کارایی روش‌های مختلف یادگیری ماشین که شامل: LR، LDA، KNN، CART، RF، SVM، MLP و NB Gaussian بودند، در هریک از این سناریوها مورد ارزیابی قرار گرفت.

مواد و روش‌ها

مشخصات محل و اجرای طرح

این تحقیق در مزرعه آزمایشی پردیس کشاورزی و منابع طبیعی دانشگاه تهران واقع در شهر کرج به مختصات $50^{\circ}57'30.2''E$ و $35^{\circ}48'18.5''N$ و با میانگین بارش سالانه ۲۵۱ میلی متر، انجام شد. در این مزرعه دو محل با بافت خاک متفاوت انتخاب شد. مزرعه اول که سال‌ها مورد بهره‌برداری قرار گرفته بود، F و مزرعه دوم که چندین سال تحت کشت نبوده، E نام گذاری شد و آزمایشات در هر دو محل انجام شد. ویژگی‌های خاک منطقه مورد مطالعه که شامل بافت خاک، شوری و اسیدیته بود، برای همه جویچه‌ها تعیین شد و میانگین آن در جدول (۱) ارائه گردید.

جدول ۱. مشخصات فیزیکی و شیمیایی خاک مزارع مورد بررسی*

نام مزرعه	عمق (متر)	بافت خاک	EC (dS/m)	pH	FC (%)	PWP (%)	چگالی ظاهری (g/cm ³)
F	۰-۰/۲	لوم رسی	۱/۵۸	۷/۲۳	۱۸/۲	۸/۷	۱/۵۰
	۰/۲-۰/۴	لوم رسی	۱/۰۳	۷/۳۷	۱۷/۵	۸/۱	۱/۴۵
	۰/۴-۰/۶	لوم شنی	۰/۹۳	۷/۱۱	۱۴/۲	۶/۰	۱/۴۷
E	۰-۰/۲	لوم رسی سیلتی	۱/۶۳	۷/۲۰	۱۷/۲	۸/۰	۱/۵۱
	۰/۲-۰/۴	لوم رسی سیلتی	۱/۲۳	۷/۲۵	۱۵/۵	۶/۹	۱/۴۸
	۰/۴-۰/۶	لوم رسی شنی	۰/۹۰	۷/۲۳	۱۵/۰	۶/۶	۱/۴۹

*. در مزرعه و در هر عمق ۳ نمونه تهیه شد و پارامترهای مد نظر تعیین و میانگین آن گزارش گردید.

EC: هدایت الکتریکی خاک (شوری)، pH: اسیدیته خاک، FC و PWP: نقاط رطوبتی خاک (درصد رطوبت وزنی)

تیمارهای مورد بررسی

در نظر گرفتن هم‌زمان تمامی پارامترهای مؤثر بر ضریب زبری در گام نخست و در یک تحقیق بسیار دشوار و تا حدود زیادی غیرممکن است؛ لذا در این تحقیق صرفاً اثر دبی، رطوبت خاک قبل از آبیاری، رخدادهای و فازهای آبیاری مختلف بر ضریب زبری در نظر گرفته شد تا کارایی بینایی ماشین در تخمین ضریب زبری مانینگ در آبیاری جویچه‌ای مورد بررسی قرار گیرد. بدین منظور، مجموعه‌ای از دبی‌های ورودی مختلف در دو دسته دبی ورودی کم (به طور متوسط ۰/۲۷ لیتر بر ثانیه) و زیاد (به طور متوسط ۰/۵۳ لیتر بر ثانیه)، دو تیمار رطوبت قبل از آبیاری (دور آبیاری ۵ و ۱۰ روزه)، سه رخداد آبیاری متوالی (آبیاری اول تا سوم) و فازهای پیشروی و ذخیره، در دو مزرعه با بافت خاک متفاوت در نظر گرفته شد.

در مزرعه E، سه دبی ورودی کم و سه دبی ورودی بالا برای هر یک از دوره‌های آبیاری ۵ و ۱۰ روزه، در رخدادهای متوالی آبیاری اعمال شد. آزمایش‌های مشابهی نیز در مزرعه F انجام شد. اما از آنجا که الگوریتم نیاز به داده‌های بیشتری برای یادگیری داشت، در دور آبیاری ۱۰ روزه مزرعه F، به جای سه دبی ورودی کم و سه دبی ورودی بالا، شش دبی ورودی کم (میانگین ۰/۲۷ لیتر بر ثانیه) و شش دبی ورودی بالا (میانگین ۰/۵۷ لیتر بر ثانیه) در نظر گرفته شد. به دلیل زمان‌بر و پرهزینه بودن جمع‌آوری داده‌ها، این افزایش داده‌ها در مزرعه E اعمال نشد. در مجموع، ۹۰ جویچه در سه رویداد متوالی بررسی شدند که شامل ۱۸ جویچه در مزرعه F و ۱۲ جویچه در مزرعه E بود. لازم به ذکر است که در هر یک از این آزمایش‌ها، فازهای پیشروی و ذخیره به صورت جداگانه مورد بررسی قرار گرفتند.

داده برداری‌های مزرعه ای

در ابتدای مزرعه، مخزنی به حجم ۲۰۰۰ لیتر به منظور کاهش نوسانات فشار آب قرار داده شد و آب توسط لوله‌های پلی اتیلن به ابتدای محل نمونه برداری انتقال یافت. در هر دو زمین، جویچه‌هایی به عرض ۷۵ سانتی‌متر و طول ۲۰ متر (طول تا حد ممکن کم در نظر گرفته شد تا عکس‌های برداشت شده از سطح جویچه نماینده مناسبی از وضعیت کلی جویچه باشند) ایجاد شد. در این جویچه‌ها، برای اندازه گیری پیشروی و پسروی جریان، ۹ میخ به فاصله ۲ متر از یکدیگر در زمین نصب شد. به منظور اندازه‌گیری دبی ورودی و خروجی، فلوم WSC تیپ ۲ در ابتدا و انتهای هر جویچه نصب شد و عمق آب در این دو فلوم در یک ساعت اول (که تقریباً سرعت نفوذ آب در خاک ثابت می‌شود) هر ۵ دقیقه و پس از آن تا انتهای آبیاری هر ۱۰ دقیقه اندازه‌گیری شد. در طول جویچه‌ها ۴ خط کش به فاصله ۴ متر از هم به منظور اندازه‌گیری عمق آب در مدت زمان آبیاری، نصب و عمق آب قرائت شد. زمان آبیاری با توجه به عدم حضور گیاه، مشاهدات مزرعه‌ای و میزان نفوذ آب در خاک، در تمام جویچه‌ها تقریباً ۱۸۰ دقیقه در نظر گرفته شد. با توجه به اینکه برای جویچه‌هایی با طول بیش

از ۱۲٫۲ متر (۴۰ فوت)، شیب بستر می‌تواند به جای گرادیان انرژی استفاده شود (Heermann et al., 1969)، شیب بستر جویچه‌ها قبل از آبیاری اندازه‌گیری شد.

رطوبت خاک قبل از آبیاری (که از عوامل مؤثر بر نفوذ آب در خاک و تغییر در وضعیت هیدرولیکی جریان است و در تصاویر برداشت شده از جویچه اثرگذار است) با استفاده از روش وزنی تعیین شد. بدین منظور، در هر جویچه از لایه سطحی خاک (۰-۱۰ سانتی‌متر) سه نمونه برداشت شد و پس از تعیین رطوبت، میانگین آن تعیین شد.

سطح مقطع جویچه (A_f) با استفاده از مقطع سنج (Walker & Skogerboe, 1987) در سه نقطه ابتدایی (۲ متر از ابتدای جویچه)، میانی (۱۰ متر از ابتدای جویچه) و انتهایی (۱۸ متر از ابتدای جویچه) قبل و بعد از هر آبیاری اندازه‌گیری شد. سطح مقطع (A_w) و محیط خیس شده (P_w) جریان در هر جویچه هم با استفاده از خط کش‌های تعیین عمق جریان و مقطع سنج در زمان‌های مختلف تعیین شد (Rezaei Rad et al., 2025). خلاصه اطلاعات برداشت از مزارع و جویچه‌های مورد بررسی در جدول (۲) و (۳) ارائه شده است.

جدول ۲. مشخصات جویچه‌های مورد بررسی در مزرعه E

جویچه	دبی ورودی (l/s)	شیب (m/m)	سطح مقطع جویچه (cm ²)	زمان پیشروی (min)	زمان پسروی (min)	سطح مقطع جریان (cm ²)	محیط خیس شده جریان (cm)
E10-1-1	-/۳۴۲	-/۰۰۷۶	-/۰۲۰	۲۷/۵۰	۱۹۴/۶۰	۳۷/۲۴	۲۵/۵۱
E10-2-1	-/۲۱۲	-/۰۰۷۶	-/۰۱۹	۱۷/۱۵	۱۸۹/۱۵	۱۹/۳۳	۲۰/۴۱
E10-3-1	-/۱۶۱	-/۰۰۷۶	-/۰۱۹	۱۸/۳۸	۱۹۱/۰۲	۱۰/۲۳	۱۵/۳۸
E10-1-2	-/۵۷۸	-/۰۰۷۲	-/۰۳۳	۹/۴۷	۱۹۴/۱۳	۴۲/۴۹	۲۶/۷۴
E10-2-2	-/۳۳۵	-/۰۰۷۲	-/۰۲۲	۱۱/۶۷	۱۸۷/۸۸	۲۲/۱۹	۲۰/۸۵
E10-3-2	-/۳۳۶	-/۰۰۷۲	-/۰۲۳	۱۱/۰۵	۱۹۰/۲۷	۱۱/۹۹	۱۵/۸۷
E10-1-3	-/۲۴۴	-/۰۰۷۶	-/۰۲۶	۸۷/۳۷	۱۸۸/۷۰	۳۲/۹۸	۲۱/۵۴
E10-2-3	-/۱۹۹	-/۰۰۷۶	-/۰۲۷	۱۷/۵۰	۱۸۹/۷۵	۲۵/۷۴	۲۱/۸۷
E10-3-3	-/۱۷۴	-/۰۰۷۶	-/۰۲۴	۱۴/۵۸	۱۸۹/۱۷	۱۱/۶۷	۱۸/۴۳
E10-1-4	-/۰۹۴	-/۰۰۶۴	-/۰۲۵	۳۶/۳۲	۱۸۸/۶۳	۴۰/۶۴	۲۳/۶۶
E10-2-4	-/۳۳۰	-/۰۰۶۴	-/۰۲۳	۱۱/۱۲	۱۸۸/۶۷	۲۸/۵۳	۱۹/۶۴
E10-3-4	-/۳۱۱	-/۰۰۶۴	-/۰۲۲	۶/۹۳	۱۹۳/۰۵	۲۶/۹۴	۲۱/۸۳
E10-1-5	-*	-	-	-	-	-	-
E10-2-5	-/۱۹۰	-/۰۰۵۷	-/۰۲۶	۲۶/۲۵	۱۸۷/۰۰	۳۴/۰۴	۲۶/۵۲
E10-3-5	-/۱۸۸	-/۰۰۵۷	-/۰۳۳	۱۵/۶۲	۱۸۸/۹۸	۲۹/۰۹	۱۹/۳۳
E10-1-6	-/۲۱۷	-/۰۰۵۰	-/۰۲۵	۳۳/۲۲	۱۹۱/۶۰	۳۴/۴۱	۲۳/۳۴
E10-2-6	-/۳۳۹	-/۰۰۵۰	-/۰۲۵	۱۱/۴۵	۱۸۷/۶۵	۴۳/۶۰	۲۷/۰۳
E10-3-6	-/۳۱۰	-/۰۰۵۰	-/۰۲۲	۹/۳۲	۱۸۹/۶۲	۳۹/۲۴	۲۶/۱۳
E5-1-1	-/۱۱۳	-/۰۰۶۸	-/۰۲۲	۳۹/۷۸	۱۸۸/۱۷	۴۹/۸۹	۲۳/۲۷
E5-2-1	-/۲۰۵	-/۰۰۶۸	-/۰۲۳	۱۱/۰۰	۱۸۷/۲۳	۲۸/۷۳	۱۹/۰۲
E5-3-1	-/۲۲۹	-/۰۰۶۸	-/۰۲۳	۹/۸۲	۱۸۹/۸۷	۱۲/۹۲	۱۶/۳۳
E5-1-2	-/۳۱۱	-/۰۰۷۲	-/۰۳۱	۲۰/۰۰	۱۸۸/۶۰	۳۷/۴۷	۲۲/۵۵
E5-2-2	-/۳۴۷	-/۰۰۷۲	-/۰۲۹	۷/۸۰	۱۸۶/۶۰	۱۶/۶۲	۱۷/۷۹
E5-3-2	-/۳۵۰	-/۰۰۷۲	-/۰۲۸	۶/۴۷	۱۸۹/۲۲	۱۷/۶۰	۲۰/۳۶
E5-1-3	-/۱۳۸	-/۰۰۶۶	-/۰۲۶	۷۹/۷۲	۱۸۶/۳۸	۱۷/۶۹	۱۷/۲۸
E5-2-3	-/۲۰۲	-/۰۰۶۶	-/۰۲۷	۱۴/۵۰	۱۸۷/۳۳	۱۸/۶۷	۱۸/۵۲
E5-3-3	-/۲۰۸	-/۰۰۶۶	-/۰۲۴	۸/۴۲	۱۸۷/۴۲	۲۱/۱۶	۲۰/۴۷
E5-1-4	-/۳۰۰	-/۰۰۷۰	-/۰۲۹	۱۵/۰۸	۱۸۶/۶۷	۴۴/۶۹	۲۵/۸۸
E5-2-4	-/۳۵۴	-/۰۰۷۰	-/۰۳۰	۸/۱۷	۱۸۷/۳۳	۳۰/۷۷	۲۴/۵۶
E5-3-4	-/۳۴۱	-/۰۰۷۰	-/۰۲۶	۶/۴۸	۱۸۸/۲۰	۲۲/۷۹	۲۲/۴۴
E5-1-5	-/۲۰۰	-/۰۰۶۲	-/۰۳۰	۳۷/۷۵	۱۹۱/۲۸	۲۶/۸۷	۱۹/۰۳
E5-2-5	-/۲۰۵	-/۰۰۶۲	-/۰۲۷	۱۳/۰۸	۱۹۰/۸۵	۱۱/۵۵	۱۲/۸۵
E5-3-5	-/۱۹۷	-/۰۰۶۲	-/۰۲۹	۷/۹۳	۱۸۷/۸۰	۱۰/۲۸	۱۶/۱۹
E5-1-6	-/۳۳۲	-/۰۰۶۴	-/۰۲۸	۱۰/۷۵	۱۹۲/۳۷	۴۰/۳۹	۲۵/۲۹
E5-2-6	-/۳۳۹	-/۰۰۶۴	-/۰۲۶	۷/۶۲	۱۹۱/۱۷	۲۸/۸۶	۲۴/۴۹
E5-3-6	-/۳۳۷	-/۰۰۶۴	-/۰۲۶	۵/۲۸	۱۸۸/۳۳	۲۰/۰۹	۲۲/۳۰

E5-3-6: مزرعه E، دور آبیاری ۵ روزه، رخداد آبیاری سوم و آزمایش شماره ۶.

*. داده از دست رفته.

جدول ۳. مشخصات جویچه‌های مورد بررسی در مزرعه F

جویچه	دبی ورودی (l/s)	شیب (m/m)	سطح مقطع جویچه (cm ²)	زمان پیشروی (min)	زمان پسروی (min)	سطح مقطع جریان (cm ²)	محیط خیس شده جریان (cm)
F10-1-1	-	-	-	-	-	-	-
F10-2-1	-/۷۹۰	-/۰۰۷۵	-/۰۲۱	۴/۳۰	۱۸۸/۵۰	۴۳/۸۴	۲۸/۵۴
F10-3-1	*	-	-	-	-	-	-
F10-1-2	-	-	-	-	-	-	-
F10-2-2	-/۴۲۰	-/۰۰۷۷	-/۰۲۶	۵/۹۰	۱۸۸/۵۰	۳۰/۱۳	۲۶/۴۰
F10-3-2	-	-	-	-	-	-	-
F10-1-3	-/۶۶۰	-/۰۰۷۲	-/۰۲۵	۵/۱۵	۱۹۰/۱۰	۴۲/۰۷	۲۴/۹۷
F10-2-3	-/۸۲۰	-/۰۰۷۲	-/۰۱۹	۳/۶۰	۱۹۰/۵۸	۴۱/۰۰	۲۸/۵۷
F10-3-3	-/۷۱۰	-/۰۰۷۲	-/۰۱۹	۴/۹۰	۱۸۶/۷۰	۴۵/۶۰	۳۳/۸۳
F10-1-4	-/۳۴۰	-/۰۰۶۵	-/۰۲۰	۷/۰۰	۱۸۷/۶۰	۴۳/۷۲	۲۳/۳۹
F10-2-4	-/۴۳۰	-/۰۰۶۵	-/۰۱۹	۶/۷۰	۱۸۸/۷۰	۱۵/۲۱	۱۸/۳۴
F10-3-4	-/۳۳۰	-/۰۰۶۵	-/۰۱۶	۸/۸۰	۱۸۸/۴۲	۳۱/۲۵	۲۶/۳۹
F10-1-5	-/۷۶۰	-/۰۰۷۵	-/۰۳۴	۴/۳۸	۱۹۹/۴۰	۳۳/۴۰	۲۱/۱۶
F10-2-5	-/۳۷۰	-/۰۰۷۵	-/۰۲۶	۷/۱۲	۱۹۵/۰۰	۲۱/۲۷	۲۲/۹۳
F10-3-5	-/۷۵۰	-/۰۰۷۵	-/۰۲۲	۵/۱۷	۹۶/۵۰	۳۵/۴۱	۲۲/۵۴
F10-1-6	-/۵۰۰	-/۰۰۷۳	-/۰۲۶	۱۳/۵۰	۱۹۹/۸۰	۴۰/۸۱	۲۱/۳۱
F10-2-6	-/۹۰۰	-/۰۰۷۳	-/۰۲۳	۳/۹۳	۱۹۳/۷۵	۴۸/۳۶	۲۵/۴۵
F10-3-6	-/۳۱۰	-/۰۰۷۳	-/۰۲۲	۸/۲۸	۹۹/۵۰	۲۴/۴۲	۲۲/۴۴
F10-1-7	-/۲۸۰	-/۰۰۷۸	-/۰۲۴	۵/۱۰	۱۸۶/۰۰	۵۹/۵۰	۲۴/۸۴
F10-2-7	-/۷۸۰	-/۰۰۷۸	-/۰۲۳	۳/۹۰	۱۹۰/۰۵	۳۸/۹۵	۲۶/۵۱
F10-3-7	-/۶۶۰	-/۰۰۷۸	-/۰۲۲	۴/۷۰	۱۴۰/۳۳	۳۳/۸۸	۳۰/۰۴
F10-1-8	-/۴۱۰	-/۰۰۱۰	-/۰۳۵	۱۰/۶۵	۱۸۵/۲۵	۳۴/۶۹	۲۳/۵۲
F10-2-8	-/۴۲۰	-/۰۰۱۰	-/۰۳۱	۶/۶۶	۱۸۸/۵۸	۲۵/۶۱	۲۰/۹۴
F10-3-8	-/۳۳۰	-/۰۰۱۰	-/۰۳۰	۷/۳۲	۱۴۲/۲۰	۲۶/۴۹	۲۴/۵۴
F10-1-9	-/۷۶۰	-/۰۰۹۰	-/۰۳۷	۳/۹۶	۱۹۰/۵۰	۴۰/۶۸	۲۲/۹۸
F10-2-9	-/۸۷۰	-/۰۰۹۰	-/۰۲۶	۳/۲۵	۲۲۰/۵۸	۴۸/۸۰	۲۸/۸۹
F10-3-9	-/۶۸۰	-/۰۰۹۰	-/۰۲۰	۴/۹۷	۲۰۲/۴۰	۴۱/۶۷	۳۲/۵۹
F10-1-10	-/۲۶۰	-/۰۰۷۶	-/۰۲۲	۱۳/۰۰	۱۸۹/۷۵	۲۷/۴۸	۲۲/۶۱
F10-2-10	-/۴۴۰	-/۰۰۷۶	-/۰۲۲	۶/۵۰	۲۱۹/۴۳	۲۷/۹۱	۲۲/۶۴
F10-3-10	-/۳۳۰	-/۰۰۷۶	-/۰۱۶	۷/۸۲	۲۰۱/۴۶	۳۱/۷۶	۲۵/۲۷
F10-1-11	-/۶۰۰	-/۰۰۹۰	-/۰۳۳	۳/۸۲	۱۹۲/۴۸	۳۷/۳۱	۲۴/۶۶
F10-2-11	-/۹۱۰	-/۰۰۹۰	-/۰۳۱	۳/۹۲	۱۹۰/۶۶	۴۹/۹۳	۲۸/۹۳
F10-3-11	-/۶۴۰	-/۰۰۹۰	-/۰۳۳	۴/۴۰	۱۸۸/۱۳	۲۸/۷۴	۲۶/۵۱
F10-1-12	-/۴۳۰	-/۰۰۹۲	-/۰۳۱	۱۱/۱۸	۱۹۲/۸۳	۴۷/۰۱	۲۵/۸۷
F10-2-12	-/۵۴۰	-/۰۰۹۲	-/۰۲۶	۹/۹۵	۱۸۹/۱۶	۳۰/۶۷	۲۵/۶۸
F10-3-12	-/۴۰۰	-/۰۰۹۲	-/۰۲۱	۷/۲۰	۱۸۸/۱۳	۲۷/۲۴	۲۲/۶۷
F5-1-1	-/۳۷۰	-/۰۰۱۰	-/۰۲۳	۱۱/۲۶	۱۲۲/۰۰	۲۰/۱۳	۱۹/۲۲
F5-2-1	-/۴۳۰	-/۰۰۱۰	-/۰۲۲	۶/۶۰	۱۸۷/۸۷	۲۱/۸۹	۲۲/۴۳
F5-3-1	-/۴۳۰	-/۰۰۱۰	-/۰۲۲	۳/۹۰	۱۸۹/۰۵	۲۴/۹۳	۲۳/۹۵
F5-1-2	-/۲۷۰	-/۰۰۲۵	-/۰۲۸	۱۴/۹۳	۱۲۲/۷۵	۲۸/۴۳	۲۰/۱۱
F5-2-2	-/۱۱۰	-/۰۰۲۵	-/۰۳۷	۸/۲۰	۱۸۷/۸۶	۹/۲۶	۱۷/۶۴
F5-3-2	-/۳۱۰	-/۰۰۲۵	-/۰۳۰	۴/۴۳	۱۸۸/۶۰	۱۷/۵۱	۱۸/۲۷
F5-1-3	-/۴۸۰	-/۰۰۱۰	-/۰۳۸	۱۰/۸۳	۱۸۶/۸۳	۳۳/۶۷	۲۰/۹۶
F5-2-3	-/۳۳۰	-/۰۰۱۰	-/۰۳۷	۷/۶۰	۱۹۲/۷۲	۱۳/۴۱	۲۰/۲۹
F5-3-3	-/۳۳۰	-/۰۰۱۰	-/۰۳۸	۷/۷۳	۱۸۹/۱۵	۱۳/۹۷	۲۱/۴۲
F5-1-4	-/۲۴۵	-/۰۰۳۸	-/۰۲۴	۲۳/۲۵	۱۹۰/۸۳	۲۵/۶۷	۱۸/۱۲
F5-2-4	-/۱۶۰	-/۰۰۳۸	-/۰۲۱	۱۸/۸۸	۱۹۱/۷۵	۸/۳۱	۱۷/۶۲
F5-3-4	-/۱۹۰	-/۰۰۳۸	-/۰۲۱	۱۱/۵۶	۱۸۷/۸۰	۱۰/۳۰	۱۸/۰۳
F5-1-5	-/۵۱۰	-/۰۰۳۳	-/۰۳۰	۱۳/۴۳	۱۸۹/۵۰	۴۲/۱۲	۲۳/۴۵
F5-2-5	-/۲۸۰	-/۰۰۳۳	-/۰۳۶	۹/۸۸	۱۹۱/۲۰	۱۶/۰۸	۲۳/۷۵
F5-3-5	-/۳۷۰	-/۰۰۳۳	-/۰۳۳	۷/۸۰	۱۹۴/۵۰	۲/۷۰	۱۳/۲۴
F5-1-6	-/۱۶۰	-/۰۰۴۰	-/۰۳۷	۲۵/۴۲	۱۸۹/۱۰	۶/۲۲	۱۱/۷۹
F5-2-6	-/۱۸۰	-/۰۰۴۰	-/۰۴۳	۱۶/۹۶	۱۹۰/۶۱	۸/۳۵	۱۴/۱۰
F5-3-6	-/۱۰۰	-/۰۰۴۰	-/۰۳۸	۲۴/۳۵	۱۹۲/۲۵	۳/۵۱	۱۲/۰۴

F10-2-12: مزرعه F، دور آبیاری ۱۰ روزه، رخداده دوم آبیاری و آزمایش شماره ۱۲.

*. داده از دست رفته.

تعیین ضریب زبری مانینگ

فاز پیشروی

اصولاً با توجه به فرضیات معادله مانینگ، امکان استفاده از این معادله در آبیاری به دلیل وجود نفوذ و در نتیجه عدم یکنواختی جریان، وجود ندارد؛ اما محققان به دلیل عدم وجود معادله مناسب و کاربردی و البته به منظور سادگی محاسبات، از این رابطه به منظور تشریح وضعیت هیدرولیک جریان در آبیاری سطحی پس از تثبیت نفوذ آب در خاک (رسیدن به نفوذ پایه) استفاده می‌نمایند. در این تحقیق به منظور تعیین ضریب زبری مانینگ در فاز پیشروی به‌جای استفاده از معادله مانینگ از مدل SIPAR_ID استفاده شد. مدل مذکور با توجه به اینکه برای تخمین ضریب زبری مانینگ از داده‌های فاز پیشروی، دبی ورودی و عمق جریان در یک نقطه و در زمان‌های مشخص استفاده می‌کند (Rodríguez & Martos, 2010)، به منظور تخمین ضریب زبری مانینگ در فاز پیشروی می‌تواند مورد استفاده قرار گیرد. وردی نژاد و همکاران (۱۳۹۵) نیز مدل SIPAR_ID را در تخمین ضریب زبری مانینگ در فاز پیشروی کارا دانستند.

فاز ذخیره

فاز ذخیره پس از رسیدن آب به انتهای جویچه شروع شده و تا زمان قطع جریان ادامه دارد. مشاهدات نشان داد که تقریباً پس از گذشت یک ساعت از شروع آبیاری، سرعت نفوذ آب در خاک ثابت شده و مقدار دبی خروجی از جویچه‌ها (به شرط ثابت بودن دبی ورودی) بدون تغییر باقی می‌ماند. پس از این لحظه فرض شد که شرط جریان یکنواخت در جویچه (در یک بازه مکانی مشخص) برقرار است و ضریب زبری توسط معادله مانینگ (رابطه ۱) محاسبه گردید و به عنوان نماینده فاز ذخیره در نظر گرفته شد.

$$Q = \frac{A}{n} \times R^{\frac{2}{3}} \times S_0^{\frac{1}{2}} \quad \text{(رابطه ۱)}$$

که در آن Q : دبی جریان (m^3/s)، A : سطح مقطع جریان (m^2)، n : ضریب زبری مانینگ ($S/m^{1/3}$)، R : شعاع هیدرولیکی (m) و S_0 : شیب کف جویچه (گرادیان انرژی) می‌باشد.

به منظور افزایش دقت در تخمین ضریب زبری مانینگ در این فاز، ضریب زبری در ابتدا و انتهای جویچه به صورت مجزا محاسبه شد. بدین منظور، با استفاده از مقطع سنج ابتدای جویچه، سطح مقطع و محیط خیس شده جریان در ابتدای جویچه محاسبه شد. سپس ضریب زبری مانینگ با استفاده از معادله مانینگ و در نظر گرفتن دبی ورودی به جویچه به عنوان دبی مورد نیاز در معادله، تعیین گردید. از آنجا که عمق جریان و مقدار دبی ورودی به جویچه پس از ثابت شدن نفوذ آب در خاک هر ده دقیقه اندازه‌گیری شده بود، ضریب زبری مانینگ در ابتدای جویچه در بازه‌های زمانی ده دقیقه‌ای تا انتهای آبیاری تعیین گردید و در نهایت میانگین ضریب زبری در این بازه‌های زمانی به عنوان ضریب زبری فاز ذخیره در ابتدای جویچه در نظر گرفته شد. با اقدامی مشابه و با استفاده از مقطع سنج انتهای جویچه و دبی خروجی از آن مقدار ضریب زبری در بازه‌های زمانی مختلف تعیین و میانگین آن مشخص شد. در انتها میانگین ضریب زبری در ابتدا و انتهای آبیاری محاسبه و گزارش شد و در مراحل مختلف تجزیه و تحلیل مورد استفاده قرار گرفت.

تعیین دقت تخمین ضریب زبری مانینگ

برای تعیین دقت تخمین ضریب زبری مانینگ در فاز پیشروی جریان، مقادیر شبیه‌سازی شده و اندازه‌گیری شده منحنی پیشروی جریان با استفاده از شاخص‌های R^2 (رابطه ۲)، $RMSE$ (رابطه ۳) و RE (رابطه ۴) مورد مقایسه قرار گرفتند. در فاز ذخیره هم فرض شد که خطای اندازه‌گیری داده‌های مزرعه‌ای قابل اغماض است و مستقیماً از معادله مانینگ استفاده شد و مقادیر محاسبه شده توسط آن به عنوان ضریب زبری مانینگ در این فاز پذیرفته شد.

$$R^2 = \left(\frac{\sum_{i=1}^n (X_i \times Y_i) - N \times \bar{X}_i \times \bar{Y}_i}{\sqrt{(\sum_{i=1}^n X_i^2 - N \times \bar{X}^2)(\sum_{i=1}^n Y_i^2 - N \times \bar{Y}^2)}} \right) \quad \text{(رابطه ۲)}$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (X_i - Y_i)^2}{N}} \quad \text{(رابطه ۳)}$$


$$RE = \frac{Y_i - X_i}{X_i} \quad \text{(رابطه ۴)}$$

که در آن x_i : داده‌های اندازه‌گیری شده، Y_i : داده‌های تخمین زده شده، N : تعداد کل داده‌های مورد بررسی، \bar{X} : میانگین داده‌های

اندازه گیری شده و \bar{Y} : میانگین داده های تخمین زده شده می باشد.

تهیه عکس ها

برای تخمین ضریب زبری مانینگ، تصاویری از سطح جویچه های آبیاری با استفاده از دوربین دیجیتال (Canon) مدل PowerShot SX540 HS با حسگر ۲۰ مگاپیکسلی و حداکثر اندازه تصاویر (رزولوشن) ۳۸۸۸ در ۵۱۸۴ تهیه شد. برای پوشش مناسب کل سطح در نظر گرفته شده و تثبیت شرایط عکس برداری و نورپردازی در تمام جویچه ها، ارابه ای (شکل ۱) به ارتفاع یک متر ساخته شد. دو سری عکس قبل و بعد از آبیاری که به ترتیب نماینده فاز پیشروی و ذخیره بودند، در ۵ نقطه مشخص (نقاط ۴، ۶، ۸، ۱۰ و ۱۲ متری از ابتدای جویچه) از سطح جویچه ها تهیه شد. در نهایت پس از حذف عکس های نویزی (عکس های غیر قابل استفاده)، ۱۴۸۶ عکس از سطح جویچه ها قبل و بعد از آبیاری جمع آوری گردید.



شکل ۱. ارابه تصویربرداری مورد استفاده و سیستم نورپردازی آن

تعیین شاخص اندازه و تعداد کلوخه ها


علاوه بر دی، رطوبت اولیه و بافت خاک، پارامترهای دیگری از جمله اندازه و تعداد کلوخه ها بر سرعت حرکت آب در جویچه و در نتیجه ضریب زبری مانینگ اثرگذارند. این در حالی است که تعیین اندازه و تعداد کلوخه ها به صورتی کمی کاری دشوار است؛ لذا تلاش شد تا با تعریف شاخص هایی اثر این پارامتر تا حد امکان در الگوریتم توسعه داده شده در نظر گرفته شود. در نتیجه شاخص هایی تحت عنوان S_d و S_w که نماینده اندازه و تعداد کلوخه ها قبل و بعد از آبیاری در هر جویچه بود، تعریف شد. بدین منظور با استفاده از تصاویر برداشت شده از سطح جویچه ها و با کمک نظرات ۳ نفر از کارشناسان، اندازه و تعداد کلوخه ها در سه دسته کلوخه زیاد، متوسط و کم قبل و بعد از آبیاری دسته بندی شدند. به منظور کمی سازی این شاخص، شاخص S_d برای کلوخه های زیاد، متوسط و کم، به ترتیب برابر با ۳، ۲ و ۱ و مقدار شاخص S_w نیز برای کلوخه های زیاد، متوسط و کم به ترتیب برابر با ۲/۵، ۱/۵ و ۰/۵ در نظر گرفته شد. لازم به ذکر است که برای تعیین این شاخص الزاماً نیاز به تصویر برداری از سطح جویچه ها نیست و هر نفر قبل از استفاده از الگوریتم با دقت در وضعیت سطح جویچه ها می تواند مقدار این شاخص را به صورت یک عدد انتخاب کند و به عنوان یک داده ورودی در اختیار مدل قرار دهد.

استخراج ویژگی

در این تحقیق ویژگی های متفاوتی در سه طیف ویژگی های مرتبط با شکل و اندازه، بافت و رنگ^۱، از تصاویر برداشت شده از سطح جویچه ها (شکل ۲) با استفاده از زبان برنامه نویسی پایتون استخراج گردیدند. بدین منظور با استفاده از گشتاور آماری به نام مومنتوم هو (Hu, 1962)،

۱. بافت، رنگ، شکل و اندازه استخراج شده از تصاویر ارتباطی با بافت خاک به صورت مستقیم ندارد و این شاخص ها مرتبط با تصاویر هستند که به تیرگی یا روشنی تصاویر، کنتراست یا غیره مربوط می شوند.

۷ ویژگی مرتبط با شکل و اندازه استخراج گردید. همچنین با استفاده از روش ماتریس هم‌وقوعی^۱ (Haralick et al., 1973) و الگوی باینری محلی (LBP) (Ojala et al., 1996) که از روش‌های استخراج بافت بسیار پرکاربرد می‌باشند (Brynolfsson et al., 2018; Han et al., 2021; Kaplan et al., 2020; Prakash & Saradha, 2021; Tesař et al., 2008; Webel et al., 2018; ۱۳۹۷)، به ترتیب ۱۶ و ۱۵۶ ویژگی بافتی از تصاویر استخراج شد. در نهایت هم ۵۱۲ ویژگی رنگی، با استفاده از فضای رنگ HSV و هیستوگرام نرمال شده آن تهیه شد.



شکل ۲. نمونه‌های از تصاویر برداشت شده از سطح خاک در جویچه‌های مختلف

سناریوهای مورد بررسی

پارامترهای زیادی بر ضریب زبری مانینگ اثرگذارند که در نظر نگرفتن هر یک از آن‌ها می‌تواند منجر به کاهش دقت تخمین ضریب زبری توسط الگوریتم گردد. بدین منظور سناریوهای مختلفی تعریف شد و دقت الگوریتم توسعه داده شده در هر یک از این سناریوها مورد بررسی قرار گرفت تا بهترین سناریو انتخاب شود. بهینه‌ترین حالت زمانی است که الگوریتم با کم‌ترین داده ورودی بیش‌ترین دقت را در تخمین ضریب زبری داشته باشد؛ اما واضح است که با کم‌شدن داده‌های ورودی دقت الگوریتم کاهش می‌یابد؛ لذا در این تحقیق سناریوی بهینه با در نظر گرفتن داده‌های ورودی مورد نیاز و دقت تخمین انتخاب گردید. سناریوهای در نظر گرفته شده به شرح زیر هستند:

سناریوی اول: استفاده از تصاویر برداشت شده از سطح جویچه‌ها

سناریوی دوم: صرفاً استفاده از همه داده‌های برداشت شده مزرعه‌ای شامل داده‌های دبی ورودی، دبی خروجی، زمان پیشروی، زمان پسروی، حجم آب نفوذ یافته، شماره رخداد آبیاری، رطوبت اولیه خاک، شیب، سرعت نفوذ نهایی، شاخص تعداد و اندازه کلوخه‌ها قبل و بعد از آبیاری، شوری و اسیدیته خاک، سطح مقطع جویچه و خیس شده جریان و محیط خیس شده

سناریوی سوم: ترکیب تصاویر برداشت شده و برخی داده‌های مزرعه‌ای شامل دبی ورودی، شیب، سطح مقطع جویچه، شماره رخداد

آبیاری و شاخص اندازه کلوخه‌ها قبل از آبیاری

کلاس‌ها (طبقه‌بندی)

به منظور سهولت، ضریب زبری در طبقه‌های مختلفی دسته‌بندی شدند. بدین منظور ضرایب زبری قبل از آبیاری (ضریب زبری فاز پیشروی) به ترتیب از کم به زیاد مرتب شدند و اعداد زبری در بازه مثبت و منفی ۱۰ درصد در یک گروه (کلاس) قرار گرفتند. با اقدامی مشابه ضرایب زبری پس از آبیاری (ضریب زبری فاز ذخیره) نیز در گروه‌های مختلف تقسیم‌بندی شدند. بدین شیوه ضرایب زبری قبل از آبیاری در ده کلاس و بعد از آبیاری در نه کلاس و در مجموع در ۱۹ کلاس دسته‌بندی شدند (جدول ۴).

با توجه به کلاس‌بندی انجام شده، اگر الگوریتم کلاس هر جویچه را به‌درستی تشخیص دهد، توانسته است مقدار ضریب زبری مانینگ را حداکثر با ۱۰ درصد خطا تخمین زند.

جدول ۴. مقدار ضریب زبری مانینگ در کلاس‌های در نظر گرفته شده

مقدار ضریب زبری مانینگ در نظر گرفته شده در هر کلاس بعد از آبیاری									
ضریب زبری مانینگ	۰/۰۱۷۵	۰/۰۲۴۲	۰/۰۳۲۷	۰/۰۴	۰/۰۵	۰/۰۶۴	۰/۰۸۳۴	۰/۱۲۴	۰/۲۵۹
کلاس	۰	۱	۲	۳	۴	۵	۶	۷	۸
مقدار ضریب زبری مانینگ در نظر گرفته شده در هر کلاس قبل از آبیاری									
ضریب زبری مانینگ	۰/۰۲۱۲	۰/۰۲۸	۰/۰۳۷۸	۰/۰۴۸	۰/۰۵۷	۰/۰۷۱	۰/۰۹۲۱	۰/۱۱۷۶	۰/۱۶۵
کلاس	۹	۱۰	۱۱	۱۲	۱۳	۱۴	۱۵	۱۶	۱۷
	۱۸								

پس از این مرحله و با در اختیار داشتن ویژگی‌های استخراج شده از تصاویر، کارایی روش‌های مختلف یادگیری ماشین نظیر: رگرسیون لجستیک (LR) (Berkson 1944)، تحلیل تفکیک خطی (LDA) (Blei, Ng, and Edu 2003)، k نزدیک‌ترین همسایه (KNN) (Cover and Hart 1967)، درخت تصمیم (CART) (Breiman et al. 1984)، جنگل تصادفی (RF) (Breiman 2001)، ماشین بردار پشتیبان (SVM) (Boser, Guyon, and Vapnik 1992)، شبکه عصبی پرسپترون (MLP) (Rumelhart and McClelland 1986) و بیز ساده (NB Gaussian) (Friedman, Geiger, and Goldszmidt 1997) در طبقه‌بندی ضریب زبری مانینگ مورد ارزیابی قرار گرفت. بدین منظور الگوریتم توسط هر یک از این طبقه‌بندها به صورت مجزا آموزش دید و مورد تست قرار گرفت.

در الگوریتم توسعه داده شده، ابتدا تمامی طبقه‌بندها با استفاده از روش اعتبارسنجی متقابل^۱ (K=10) آموزش دیده و تست شدند و عملکرد هر یک با استفاده از شاخص‌های مختلف مورد ارزیابی قرار گرفت و بهترین روش طبقه‌بندی انتخاب گردید. پس از انتخاب بهترین روش، داده‌ها در هر سناریو به دو بخش آموزش (۸۰ درصد نمونه‌ها) و آزمون (۲۰ درصد نمونه‌ها) تقسیم شده و الگوریتم مجدداً بر مبنای آن، آموزش دید. در نهایت با بررسی شاخص‌های مختلف، دقت طبقه‌بندی الگوریتم (با استفاده از روش طبقه‌بند انتخاب شده) تعیین شده و بهترین سناریو انتخاب می‌شود.

ارزیابی دقت روش‌های مختلف با استفاده از شاخص‌های آماری

برای ارزیابی عملکرد الگوریتم پیشنهادی از سه شاخص آماری شامل، یادآوری^۲، صحت^۳، دقت^۴ و میانگین هارمونیک یادآوری و دقت^۵ که در مسائل طبقه‌بندی^۶ بسیار پر کاربرد هستند (Omid et al., 2010; Teimouri et al., 2014)؛ استفاده گردید.

$$\text{Recall} = \frac{TP}{TP+FN} \quad (\text{رابطه ۵})$$

$$\text{Precision} = \frac{TN}{TN+FP} \quad (\text{رابطه ۶})$$

1. K-Fold Cross Validation
2. Recall
3. Precision
4. Accuracy
5. F1-score
6. Classification

$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN} \quad \text{رابطه ۷}$$

$$F1_score = 2 \frac{\text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}} \quad \text{رابطه ۸}$$


که در آن‌ها، TP : تعداد نمونه‌هایی است که به عنوان کلاس A دسته‌بندی می‌شوند درحالی‌که این نمونه‌ها به‌درستی جز این کلاس محسوب می‌گردند، TN : تعداد نمونه‌هایی است که به عنوان کلاس غیر A دسته‌بندی می‌شوند درحالی‌که این نمونه‌ها به‌درستی جز کلاس A محسوب نمی‌گردند، FP : تعداد نمونه‌هایی است که جز کلاس A دسته‌بندی می‌شوند درحالی‌که این نمونه‌ها جز کلاس A نمی‌باشند، FN : تعداد نمونه‌هایی است که جز کلاس غیر A دسته‌بندی می‌شوند درحالی‌که این نمونه‌ها جز کلاس A بوده است.

نتایج و بحث

مقادیر ضریب زبری مانینگ

مقادیر ضریب زبری مانینگ در فاز پیشروی و ذخیره و دقت تخمین ضریب زبری در فاز پیشروی در مزرعه E و F در جدول (۵) و (۶) ارائه شده است. شاخص ضریب تعیین در مزرعه E بین ۰/۹۱ تا ۰/۹۹۹ و در مزرعه F بین ۰/۹۸ تا ۱ متغیر بود. شاخص ریشه دوم مجموع مربعات خطا هم در مزرعه E و F به ترتیب مقادیری در بازه ۰/۲ تا ۲/۶ دقیقه و ۰/۰۸ تا ۰/۸ دقیقه داشت. مقدار خطای نسبی مدل هم به ترتیب بین ۰/۲۹ تا ۱۰/۸ و ۰/۹ تا ۱۲/۴ درصد در مزرعه E و F تعیین گردید. میانگین شاخص‌های R^2 ، RMSE و RE در هر دو مزرعه به ترتیب برابر ۰/۹۹۵، ۰/۳۶۳ دقیقه و ۴/۲۴ درصد بود که نشان از دقت بسیار خوب مدل SIPAR_ID در تخمین منحنی پیشروی جریان داشت. (Nie et al., 2018, 2014; Ramezani Etedali et al., 2011; رمضان‌ی اعتدالی و همکاران؛ ۱۳۸۸) هم دقت مدل SIPAR_ID را قابل قبول و قابل توصیه بیان کردند.

با دقت در مقادیر جدول (۵) و (۶) می‌توان دریافت که ضریب زبری مانینگ در فاز پیشروی و ذخیره در مزرعه E به ترتیب، حداقل ۰/۰۱۷، ۰/۰۱۶ و حداکثر ۰/۶۳۶، ۰/۳۱۷ و به طور میانگین ۰/۱۱، ۰/۰۷۳ بود و در مزرعه F حداقل ۰/۰۲۶، ۰/۰۱۵ و حداکثر ۰/۱۸، ۰/۰۹ و به طور میانگین ۰/۰۶۴، ۰/۰۴۱ تعیین شد. بررسی روند کلی تغییرات نشان داد که با افزایش شماره رخداد آبیاری، ضریب زبری مانینگ کاهش می‌یابد که با نتایج تحقیقات (Bahmani et al., 2020; Zarakani et al., 2020) همسو می‌باشد. این کاهش زبری در اثر افزایش شماره رخداد آبیاری، در هر دو فاز پیشروی و ذخیره مشاهده شد. در توجیه این فرایند می‌توان به خیس شدن جویچه در اثر آبیاری، اشاره کرد. چرخه خیس شدن و خشک شدن خاک در فاصله دو آبیاری متوالی، سبب شکسته و حل شدن کلوخه‌ها می‌شود (شکل ۳) از طرف دیگر خاک فرسایش یافته و همراه آب در درز و شکاف‌های موجود در سطح خاک قرار می‌گیرد و لایه سطحی خاک پس از هر آبیاری متراکم‌تر و نرم‌تر می‌شود که در نهایت منجر به تثبیت بستر جویچه و کاهش ضریب زبری می‌گردد. (Amiri et al., 2016; Grassi, 1972; Harun-ur-Rashid, 1990; Kassem & Ghonimy, 2011) دلایل مشابهی را برای کاهش ضریب زبری طی رخدادهای مختلف آبیاری ذکر نمودند.



شکل ۳. یک نمونه از تصاویر جویچه‌های مورد بررسی، قبل و بعد از آبیاری (۱۳۹۷/۰۴/۱۸ - F10-1-8)

جدول ۵. مقادیر شاخص‌های ارزیابی دقت تخمین ضریب زبری مایننگ در فاز پیشروی

شاخص ارزیابی			جوابچه	شاخص ارزیابی			جوابچه
RE (%)	RMSE (min)	R ²		RE (%)	RMSE (min)	R ²	
-	-	-	F10-1-1	۲/۹۴	-/۲۹	-/۹۹۶	E10-1-1
۱/۷۴	-/۲۶	-/۹۹۸	F10-2-1	۶/۴۷	-/۳۶	-/۹۹۷	E10-2-1
-	-	-	F10-3-1	۱۰/۴	-/۷۹	-/۹۸	E10-3-1
-	-	-	F10-1-2	۷/۱۹	-/۵۷۴	-/۹۹۷	E10-1-2
۳/۳۸	-/۲۱	-/۹۹۹	F10-2-2	۳/۳۴	-/۲۸	-/۹۹۸	E10-2-2
-	-	-	F10-3-2	۸/۶	-/۴۶	-/۹۹۴	E10-3-2
۱/۶	-/۱۶	-/۹۹۹	F10-1-3	۳/۲	-/۳۷	-/۹۹۶	E10-1-3
۸/۳	-/۴۶	-/۹۹۵	F10-2-3	۲/۵۸	-/۲۸۷۵	-/۹۹۷۵	E10-2-3
-/۹	-/۰۸	۱	F10-3-3	۳/۷	-/۳۳	-/۹۹۶	E10-3-3
۱۲/۰۲	-/۷۴	-/۹۹	F10-1-4	۳/۷۶	-/۳۲	-/۹۹۷	E10-1-4
۳/۲۵	-/۲۵	-/۹۹۸	F10-2-4	۵/۱	-/۴۱	-/۹۹۵	E10-2-4
۲/۱۶	-/۱۸	-/۹۹۹	F10-3-4	۹/۲	-/۵۴	-/۹۹۲	E10-3-4
۲/۱	-/۲۱	-/۹۹۹	F10-1-5	-	-	-	E10-1-5
۷/۵۵	-/۵۷	-/۹۹	F10-2-5	۳/۶	-/۲۹	-/۹۹۸	E10-2-5
۲/۵	-/۲۸	-/۹۹۸	F10-3-5	۱/۸	-/۲۱۲	-/۹۹۹	E10-3-5
۱۲/۴	-/۸۲	-/۹۸	F10-1-6	۸/۴	-/۶۹	-/۹۸۶	E10-1-6
۱/۱۴	-/۱۵	-/۹۹۹	F10-2-6	۲/۱	-/۲۲	-/۹۹۸	E10-2-6
۱/۶	-/۱۹	-/۹۹۹	F10-3-6	۲/۶	-/۳۱	-/۹۹۷	E10-3-6
۳/۶۵	-/۵۲	-/۹۹۷	F10-1-7	۱۰/۲	-/۶۶	-/۹۸۶	E5-1-1
۱/۳	-/۱۷	-/۹۹۹	F10-2-7	۳/۸	-/۳۵	-/۹۹۷	E5-2-1
۲/۱	-/۲۸	-/۹۹۹	F10-3-7	۴/۷	-/۳۸	-/۹۹۶	E5-3-1
۶/۳۸	-/۴۳	-/۹۹۴	F10-1-8	۵/۴۵	-/۳۹	-/۹۹۵	E5-1-2
۱/۴۵	-/۱۷	-/۹۹۹	F10-2-8	۵/۱۵	-/۴۵	-/۹۹۴	E5-2-2
۱/۳۶	-/۱۳	-/۹۹۹	F10-3-8	۲/۷۸	-/۲۹	-/۹۹۷	E5-3-2
۳/۹	-/۲۲	-/۹۹۹	F10-1-9	۱۰/۸	-/۸۳	-/۹۸	E5-1-3
۱/۳	-/۱	۱	F10-2-9	-/۲۹	-/۲۲	-/۹۹۸	E5-2-3
۱/۹	-/۱۵	-/۹۹۹	F10-3-9	۲/۸	-/۲۵	-/۹۹۸	E5-3-3
۹/۱	-/۵۶	-/۹۹۱	F10-1-10	۶/۹	-/۵۱	-/۹۹۳	E5-1-4
۱/۸	-/۱۶	-/۹۹۹	F10-2-10	۵/۳۳	-/۲۹	-/۹۹۷	E5-2-4
۲/۴۷	-/۲۲	-/۹۹۸	F10-3-10	۳/۵۶	-/۲۳	-/۹۹۷	E5-3-4
۲/۷	-/۲۹	-/۹۹۸	F10-1-11	۶	۲/۶	-/۹۱	E5-1-5
۳/۲۴	-/۲۶	-/۹۹۹	F10-2-11	۴/۲۷	-/۲۵	-/۹۹۸	E5-2-5
۹/۴۷	-/۵۱	-/۹۹۸	F10-3-11	۲/۸	-/۲	-/۹۹۸	E5-3-5
۲/۷۵	-/۲۹	-/۹۹۷	F10-1-12	۳	-/۲۵	-/۹۹۸	E5-1-6
۴/۳۸	-/۳۱	-/۹۹۷	F10-2-12	۴/۰۶	-/۳۷	-/۹۹۶	E5-2-6
۱۲/۱	-/۶۸	-/۹۹۲	F10-3-12	۲/۷۷	-/۳۱	-/۹۹۷	E5-3-6
۳/۸	-/۴۲	-/۹۹۴	F5-1-1				
۱/۴	-/۱۴	-/۹۹۹	F5-2-1				
۱/۹	-/۱۹	-/۹۹۹	F5-3-1				
۴/۲۳	-/۴۷	-/۹۹۳	F5-1-2				
۱/۸	-/۱۵	-/۹۹۹	F5-2-2				
۴/۹۷	-/۳۲	-/۹۹۶	F5-3-2				
۱/۲	-/۴۳	-/۹۹۴	F5-1-3				
۳/۳	-/۲۶	-/۹۹۷	F5-2-3				
۶/۵	-/۴۶	-/۹۹۳	F5-3-3				
۱/۸۵	-/۲۶۹	-/۹۹۸	F5-1-4				
۳/۲۳	-/۲۶	-/۹۹۸	F5-2-4				
۴/۲۲	-/۳۱	-/۹۹۷	F5-3-4				
۲/۳۵	-/۲۲	-/۹۹۸	F5-1-5				
۱/۱	-/۱۷	-/۹۹۹	F5-2-5				
۱/۷	-/۱۳	۱	F5-3-5				
۳/۱۳	-/۱۹	-/۹۹۹	F5-1-6				
۶/۹۷	-/۵۶	-/۹۹	F5-2-6				
۵	-/۳۶	-/۹۹۶	F5-3-6				



جدول ۶. مقادیر ضریب زبری مانینگ در فاز پیشروی و ذخیره

فاز ذخیره	فاز پیشروی	جویچه	فاز ذخیره	فاز پیشروی	جویچه
-	-	F10-1-1	-/۰.۵۹	-/۰.۷۴	E10-1-1
-/۰.۲۳	-/۰.۳۱	F10-2-1	-/۰.۳۸۴	-/۰.۴۳۲	E10-2-1
-	-	F10-3-1	-/۰.۲۲۴۱	-/۰.۲۳۷	E10-3-1
-	-	F10-1-2	-/۰.۸۵۳	-/۱.۰۱	E10-1-2
-/۰.۳۴	-/۰.۴	F10-2-2	-/۰.۳۶	-/۰.۳۷۸	E10-2-2
-	-	F10-3-2	-/۰.۱۵۷	-/۰.۱۷۳	E10-3-2
-/۰.۳۴۵	-/۰.۶۰۸	F10-1-3	-/۱۲۴	-/۱۳۳	E10-1-3
-/۰.۲۷	-/۰.۳۹۲	F10-2-3	-/۰.۶۶	-/۰.۸۹۸	E10-2-3
-/۰.۳۳۴	-/۰.۵۵۸	F10-3-3	-/۰.۲۵۱	-/۰.۴۳۹	E10-3-3
-/۰.۸۱	-/۱۸	F10-1-4	-/۲۸۱	-/۴۵۷	E10-1-4
-/۰.۱۵	-/۰.۲۶	F10-2-4	-/۰.۴۵	-/۰.۵۹	E10-2-4
-/۰.۴۳۲	-/۰.۴۸۸	F10-3-4	-/۰.۳۷۳	-/۰.۵۳۸	E10-3-4
-/۰.۲۶	-/۰.۹	F10-1-5	-	-	E10-1-5
-/۰.۲۴	-/۰.۴۱	F10-2-5	-/۱۴۱۱	-/۲۳۶	E10-2-5
-/۰.۳۵۶	-/۰.۴۵۶	F10-3-5	-/۱۱۲۳	-/۱۸۷۱	E10-3-5
-/۰.۶۶۷	-/۱	F10-1-6	-/۰.۸۳	-/۱۷۸	E10-1-6
-/۰.۳۷	-/۰.۳۱	F10-2-6	-/۰.۶۴	-/۰.۸۸۲	E10-2-6
-/۰.۳۹	-/۰.۹۹	F10-3-6	-/۰.۶۳۵	-/۰.۷۹۸	E10-3-6
-/۰.۵	-/۰.۷۴	F10-1-7	-/۳۱۷	-/۶۳۶	E5-1-1
-/۰.۲۶۷	-/۰.۲۸	F10-2-7	-/۰.۷۸۶	-/۰.۸۲۱	E5-2-1
-/۰.۲۶	-/۰.۵۱	F10-3-7	-/۰.۱۹۸	-/۰.۲۲۸	E5-3-1
-/۰.۷۵	-/۱۵	F10-1-8	-/۰.۸	-/۱۴۸	E5-1-2
-/۰.۳۷	-/۰.۵۵	F10-2-8	-/۰.۱۹۳	-/۰.۲۸۶	E5-2-2
-/۰.۵۲	-/۰.۶۵	F10-3-8	-/۰.۲۲	-/۰.۴	E5-3-2
-/۰.۳۶	-/۰.۴۱۶	F10-1-9	-/۱۷۹	-/۱۷۹۹	E5-1-3
-/۰.۴۲۷	-/۰.۳۸	F10-2-9	-/۰.۴۴۳	-/۰.۵۳۹	E5-2-3
-/۰.۳۳۸	-/۰.۴۸۷	F10-3-9	-/۰.۴۴۸	-/۰.۵۳۶	E5-3-3
-/۰.۵۵	-/۱۱۳۲	F10-1-10	-/۰.۸۹۶	-/۱۵۹	E5-1-4
-/۰.۳۱	-/۰.۵۲	F10-2-10	-/۰.۴۳۴	-/۰.۵	E5-2-4
-/۰.۴۷	-/۰.۵۴	F10-3-10	-/۰.۲۹۳	-/۰.۴۷۱	E5-3-4
-/۰.۳۸	-/۰.۸۸	F10-1-11	-/۱۱۷۹	-/۱۵۸	E5-1-5
-/۰.۴۱	-/۰.۵۳	F10-2-11	-/۰.۲۱۲	-/۰.۵۱۵	E5-2-5
-/۰.۲۴	-/۰.۴۲۵	F10-3-11	-/۰.۱۶۶	-/۰.۲۷۵	E5-3-5
-/۰.۸۷	-/۱۱۶۳	F10-1-12	-/۰.۷۲۲	-/۱۱۲	E5-1-6
-/۰.۳۷۱	-/۰.۵۳۹	F10-2-12	-/۰.۳۸۷	-/۰.۵۶	E5-2-6
-/۰.۳۹	-/۰.۴۷۶	F10-3-12	-/۰.۲۲۷	-/۰.۳۳۶	E5-3-6
-/۰.۳۳۸۶	-/۰.۷۵	F5-1-1			
-/۰.۲۵۵	-/۰.۶	F5-2-1			
-/۰.۳۱۸	-/۰.۵۶	F5-3-1			
-/۰.۹	-/۱۱	F5-1-2			
-/۰.۳۷۶	-/۰.۶۲۹	F5-2-2			
-/۰.۲۹	-/۰.۴۷۳	F5-3-2			
-/۰.۵۱۶	-/۰.۷	F5-1-3			
-/۰.۱۶۸	-/۰.۳۱	F5-2-3			
-/۰.۱۷۸	-/۰.۲۷	F5-3-3			
-/۰.۸۶	-/۱	F5-1-4			
-/۰.۲۳	-/۰.۴۷۱	F5-2-4			
-/۰.۲۲	-/۰.۴۷	F5-3-4			
-/۰.۷۴	-/۱۴۸	F5-1-5			
-/۰.۲۴	-/۰.۳۶۲	F5-2-5			
-/۰.۱۵	-/۰.۲۶۸	F5-3-5			
-/۰.۵۴۶	-/۱.۰۱	F5-1-6			
-/۰.۴۷	-/۰.۵۴	F5-2-6			
-/۰.۶۱	-/۰.۶۲۷	F5-3-6			

ارزیابی کارایی الگوریتم توسعه یافته در تخمین ضریب زبری


بررسی دقت تخمین ضریب زبری ماینینگ در سناریوی اول

در سناریوی اول صرفاً از تصاویر برداشت شده از جویچه‌ها برای طبقه‌بندی استفاده شد و تأثیر پارامترهای اندازه‌گیری شده در مزرعه نظیر دبی، شیب و غیره نادیده گرفته شد. جدول (۷) مقادیر شاخص‌های دقت (Accuracy)، یادآوری (Recall) و صحت (Precision) را در ارزیابی عملکرد طبقه‌بندی‌های مختلف (آموزش و آزمون الگوریتم توسط روش K-fold انجام شد و K برابر ۱۰ در نظر گرفته شد) نشان می‌دهد. نتایج نشان داد که در سناریوی اول، روش جنگل تصادفی (RF) با شاخص‌های accuracy، recall و precision برابر با ۰.۶۰ و ۰.۶۰ و ۰.۵۵ درصد، بهترین عملکرد را در طبقه‌بندی داده‌ها داشته است (شکل ۴). پس از این روش، روش‌های k نزدیک‌ترین همسایه (KNN) و درخت تصمیم (CART) به ترتیب بیش‌ترین دقت را در تخمین کلاس ضریب زبری ماینینگ از خود نشان دادند.


جدول ۷. میانگین شاخص‌های دقت، صحت و یادآوری روش K-fold در ارزیابی عملکرد روش‌های یادگیری ماشین

سناریو	LR	LDA	KNN	CART	RF	NB	SVM	MLP
سناریوی اول	accuracy: ۰/۳۲	accuracy: ۰/۳۹	accuracy: ۰/۴۰	accuracy: ۰/۳۷	accuracy: ۰/۶۰	accuracy: ۰/۲۳	accuracy: ۰/۱۷	accuracy: ۰/۳۷
	recall: ۰/۲۳	recall: ۰/۳۹	recall: ۰/۴۱	recall: ۰/۳۹	recall: ۰/۶۰	recall: ۰/۲۴	recall: ۰/۱۷	recall: ۰/۳۳
	precision: ۰/۲۵	precision: ۰/۳۹	precision: ۰/۴۰	precision: ۰/۳۷	precision: ۰/۵۵	precision: ۰/۲۹	precision: ۰/۱۹	precision: ۰/۳۳
سناریوی دوم	accuracy: ۰/۳۰	accuracy: ۰/۳۸	accuracy: ۰/۴۵	accuracy: ۰/۳۷	accuracy: ۰/۳۷	accuracy: ۰/۲۴	accuracy: ۰/۴۰	accuracy: ۰/۴۰
	recall: ۰/۲۸	recall: ۰/۳۵	recall: ۰/۴۳	recall: ۰/۳۴	recall: ۰/۳۵	recall: ۰/۲۱	recall: ۰/۳۷	recall: ۰/۲۸
	precision: ۰/۲۹	precision: ۰/۳۸	precision: ۰/۴۵	precision: ۰/۳۸	precision: ۰/۳۸	precision: ۰/۳۴	precision: ۰/۳۷	precision: ۰/۴۱
سناریوی سوم	accuracy: ۰/۴۴	accuracy: ۰/۵۰	accuracy: ۰/۷۱	accuracy: ۰/۸۵	accuracy: ۰/۸۵	accuracy: ۰/۳۰	accuracy: ۰/۴۵	accuracy: ۰/۵۵
	recall: ۰/۴۶	recall: ۰/۵۱	recall: ۰/۷۳	recall: ۰/۸۶	recall: ۰/۸۸	recall: ۰/۳۶	recall: ۰/۴۴	recall: ۰/۵۶
	precision: ۰/۴۳	precision: ۰/۵۳	precision: ۰/۷۲	precision: ۰/۸۵	precision: ۰/۸۵	precision: ۰/۳۷	precision: ۰/۴۱	precision: ۰/۵۶


Machine Learning algorithm comparison (accuracy)



Machine Learning algorithm comparison (precision)



Machine Learning algorithm comparison (recall)



شکل ۴. مقایسه مقادیر شاخص‌های Precision، Accuracy و Recall در سناریوی اول

دقت پایین روش‌های مختلف یادگیری ماشین در این سناریو قابل پیش‌بینی بود، چراکه تصاویر برداشت شده از جویچه با وجود

اطلاعات فراوانی که در رابطه با فاز آبیاری، شماره رخداد آبیاری، اندازه و تعداد کلوخه‌ها، سطح مقطع جویچه، ساختار و ساختمان خاک، اندازه درز و ترک‌ها و غیره می‌توانند ارائه نمایند، هیچ‌گونه اطلاعاتی در ارتباط با دبی جریان، شیب، سطح مقطع و محیط خیس شده جریان و غیره در اختیار قرار نمی‌دهند. این در حالی است که این پارامترها در ضریب زبری مانینگ بسیار تأثیرگذارند (Kamali et al., 2018; Sepaskhah & Bondar, 2002; Mailapalli et al., 2008). به بیان دیگر، الگوریتم توسط این داده‌های ورودی به تنهایی نمی‌تواند به درستی آموزش ببیند چراکه دیگر پارامترهای اثرگذاری وجود دارند که حضور آنها به منظور افزایش همبستگی بین داده‌های ورودی و ضریب زبری مانینگ ضروری است. در واقع داده‌های هیدرولیکی و مزرعه‌ای اطلاعاتی را در اختیار الگوریتم قرار می‌دهند که همراه با تصاویر، می‌تواند منجر به افزایش همبستگی بین داده‌های ورودی و ضریب زبری مانینگ و در نتیجه افزایش کارایی الگوریتم گردد. پس از تشخیص بهترین روش، با تقسیم کل داده به دو بخش آموزش و آزمون، کارایی روش جنگل تصادفی در سناریو اول در طبقه‌بندی ضریب زبری در هر کلاس مورد ارزیابی قرار گرفت (جدول ۸). مطابق با نتایج این جدول فقط در کلاس ۶ شاخص‌های دقت در طبقه‌بندی برابر با ۱۰۰ درصد بود و سایر کلاس‌ها دقت پایین‌تری داشتند. میانگین شاخص‌های precision، recall و F1-score در تمام کلاس‌ها به ترتیب برابر با ۷۴، ۶۵ و ۶۶ درصد تعیین شد که نشان از دقت نسبتاً پایین الگوریتم در این سناریو داشت.

جدول ۸. میانگین شاخص‌های precision، recall و F1-score در کلاس‌های مختلف با استفاده از طبقه بند جنگل تصادفی در سناریوی اول

کلاس	precision	recall	F1-score	تعداد داده در نظر گرفته شده در کلاس
۰	۰/۵۸	۰/۶۹	۰/۶۳	۱۶
۱	۱	۰/۶	۰/۷۵	۵
۲	۰/۵	۰/۴۵	۰/۴۸	۱۱
۳	۱	۰/۲	۰/۳۳	۱۵
۴	۰/۶۲	۰/۷۷	۰/۶۹	۳۱
۵	۰/۵۷	۰/۷۵	۰/۶۵	۲۸
۶	۱	۱	۱	۸
۷	۱	۰/۵۷	۰/۷۳	۲۱
۸	۰/۴۶	۰/۶۷	۰/۵۵	۹
۹	۰/۶۷	۰/۷۷	۰/۷۱	۱۳
۱۰	۰/۶۷	۰/۶۷	۰/۶۷	۳
۱۱	۰/۶۹	۰/۶۹	۰/۶۹	۲۹
۱۲	۰/۵۴	۰/۴۴	۰/۴۸	۱۶
۱۳	۰/۶۳	۰/۹۴	۰/۷۵	۳۱
۱۴	۰/۷۵	۰/۶۹	۰/۷۲	۱۳
۱۵	۰/۱۸	۰/۶۲	۰/۷	۱۳
۱۶	۰/۷۹	۰/۵۲	۰/۶۳	۲۱
۱۷	۰/۱۸	۰/۶۷	۰/۷۳	۶
۱۸	۱	۰/۶	۰/۷۵	۵
میانگین	۰/۷۴	۰/۶۵	۰/۶۶	۲۹۶

جدول (۹) ماتریس اغتشاش روش جنگل تصادفی را در طبقه‌بندی داده‌های زبری در سناریوی اول نشان می‌دهد. نتایج نشان داد که الگوریتم در اکثر کلاس‌ها، نتوانسته است کلاس درست داده‌ها تشخیص دهد و در طبقه‌بندی صحیح، موفق نبوده است. از آنجا که تفسیر تصاویر به صورت مجزا و بدون توجه به داده‌برداری‌های مزرعه‌ای بسیار دشوار است، بررسی علت دقیق این پراکندگی تا حدودی مشکل است اما این دقت پایین احتمالاً به دلیل تأثیر کمبود داده مورد نیاز می‌باشد. در واقع ممکن است دو نمونه به لحاظ شکل و بستر جویچه در تصاویر شبیه به هم تشخیص داده شوند در حالی که با توجه به دبی ورودی، شیب و غیره در کلاس‌های متفاوتی به لحاظ مقدار ضریب زبری قرار داشته باشند. وجود چنین شرایطی سبب می‌شود تا همبستگی بین داده‌های ورودی و پارمتر هدف (ضریب زبری مانینگ) و در نتیجه دقت و کارایی الگوریتم کاهش یابد.

جدول ۹. ماتریس اغتشاش الگوریتم توسعه یافته در سناریوی اول

کلاس (واقعی)																		
۱۸	۱۷	۱۶	۱۵	۱۴	۱۳	۱۲	۱۱	۱۰	۹	۸	۷	۶	۵	۴	۳	۲	۱	۰
۰	۰	۱	۱	۰	۱	۱	۱	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۱۱
۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۲	۰	۰	۳	۰	۱
۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۴	۲	۰	۵	۰	۲
۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۴	۷	۳	۱	۰	۳
۰	۰	۰	۰	۰	۰	۰	۰	۱	۰	۰	۰	۰	۵	۲۴	۰	۱	۰	۴
۰	۰	۰	۰	۰	۰	۰	۱	۰	۰	۰	۰	۰	۲۱	۳	۰	۳	۰	۵
۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۸	۰	۰	۰	۰	۰	۶
۰	۰	۰	۰	۰	۰	۰	۰	۱	۴	۱۲	۰	۱	۳	۰	۰	۰	۰	۷
۰	۰	۰	۰	۰	۰	۰	۰	۳	۶	۰	۰	۰	۰	۰	۰	۰	۰	۸
۰	۰	۰	۰	۰	۰	۰	۰	۱۰	۳	۰	۰	۰	۰	۰	۰	۰	۰	۹
۰	۰	۰	۰	۰	۰	۱	۰	۲	۰	۰	۰	۰	۰	۰	۰	۰	۰	۱۰
۰	۰	۰	۰	۰	۵	۲	۲۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۲	۱۱
۰	۰	۰	۰	۲	۵	۷	۱	۰	۰	۰	۰	۰	۰	۰	۰	۰	۱	۱۲
۰	۰	۰	۰	۰	۲۹	۰	۱	۰	۰	۰	۰	۰	۰	۰	۰	۰	۱	۱۳
۰	۰	۰	۰	۹	۳	۰	۱	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۱۴
۰	۰	۱	۸	۱	۰	۱	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۲	۱۵
۰	۱	۱۱	۱	۰	۲	۰	۵	۰	۰	۰	۰	۰	۰	۰	۰	۰	۱	۱۶
۰	۴	۰	۰	۰	۱	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۱	۱۷
۳	۰	۱	۰	۰	۰	۱	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۱۸

کلاس (پیش‌بینی)

جدول (۱۰) نمونه‌ای از تصاویر برداشت شده از جویچه‌ها را در کلاس ۱۶ و کلاس‌های ۰، ۱۱، ۱۳ و ۱۵ نشان می‌دهد. همان‌طور که بیان شد، الگوریتم توسعه داده شده نمونه‌ها را در کلاس‌های ۱۶، ۱۵، ۱۳، ۱۱ و ۰ طبقه‌بندی نموده است. این در حالی است که تمام نمونه‌ها می‌بایست در کلاس ۱۶ قرار گیرند. بررسی تصاویر سطح جویچه در کلاس‌های غلط نشان می‌دهد که این کلاس‌ها به لحاظ شکل بستر جویچه، تفاوت زیادی با یکدیگر ندارند. به عنوان نمونه تصویر نشان داده در جدول (۱۰) که مربوط به کلاس ۱۵ می‌باشد، همانند تصویر متناظر آن در کلاس ۱۶، مربوط به فاز پیشروی و آبیاری اول می‌باشد. تصویر دوم در کلاس ۱۶ که متناظر با تصویر جویچه کلاس ۱۳ می‌باشد نیز دارای وضعیت بستر نسبتاً مشابهی هستند و فاز و رخداد آبیاری در آن به درستی انتخاب شده است. تصویر چهارم در کلاس ۱۶، مربوط به آبیاری سوم و قبل از آبیاری است اما از آنجا که جویچه هنوز کاملاً خشک نشده و رنگ خاک تیره‌تر بود، الگوریتم تصویر متناظر با آن را در کلاس صفر و فاز ذخیره تشخیص داده است. به بیان دیگر آموزش شبکه نسبتاً مناسب بوده است اما از آنجا که اطلاعات مهم و تأثیرگذار بر ضریب زبری مانند دبی ورودی، شیب و غیره در دسترس نبوده است، طبقه‌بندی با مشکل مواجه شده است و نتوانسته است علی‌رغم استخراج ویژگی‌های بسیار مناسب از تصاویر، دقت مناسبی در تخمین ضریب زبری مانینگ داشته باشد.

بررسی دقت تخمین ضریب زبری مانینگ در سناریوی دوم

در سناریوی دوم، تمام داده‌های برداشت شده مزرعه‌ای که شامل: داده‌های دبی ورودی، دبی خروجی، زمان پیشروی، زمان پسروی، حجم آب نفوذ یافته، شماره رخداد آبیاری، رطوبت اولیه خاک، شیب، سرعت نفوذ نهایی، شاخص تعداد و اندازه کلوخه‌ها قبل و بعد از آبیاری، شوری و اسیدیته خاک، سطح مقطع جویچه و خیس شده جریان و محیط خیس شده بودند، در نظر گرفته شدند و از تأثیر تصاویر صرف نظر شد. نتایج نشان داد که روش k نزدیک‌ترین همسایه (KNN) با شاخص‌های Accuracy، Precision و Recall برابر با ۴۵، ۴۳ و ۴۵ درصد بیش‌ترین دقت را در طبقه‌بندی نمونه‌های ضریب زبری در این سناریو داشته است (جدول ۷).

بررسی شاخص‌های ارزیابی عملکرد طبقه‌بندی نشان داد که همه روش‌ها در طبقه‌بندی داده‌های ضریب زبری مانینگ بر اساس داده‌های اندازه‌گیری شده در مزرعه ناموفق بوده‌اند چراکه تأثیر نوع بافت و ساختمان خاک، درز و شکاف‌های خاک، مقدار خیس شدگی، عوارض موجود در بستر جویچه و غیره بر ضریب زبری در نظر گرفته نشده است و این موضوع منجر به کاهش دقت طبقه‌بندی‌ها شده





است. در مجموع باید بیان نمود که تصاویر در طبقه‌بندی ضریب زبری توسط الگوریتم ارائه شده از اهمیت ویژه‌ای برخوردار است و امکان حذف آن از فرایند یادگیری وجود ندارد.

جدول ۱۰. نمونه‌ای از تصاویر برداشت شده از سطح جویچه در سناریوی اول که در کلاس ۱۶، ۱۵، ۱۳، ۱۱ و + طبقه‌بندی شدند

مشخصات جویچه	کلاس	تصویر	تصویر	کلاس	مشخصات جویچه
F5-1-2	۱۶			۱۵	E5-1-6
F10-3-6	۱۶			۱۳	F10-3-10
E10-2-6	۱۶			۱۱	E10-2-2
E10-3-6	۱۶			+	E10-3-2

یکی دیگر از دلایل مهمی که کارایی این سناریو را تا حد زیادی کاهش داده است به نوع تعریف کلاس‌ها بر می‌گردد. با توجه به اینکه در این تحقیق به جهت سهولت تشخیص کلاس‌ها، زبری قبل و بعد از آبیاری به شکل مجزا تقسیم‌بندی و کلاس‌بندی شدند، ممکن است دو نمونه علی‌رغم داشتن دو فاز متفاوت، مقداری یکسان برای ضریب زبری داشته باشند و در نتیجه در دو کلاس مختلف قرار گیرند (جدول ۱۱). از آنجا که داده‌های مزرعه‌ای اطلاعاتی در ارتباط با فاز آبیاری و وضعیت بستر جویچه ارائه ننموده‌اند، الگوریتم نتوانسته است به شکل مناسبی نمونه‌ها را طبقه‌بندی نماید.

جدول ۱۱. نمونه‌ای از تصاویر و اطلاعات جویچه‌های مورد بررسی در سناریوی سوم

کلاس	زبری	دبی ورودی (لیتر بر ثانیه)	تصویر	جویچه
۱۰	۰/۰۲۵۵	۰/۴۳		F10-2-4
۱	۰/۰۲۵۵	۰/۴۳		F5-2-1

بررسی دقت تخمین ضریب زبری مانینگ در سناریوی سوم

در سناریوی سوم، از تصاویر برداشت شده از سطح جویچه و برخی داده‌های مزرعه‌ای که عبارت‌اند از: دبی ورودی، شیب، سطح مقطع جویچه، شماره رخدادهای آبیاری و شاخص اندازه کلوخه‌ها قبل از آبیاری، استفاده شد. نتایج اعتبارسنجی در هر ده fold مورد بررسی نشان داد که روش RF با مقادیر شاخص‌های Accuracy، Precision و Recall برابر با ۸۵، ۸۸ و ۸۵ درصد و روش CART با میانگین شاخص‌های برابر با ۸۵، ۸۶ و ۸۵ درصد مناسب‌ترین عملکرد را داشته‌اند (جدول ۷). (Adab et al., 2020) الگوریتم جنگل تصادفی را در تخمین میزان رطوبت خاک، به عنوان مناسب‌ترین روش معرفی نموده و بیان کردند که ارائه داده‌های کمکی به الگوریتم (علاوه بر تصاویر) می‌تواند دقت و کارایی این روش را افزایش دهد.



جدول ۱۲. میانگین شاخص‌های precision، recall و F1-score در کلاس‌های مختلف با استفاده از طبقه بند جنگل تصادفی در سناریوی سوم

کلاس	precision	recall	F1-score	تعداد داده در نظر گرفته شده در کلاس
۰	۰/۸۹	۱	۰/۹۴	۱۷
۱	۱	۰/۸	۰/۸۹	۵
۲	۰/۷۷	۱	۰/۸۷	۱۰
۳	۰/۹۳	۰/۸۷	۰/۹	۱۵
۴	۰/۹۴	۰/۹۷	۰/۹۶	۳۴
۵	۱	۰/۹۶	۰/۹۸	۲۸
۶	۱	۱	۱	۸
۷	۱	۰/۸۵	۰/۹۲	۲۰
۸	۰/۸۶	۱	۰/۹۲	۶
۹	۱	۱	۱	۱۴
۱۰	۱	۱	۱	۳
۱۱	۱	۱	۱	۲۳
۱۲	۱	۱	۱	۱۵
۱۳	۰/۹۴	۰/۸۶	۰/۹	۳۵
۱۴	۰/۹۳	۱	۰/۹۷	۱۴
۱۵	۰/۹۴	۱	۰/۹۷	۱۶
۱۶	۰/۸۹	۰/۸۹	۰/۸۹	۱۸
۱۷	۱	۱	۱	۸
۱۸	۱	۱	۱	۷
میانگین	۰/۹۵	۰/۹۶	۰/۹۵	مجموع ۲۹۶

با آموزش و تست روش RF و CART که بهترین نتایج را داشتند مشخص شد که روش CART با میانگین شاخص‌های precision، recall و F1-score برابر با ۹۵، ۹۶ و ۹۵ درصد در هر ۱۹ کلاس، دقیق‌ترین طبقه‌بندی داده را ارائه نموده‌اند (جدول ۱۲). این نتایج نشان داد که سایر پارامترهای مزرعه‌ای نظیر سطح مقطع و محیط خیس شده جریان، شوری، اسیدیته، رطوبت قبل از آبیاری، شاخص اندازه و تعداد کلوخه‌ها بعد از آبیاری و غیره (و سایر پارامترهای در نظر گرفته نشده نسبت به سناریو اول) با توجه به در نظر گرفتن توأمان تصاویر و برخی داده‌های مزرعه‌ای، از اهمیت نسبتاً پایینی برخوردارند و می‌توانند به منظور افزایش سرعت در تخمین و طبقه‌بندی نمونه‌های زبری حذف شوند. علاوه بر این اندازه‌گیری این پارامترها در مزرعه بسیار دشوار و زمان‌بر بوده و در نظر نگرفتن آن‌ها منجر به کاهش هزینه و زمان لازم برای داده‌برداری می‌شود.

جدول (۱۳) ماتریس اغتشاش روش CART در طبقه‌بندی نمونه‌های زبری را نشان می‌دهد. نتایج نشان داد که طبقه‌بندی در کلاس‌های ۱، ۳، ۴، ۵، ۷، ۱۳ و ۱۶ در برخی نمونه‌ها با خطا همراه بوده است؛ که از این بین، الگوریتم در کلاس ۱۳ از مجموع ۳۵ نمونه، ۳۰ نمونه را در کلاس صحیح، ۱ نمونه را در کلاس ۱۴، ۱ نمونه را در کلاس ۴، یک نمونه را در کلاس ۳ و دو نمونه را در کلاس صفر طبقه‌بندی نموده است؛ که نسبت به سایر کلاس‌ها پراکندگی طبقه‌بندی‌های غیر صحیح بیش‌تر است.

جدول (۱۴) نمونه تصاویر برداشت شده از جویچه‌ها را در کلاس ۱۳ و سایر کلاس‌هایی که نمونه‌ی کلاس ۱۳ به اشتباه در آن‌ها طبقه‌بندی شده است، نشان می‌دهد. در کلاس ۱۳ الگوریتم نتوانسته است فاز آبیاری صحیح را تشخیص دهد و به‌جز نمونه طبقه‌بندی شده در کلاس ۱۴، سایر نمونه‌های جانمایی شده در کلاس غیر صحیح، در کلاس با فاز ذخیره قرار گرفته‌اند؛ به عبارت دیگر، کلاس ۱۳ مربوط به فاز پیشروی و جویچه‌های خشک بوده است. در حالی که الگوریتم ۴ نمونه از ۳۵ نمونه تست شده را در کلاس‌های با فاز ذخیره طبقه‌بندی نموده است. برعکس این نوع طبقه‌بندی در کلاس ۷ هم مشاهده شده است. در سایر کلاس‌های دارای طبقه‌بندی غلط، حداقل فاز آبیاری به درستی تشخیص داده شده است. علت این‌گونه طبقه‌بندی نادرست به دلیل پیچیدگی الگوریتم و ماهیت آن، مشخص نیست





اما همان‌طور که پیش‌تر اشاره شد از اثرات عدم قطعیت در تخمین ضریب زبری مانینگ و بروز این‌گونه خطاها نمی‌توان چشم‌پوشی کرد.

جدول ۱۳. ماتریس اغتشاش الگوریتم توسعه یافته در سناریوی سوم




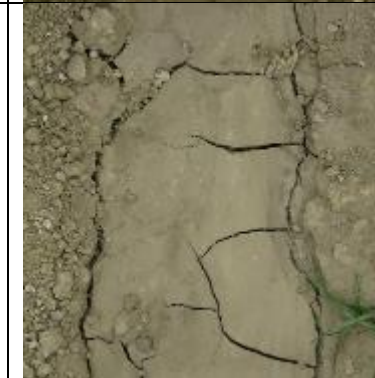
کلاس (واقعی)																		
۱۸	۱۷	۱۶	۱۵	۱۴	۱۳	۱۲	۱۱	۱۰	۹	۸	۷	۶	۵	۴	۳	۲	۱	۰
۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۱۷
۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۱	۰	۰	۴	۱
۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۱۰	۰	۰	۲
۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۱۳	۲	۰	۰	۳
۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۳۳	۰	۱	۰	۰	۴
۰	۰	۰	۰	۰	۰	۰	۰	۰	۱	۰	۰	۲۷	۰	۰	۰	۰	۰	۵
۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۸	۰	۰	۰	۰	۰	۰	۰	۶
۰	۰	۲	۱	۰	۰	۰	۰	۰	۰	۰	۱۷	۰	۰	۰	۰	۰	۰	۷
۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۶	۰	۰	۰	۰	۰	۰	۰	۸
۰	۰	۰	۰	۰	۰	۰	۰	۰	۱۴	۰	۰	۰	۰	۰	۰	۰	۰	۹
۰	۰	۰	۰	۰	۰	۰	۰	۳	۰	۰	۰	۰	۰	۰	۰	۰	۰	۱۰
۰	۰	۰	۰	۰	۰	۲۳	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۱۱
۰	۰	۰	۰	۰	۱۵	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۱۲
۰	۰	۰	۰	۱	۳۰	۰	۰	۰	۰	۰	۰	۰	۰	۱	۱	۰	۲	۱۳
۰	۰	۰	۰	۱۴	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۱۴
۰	۰	۰	۱۶	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۱۵
۰	۰	۱۶	۰	۰	۲	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۱۶
۰	۸	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۱۷
۷	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۱۸

کلاس (تخمینی)

جدول ۱۴. نمونه‌ای از تصاویر برداشت شده از سطح جویچه در سناریوی سوم که در کلاس ۱۳، ۱۴، ۴، ۳ و ۰ طبقه‌بندی شدند

مشخصات جویچه	کلاس	تصویر	مشخصات جویچه	کلاس	تصویر
E5-2-3	۱۳		E5-2-2	۰	
E5-2-6	۱۳		E10-1-1	۳	

ادامه جدول ۱۴

F5-2-1 ۱۳			F5-2-6 ۴
F5-2-6 ۱۳			F10-3-8 ۱۴

نتیجه‌گیری

تخمین دقیق ضریب زبری مانینگ که یکی از پارامترهای مهم در شبیه‌سازی و طراحی سیستم‌های آبیاری سطحی است، همواره به دلیل پیچیدگی‌های آن چالش‌برانگیز بوده است. تاکنون مدل‌ها و روش‌های متعددی برای تخمین این ضریب پیشنهاد شده‌اند، اما بیشتر این روش‌ها یا دقت کافی ندارند یا بسیار زمان‌بر و پرهزینه هستند. تحقیقات پیشین نشان می‌دهند که با استفاده از تکنیک‌های یادگیری ماشین و پردازش تصویر، می‌توان پیچیدگی‌های این محاسبات را با استخراج ویژگی‌های مرتبط از تصاویر سطح خاک تا حد زیادی کاهش داد. در این پژوهش، هدف اصلی بررسی کارایی این تکنیک‌ها در تخمین ضریب زبری مانینگ در سیستم آبیاری جویچه‌ای در فازهای پیشروی و ذخیره بود. بدین منظور، الگوریتمی بر پایه تکنیک‌های پردازش تصویر و یادگیری ماشین طراحی و در سه سناریوی مختلف توسعه یافت: (i) استفاده از تصاویر، (ii) استفاده فقط از داده‌های میدانی و (iii) استفاده از تصاویر به همراه برخی داده‌های منتخب میدانی.

نتایج نشان داد که ضریب زبری مانینگ در جویچه‌های با طول کوتاه در فاز پیشروی نسبت به فاز ذخیره مقدار بسیار بالاتری دارد که این موضوع اهمیت بررسی تغییرات زمانی ضریب زبری را طی یک رخداد آبیاری برجسته‌تر می‌کند. الگوریتم توسعه یافته که قابلیت تخمین ضریب زبری مانینگ در فازهای پیشروی و ذخیره و در رخدادهای مختلف آبیاری را داراست، در سناریوهای اول و دوم (که به ترتیب از تأثیر داده‌های مزرعه‌ای و تصاویر در آن‌ها صرف‌نظر شده بود) عملکرد مناسبی در طبقه‌بندی نداشته است. چراکه در هر یک از این سناریوها پارامترهای بسیار مؤثر بر ضریب زبری از فرایند یادگیری کنار گذاشته شده بودند و منجر به کاهش دقت الگوریتم شدند؛ در سناریوی سوم که همزمان از داده‌های مزرعه‌ای و تصاویر استفاده شد، دقت قابل‌قبولی در تخمین ضریب زبری در فازهای مختلف آبیاری مشاهده شد و به عنوان سناریوی برتر برای تخمین زبری معرفی گردید.

اگرچه الگوریتم در جویچه‌های بدون پوشش گیاهی ضریب زبری مانینگ را با دقت بالایی تخمین زد، اما استفاده بدون محدودیت از این الگوریتم در شرایط مختلف مزرعه‌ای همچنان با محدودیت‌هایی رو به رو است. چراکه در این مطالعه، برخی عوامل مانند پوشش

گیاهی نادیده گرفته شدند و تنها بازه‌ای محدود از متغیرهای مزرعه‌ای و هیدرولیکی در نظر گرفته شدند. علاوه بر این، طبقه‌بندی کردن مقادیر پیوسته ضریب زبری مانینگ، نیز یکی دیگر از عوامل ایجاد محدودیت در استفاده گسترده از الگوریتم توسعه یافته است که منجر به کاهش دقت تخمین زبری گردیده است. لذا لازم است تا مطالعات آینده پارامترهای گسترده‌تر و متنوع‌تری را شامل شوند و ضریب زبری نیز به صورت مقادیر پیوسته در نظر گرفته شود تا جامعیت و دقت تخمین زبری بیش از پیش افزایش یابد. مطالعات آینده همچنین باید بر حذف اثرات مقدار و شدت نور پردازی، نوع دوربین عکس برداری و زاویه و فاصله قرار گیری آن متمرکز شوند تا بتوان به توسعه نرم افزاری به‌هنگام، قابل اعتماد و دقیق برای تخمین ضریب زبری مانینگ و مدیریت سیستم آبیاری سطحی امیدوار بود.

سپاس‌گزاری

از حمایت مالی پارک علم و فناوری دانشگاه تهران از این تحقیق در قالب اعتبار شماره ۵۸۸۸۶۵۶ قدردانی می‌گردد.

"هیچ‌گونه تعارض منافع توسط نویسندگان وجود ندارد"

منابع

- تیموری، نیما. (۱۳۹۷). طراحی، ساخت و ارزیابی یک سامانه هوشمند به منظور درجه‌بندی قطعات مرغ بصورت بر خط با استفاده از فناوری بینایی سه بعدی. دانشگاه تهران.
- رضائی اعتدالی، هادی؛ لیاقت، عبدالمجید و عباسی، فریبرز. (۱۳۸۸). ارزیابی مدل Evaluate برای تخمین ضریب زبری مانینگ در آبیاری جویچه‌ای. *مجله تحقیقات مهندسی کشاورزی* ۱۰ (۳) ۸۳-۹۴.
- عباسی، فریبرز و ابراهیمیان، حامد. (۱۴۰۲). هیدرولیک آبیاری سطحی. انتشارات نشر دانشگاهی، چاپ اول، ۳۶۸ صفحه.
- عباسی، فریبرز. (۱۳۹۱). اصول جریان در آبیاری سطحی. کمیته ملی آبیاری و زهکشی ایران، ۲۳۲ صفحه.
- وردی‌نژاد، وحیدرضا؛ احمدی، حجت؛ همتی، محمد و ابراهیمیان، حامد. (۱۳۹۵). ارزیابی و مقایسه روش‌های مختلف تخمین پارامترهای نفوذ در سیستم‌های مختلف آبیاری جویچه‌ای و رژیم‌های مختلف جریان ورودی. *نشریه علوم آب و خاک*، ۲۰ (۷۶) ۱۶۱-۱۷۶.

REFERENCES

- Adab, H., Morbidelli, R., Saltalippi, C., Moradian, M., & Ghalhari, G. A. F. (2020). Machine learning to estimate surface soil moisture from remote sensing data. *Water (Switzerland)*, 12(11), 1–28. <https://doi.org/10.3390/w12113223>
- Amiri, M. J., Bahrami, M., Hamidifar, H., & Eslamian, S. (2016). Modification of furrow Manning's roughness coefficient estimation by finite difference technique under surge and continuous flow. *International Journal of Hydrology Science and Technology*, 6(3), 226–237. <https://doi.org/10.1504/IJHST.2016.077390>
- Angelaki, A., Singh Nain, S., Singh, V., & Sihag, P. (2018). Estimation of models for cumulative infiltration of soil using machine learning methods. *ISH Journal of Hydraulic Engineering*, 27(2), 162–169. <https://doi.org/10.1080/09715010.2018.1531274>
- Ansari, N., Ratri, S. S., Jahan, A., Ashik-e-rabbani, M., & Rahman, A. (2021). Inspection of paddy seed varietal purity using machine vision and multivariate analysis. *Journal of Agriculture and Food Research*, 3(December 2020), 100109. <https://doi.org/10.1016/j.jafr.2021.100109>
- Bahmani, O., Akhavan, S., Khoramian, M., & Gholizadeh Khalteh, Gh. (2020). Effect of Different Tillage Methods and furrow spacing on Soil Hydraulic Characteristics in Furrow Irrigation. *Irrigation Sciences and Engineering*, 43(1), 145–156. <https://doi.org/10.22055/jise.2018.24226.1712>
- Bautista, E., & Schlegel, J. L. (2017). Estimation of Infiltration and Hydraulic Resistance in Furrow Irrigation, with Infiltration Dependent on Flow Depth. *Transactions of the ASABE*, 60(6), 1873–1884. <https://doi.org/10.13031/trans.12263>
- Berkson, J. (1944). Application to the Logistic Function to Bio-Assay. *Journal of the American Statistical Association*, 39(227), 357. <https://doi.org/10.2307/2280041>
- Blei, D. M., Ng, A. Y., & Edu, J. B. (2003). Latent Dirichlet Allocation Michael I. Jordan. *Journal of Machine Learning Research*, 3, 993–1022.
- Boser, B. E., Guyon, I. M., & Vapnik, V. N. (1992). Training algorithm for optimal margin classifiers. *Proceedings of the Fifth Annual ACM Workshop on Computational Learning Theory*, 144–152.



<https://doi.org/10.1145/130385.130401>

- Breiman, L. (1984). Classification and Regression Trees . In *Chapter 7* (Issue January). Chapman and Hall/CRC.
- Breiman, L., Friedman, J. H., Olshen, R. A., & Stone, C. J. (1984). Classification and regression trees. In *Classification and Regression Trees*. CRC Press. <https://doi.org/10.1201/9781315139470/CLASSIFICATION-REGRESSION-TREES-LEO-BREIMAN>
- Brosnan, T., & Sun, D. W. (2004). Improving quality inspection of food products by computer vision - A review. *Journal of Food Engineering*, *61*, 3–16. [https://doi.org/10.1016/S0260-8774\(03\)00183-3](https://doi.org/10.1016/S0260-8774(03)00183-3)
- Brynnfsson, P., Löfstedt, T., Asklund, T., Nyholm, T., & Garpebring, A. (2018). PV-0527: Gray-level invariant Haralick texture features. *Radiotherapy and Oncology*, *127*, S279–S280. [https://doi.org/10.1016/S0167-8140\(18\)30837-5](https://doi.org/10.1016/S0167-8140(18)30837-5)
- Capra, A., & Scicolone, B. (2002). Estimation of Manning Roughness Coefficient for Bare and Vegetated Furrow Irrigation. *Biosystems Engineering*, *83*(1), 119–126. <https://doi.org/10.1006/bioe.2002.0092>
- Chung, S. O., Cho, K. H., Cho, J. W., Jung, K. Y., & Yamakawa, T. (2012). Soil Texture Classification Algorithm Using RGB Characteristics of Soil Images. *Journal of the Faculty of Agriculture Kyushu University*, *57*(2), 393–397.
- Clemmens, A. J., Eisenhauer, D. E., & Maheshwari, B. L. (2001). Infiltration and Roughness Equations for Surface Irrigation: How Form Influences Estimation. *ASAE Meeting Paper No. 01-2255*, 1–19.
- Cover, T. M., & Hart, P. E. (1967). Nearest Neighbor Pattern Classification. *IEEE Transactions on Information Theory*, *13*(1), 21–27. <https://doi.org/10.1109/TIT.1967.1053964>
- Díaz, R. G. (2005). Analysis of Manning coefficient for small-depth flows on vegetated beds. *Hydrological Processes*, *19*(16), 3221–3233. <https://doi.org/10.1002/hyp.5820>
- Dong, Q., Zhang, S., Bai, M., Xu, D., & Feng, H. (2018). Modeling the effects of spatial variability of irrigation parameters on border irrigation performance at a field scale. *Water (Switzerland)*, *10*(12). <https://doi.org/10.3390/w10121770>
- Esfandiari, M., & Maheshwari, B. L. (1998). Suitability of Selected Flow Equations and Variation of Manning's n in Furrow Irrigation. *Journal of Irrigation and Drainage Engineering*, *124*(2), 89–95. [https://doi.org/10.1061/\(ASCE\)0733-9437\(1998\)124:2\(89\)](https://doi.org/10.1061/(ASCE)0733-9437(1998)124:2(89))
- Friedman, N., Geiger, D., & Goldszmidt, M. (1997). Bayesian Network Classifiers . *Machine Learning*, *29*, 131–163.
- Gillies, M. H., & Smith, R. J. (2015). SISCO: surface irrigation simulation, calibration and optimisation. *Irrigation Science*, *33*(5), 339–355. <https://doi.org/10.1007/s00271-015-0470-8>
- Gilliot, J. M., Vaudour, E., & Michelin, J. (2017). Soil surface roughness measurement: A new fully automatic photogrammetric approach applied to agricultural bare fields. *Computers and Electronics in Agriculture*, *134*, 63–78. <https://doi.org/10.1016/j.compag.2017.01.010>
- Grassi, C. J. (1972). Infiltration Characteristics of Furrow Irrigation in Heavy-Textured Soil. Wageningen University.
- Han, Y., Song, T., Feng, J., & Xie, Y. (2021). Grayscale-inversion and rotation invariant image description with sorted LBP features. *Signal Processing: Image Communication*, *99*, 116491. <https://doi.org/10.1016/J.IMAGE.2021.116491>
- Haralick, R. M., Dinstein, I., & Shanmugam, K. (1973). Textural Features for Image Classification. *Transactions on Systems, Man and Cybernetics*, *SMC-3*(6), 610–621. <https://doi.org/10.1109/TSMC.1973.4309314>
- Harun-ur-Rashid, M. (1990). Estimation of Manning's roughness coefficient for basin and border irrigation. *Agricultural Water Management*, *18*, 29–33.
- Heermann, D. F., Wenstrom, R. J., & Evans, N. A. (1969). Prediction of Flow Resistance in Furrows from Soil Roughness. *TRANSACTIONS of the ASAE*, 482–489.
- Hu, M. K. (1962). Visual Pattern Recognition by Moment Invariants. *IRE Transactions on Information Theory*, *8*(2), 179–187. <https://doi.org/10.1109/TIT.1962.1057692>
- Kamali, P., Ebrahimian, H., & Parsinejad, M. (2018). Estimation of Manning roughness coefficient for vegetated furrows. *Irrigation Science*, *36*(6), 339–348. <https://doi.org/10.1007/s00271-018-0593-9>
- Kaplan, K., Kaya, Y., Kuncan, M., & Ertunç, H. M. (2020). Brain tumor classification using modified local binary patterns (LBP) feature extraction methods. *Medical Hypotheses*, *139*, 109696. <https://doi.org/10.1016/J.MEHY.2020.109696>
- Kassem, M. A., & Ghonimy, M. I. (2011). DETERMINATION OF MANNING ROUGHNESS COEFFICIENT FOR BORDER IRRIGATION SYSTEM. *Misr Journal of Agricultural Engineering*,

- 28(2), 302–323. <https://doi.org/10.21608/mj.2011.105095>
- Kumar, V., Vimal, B. K., Kumar, R., Kumar, R., & Kumar, M. (2014). Determination of soil pH by using digital image processing technique. *Journal of Applied and Natural Science*, 32(1), 0–4.
- Li, Z., & Zhang, J. (2001). Calculation of Field Manning's Roughness Coefficient. *Agricultural Water Management*, 49, 153–161.
- Maheshwari, B. L. (1992). Suitability of different flow equations and hydraulic resistance parameters for flows in surface irrigation: A review. *Water Resources Research*, 28(8), 2059–2066. <https://doi.org/10.1029/92WR00424>
- Mailapalli, D. R., Raghuvanshi, N. S., Singh, R., Schmitz, G. H., & Lennartz, F. (2008). Spatial and Temporal Variation of Manning's Roughness Coefficient in Furrow Irrigation. *Journal of Irrigation and Drainage Engineering*, 134(2), 185–192. [https://doi.org/10.1061/\(ASCE\)0733-9437\(2008\)134:2\(185\)](https://doi.org/10.1061/(ASCE)0733-9437(2008)134:2(185))
- Mauricio, G., Melecio, I., & Eduardo, R. (2015). Roughness Manning Coefficient Variation in Irrigation Open Channels by Changing Width and Roughness Surface in the Armfield C4MKII Equipment. *ASABE Annual International Meeting*, 1–8.
- Mazarei, R., Soltani Mohammadi, A., Ebrahimian, H., & Naseri, A. A. (2021). Temporal variability of infiltration and roughness coefficients and furrow irrigation performance under different inflow rates. *Agricultural Water Management*, 245, 106465. <https://doi.org/10.1016/j.agwat.2020.106465>
- Miao, Q., Shi, H., Gonçalves, J. M., & Pereira, L. S. (2015). Field assessment of basin irrigation performance and water saving in Hetao, Yellow River basin: Issues to support irrigation systems modernisation. *Biosystems Engineering*, 136, 102–116. <https://doi.org/10.1016/j.biosystemseng.2015.05.010>
- Mwendera, E. J., & Feyen, J. (1992). Estimation of depression storage and Manning's resistance coefficient from random roughness measurements. *Geoderma*, 52(3–4), 235–250. [https://doi.org/10.1016/0016-7061\(92\)90039-A](https://doi.org/10.1016/0016-7061(92)90039-A)
- Nie, W. B., Fei, L. J., & Ma, X. Y. (2014). Applied closed-end furrow irrigation optimized design based on field and simulated advance data. *Journal of Agricultural Science and Technology*, 16(2), 395–408.
- Nie, W.-B., Li, Y.-B., Zhang, F., Dong, S.-X., Wang, H., & Ma, X.-Y. (2018). A Method for Determining the Discharge of Closed-End Furrow Irrigation Based on the Representative Value of Manning's Roughness and Field Mean Infiltration Parameters Estimated Using the PTF at Regional Scale. *Water*, 10(12), 1825. <https://doi.org/10.3390/w10121825>
- Ojala, T., Pietikäinen, M., & Harwood, D. (1996). A comparative study of texture measures with classification based on featured distributions. *Pattern Recognition*, 29(1), 51–59. [https://doi.org/10.1016/0031-3203\(95\)00067-4](https://doi.org/10.1016/0031-3203(95)00067-4)
- Omid, M., Mahmoudi, A., & Omid, M. H. (2010). Development of pistachio sorting system using principal component analysis (PCA) assisted artificial neural network (ANN) of impact acoustics. *Expert Systems with Applications*, 37(10), 7205–7212. <https://doi.org/10.1016/j.eswa.2010.04.008>
- Peng, X., Horn, R., Peth, S., & Smucker, A. (2006). Quantification of soil shrinkage in 2D by digital image processing of soil surface. *Soil and Tillage Research*, 91(1–2), 173–180. <https://doi.org/10.1016/j.still.2005.12.012>
- Prakash, K., & Saradha, S. (2021). Efficient prediction and classification for cirrhosis disease using LBP, GLCM and SVM from MRI images. *Materials Today: Proceedings*. <https://doi.org/10.1016/J.MATPR.2021.03.418>
- Rahimi-ajdadi, F., Abbaspour-gilandeh, Y., & Mollazade, K. (2018). Development of a novel machine vision procedure for rapid and non-contact measurement of soil moisture content. *Measurement*, 121(Febuary), 179–189. <https://doi.org/10.1016/j.measurement.2018.02.060>
- Rahimi-Ajdadi, F., Gilandeh, Y. A., Mollazade, K., & Hasanzadeh, R. P. (2016). Application of machine vision for classification of soil aggregate size. *Soil and Tillage Research*, 162, 8–17. <https://doi.org/10.1016/j.still.2016.04.012>
- Ramezani Etedali, H., Ebrahimian, H., Abbasi, F., & Liaghat, A. (2011). Evaluating models for the estimation of furrow irrigation infiltration and roughness. *Spanish Journal of Agricultural Research*, 9(2), 641. <https://doi.org/10.5424/sjar/20110902-342-10>
- Ramezani Etedali, H., Liaghat, A., & Abbasi, F. (2012). Evaluation of The EVALUE Model for Estimating Manning's Roughness in Furrow Irrigation. *Irrigation and Drainage*, 61(3), 410–415. <https://doi.org/10.1002/ird.650>
- Rezaei Rad, H., Ebrahimian, H., Liaghat, A. et al. Temporal variation of Manning roughness coefficient in furrow irrigation and its relationship with various field parameters. *Appl Water Sci* 15, 7 (2025). <https://doi.org/10.1007/s13201-024-02334-9>



- Riegler-Nurscher, P., Prankl, J., & Vincze, M. (2019). Tillage Machine Control Based on a Vision System for Soil Roughness and Soil Cover Estimation. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 11754 LNCS, 201–210. https://doi.org/10.1007/978-3-030-34995-0_19
- Rodríguez, J. A., & Martos, J. C. (2010). SIPAR_ID: Freeware for surface irrigation parameter identification. *Environmental Modelling & Software*, 25(11), 1487–1488. <https://doi.org/10.1016/j.envsoft.2008.09.001>
- Rumelhart, D. E., & McClelland, J. L. (1986). *Parallel distributed processing: explorations in the microstructure of cognition*. MIT Press. <https://dl.acm.org/doi/10.5555/104279>
- Sabzi, S., Abbaspour-Gilandeh, Y., & Javadikia, H. (2017). The use of soft computing to classification of some weeds based on video processing. *Applied Soft Computing*, 56, 107–123. <https://doi.org/10.1016/j.asoc.2017.03.006>
- Salahou, M. K., Jiao, X., & Lü, H. (2018). Border irrigation performance with distance-based cut-off. *Agricultural Water Management*, 201(2016), 27–37. <https://doi.org/10.1016/j.agwat.2018.01.014>
- Sauzet, O., Cammas, C., Gilliot, J. M., Bajard, M., & Montagne, D. (2017). Development of a novel image analysis procedure to quantify biological porosity and illuvial clay in large soil thin sections. *Geoderma*, 292, 135–148. <https://doi.org/10.1016/j.geoderma.2017.01.004>
- Sedaghatdoost, A., & Ebrahimian, H. (2015). Calibration of infiltration, roughness and longitudinal dispersivity coefficients in furrow fertigation using inverse modelling with a genetic algorithm. *Biosystems Engineering*, 136, 129–139. <https://doi.org/10.1016/j.biosystemseng.2015.05.011>
- Segeren, A. G., & Trout, T. J. (1991). Hydraulic Resistance of Soil Surface Seals in Irrigated Furrows. *Soil Science Society of America Journal*, 55(3), 640–646. <https://doi.org/10.2136/sssaj1991.03615995005500030002x>
- Sepaskhah, A. R., & Bondar, H. (2002). Estimation of Manning Roughness Coefficient for Bare and Vegetated Furrow Irrigation. *Biosystems Engineering*, 82(3), 351–357. <https://doi.org/10.1006/bioe.2002.0076>
- Seyedzadeh, A., Panahi, A., Maroufpoor, E., & Singh, V. P. (2019). Development of an analytical method for estimating Manning's coefficient of roughness for border irrigation. *Irrigation Science*, 37(4), 523–531. <https://doi.org/10.1007/s00271-019-00631-9>
- Shit, P. K., Bhunia, G. S., & Maiti, R. (2015). Soil crack morphology analysis using image processing techniques. *Modeling Earth Systems and Environment*, 1(November), 1–7. <https://doi.org/10.1007/s40808-015-0036-z>
- Strelkoff, T. S., Clemmens, A. J., El-Ansary, M., & Awad, M. (1999). Surface-Irrigation Evaluation Models: Application To Level Basins In Egypt. *Transactions of the ASAE*, 42(4), 1027–1036. <https://doi.org/10.13031/2013.13250>
- Sudarsan, B., Ji, W., Biswas, A., & Adamchuk, V. (2016). Microscope-based computer vision to characterize soil texture and soil organic matter. *Biosystems Engineering*, 152, 41–50. <https://doi.org/10.1016/j.biosystemseng.2016.06.006>
- Taneja, P., Vasava, H. K., Daggupati, P., & Biswas, A. (2021). Multi-algorithm comparison to predict soil organic matter and soil moisture content from cell phone images. *Geoderma*, 385(December 2020), 114863. <https://doi.org/10.1016/j.geoderma.2020.114863>
- Teimouri, N., Dyrmann, M., Nielsen, P. R., Mathiassen, S. K., Somerville, G. J., & Jørgensen, R. N. (2018). Weed Growth Stage Estimator Using Deep Convolutional Neural Networks. *Sensors*, 18(5), 1–13. <https://doi.org/10.3390/S18051580>
- Teimouri, N., Omid, M., Mollazade, K., & Rajabipour, A. (2014). A novel artificial neural networks assisted segmentation algorithm for discriminating almond nut and shell from background and shadow. *Computers and Electronics in Agriculture*, 105, 34–43. <https://doi.org/10.1016/J.COMPAG.2014.04.008>
- Tesař, L., Shimizu, A., Smutek, D., Kobatake, H., & Nawano, S. (2008). Medical image analysis of 3D CT images based on extension of Haralick texture features. *Computerized Medical Imaging and Graphics*, 32(6), 513–520. <https://doi.org/10.1016/J.COMPMEDIMAG.2008.05.005>
- Trout, T. J. (1992). Furrow Flow Velocity Effect on Hydraulic Roughness. *Journal of Irrigation and Drainage Engineering*, 118(6), 981–987. [https://doi.org/10.1061/\(ASCE\)0733-9437\(1992\)118:6\(981\)](https://doi.org/10.1061/(ASCE)0733-9437(1992)118:6(981))
- Walker, W. R. (2003). SIRMOD III Surface Irrigation Simulation , Evaluation and Design Guide and Technical Documentation. Utah State University.
- Walker, W. R., & Skogerboe, G. V. (1987). *surface irrigation theory and practice* (1st ed.). prentice-hall. <https://hdl.handle.net/10568/36729>
- Webel, J., Gola, J., Britz, D., & Mücklich, F. (2018). A new analysis approach based on Haralick texture features for the characterization of microstructure on the example of low-alloy steels. *Materials*

Characterization, 144, 584–596. <https://doi.org/10.1016/J.MATCHAR.2018.08.009>

Zarakani, K., Remazani Etedali, H., & Daneshkar Arasteh, P. (2020). Estimation of infiltration parameters and Manning roughness coefficient under two continuous and cutback flows regims Keyvan. *Journal of Water and Soil Resources Conservation*, 9(2).

Persian References:

Abbasi, F. (2012). Principles of flow in surface irrigation. National Committee on Irrigation and Drainage of Iran, 232 pages. (in Persian)

Abbasi, F., & Ebrahimian, H. (2023). Hydraulics of surface irrigation. Academic Publishing Center, 1st edition, 368 pages. (in Persian)

Ramezani Etedali, H., Liaghat, A., & Abbasi, F. (2009). Evaluation of the Evaluate model for estimating Manning's roughness coefficient in furrow irrigation. *Journal of Agricultural Engineering Research*, 10(3), 83–94. (in Persian)

Timouri, N. (2018). Design, construct, and evaluate an intelligent system for online grading poultry parts using 3D vision technology. University of Tehran. (in Persian)

Vardinejad, V., Ahmadi, H., Hemmati, M., & Ebrahimian, H. (2016). Evaluation and comparison of different methods for estimating infiltration parameters in various furrow irrigation systems and inflow regimes. *Journal of Water and Soil Science*, 20(76), 161–176. (in Persian)