



Research Paper

Detection of wheat yellow rust disease using visible images and artificial neural network (laboratory study)

M. H. Saeidirad^{1*}, F. Afshari², R. Pakdel³, J. Baradaran Motie³, S. Zarifneshat¹ and N. Lovaimi⁵

¹ Department of Agricultural Engineering Institute, Khorasan Razavi Agricultural and Natural Resources Research and Education Center, AREEO, Mashhad, Iran.

² Seed and Plant Improvement Institute, Agricultural Research, Education and Extension Organization ,AREEO, Karaj, Iran.

³ Department of Biosystems Engineering, Faculty of Agriculture, Ferdowsi University of Mashhad, Iran.

⁴ Department of Agricultural Engineering Institute, Khoozestan Agricultural and Natural Resources Research and Education Center, AREEO, Ahvaz, Iran.

Article history

Submitted: 2024/11/10

Revised: 2024/11/23

Accepted: 2024/12/17

Published

online: 2025/03/21

Keywords:

Image Processing

Neural network

Wheat

Yellow rust.

Abstract

Yellow rust is one of the most important wheat diseases in Iran. One of the most critical aspects of managing yellow rust is the identification of infection foci in the field, as early detection and timely spraying can prevent disease spread and reduce yield losses. The objective of this study was to detect wheat yellow rust under laboratory conditions (using artificially induced infection) by employing visible-light camera images and image processing techniques. For laboratory sample preparation, a yellow rust-susceptible wheat cultivar (Bolani) was planted in pots with a diameter of 15 cm and maintained under controlled conditions. Artificial inoculation was performed at the seedling stage to induce infection. Images of infected plants were then captured, and image preprocessing and processing were conducted using MATLAB software. Various vegetation indices derived from visible images were evaluated, and the most suitable index for yellow rust detection was identified. To determine the most effective disease detection model, several classification methods were assessed, including supervised classification approaches such as self-organizing neural networks, learning vector quantization neural networks, radial basis function neural networks, support vector machines (SVM), multilayer perceptron neural networks, k-nearest neighbor classification, and k-means clustering. The results showed that red and green component reflectance indices ranked first and second, respectively, in discriminant analysis of laboratory samples. The SVM classifier achieved the highest accuracy among all methods, with classification accuracies of 98.06% in the training phase and 95.44% in the testing phase when applied to visible images.

*Corresponding author

email:

saedirad@yahoo.com

ORCID: 

0000-0001-8955-6811



How to cite this paper:

Saeidirad, M. H., Afshari, F., Pakdel, R., Baradaran Motie, J., Zarifneshat, S., and Lovaimi, N. (2025). Detection of wheat yellow rust disease using visible images and artificial neural network (laboratory study), *Journal of Research in Mechanics of Agricultural Machinery*. 34: 1-12. <https://dx.doi.org/10.22034/JRMAM.2024.15006.733>. (In Persian)



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

<https://dx.doi.org/10.22034/JRMAM.2024.15006.733>

EXTENDED ABSTRACT

Introduction

Yellow rust is one of the most important wheat diseases, caused by the *Puccinia striiformis f. sp. tritici* (*Pst*) fungus, substantially reducing yield and quality. Studies indicate that yellow rust reduces wheat production by approximately 15% on average. This disease periodically becomes epidemic, causing severe damage to wheat crops.

One of the most crucial aspects of combating yellow rust is identifying affected areas and foci within the field. If spraying is conducted in the early stages, the spread of the disease and its associated damage can be effectively mitigated. Initially, disease detection relied on visual inspection, which, despite its practicality, is time-consuming, costly, and prone to errors. Additionally, visual inspection can contribute to disease spread, further complicating control efforts. Due to these limitations, researchers have been striving to develop more precise and faster methods to enable accurate and timely identification, thereby minimizing the damage caused by this disease. In recent years, chemical and molecular techniques, such as polymerase chain reaction (PCR), have been employed for plant disease detection. While these methods provide high accuracy, they are destructive, time-consuming, and require specific chemical reagents.

With advancements in agricultural technology, image processing techniques have emerged as non-destructive and rapid approaches for detecting various plant diseases. Some of these methods include multispectral and hyperspectral imaging, infrared spectroscopy, and color imaging. Thus, the present study aims to identify yellow rust in wheat samples under laboratory conditions using visible image processing methods.

Material and Methods

For laboratory sample preparation, the Bolani variety was used. After planting,

inoculation of yellow rust fungus was performed on the leaves at the seedling stage. Once the samples were prepared, 50 leaves were cut from each wheat sample with a specific disease severity. For imaging, a Canon (PowerShot G9, Made in Japan) visible camera was utilized. The shooting angle was set at 90 degrees relative to the leaves, and images were captured from a distance of 20 cm. To execute the image processing procedure, pre-processing techniques such as Gaussian low-pass filtering and histogram expansion were applied using MATLAB software. A total of nine color indices were extracted based on the average RGB color components. Then, various vegetation indices were evaluated for visible images, and the most suitable index for diagnosing yellow rust disease was introduced.

Results and Discussion

A stepwise discriminant function analysis (DFA) method was employed to select and rank color indices and vegetation metrics. In this approach, the index that produces the lowest Wilks' lambda value in a univariate model is selected first, followed by the identification of additional indices that, when included, further reduce the Wilks' lambda value. A lower Wilks' lambda at the end of the analysis indicates higher model accuracy and classification quality. Indices that do not contribute to reducing Wilks' lambda are eliminated during this process. To implement this methodology, data from extracted indices of each image were recorded using SPSS 18 and analyzed via stepwise discriminant analysis. The indices were examined separately for wheat leaf samples with distinct infection levels (H: healthy, S10: tenth day of infection, ST: fully infected). The results of the stepwise discriminant analysis for pairwise differentiation of wheat leaf samples showed that the reflectance indices of the red and green components ranked first and second in the S-H10 and H10-ST comparisons. For the S-ST sample, the blue reflectance index ranked highest, followed by VDI, Blue, and

RED indices in second to fourth place. Consequently, the red reflectance index was identified as the optimal metric for distinguishing between samples. Additionally, NGDBA, NDGI, and TGI were ranked sixth to seventh across all three sample groups. The lowest Wilks' lambda values calculated for the S-H10, S-ST, and H10-ST comparisons were 0.098, 0.088, and 0.085, respectively, indicating relatively high classification accuracy.

In this study, several neural network classifiers were applied to classify wheat yellow rust, including the self-organizing map (SOM), learning vector quantization (LVQ), radial basis function (RBF), support vector machine (SVM), multilayer perceptron (MLP), k-nearest neighbor (KNN), and k-means clustering. The evaluation of these neural networks revealed that their accuracy during the training phase exceeded 86.05%. Among them, SVM, MLP, and KNN demonstrated the highest performance in training. Similarly, in the testing phase, all studied neural networks achieved accuracy rates above 87.06%, with SVM, RBF, and LVQ showing the best classification performance. Overall, the SVM model exhibited the highest accuracy across both the training and testing stages, achieving a maximum accuracy of 98.06% during training and 95.44% during testing.

Conclusions

The findings of this study indicate that the use of an RGB imaging system is an effective method for detecting yellow rust infection in wheat. Stepwise discriminant analysis for ranking color reflectance indices revealed that the red and green components play a crucial role in distinguishing between S-H10 and H10-ST samples. Furthermore, the evaluation of classification models demonstrated that the SVM neural network achieved the highest accuracy in both training and testing phases for visible images, with an accuracy of 98.06% in training and 95.44% in testing. Thus, SVM was identified as the most effective model for detecting yellow rust in wheat. The

proposed method can serve as a precise and non-invasive system for monitoring crop health. Additionally, leveraging artificial intelligence models such as SVM and selected vegetation indices can facilitate the development of automated and intelligent systems for early detection of plant diseases, significantly improving disease management and reducing agricultural losses.

Author Contributions

Mohammad Hossein Saeidirad was responsible for conceptualization, methodology, writing review & editing, supervision, and project administration. Farzad Afshari contributed to validation and laboratory sample preparation. Reyhaneh Pakdel contributed to data curation, writing-original draft, image processing using software and visualization. Jalal Baradaran Motie contributed to pre-processing techniques. Saeed Zarifneshat contributed to analyzing via stepwise discriminant analysis. Naim Lovaimi contributed to laboratory sample photographing.

Data Availability Statement

The datasets generated and/or analyzed during the current study are available from the corresponding author upon reasonable request.

Acknowledgements

This optional section acknowledges individuals or organizations that significantly contributed to the research beyond author contributions or funding. This may include administrative, technical support, or in-kind donations.

Ethical Considerations

This section states ethical approval details (e.g., Ethics Committee, ethical code) and confirms adherence to ethical standards, including avoidance of data fabrication, falsification, plagiarism, and misconduct.



تشخیص آلودگی زنگ زرد گندم به کمک تصاویر مرئی و شبکه عصبی مصنوعی (مطالعه آزمایشگاهی)

محمدحسین سعیدی راد^{۱*}، فرزاد افشاری^۲، ریحانه پاکدل^۳، جلال برادران مطیع^۳، سعید ظریف نشاط^۱ و نعیم لویمی^۲

- ۱- بخش تحقیقات فنی و مهندسی کشاورزی، مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی خراسان رضوی، مشهد.
- ۲- بخش تحقیقات غلات، موسسه تحقیقات اصلاح و تهیه نهال و بذر، سازمان تحقیقات، آموزش و ترویج کشاورزی، کرج.
- ۳- گروه مهندسی بیوسیستم دانشگاه فردوسی مشهد، مشهد.
- ۴- بخش تحقیقات فنی و مهندسی کشاورزی، مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی خوزستان، اهواز.

ناریخچه مقاله	چکیده
دریافت: ۱۴۰۳/۰۸/۲۰	زنگ زرد یکی از مهم‌ترین بیماری‌های گندم در ایران است. از مهم‌ترین و اساسی‌ترین نکات در مبارزه با بیماری زنگ زرد، شناسایی نقاط و کانون‌های این بیماری در مزرعه است که در صورت سمپاشی، در مراحل اولیه می‌توان از شیوع این بیماری و خسارت ناشی از آن جلوگیری کرد. هدف از این پژوهش تشخیص بیماری زنگ زرد گندم در نمونه‌های آزمایشگاهی (با ایجاد آلودگی مصنوعی) و با استفاده از تصاویر دوربین مرئی و پردازش تصاویر به دست آمده بود. برای تهیه نمونه‌های آزمایشگاهی، رقم حساس به زنگ زرد (رقم بولانی) در گلدان‌هایی به قطر ۱۵ سانتی‌متر کاشته و در محیط پایش شده نگهداری شدند. در مرحله گیاهچه‌ای، مایه‌زنی جهت تولید آلودگی بر روی گیاه صورت گرفت. سپس از گیاه آلوده تصاویری تهیه و پیش‌پردازش و پردازش تصاویر به کمک نرم‌افزار Matlab بررسی شد. سپس شاخص‌های پوشش گیاهی گوناگون برای تصاویر مرئی مورد ارزیابی قرار گرفته و مناسب‌ترین شاخص برای تشخیص بیماری زنگ زرد معرفی شد. برای تعیین مدل مناسب تشخیص بیماری زنگ زرد، روش‌هایی شامل طبقه‌بندی نظارت شده بر روی تصاویر شامل روش‌های شبکه عصبی خود سازمان دهنده، شبکه عصبی چندی ساز بردار یادگیر، شبکه عصبی تابع پایه شعاعی، طبقه‌بندی ماشین بردار پشتیبان، شبکه عصبی پرسپترون چند لایه، طبقه‌بندی نزدیک‌ترین همسایه و طبقه‌بندی خوشه‌بندی k میانگین (K-means) ارزیابی شد. نتایج نشان داد که، شاخص انعکاس مؤلفه‌های قرمز و سبز در نمونه‌های آزمایشگاهی رتبه اول و دوم را در تحلیل افتراقی به خود اختصاص دادند. دقت شبکه عصبی ماشین بردار پشتیبان در طبقه‌بندی نظارت شده بر روی تصاویر مرئی در مرحله یادگیری و آزمایش به ترتیب ۹۸/۰۶ و ۹۵/۴۴ درصد بود که بیش‌ترین دقت نسبت به سایر روش‌های طبقه‌بندی را نشان داد.
واژه‌های کلیدی: پردازش تصویر زنگ زرد شبکه عصبی گندم.	
*پست الکترونیکی نویسنده مسئول: saidirad@yahoo.com	
ORCID:  ۰۰۰۰-۰۰۰۱-۸۹۵۵-۶۸۱۱	
	

نحوه استناد به این مقاله:

سعیدی راد، م.ح.، افشاری، ف.، پاکدل، ر.، برادران مطیع، ج.، ظریف نشاط، س. و لویمی، ن. (۱۴۰۴). تشخیص آلودگی زنگ زرد گندم به کمک تصاویر مرئی و شبکه عصبی مصنوعی. نشریه پژوهش‌های مکانیک ماشین‌های کشاورزی، ۳۴: ۱۲-۱. شناسه دیجیتال:

<https://dx.doi.org/10.22034/JRMAM.2024.15006.733>

مقدمه

زنگ زرد گندم در اثر فعالیت قارچ *Puccinia striiformis f. sp. tritici (Pst)* ایجاد و باعث کاهش قابل توجه عملکرد و کیفیت گندم می‌شود (Zheng et al., 2018; Wellings, 2011). این بیماری در برخی سال‌ها به علت فراهم شدن شرایط مساعد جوی و ظهور نژادهای پرآزار روی ژن‌های مقاومت ارقام رایج کشور و حساس شدن آن‌ها به بیماری، خسارت زیادی به محصول گندم وارد کرده است. بیماری زنگ زرد تقریباً از سال ۱۳۷۰ به کشور وارد شده و در برخی استان‌ها شیوع پیدا کرده، اما با توجه به سطح محدود مزارع آلوده در آن سال، بیماری به صورت کامل پایش شد. در اثر همه‌گیری این بیماری در سال ۱۳۷۲ به خاطر شکسته شدن مقاومت گندم فلات که به طور وسیع در مناطق مختلف کشور کشت شده بود، خسارت چشم‌گیری به وجود آورد. زنگ زرد به طور متوسط موجب کاهش محصول گندم در حدود ۱۵ درصد شد و ۱/۵ میلیون تن گندم در اثر این بیماری از بین رفت. این بیماری هرچند سال یک‌بار به صورت همه‌گیر (اپیدمی) درآمد و خسارات زیادی به محصول گندم وارد می‌کند (Torabi et al., 1995).

زنگ گندم در اغلب استان‌های کشور هر ساله مشاهده می‌شود ولی در استان‌های غربی، شمال غربی، خوزستان و فارس شدت بیش‌تری داشته است. در صورت عدم پایش بیماری، زنگ زرد گندم تا ۷۳ درصد خسارت روی رقم حساس ایجاد می‌کند (Kazemi & Momeni, 2015).

علائم بیماری زنگ زرد در روی برگ‌های جوان به صورت جوش یا تاول‌هایی به رنگ زرد مایل به نارنجی ظاهر می‌شود. سپس این جوش‌ها به هم پیوسته شده و نوارهایی در امتداد رگبرگ‌ها در هر دو سطح برگ نمایان می‌شود. زنگ زرد به اندام‌های مختلف گندم مانند برگ، غلاف، ساقه، خوشه، گلوم و گلومل و حتی ریشک‌ها حمله می‌کند و در بهار زودتر از سایر زنگ‌ها ظاهر می‌شود (Khodabande, 2013).

ابتدایی‌ترین روش برای شناسایی بیماری زنگ زرد در مزارع گندم رویت چشمی است که با بررسی برگ گندم در مزرعه صورت می‌گیرد. پرهزینه و وقت‌گیر بودن، انتقال بیشتر بیماری و احتمال بالای خطا از معایب عمده و تأثیرگذار این روش است. از این رو، محققین در تلاش برای پیدا کردن روش‌های دقیق‌تر و سریع‌تر هستند تا بتوانند با شناسایی دقیق و به موقع بیماری از شدت خسارات ناشی از

آن بکاهند. در سال‌های اخیر از روش‌های شیمیایی و مولکولی مثل واکنش زنجیره‌ای پلیمیر (PCR)^۱، در شناسایی انواع بیماری‌های گیاهی استفاده شده است. این روش‌ها اگرچه ابزاری قوی برای اطمینان از وجود بیماری‌های گیاهی هستند، اما مخرب، زمان‌بر و نیازمند مواد شیمیایی خاص هستند (Sankaran et al., 2010).

با پیشرفت و تحول فناوری در کشاورزی، از روش‌های طیف‌سنجی و تصویربرداری به عنوان روش‌های غیرمخرب در تشخیص بیماری‌های گیاهی استفاده می‌شود. برخی از این روش‌ها عبارتند از: تصویربرداری چند طیفی^۲ و ابر طیفی^۳ (Su et al., 2019; Whetton et al., 2018; Su et al., 2019)، طیف‌سنجی مادون قرمز^۴ (Atanassova et al., 2019) و تصویربرداری رنگی (Qiu et al., 2019; Zhang et al., 2018; Elangovan and Nalini 2017).

به عنوان مثال در تحقیقی به بررسی شاخص‌های پوشش گیاهی برای تشخیص گندم آلوده به بیماری زنگ زرد، با استفاده از تصویربرداری ابر طیفی پرداخته شد. مزرعه به دو بخش تقسیم و نیمی به بیماری زنگ زرد آلوده و نیمی به بیماری زنگ برگ (زنگ قهوه‌ای) آلوده شد. تصویربرداری طیفی از پوشش گیاهی توسط دوربین طیف نگار دستی در زمان‌های قبل از آلودگی (گندم سالم)، پس از آلودگی (قبل از بروز نشانه‌های بیماری) و در طول دوره بیماری هر ۱۵ روز انجام و شناسایی بیماری، مدل‌سازی شد. نتایج نشان داد در بهترین مدل، دقت پیش‌بینی بیماری توسط تصاویر طیفی در مرحله آموزشی مدل ۹۹/۷ درصد و در مرحله آزمایش ۸۲ درصد است. همچنین این پژوهش‌گران گزارش دادند که با استفاده از الگوریتم KNN^۵ و حذف خصوصیات طیفی گندم‌های سالم از تصاویر، دقت مدل‌سازی می‌تواند تا ۱۰۰ درصد افزایش یابد (Wang et al., 2015).

در تحقیق دیگری محققان به بررسی توانایی استفاده از تصاویر طیفی در تشخیص بیماری‌های گیاهی گندم پرداختند. به همین منظور از تصاویر طیفی با قدرت تفکیک زمینی بالا دریافت شده از ماهواره به همراه تصاویر طیفی هوایی توسط فراطیفی‌سنجنده هوابرد HYMAP^۶ استفاده

1- Polymerase Chain Reaction

2- Multispectral Imaging

3- Hyperspectral Imaging

4- Infrared Spectroscopy

5- K-Nearest Neighbor classifier

6- Hyperspectral mapper

بررسی نتایج سایر محققان نشان می‌دهد که امکان تشخیص بیماری‌های گیاهی با استفاده از روش‌های پردازش تصویر وجود دارد. هدف از پژوهش حاضر، تشخیص بیماری زنگ زرد گندم در نمونه‌های آزمایشگاهی (با آلودگی مصنوعی) و با استفاده از روش‌های پردازش تصاویر مرئی بوده است.

مواد و روش‌ها

برای تهیه نمونه‌های آزمایشگاهی از رقم حساس به زنگ زرد (رقم بولانی) استفاده گردید. بذر این رقم به تعداد کافی در گلدان‌هایی به قطر ۱۵ سانتی‌متر، با بستر خاک، ماسه و خاک برگ ضدعفونی شده، کاشته شد و در مرحله گیاهچه‌ای بر روی برگ اول و براساس روش پیشنهادی مایه‌زنی قارچ زنگ صورت گرفت. بعد از مایه‌زنی گلدان‌ها در دمای ۱۰ درجه سلسیوس و تاریکی قرار داده و سپس تا زمان اسپوردهی نمونه‌ها به صورت جداگانه زیر سرپوش شفاف کریستالی در دمای ۱۸ درجه سلسیوس به مدت ۱۶ ساعت و نور ۱۶۰۰۰ لوکس و در ۱۶ درجه سلسیوس به مدت ۸ ساعت و در تاریکی در گلخانه نگهداری شدند (شکل ۱).

برای عکس‌برداری از نمونه‌ها، از هر نمونه گندم با شدت بیماری مشخص (تعداد روزهای بعد از آلودگی) ۵۰ برگ آلوده با قیچی از گیاه بریده شد. نمونه‌ها در روز دهم آلودگی و روز هفدم آلودگی انتخاب شدند. با توجه به این‌که طول دوره بیماری ۱۵ روز است، لذا نمونه‌ها پس از دوره ۱۷ روزه، به‌عنوان آلوده کامل در نظر گرفته شدند (Torabi *et al.*, 1995). از دوربین رقمی (Canon PowerShot G9, Made in Japan, 12MP F-12.5) جهت تصویربرداری استفاده شد و تنظیمات دوربین نیز شامل: فاصله کانونی: ۷ میلی‌متر، Stop: f/2.8 و تصاویر با وضوح ۱۸۰ نقطه در اینچ گرفته شدند. لازم به ذکر است که زاویه عکس برداری ۹۰ درجه نسبت به برگ‌ها بود و تصاویر از فاصله ۲۰ سانتی‌متری گرفته شدند. بر این اساس، تصاویر با حداقل نوفه، پس‌زمینه واضح و قابل تشخیص بودند. همه تصاویر در شرایط نور طبیعی در ساعات بین ۱۱ تا ۱۲ صبح گرفته شدند (شکل ۲).

شد و به کمک شاخص اختلاف گیاهی نرمال شده NDVI^۱ شدت آلودگی سطح مزرعه به بیماری زنگ زرد و کپک پودری برآورد گردید. نتایج نشان داد که در مقایسه با اطلاعات کسب شده از طریق داده‌برداری زمینی تصاویر طیفی توانستند با دقت ۵۶/۸ تا ۸۸/۶ درصد شدت بیماری را برآورد کرده و بدین ترتیب روش تصویربرداری طیفی روشی مناسب در شناسایی مناطق آلوده و تخمین میزان آلودگی بیماری‌های قارچی گندم معرفی شد (Franke and Menz, 2007).

در پژوهش دیگری بیماری زنگ زرد، به وسیله تصاویر ابرطیفی و مدل‌سازی از شاخص‌های پوشش گیاهی و ویژگی‌های بافت، با دقت ۹۵/۸ درصد تشخیص داده شد. همچنین با استفاده از مؤلفه‌های طیفی استخراج شده از تصاویر فراطیفی، بیماری زنگ زرد سه روز قبل از ظهور علائم شناسایی شد (Yu *et al.*, 2018).

زنگ زرد باعث ایجاد تغییر شکل‌هایی در بافت برگ گندم می‌شود که شدت بیماری را آشکار می‌کند. محققان برای شناسایی زنگ زرد از ماتریس هم‌رخدادی سطح خاکستری (GLCM)^۲ استفاده کردند. ویژگی‌های بافتی شامل اطلاعات سطح خاکستری و رنگ است. روش GLCM یک توصیف‌گر ویژگی بافت است که از تصاویر سطح خاکستری استخراج می‌شود. ترکیب رنگ بافت با ویژگی‌های GLCM، الگوهای پنهان موجود در کانال‌های رنگی را آشکار می‌کند. آنها مدل‌های طبقه‌بندی مختلفی با استفاده از فضاها رنگی RGB، HSV، و $La*b*$ و دو روش طبقه‌بندی SVM^۳ و KNN را توسعه دادند. مدل ترکیبی آن‌ها که در آن HSV و SVM به کار گرفته شد، با دقت ۹۲/۴ درصد از مدل‌های دیگر بهتر عمل کرد (Hayit *et al.*, 2023).

محققان دیگر به منظور شناسایی و تشخیص بلادرنگ زنگ زرد گندم به کمک تصاویر مرئی، ابتدا تصاویر رنگی گرفته شده از زنگ زرد را با استفاده از کانال رنگی G از فضای RGB، به تصویر خاکستری تبدیل و تصویر دودویی از نقاط بیماری را استخراج کردند. طبق نتایج، دقت میزان تشخیص زنگ زرد در روش آن‌ها ۹۶/۲٪ درصد و در پردازش تصویر به ۹۲/۳ درصد رسید که تقریباً برابر با نتیجه بینایی انسان بود (Xu *et al.*, 2017).


1- Normalized Differences Vegetaton Index

2- Gray-Level Co-occurrence Matrix

3- Support vector machine



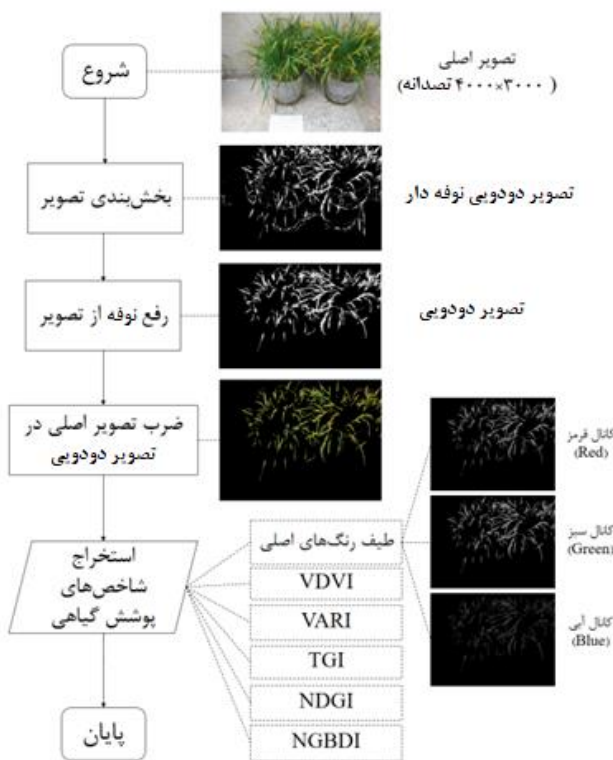
شکل ۱- نمونه‌های آزمایشگاهی گندم، الف) قبل از مایه‌زنی، ب) آلودگی کامل



شکل ۲- نمونه‌های گندم با شدت بیماری مشخص؛ الف) سالم (H)، ب) روز دهم آلودگی (S10)، پ) آلودگی کامل (ST)

پایین گذر برای حذف نوفه‌های احتمالی و حذف پس زمینه از برخی تصاویر بود. به‌طور کلی، تبدیل فضاهای رنگی بعد از روش‌های پیش‌پردازش مانند فیلتر کردن، حذف پس زمینه و غیره انجام می‌شود. در این پژوهش نیز از میانگین مؤلفه‌های رنگی RGB (قرمز، سبز و آبی)، HSI (طول موج فام، اشباع و شدت روشنایی) و $L^*a^*b^*$ (L میزان روشنایی، a میزان قرمز-سبز، و b آبی-زرد بودن)، در مجموع ۹ شاخص رنگی استفاده شد. لازم به ذکر است که همه‌ی مؤلفه‌های فضاهای رنگی ذکر شده را می‌توان با روابط تبدیل از فضای رنگی RGB به دست آورد. روابط تبدیل رنگ از فضای رنگی RGB به فضاهای HSI و $L^*a^*b^*$ در جدول ۱ نشان داده شده است.

به منظور اجرای فرایند پردازش تصویر و کاهش نوفه تصاویر و حذف اثر تغییرات جزئی در تصویر فیلتر پایین گذر گوسی در محیط نرم‌افزار Matlab بر تصاویر اعمال گردید (شکل ۳). پیش‌پردازش و پردازش تصاویر تهیه شده با استفاده از دوربین مرئی به کمک نرم افزار Matlab (R2019b, Mathworks, Inc., Natick, MA, USA) بررسی شد و پیش‌پردازش‌هایی از جمله بسط هیستوگرام به منظور بهبود وضوح بر روی تصاویر انجام گرفت. سپس هر تصویر RGB به سه تصویر خاکستری در مؤلفه‌های قرمز، سبز و آبی تفکیک شد. به منظور اجرای فرایند پردازش تصویر، تصاویر از نظر ابعاد، کاهش میزان نوفه و همچنین بهبود سطوح خاکستری در مؤلفه‌های مختلف مورد پیش‌پردازش قرار گرفتند. فرایند پیش‌پردازش برای تصاویر مرئی (RGB) شامل اعمال فیلتر



شکل ۳- مراحل پردازش و استخراج شاخص ها در تصاویر

جدول ۱- توابع تبدیل از RGB به فضاهای رنگی تحلیل شده (wang et al., 2019)

فضای رنگی	کانال	تبدیل از RGB
RGB	R	$r = R / (R + G + B)$
	G	$g = G / (R + G + B)$
	B	$b = B / (R + G + B)$
HSI	H	$H = \begin{cases} \theta, & \text{if } B \leq G \\ 360 - \theta, & \text{if } B \geq G \end{cases} \theta = \arccos \left\{ \frac{\frac{1}{2}(R-G) + (R-B)}{\sqrt{(R-G)^2 + (R-B) + (G-B)}} \right\}$
	S	$S = 1 - \frac{3}{R+G+B} [\min(R, G, B)]$
	I	$I = \frac{1}{3}(R + G + B)$
L*a*b*	L*	$L^* = \begin{cases} 116 \left(\frac{Y}{Y_n}\right)^{\frac{1}{3}} - 16, & \text{if } \frac{Y}{Y_n} > 0.008856 \\ 903.3 \left(\frac{Y}{Y_n}\right), & \text{if } \frac{Y}{Y_n} \leq 0.008856 \end{cases}$
	a*	$a^* = 500 \left(f \left(\frac{X}{X_n} \right) - f \left(\frac{Y}{Y_n} \right) \right) f(x) = \begin{cases} X^{\frac{1}{3}}, & \text{if } X > 0.008856 \\ 7.787X + \frac{16}{116}, & \text{if } X < 0.008856 \end{cases}$
	b*	$b^* = 200 \left(f \left(\frac{Y}{Y_n} \right) - f \left(\frac{Z}{Z_n} \right) \right)$

شاخص های شکلی، رنگ و بافت از مهمترین ویژگی های مورد استفاده بر روی تصاویر محصولات کشاورزی است (Hayit et al., 2023). شاخص های پوشش گیاهی گوناگون که با سلامتی پوشش گیاهی در ارتباط هستند (جدول ۲) مورد ارزیابی قرار گرفته و مناسب ترین شاخص برای تشخیص بیماری زنگ زرد معرفی شد.

یکی از مراحل اصلی در روند پردازش تصویر استخراج، بررسی و انتخاب شاخص هایی است که توصیف مناسبی از مکان های مدنظر ارائه نموده و بیشترین تفکیک را در فرایند طبقه بندی داشته باشد. عموماً شاخص هایی که ضمن دقت کافی قابل سنجش بوده و اندازه گیری آنها با تجهیزات ارزان تر و در دسترس امکان پذیر باشد، مناسب تر هستند.

جدول ۲- شاخص‌های پوشش گیاهی مورد استفاده برای تشخیص بیماری زنگ زرد گندم

منبع	نحوه محاسبه	نام شاخص
Riccardi <i>et al.</i> (2014)	RED, GREEN, BLUE	طیف رنگ‌های اصلی
Xue and Su, 2017)	$VDVI = \frac{2 \times G - R - B}{2 \times G + R + B}$	VDVI
McKinnon and Hoff, (2017)	$VARI = \frac{G - R}{G + R - B}$	VARI
McKinnon and Hoff, (2017)	$TGI = G - 0.39 \times R - 0.61 \times B$	TGI
Xue and Su, (2017)	$NDGI = \frac{G - R}{G + R}$	NDGI
Xue and Su, (2017)	$NGDBI = \frac{G - B}{G + B}$	NGBDI

آن است که بتوان این ضریب را هر چه بیش‌تر به صفر نزدیک کند.

برای تعیین مدل مناسب تشخیص بیماری زنگ زرد، روش‌های گوناگون طبقه‌بندی نظارت شده بر روی تصاویر شامل روش‌های شبکه عصبی خود سازمان‌دهنده (SOM)، شبکه عصبی چندی ساز بردار یادگیر (LVQ)، شبکه عصبی تابع پایه شعاعی (RBF)، طبقه‌بندی ماشین بردار پشتیبان (SVM)، شبکه عصبی پرسپترون چند لایه (MLP)، طبقه‌بندی نزدیک‌ترین همسایه (KNN) و طبقه‌بندی خوشه‌بندی k میانگین (K-means) ارزیابی شد.

برای ارزیابی عملکرد الگوریتم‌های استفاده شده در این مطالعه از معیار دقت (ACC) استفاده شد. لازم به ذکر است که بهترین عملکرد طبقه‌بندی کننده زمانی حاصل می‌شود که مقدار این معیار نزدیک به ۱۰۰ باشد. میزان دقت، نسبت نمونه‌های طبقه‌بندی شده صحیح به کل نمونه‌ها را نشان می‌دهد که از معادله (۱) محاسبه می‌شود (Kumar *et al.*, 2012).

$$ACC = \frac{n_p}{n_p + n_{mp}} \times 100 \quad (1)$$

در این معادله n_p تعداد نمونه‌هایی است که به درستی طبقه‌بندی شده‌اند و n_{mp} تعداد نمونه‌هایی است که به صورت اشتباه طبقه‌بندی شده‌اند. کلیه مراحل تجزیه و تحلیل تصاویر، کالیبره کردن تصاویر و طبقه‌بندی آن‌ها در نرم‌افزار Matlab (R2019b, Mathworks, Inc) انجام شد.

برای انتخاب و رتبه‌بندی شاخص‌ها روش تحلیل افتراقی گام به گام^۱ مورد استفاده قرار گرفت. در این روش در هر گام همه شاخص‌ها بررسی می‌شوند تا مشخص شود کدام یک بیش‌ترین مشارکت را در تفکیک بین طبقه‌ها دارد. سپس آن شاخص انتخاب شده و دوباره ارزیابی با شاخص‌های باقیمانده انجام می‌شود. بدین ترتیب همه شاخص‌ها رتبه‌بندی می‌شوند. در تحلیل افتراقی گام به گام، ابتدا شاخصی که کم‌ترین عدد لاندای ویلکس را در مدل تک متغیره تولید می‌کند انتخاب و سپس در هر گام به ترتیب شاخصی که بتواند با اضافه شدن به مدل عدد لاندای ویلکس را کاهش دهد معرفی شد. کوچک‌تر بودن عدد ویلکس در پایان تحلیل نشان‌دهنده کیفیت و دقت بالاتر مدل طبقه‌بند است. در این تحلیل برخی شاخص‌ها که تأثیری بر کاهش عدد ویلکس ندارند حذف می‌شوند. بدین منظور داده‌های مربوط به شاخص‌های استخراج شده از هر تصویر در نرم‌افزار SPSS 18 ثبت شد و به کمک روش تحلیل افتراقی گام به گام مورد بررسی قرار گرفت. به کمک این روش شدت شاخص‌ها به طور جداگانه برای نمونه‌های برگ گندم با شدت آلودگی مشخص (H: سالم، S10: روز دهم آلودگی و ST: آلودگی کامل) مورد بررسی قرار گرفت. عدد لاندای ویلکس برای تفکیک دو به دو نمونه‌های برگ گندم (S-HT، S-H10) و H10-HT محاسبه شد.

خروجی این مرحله شامل لیستی از شاخص‌ها است که به ترتیب بیش‌ترین تا کم‌ترین اثر را در طبقه‌بندی و تفکیک طبقه‌ها دارند. میزان اثر بخشی هر شاخص از طریق محاسبه ضریب لاندای ویلکس بررسی شد. بهترین مجموعه شاخص‌ها

نتایج و بحث

نتایج حاصل از تحلیل افتراقی گام به گام در جدول ۳ آمده است.

مطابق با جدول ۳، شاخص انعکاس مؤلفه‌های قرمز و سبز در نمونه‌های S-H10 و H10-HT رتبه اول و دوم را در تحلیل DFA به خود اختصاص دادند. برای نمونه S-HT، شاخص انعکاس مؤلفه آبی رتبه اول را دارا بوده و سپس شاخص‌های VDI، Blue و RED در رتبه‌های دوم تا چهارم قرار دارند. بنابراین شاخص انعکاس مؤلفه قرمز برای دو نمونه به عنوان بهترین شاخص‌ها برای عملیات

تفکیک انتخاب شدند. نتایج پژوهش (Liu et al., 2018) نیز نشان داد که از بین مؤلفه‌های مرئی، مؤلفه قرمز بیش‌ترین تأثیر را در شناسایی بیماری زنگ زرد دارد. شاخص‌های NGDBA، NDGI و TGI نیز در رتبه‌های ششم تا هفتم برای هر سه نمونه هستند. کم‌ترین عدد لاندای ویلکس نیز به ترتیب برای سه نمونه S-H10، S-HT و H10-HT برابر با ۰/۰۹۸، ۰/۰۸۸ و ۰/۰۸۵ محاسبه شد. این مقادیر نشان می‌دهد سامانه طبقه‌بند دقت نسبی خوبی خواهد داشت.


جدول ۳- ترتیب شاخص‌ها و عدد لاندای ویلکس محاسبه شده برای مدل طبقه‌بند چند متغیره در تصاویر

H10-HT		S-HT		S-H10		نمونه
عدد ویلکس لاندای	شاخص	عدد ویلکس لاندای	شاخص	عدد ویلکس لاندای	شاخص	گام
۰/۳۸۷	RED	۰/۵۶۷	BLUE	۰/۴۱۲	RED	۱
۰/۳۵۷	GREEN	۰/۴۵۷	VDVI	۰/۳۰۵	GREEN	۲
۰/۲۱۰	BLUE	۰/۴۱۵	BLUE	۰/۲۸۷	VARI	۳
۰/۲۰۰	VDVI	۰/۳۲۸	RED	۰/۲۵۵	VDVI	۴
۰/۱۹۹	NGBDI	۰/۲۲۵	VARI	۰/۱۸۸	BLUE	۵
۰/۱۱۰	TGI	۰/۱۰۱	NDGI	۰/۱۵۶	NGBDI	۶
۰/۸۷	NDGI	۰/۱۰۰	TGI	۰/۱۱۱	NDGI	۷
۰/۰۸۵	VARI	۰/۰۸۸	NGBDI	۰/۰۹۸	TGI	۸

در این پژوهش بیش از ۸۷/۰۶ بود. علاوه بر این شبکه‌های عصبی SVM، RBF، LVQ، k-means، SOM، MLP و KNN به ترتیب دارای بیش‌ترین عملکرد در مرحله آزمایش بودند. بنابراین شبکه SVM دارای بالاترین عملکرد در مراحل یادگیری و آزمایش است. حداکثر دقت شبکه عصبی SVM در مرحله یادگیری و آزمایش به ترتیب ۹۸/۰۶ و ۹۵/۴۴ درصد است (شکل ۴). در پژوهش (Zheng et al., 2021) نیز از سه الگوریتم LDA، SVM و ANN به منظور شناسایی و طبقه‌بندی بیماری زنگ زرد استفاده شد که الگوریتم SVM با ۸۴/۲ درصد بهترین عملکرد را داشته است. در تحقیق (Hayit et al., 2023) نیز مدل‌های طبقه‌بندی مختلفی با استفاده از فضاها رنگی RGB، HSV و La^*b^* و دو روش طبقه‌بندی SVM و KNN توسعه یافته است. مدل ترکیبی آن‌ها که در آن HSV و SVM به کارگرفته شد، با دقت ۹۲/۴ درصد از مدل‌های دیگر بهتر عمل کرده است.

الگوریتم‌های چندگانه می‌توانند یک طبقه یا مقدار پیوسته را بر اساس ویژگی‌های یک نمونه پیش‌بینی کنند. در این مطالعه، طبقه‌بندی کننده‌های شبکه عصبی خود سازمان دهنده (SOM)، شبکه عصبی چندی ساز بردار یادگیر (LVQ)، شبکه عصبی تابع پایه شعاعی (RBF)، طبقه بندی ماشین بردار پشتیبان (SVM)، شبکه عصبی پرسپترون چند لایه (MLP)، طبقه‌بندی نزدیک‌ترین همسایه (KNN) و طبقه‌بندی خوشه‌بندی k میانگین (K-means) برای طبقه‌بندی بیماری زنگ زرد اعمال شدند.

بر اساس نتایج تحلیل افتراقی، مؤلفه‌های سبز، آبی و قرمز مؤثرترین شاخص‌ها در طبقه‌بند تصویر مورد مطالعه معرفی شدند. ارزیابی شبکه‌های عصبی فوق‌الذکر نشان داد که دقت هر هفت شبکه عصبی مورد مطالعه در مرحله یادگیری بیش از ۸۶/۰۵ درصد است. بنابراین در مرحله یادگیری به ترتیب شبکه‌های عصبی SVM، MLP، KNN، RBF، SOM، k-means و LVQ دارای بیش‌ترین عملکرد هستند. همچنین در مرحله آزمایش نیز دقت هر ۷ شبکه عصبی مورد مطالعه



شکل ۴- مقایسه دقت سیستم‌های طبقه‌بند برای تصاویر مرئی

فرزاد افشاری: اعتبارسنجی و آماده‌سازی نمونه‌های آزمایشگاهی.
 ریحانه پاکدل: سامان‌دهی داده‌ها، نگارش پیش‌نویس اولیه، پردازش تصاویر با نرم‌افزار، تهیه نمودارها و نمایش‌های تصویری.
 جلال برادران مطیع: پیش‌پردازش داده‌ها.
 سعید ظریف نشاط: تحلیل داده‌ها با استفاده از روش تحلیل افتراقی گام به گام.
 نعیم لویمی: تصویربرداری از نمونه‌های آزمایشگاهی.

اصول اخلاقی

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

منابع

- Atanassova, S., Nikolov, P., Valchev, N., Masheva, S. & Yorgov, D. (2019, February). Early detection of powdery mildew (*Podosphaera xanthii*) on cucumber leaves based on visible and near-infrared spectroscopy. In *AIP conference proceedings* (Vol. 2075, No. 1). AIP Publishing. <https://doi.org/10.1063/1.5091341>
- Elangovan, K. & Nalini, S. (2017). Plant disease classification using image segmentation and SVM techniques. *International Journal of Computational Intelligence Research*, 13(7), 1821-1828.
- Franke, J. & Menz, G. (2007). Multi-temporal wheat disease detection by multi-spectral remote sensing.

نتیجه‌گیری

در تحقیق حاضر امکان تشخیص آلودگی زنگ زرد گندم به کمک سیستم تصویربرداری RGB مورد بررسی قرار گرفت و نتایج زیر حاصل شد. رتبه‌بندی شاخص‌ها با استفاده از روش تحلیل افتراقی گام به گام برای تصاویر مرئی نشان داد که شاخص انعکاس مؤلفه‌های قرمز و سبز در نمونه‌های S-H10 و H10-HT رتبه اول و دوم را به خود اختصاص دادند. حداکثر دقت شبکه عصبی SVM در تصاویر مرئی در مرحله یادگیری و آزمایش به ترتیب ۹۸/۰۶ و ۹۵/۴۴ درصد است، بنابراین شبکه عصبی SVM دارای بالاترین عملکرد در تشخیص زنگ زرد گندم است.

تضاد منافع نویسندگان

در این مقاله هیچ‌گونه تضاد منافی وجود ندارد و این مسئله مورد تایید همه نویسندگان است.

دسترسی به داده‌ها

همه اطلاعات و نتایج در متن مقاله ارائه شده است.

مشارکت نویسندگان

نحوه و میزان مشارکت نویسندگان در انجام این پژوهش به صورت زیر است:

محمدحسین سعیدی‌راد: مسئول ایده‌پردازی، روش‌شناسی، بازبینی و ویرایش نهایی، نظارت و مدیریت پروژه.

- resistance genes in different parts of Iran. *Cereal Rusts and Powdery Mildews Bulletin*, 23(1), 9-12.
- Wang, A., Zhang, W., & Wei, X. (2019). A review on weed detection using ground-based machine vision and image processing techniques. *Computers and electronics in agriculture*, 158, 226-240. <https://doi.org/10.1016/j.compag.2019.02.005>
- Wang, H., Qin, F., Liu, Q., Ruan, L., Wang, R., Ma, Z. & Wang, H. (2015). Identification and disease index inversion of wheat stripe rust and wheat leaf rust based on hyperspectral data at canopy level. *Journal of Spectroscopy*, <https://doi.org/10.1155/2015/651810>
- Wellings, C. R. (2011). Global status of stripe rust: a review of historical and current threats. *Euphytica*, 179(1), 129-141. <https://doi.org/10.1007/s10681-011-0360-y>
- Whetton, R. L., Waive, T. W. & Mouazen, A. M. (2018). Hyperspectral measurements of yellow rust and fusarium head blight in cereal crops: Part 2: On-line field measurement. *Biosystems engineering*, 167, 144-158. <https://doi.org/10.1016/j.biosystemseng.2018.01.004>
- Xu, P., Wu, G., Guo, Y., Yang, H. & Zhang, R. (2017). Automatic wheat leaf rust detection and grading diagnosis via embedded image processing system. *Procedia Computer Science*, 107, 836-841. <https://doi.org/10.1016/j.procs.2017.03.177>
- Xue, J. & Su, B. (2017). Significant remote sensing vegetation indices: A review of developments and applications. *Journal of sensors*, <https://doi.org/10.1155/2017/1353691>
- Yu, K., Anderegg, J., Mikaberidze, A., Karisto, P., Mascher, F., McDonald, B. A. & Hund, A. (2018). Hyperspectral canopy sensing of wheat septoria tritici blotch disease. *Frontiers in plant science*, 9, 1195. <https://doi.org/10.3389/fpls.2018.01195>
- Zhang, D., Zhou, X., Zhang, J., Lan, Y., Xu, C. & Liang, D. (2018). Detection of rice sheath blight using an unmanned aerial system with high-resolution color and multispectral imaging. *PloS one*, 13(5), e0187470. <https://doi.org/10.1371/journal.pone.0187470>
- Zheng, Q., Huang, W., Cui, X., Dong, Y., Shi, Y., Ma, H. & Liu, L. (2018). Identification of wheat yellow rust using optimal three-band spectral indices in different growth stages. *Sensors*, 19(1), 35. <https://doi.org/10.3390/s19010035>
- Zheng, Q., Ye, H., Huang, W., Dong, Y., Jiang, H., Wang, C., ... & Chen, S. (2021). Integrating spectral information and meteorological data to monitor wheat yellow rust at a regional scale: A case study. *Remote Sensing*, 13(2), 278. <https://doi.org/10.3390/rs13020278>
- Precision Agriculture*, 8, 161-172. <https://doi.org/10.1007/s11119-007-9036-y>
- Hayit, T., Erbay, H., Varçın, F., Hayit, F. & Akci, N. (2023). The classification of wheat yellow rust disease based on a combination of textural and deep features. *Multimedia Tools and Applications*, 82(30), 47405-47423. <https://doi.org/10.1007/s11042-023-15199-y>
- Kazemi, H. & Momeni, H. (2015). Management of stripe rust disease of wheat (Applied instruction). *Iranian Research Institute of Plant Protection*. Registration No. 46869. (In Persian).
- Khodabande, N. (2013). *Cereals*. University of Tehran Press, 10th Edition. (In Persian).
- Kumar, R., Goyal, M. K., Ahmed, P. & Kumar, A. (2012, December). Unconstrained handwritten numeral recognition using majority voting classifier. In *2012 2nd IEEE International Conference on Parallel, Distributed and Grid Computing* (pp. 284-289). IEEE. <https://doi.org/10.1109/PDGC.2012.6449833>
- Liu, W., Yang, G., Xu, F., Qiao, H., Fan, J., Song, Y. & Zhou, Y. (2018). Comparisons of detection of wheat stripe rust using hyperspectral and uav aerial photography. *Acta Phytopathol. Sinica*, 48(2), 223-227. <https://doi.org/10.13926/j.cnki.apps.000170>
- McKinnon, T. & Hoff, P. (2017). Comparing RGB-based vegetation indices with NDVI for agricultural drone imagery. *AGBX*, 2, 1-17.
- Qiu, R., Yang, C., Moghimi, A., Zhang, M., Steffenson, B. J. & Hirsch, C. D. (2019). Detection of fusarium head blight in wheat using a deep neural network and color imaging. *Remote Sensing*, 11(22), 2658. <https://doi.org/10.3390/rs11222658>
- Riccardi, M., Mele, G., Pulvento, C., Lavini, A., d'Andria, R. & Jacobsen, S. E. (2014). Non-destructive evaluation of chlorophyll content in quinoa and amaranth leaves by simple and multiple regression analysis of RGB image components. *Photosynthesis research*, 120, 263-272. <https://doi.org/10.1007/s11120-014-9970-2>
- Sankaran, S., Mishra, A., Ehsani, R. & Davis, C. (2010). A review of advanced techniques for detecting plant diseases. *Computers and electronics in agriculture*, 72(1), 1-13. <https://doi.org/10.1016/j.compag.2010.02.007>
- Su, J., Liu, C., Coombes, M., Hu, X., Wang, C., Xu, X. & Chen, W. H. (2018). Wheat yellow rust monitoring by learning from multispectral UAV aerial imagery. *Computers and electronics in agriculture*, 155, 157-166. <https://doi.org/10.1016/j.compag.2018.10.017>
- Su, J., Liu, C., Hu, X., Xu, X., Guo, L. & Chen, W. H. (2019). Spatio-temporal monitoring of wheat yellow rust using UAV multispectral imagery. *Computers and electronics in agriculture*, 167, 105035. <https://doi.org/10.1016/j.compag.2019.105035>
- Torabi, M., Mardoukhi, V., Nazari, K., Afshari, F., Forootan, A. R., Ramai, M. A. & Kashani, A. S. (1995). Effectiveness of wheat yellow rust