



## Estimation of Iron Content in Apple Leaves Using an Artificial Neural Network and Image Processing Model

Hojjat Sadeghi<sup>1</sup> | Ebrahim Sepehr<sup>2✉</sup> | Aydin Imani<sup>3</sup>

1. Department of Soil Science, Faculty of Agriculture, Urmia University, Urmia, Iran. Email: [hjsadeghi3@gmail.com](mailto:hjsadeghi3@gmail.com)

2. Corresponding author, Department of Soil Science, Faculty of Agriculture, Urmia University, Urmia, Iran. Email: [e.sepehr@urmia.ac.ir](mailto:e.sepehr@urmia.ac.ir)

3. Department of Soil Science, Faculty of Agriculture, Urmia University, Urmia, Iran. Email: [aydin.imani@urmia.ac.ir](mailto:aydin.imani@urmia.ac.ir)

---

### Article Info

**Article type:** Research Article

**Article history:**

**Received:** July. 2, 2025

**Revised:** Jan. 19, 2026

**Accepted:** Apr. 26, 2026

**Published online:** May. 2026

**Keywords:**

Apple leaf,  
Machine learning,  
Active iron,  
Image processing

---

### ABSTRACT

Iron deficiency is one of the most common nutritional problems in fruit trees grown in calcareous soils. Rapid detection of iron deficiency using image processing and machine learning can serve as a low-cost method to address this issue. Therefore, to investigate the relationship between iron deficiency and leaf color characteristics, a database consisting of 1,500 apple leaf images with varying levels of iron deficiency (severe, moderate, mild, and none) was collected. Imaging was performed using a smartphone camera, and the active and total iron content of each sample was measured using an atomic absorption spectrometer. Color features were extracted from RGB, Lab, HSV, and NTSC color spaces, along with eight combined color indices. Modeling was performed using two approaches: linear regression and artificial neural networks. The linear model showed a moderate ability to predict active iron with a determination coefficient of  $R^2 = 0.74$  but showed no correlation with total iron content. In contrast, the neural network model achieved better performance with  $R^2 = 0.80$ , RMSE = 1.156, and MAPE = 25.03. As a result, the ANN model based on leaf color features can be considered a rapid and non-destructive method for detecting iron deficiency and estimating iron content in apple leaves.

---

Cite this article: Sadeghi, H., Sepehr, E., Imani, A., (2026) Estimation of Iron Content in Apple Leaves Using an Artificial Neural Network and Image Processing Model, *Iranian Journal of Soil and Water Research*, 57 (3), 751-766. <https://doi.org/10.22059/ijswr.2026.397919.669970>

© The Author(s).

Publisher: University of Tehran Press.



DOI: <https://doi.org/10.22059/ijswr.2026.397919.669970>

---



## EXTENDED ABSTRACT

### Introduction

Iron deficiency is an important nutritional disorder in fruit trees growing on calcareous soils, where a high pH limits the availability of iron. This leads to reduced growth, leaf chlorosis and yield loss. Conventional detection methods are accurate but time consuming and costly. Recent advances in digital imaging and machine learning offer a fast, cost-effective and non-destructive alternative. This study investigates the use of leaf color features and machine learning to estimate active iron content in apple leaves under field conditions.

### Methods

A total of 1575 images of apple leaves were collected from about 50 orchards around Urmia, Iran. The samples represented four levels of iron deficiency: none, low, moderate, and severe. The images were captured using a Samsung smartphone camera mounted 15 cm above the leaves in a custom-built imaging chamber under uniform lighting. The images were saved in 24-bit RGB format with JPEG enhancement. The active iron content and total iron content of the corresponding leaf samples were measured by atomic absorption spectroscopy. Active iron was extracted using the 1.5% phenanthroline method (pH = 3), while total iron was measured by dry ashing followed by acid digestion. To extract color features, images were first preprocessed to remove background noise using the Excess Green (ExG) index. Subsequently, color features were extracted from the RGB, HSV, Lab, and NTSC spaces as well as eight vegetation indices (e.g., GMR, GDR, DGCI, NRI, NGI). The mean value of each color channel was used as input. The most important features were selected by univariate regression analysis. A multilayer perceptron (MLP) neural network was developed in MATLAB 2017 using the Levenberg–Marquardt training algorithm. The dataset was randomly split into 70% training, 15% validation, and 15% test. Model accuracy was assessed using  $R^2$ , root mean square error (RMSE), and mean absolute percentage error (MAPE).

### Results

A univariate regression analysis was performed to evaluate the relationship between color features and active iron content. Among the RGB channels, R and G showed the highest correlation with active iron content ( $R^2 = 0.67$ ). The H and V channels in HSV and the L and b channels in Lab also showed acceptable accuracy, indicating the importance of brightness and hue changes due to iron deficiency. Indices such as NRI and DGCI also showed promising performance. However, no significant correlation was found between total iron content and any color feature. Using the best performing features (R, H, Y, I), a multilayer perceptron neural network (MLP) with a 4–25–1 architecture was developed. The model was trained using the Levenberg–Marquardt algorithm in MATLAB. The prediction accuracy reached  $R^2 = 0.80$  with RMSE = 1.56 and MAPE = 25.03% for the entire dataset. Histogram and scatter plots confirmed that the predicted values matched the actual values very well, especially at low iron levels. A comparison with multiple linear regression ( $R^2 = 0.74$ , RMSE = 1.33, MAPE = 31.54%) confirmed the superior performance of the neural network in modeling complex nonlinear relationships between leaf color and active iron content.

### Conclusion

This study confirmed that active iron in apple leaves can be accurately estimated using image-based color features and an artificial neural network. The most important color channels (R, H, Y, I) showed the strongest correlations with the active iron, while the total iron showed no significant correlation. These results underline the potential of a low-cost, smartphone-based image analysis system for the early diagnosis of iron deficiency in orchards. This approach could replace costly laboratory testing and enable scalable, real-time nutrient monitoring to support precision agriculture. Future developments could focus on extending the model to other micronutrients and integrating the system into mobile applications for farmers and extension specialists to bridge the gap between advanced analytics and on-farm decision making.

### Funding

This research did not receive any specific grant from funding agencies in the public, commercial, or not-for-profit sectors.

### Authorship contribution

Conceptualization, E.S. and A.I.; methodology, E.S., A.I. and H.S.; software, A.I.; validation, E.S. and A.I.; formal analysis, H.S. and A.I.; investigation, H.S. and A.I.; resources, E.S.; data curation, E.S. and H.S.; writing—original draft preparation, H.S. and A.I.; writing—review and editing, E.S. and A.I.; visualization, H.S. and A.I.; supervision, E.S. and A.I.; project administration, E.S.; funding acquisition, E.S. All authors have read and agreed to the published version of the manuscript.

**Declaration of Generative AI and AI-assisted technologies in the writing process**

The authors declare that they did not use of generative AI and AI-assisted technologies to write the manuscript.

**Data availability statement**

Data available on request from the authors.

**Acknowledgements**

The authors sincerely appreciate the support and facilities provided by the Department of Soil Science Engineering, Faculty of Agriculture, Urmia University, Iran.

**Conflict of interest**

The authors declare no conflict of interest.

## تخمین مقدار آهن برگ سیب با استفاده از مدل مبتنی بر شبکه عصبی و پردازش تصویر

حجت صادقی<sup>۱</sup> | ابراهیم سپهر<sup>۲</sup> | آیدین ایمانی<sup>۳</sup>۱. گروه علوم خاک، دانشکده کشاورزی، دانشگاه ارومیه، ارومیه، ایران. رایانامه: [hjsadeghi3@gmail.com](mailto:hjsadeghi3@gmail.com)۲. نویسنده مسئول، گروه علوم خاک، دانشکده کشاورزی، دانشگاه ارومیه، ارومیه، ایران. رایانامه: [e.sepehr@urmia.ac.ir](mailto:e.sepehr@urmia.ac.ir)۳. گروه علوم خاک، دانشکده کشاورزی، دانشگاه ارومیه، ارومیه، ایران. رایانامه: [aydin.imani@urmia.ac.ir](mailto:aydin.imani@urmia.ac.ir)

## چکیده

## اطلاعات مقاله

نوع مقاله: مقاله پژوهشی

کمبود آهن به عنوان یکی از شایع‌ترین مشکلات تغذیه‌ای گیاهان باغی واقع در خاک‌های آهنی است. تشخیص سریع کمبود آهن با استفاده از پردازش تصویر و یادگیری ماشین می‌تواند به عنوان یک روش ارزان به رفع این مشکل کمک کند. از این رو برای بررسی ارتباط بین کمبود آهن و ویژگی‌های رنگ برگ، یک پایگاه داده شامل ۱۵۷۵ تصویر برگ سیب با سطوح مختلف کمبود آهن (شدید، متوسط، کم و بدون کمبود) جمع‌آوری گردید. تصویربرداری با استفاده از دوربین گوشی هوشمند انجام گرفت و مقادیر آهن فعال و کل هر نمونه با دستگاه جذب اتمی اندازه‌گیری گردید. ویژگی‌های رنگی از فضاها رنگی RGB، Lab، HSV و NTSC به همراه ۸ شاخص رنگی ترکیبی استخراج شد. مدل‌سازی با دو رویکرد رگرسیون خطی و شبکه عصبی مصنوعی انجام گرفت. نتایج مدل خطی نشان داد مدل خطی قادر به پیش‌بینی آهن فعال با ضریب تعیین  $R^2 = 0.74$  است، اما با آهن کل همبستگی نشان نداد. مدل شبکه عصبی با دقت  $R^2 = 0.80$  و مقادیر خطای  $RMSE = 1.156$  و  $MAPE = 25.03$  عملکرد بهتری نسبت به مدل خطی داشت. در نتیجه، مدل شبکه عصبی با استفاده از ویژگی‌های رنگی برگ می‌تواند به عنوان روش سریع و غیر مخرب در تشخیص کمبود آهن و تخمین میزان آهن برگ سیب مورد استفاده قرار بگیرد.

تاریخ دریافت: ۱۴۰۴/۴/۱۱

تاریخ بازنگری: ۱۴۰۴/۱۰/۲۹

تاریخ پذیرش: ۱۴۰۵/۲/۶

تاریخ انتشار: خرداد ۱۴۰۵

## واژه‌های کلیدی:

برگ سیب،  
یادگیری ماشین،  
آهن فعال،  
پردازش تصویر

استناد: صادقی، حجت، سپهر، ابراهیم، ایمانی، آیدین، (۱۴۰۵) تخمین مقدار آهن برگ سیب با استفاده از مدل مبتنی بر شبکه عصبی و پردازش تصویر، مجله تحقیقات

<https://doi.org/10.22059/ijswr.2026.397919.669970>. ۷۵۱-۷۶۶، (۳)، ۵۷، آب و خاک ایران،

© نویسنده‌گان.

ناشر: مؤسسه انتشارات دانشگاه تهران.

DOI: <https://doi.org/10.22059/ijswr.2026.397919.669970>

## مقدمه

آهن نقش مهمی در فرایندهای حیاتی گیاه مانند فتوسنتز، تنفس و سنتز DNA داشته و یکی از عناصر مهم در رشد گیاه شناخته می‌شود. کلروز آهن یکی از مهم‌ترین اختلالات تغذیه‌ای باغ‌های واقع در خاک‌های آهکی و قلیایی نواحی است (Chaney., 1984). به دلیل وجود کربنات کلسیم، فسفات و pH قلیایی در این نوع خاک‌ها دسترسی گیاه به آهن موجود در خاک (حتی با وجود آهن کافی در خاک) کاهش می‌یابد. کلروز ناشی از آهن باعث کاهش سطح برگ، رشد رویشی، ریزش برگ‌ها، نارس شدن میوه و کاهش عملکرد و کیفیت میوه می‌شود و به طبع آن موجب بروز مشکلات فراوان در تولید میوه‌های تجاری می‌شود (Rout & Sahoo., 2015; Vasconcelos & Grusak., 2014). در پدیده پارادوکس کلروز آهن غلظت آهن کل در برگ‌های سبز و سالم ممکن است کمتر از برگ‌های دچار کلروز و کمبود آهن باشد (Morales et al., 1998). بنابراین از اندازه‌گیری آهن فعال ( $Fe^{2+}$ ) در برگ‌ها که شاخص مناسب‌تری برای تشخیص کمبود آهن در برگ است، استفاده می‌شود (Pestana et al., 2005). علامت مهم کمبود آهن، کلروز بین رگبرگی است که در شرایط کمبود شدید خود رگبرگ نیز دچار کلروز و زردی شده و برگ سفید می‌شود. در مواقعی نیز لکه‌های نکروزه قهوه‌ای مایل به قرمز در حاشیه برگ‌های جوان ایجاد می‌شوند (Merry et al., 2022).

تشخیص سریع و به موقع کمبود موجب افزایش تولید، سودآوری و کاهش هزینه‌ها شده و از ورود کودهای اضافی به خاک جلوگیری می‌کند (Hedley., 2015). پیش از این تشخیص کمبود مواد مغذی توسط متخصصان و تحلیل‌های شیمیایی انجام می‌گرفت (Sankaran et al., 2010). این روش‌ها با وجود برخورداری از دقت بالا دارای مشکلاتی از قبیل زمان‌بر بودن، عدم دسترسی راحت به متخصص و تجهیزات آزمایشگاهی، هزینه زیاد انجام آزمایشات هستند (Kendler et al., 2022). با پیشرفت‌های صورت‌گرفته در تصویربرداری دیجیتال و هوش مصنوعی، استفاده از این روش‌ها برای تشخیص تنش‌های غیرزیستی، مانند کمبود مواد مغذی، توجه بسیاری از پژوهشگران را به خود جلب کرده است (Barbedo, 2013). در تحقیقات مختلف از فضاهای مختلف رنگی مانند RGB (Pagola et al., 2009)، HSI (Sayeed et al., 2016)،  $L^*a^*b$  (Wang et al., 2014) و HSV (Bai et al., 2018) برای نشان دادن تغییرات در عناصر غذایی استفاده شده است. در شرایط کمبودهای تغذیه‌ای، گیاه معمولاً رنگ سبز روشن، زرد، قرمز و حتی قهوه‌ای را نشان می‌دهد. شناسایی مبتنی بر رنگ به طور گسترده‌ای برای بررسی مقدار نیتروژن استفاده شده است (Mercado-Luna et al., 2010). از آن‌جا که کمبود آهن یکی از عوامل محدودکننده رشد گیاه محسوب می‌شود و روش‌های سنتی تشخیص آن برای کشاورزان هزینه‌بر و دشوار است، طراحی یک سامانه پایش مستمر برای ارزیابی وضعیت تغذیه‌ای گیاهان امری ضروری به نظر می‌رسد؛ چرا که چنین سیستمی می‌تواند نقش مؤثری در ارتقاء کیفیت و افزایش بهره‌وری محصولات ایفا کند.

## پیشینه پژوهش

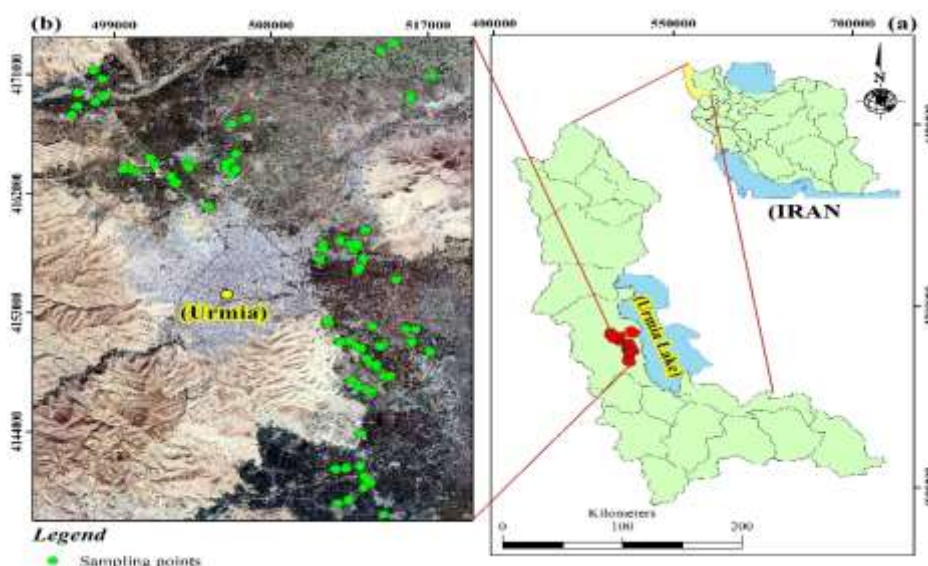
مطالعات متعددی به منظور تخمین عناصر غذایی گیاه از طریق پردازش تصویر انجام شده است. در این راستا، از تصاویر برگ و سایر بخش‌های گیاه برای استخراج ویژگی‌های مختلف مانند رنگ، بافت و شاخص‌های طیفی استفاده شده است. Vesali و همکاران (۲۰۱۵) نرم‌افزاری برای تخمین کلروفیل برگ ذرت با استفاده از تصاویر گرفته شده توسط گوشی هوشمند ارائه کردند. Chen و همکاران (۲۰۱۳) از تصاویر اسکن شده برگ و غلاف برنج برای تخمین فسفر استفاده کردند. Xu و همکاران (۲۰۱۱) تصاویر رنگی برگ گوجه فرنگی را برای شناسایی کمبود نیتروژن و پتاسیم مورد بررسی قرار دادند. Luz و همکاران (۲۰۱۸) از ویژگی‌های بافتی تصاویر برگ ذرت برای شناسایی کمبود بور استفاده کردند. Tewari و همکاران (۲۰۱۳) سامانه‌ای برای تهیه تصاویر رنگی گیاه برنج در مزرعه طراحی کردند و از آن برای تخمین نیتروژن استفاده کردند. آنها با استفاده از تصاویر رنگی RGB و مدل‌سازی رگرسیونی نشان دادند که با استفاده از ویژگی‌های رنگی می‌توان محتوای نیتروژن گیاهی را با دقت بالایی تخمین زد. Lee (۲۰۱۳) از تصاویر دیجیتالی برای تخمین محتوای نیتروژن تاج پوشش برنج به عنوان یک روش غیرمخرب نظارت بر وضعیت تغذیه‌ای گیاه استفاده کرد. آنها شاخص‌های مختلفی از جمله سطح برگ، وزن خشک شاخه و تجمع نیتروژن را اندازه گرفتند و نشان دادند که سامانه با استفاده از ویژگی‌های رنگی قادر است با دقت قابل قبولی میزان نیتروژن را تخمین بزند. Rorie و همکاران (۲۰۱۱) از دوربین دیجیتال و نرم‌افزار تحلیل تصویر برای ارزیابی غلظت نیتروژن برگ ذرت استفاده کردند. نتایج نشان داد که همبستگی بالایی بین میزان نیتروژن گیاه و شاخص رنگی سبز تیره (Dark green color index - DGCI) وجود دارد. Bai و همکاران (۲۰۱۸) از تصویربرداری RGB و بررسی ویژگی‌های فضاهای رنگی HSV برای

پیش‌بینی میزان آهن گیاه سویا استفاده کرده و نشان دادند که این روش از پتانسیل بالایی برای توسعه یک سامانه تصویربرداری برای تخمین میزان آهن گیاه سویا برخوردار است. Hajizadeh و همکاران (۲۰۲۴) از مدل شبکه عصبی برای طبقه بندی تصاویر برگ هلو براساس کمبود آهن استفاده کردند. در این تحقیق برگ‌های هلو بر اساس میزان شدت کمبود به چهار کلاس مختلف کمبود (شدید، متوسط، کم، بدون کمبود) با استفاده از روش خوشه‌بندی KNN تقسیم شدند. با استفاده از اعمال الگوریتم آنالیز مولفه اصلی (Principal Component analysis - PCA) بر روی ویژگی‌های استخراج شده از فضاها رنگی RGB، HSV و Lab مدل شبکه عصبی قادر بود با دقت ۰/۹ کمبود آهن در برگ هلو را تشخیص دهد. فیروزی و همکاران (۲۰۲۵) با استفاده از پردازش تصویر و شبکه عصبی مصنوعی، مدلی برای تخمین آهن فعال در برگ انگور توسعه دادند. نتایج با ضریب تعیین  $R^2=0.84$ ، نشان‌دهنده موفقیت مدل در پیش‌بینی دقیق مقادیر آهن و توانایی آن در پایش وضعیت تغذیه‌ای گیاه بود. با بررسی منابع موجود مشاهده می‌گردد علی‌رغم اهمیت عناصر کم‌مصرف به خصوص آهن در تولید محصولات کشاورزی، تحقیقات محدودی در این زمینه انجام گرفته است. با توجه به گسترش روز افزون تکنولوژی‌های نوین در حوزه نگهداری و تولید محصولات کشاورزی، توسعه یک روش سریع، در دسترس و ارزان جهت تخمین آهن موجود در برگ گیاه می‌تواند به کشاورزان در رسیدگی به موقع باغات کمک کند. هدف از مطالعه حاضر استفاده از ویژگی‌های رنگی برگ درخت سیب جهت تخمین مقدار آهن موجود در آن با استفاده از یادگیری ماشین است.

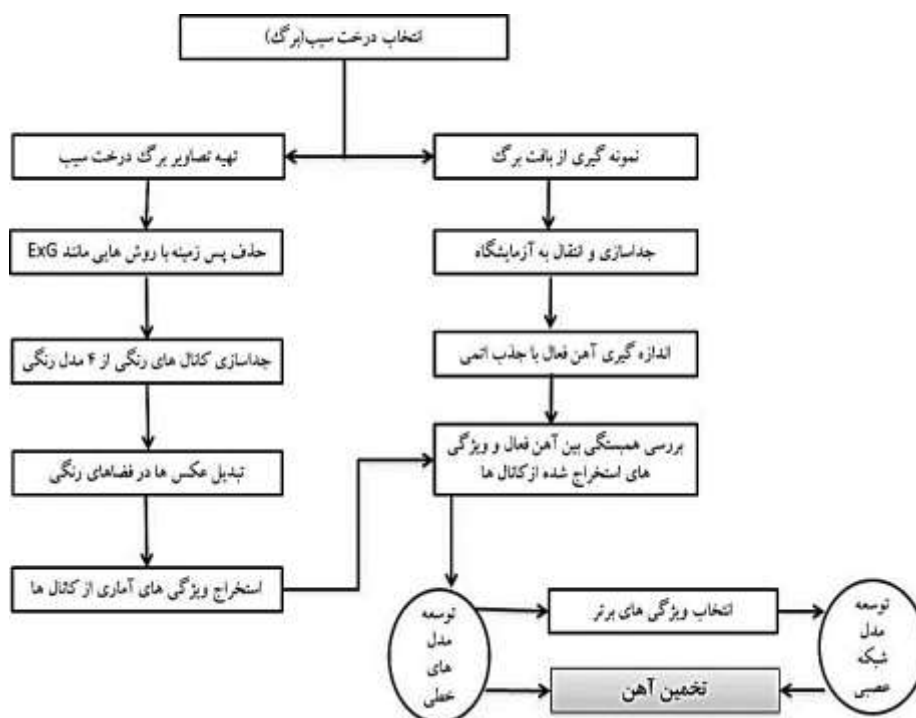
## روش پژوهش

### جمع‌آوری داده و تصویربرداری

به منظور تهیه پایگاه داده، ۱۵۷۵ تصویر برگ سیب (۱۷۵ نمونه و در هر بار تصویربرداری ۹ برگ) با کمبودهای شدید، متوسط، کم و بدون کمبود از حدود ۵۰ باغ سیب در اطراف شهرستان ارومیه شامل: جاده سرو، جاده سنتو، جاده دریا، جاده بالانج و جاده سلماس نمونه برداری شد (شکل ۱). عملیات تصویربرداری از برگ‌ها و نیز اندازه‌گیری‌های مربوط به آهن در آزمایشگاه گروه مهندسی علوم خاک دانشکده کشاورزی دانشگاه ارومیه در تیرماه سال ۱۴۰۰ انجام شد. تصاویر برداری با دوربین سامسونگ از فاصله ۱۵ سانتی‌متر نمونه‌ها در داخل محفظه مخصوص تصویربرداری انجام گرفت. تصاویر ۲۴ بیتی رنگی و در فضای رنگی RGB با فرمت JPEG ذخیره شدند. پس از انتقال تصاویر به رایانه، مقدار آهن فعال و آهن کل قرائت شده با تصاویر هر نمونه مطابقت داده شد و برای مرحله پردازش تصویر مورد استفاده قرار گرفت. مراحل کلی انجام تحقیق در شکل ۲ نشان داده شده است.



شکل ۱. مناطق نمونه‌برداری شده



شکل ۲. روند مدل سازی و تخمین آهن مورد استفاده در تحقیق حاضر

### اندازه گیری آهن

**آهن فعال:** برای اندازه گیری از روش فنان ترولین ۱/۵ درصد با pH=3 استفاده شد (Zohlen, 2000). به یک گرم از نمونه های برگ بریده شده ۱۰ میلی لیتر فنان ترولین ۱/۵ درصد اضافه و بلافاصله با همزن به مدت ۱۰ ثانیه مخلوط شد. لوله های حاوی نمونه و محلول عصاره گیری به مدت ۱۶ ساعت در دمای محیط قرار گرفتند. پس از این مدت، لوله ها به مدت ۵ دقیقه سانتریفیوژ و عصاره رویی از طریق کاغذ صافی به لوله های ۱۵ میلی لیتری منتقل شد. اندازه گیری آهن نمونه ها با دستگاه جذب اتمی (Shimadzu AA-6300) و با استفاده از سری استاندارد آهن در همان روز انجام شد.

**آهن کل:** برای اندازه گیری آهن کل از روش عصاره هضم خشک استفاده شد. ۱ گرم نمونه برگ پودر شده با دقت ۰/۰۰۱ توزین و به بوته های چینی منتقل و در کوره الکتریکی در دمای ۵۵۰ درجه سلسیوس به مدت ۷ ساعت به خاکستر تبدیل شد. سپس ۱۰ میلی لیتر اسید کلریدریک ۲ نرمال به بوته چینی اضافه و پس از نیم ساعت هضم در بالن های ۵۰ حجمی صاف شد. مقدار کل آهن موجود در این عصاره ها توسط دستگاه جذب اتمی اندازه گیری شد (Estefan, Sommer, & Ryan, 2013).

### پردازش تصویر و استخراج ویژگی


به منظور بهبود کیفیت تصاویر و حذف نویزهای ناخواسته، عملیات پیش پردازش بر روی تصاویر پیاده سازی شد تا تصاویر برای مرحله استخراج ویژگی آماده شوند. از شاخص سبزیگی مضاعف (ExG) به دلیل سادگی محاسباتی و توانایی بالای برای تفکیک پیکسل های گیاه از پس زمینه استفاده شد (Woebbecke et al., 1995). این شاخص با تقویت مؤلفه سبز و کاهش اثر کانال های قرمز و آبی، امکان تفکیک دقیق پیکسل های برگ از محیط اطراف را فراهم می کند (شکل ۳) (رابطه ۱):

$$ExG = (2 \times G) - R - B \quad \text{رابطه ۱}$$

که R، G و B به ترتیب شدت رنگ قرمز سبز و آبی را نشان می دهند. مقدار این شاخص در پیکسل های گیاهی مثبت است اما مقدار آن در پس زمینه می تواند مثبت یا منفی باشد.

پس از جداسازی پیکسل های گیاهی، ویژگی های رنگی از طریق تبدیلات خطی و غیرخطی استخراج شدند. در این تحقیق، چهار مدل رنگی RGB، HSV، Lab و NTSC که هر یک شامل سه کانال هستند، به همراه هشت شاخص رنگی ترکیبی مورد بررسی قرار

گرفتند. از هر کانال رنگی، پارامتر آماری میانگین<sup>۱</sup> استخراج شده و به عنوان ورودی‌های مدل خطی و مدل شبکه عصبی مورد استفاده قرار گرفتند. علاوه بر ویژگی‌های آماری استخراج شده از کانال‌های رنگی، شاخص‌های رنگی ترکیبی GMR، GDR، GBG، DGCI، NRI و VI نیز با استفاده از روابط زیر بدست آمدند (رابطه ۹ - ۲):



شکل ۳. تفکیک پیکسل‌های گیاه از پس‌زمینه برای برگ‌های (الف) بدون کمبود، (ب) کمبود کم، (ج) کمبود متوسط، (د) کمبود شدید

$GMR = G - R$	رابطه ۲
$GDR = G / R$	رابطه ۳
$DGCI = [(Hue / 60 - 1) + (1 - 5) + (1 - B)] / 3$	رابطه ۴
$NRI = \frac{R}{R + G + B}$	رابطه ۵
$NGI = \frac{R + G + B}{G - R}$	رابطه ۶
$VI = \frac{G - R}{G + R}$	رابطه ۷
$GBR = \frac{B}{R}$	رابطه ۸
$GBG = \frac{B}{G}$	رابطه ۹

#### توسعه مدل

ارتباط ویژگی‌های استخراج شده از تصاویر با مقدار آهن فعال اندازه‌گیری شده با استفاده از رگرسیون‌های تک متغیره بررسی و ویژگی‌های برتر به عنوان ورودی مدل شبکه عصبی انتخاب شدند. از شبکه عصبی پرسپترون چند لایه برای مدل‌سازی استفاده شد. تمامی مراحل مدل‌سازی در نرم‌افزار MATLAB 2017 پیاده‌سازی گردید. از الگوریتم لوبنبرگ-مارکوارت برای یادگیری استفاده شد. این روش از دقت

و سرعت بیشتری نسبت به سایر روش‌ها برخوردار است و نیاز کمتری به ورودی داده‌ها در حین آموزش دارد. برای جلوگیری از نشت اطلاعات در فرآیند آموزش، ۷۰ درصد داده‌ها به صورت تصادفی به عنوان داده‌های آموزشی برای آموزش و ۱۵ درصد برای اعتبارسنجی استفاده شد. در نهایت، ۱۵ درصد باقی‌مانده به عنوان داده‌های تست پس از آموزش برای ارزیابی دقت شبکه مورد استفاده قرار گرفت. از شاخص‌های ضریب تعیین ( $R^2$ )، مجذور میانگین مربعات خطا (RMSE) و درصد میانگین خطای مطلق (MAPE) برای ارزیابی دقت مدل استفاده شد.

## نتایج و بحث

### نتایج آهن فعال و کل

مقادیر آماری اندازه‌گیری‌های مربوط به آهن فعال و آهن کل موجود در نمونه‌های جمع‌آوری شده، در جدول (۱) نشان داده شده است. کمترین مقدار آهن فعال اندازه‌گیری شده در آزمایشگاه برابر با ۰/۲ میلی‌گرم بر کیلوگرم و حداکثر مقدار آن ۱۱/۰۹ میلی‌گرم بر کیلوگرم بود. میانگین آهن فعال نمونه‌های جمع‌آوری شده برابر با ۷/۳۳ میلی‌گرم بر کیلوگرم و میانه آن ۸/۰ میلی‌گرم بر کیلوگرم بود. حداقل مقدار آهن کل اندازه‌گیری شده ۸۱ میلی‌گرم بر کیلوگرم و مقدار حداکثر آن ۵۰۱ میلی‌گرم بر کیلوگرم بود. میانگین آهن کل نمونه‌های موجود در پایگاه داده برابر با ۳۳۸/۹۱ میلی‌گرم بر کیلوگرم بدست آمد.

جدول ۱. مقادیر حداقل و حداکثر آهن فعال و کل (میلی‌گرم بر کیلوگرم)

معیار	حداقل	حداکثر	میانگین	انحراف معیار
آهن کل	۸۱	۵۰۱	۳۳۸/۹۱	۹۶/۵۶
آهن فعال	۰/۲	۱۱/۰۹	۷/۳۳	۲/۶۱

### همبستگی ویژگی‌های رنگی با مقدار آهن

در این بخش ارتباط بین مقادیر آهن فعال و کل و ویژگی‌های رنگی استخراج شده از کانال‌های رنگی مختلف در فضاهای رنگی RGB، HSV، Lab، NTSc و شاخص‌های ترکیبی رنگی، مورد بررسی قرار گرفت (جدول ۲). از شاخص‌های  $R^2$ ، RMSE و MAPE برای ارزیابی مدل‌ها استفاده شد. میانگین کانال‌های رنگی G و R به دلیل ارتباط مستقیم با تغییرات رنگ برگ در اثر آهن، پیش‌بینی قابل قبولی ارائه کردند و بالاترین دقت پیش‌بینی ( $R^2 = 0.67$ ) و کمترین مقدار RMSE را داشتند. در فضای HSV، میانگین کانال‌های H و V دقت مشابهی با فضای RGB ارائه و بیشترین همبستگی با آهن فعال را نشان دادند. در فضای Lab، کانال‌های L و b به ترتیب با ( $R^2 = 0.67$ ) و ( $R^2 = 0.56$ ) دارای همبستگی بودند که این نتایج با تأثیر روشنایی (L) و تغییرات رنگ زرد (b) در برگ مرتبط است. تغییرات شاخص‌های ترکیبی NRI و DGCI نیز با میزان آهن فعال همبستگی داشت.


با توجه به نتایج مشاهده گردید، ویژگی میانگین در کانال‌های رنگی و شاخص‌های ترکیبی، خصوصاً در کانال‌های R، H و L نقش کلیدی در پیش‌بینی آهن فعال داشت که نشان‌دهنده تغییرات فیزیکی برگ‌ها به دلیل کمبود یا افزایش آهن است. ویژگی‌های R، H، Y و I در ارزیابی‌های مختلف از جمله RMSE، MAPE و  $R^2$  عملکرد بهتری نسبت به سایر ویژگی‌ها داشتند. به خصوص ویژگی‌های R و H دارای کمترین میزان خطا و بالاترین دقت بودند (شکل ۴). ویژگی‌های Y و I نیز عملکرد مناسبی را داشتند و توانستند ارتباط قابل قبولی با مقدار آهن فعال برقرار کنند. دقت کمتر کانال‌هایی مانند S و b در پیش‌بینی آهن نشان‌دهنده حساسیت کمتر آن‌ها به تغییرات آهن در برگ‌ها است (جدول ۲).

نتایج نشان داد بین هیچ یک از مولفه‌های رنگی و مقدار آهن کل همبستگی معنی داری وجود ندارد (شکل ۵). این نتایج با نتایج تحقیق Firuzi et al., (2025) و Romheld (2000) نیز مطابقت داشت. ارزیابی نتایج مدل‌ها توسط پارامترهای  $R^2$ ، RMSE، MAPE انجام شد و به دلیل ضریب تعیین پایین و خطای بسیار زیاد بین این مولفه‌ها، نتایج مربوط به آهن کل در این بخش ذکر نشدند.




جدول ۲. نتایج مدل سازی خطی تک متغیره بین ویژگی های رنگی و آهن فعال


مدل	میانگین مطلق درصد خطا (%)		ضریب تعیین R <sup>2</sup>
	مجذور میانگین مربعات خطا RMSE	MAPE	
R	۱/۴۶	۳۵/۸۴	۰/۶۷
G	۱/۴۹	۴۲/۳۶	۰/۶۶
B	۲/۱۴	۷۰/۳۹	۰/۱۵
H	۱/۴۶	۳۳/۰۷	۰/۶۸
S	۲/۳۱	۹۸/۵۲	۰/۲۰
V	۱/۴۹	۴۰/۹۴	۰/۶۷
L	۱/۴۶	۴۰/۲۲	۰/۶۸
a*	۲/۵۹	۹۴/۵۱	۰/۰۱
b*	۱/۷۰	۶۸/۱۳	۰/۵۷
Y	۱/۴۷	۳۹/۵۸	۰/۶۷
I	۱/۴۴	۳۸/۶۶	۰/۶۷
Q	۲/۱۹	۹۳/۵۹	۰/۲۸
VI	۱/۹۱	۴۱/۹۰	۰/۴۵
NGI	۲/۷۵	۹۰/۷۷	۰/۰۱
NRI	۱/۵۳	۴۴/۵۷	۰/۶۵
GBG	۲/۳۳	۹۹/۷۱	۰/۱۹
GBR	۱/۸۸	۷۷/۸۱	۰/۴۷
GDR	۱/۹۱	۴۳/۱۰	۰/۴۵
GMR	۲/۳۷	۶۵/۶۹	۰/۱۶
DGCI	۱/۰۸	۷۰/۹۷	۰/۵۳




(ب)



(الف)




(د)




(ج)

شکل ۴. همبستگی بین آهن فعال با مولفه های رنگی (الف) R (ب) H (ج) Y (د) I



(ب)




(الف)

شکل ۵. همبستگی بین آهن کل با مولفه‌های رنگی (الف) R (ب) G

### تخمین آهن فعال با مدل شبکه عصبی

در این تحقیق از یک شبکه عصبی مصنوعی پرسپترون چند لایه استفاده شد. ویژگی‌های برتر مرحله مدلسازی خطی (I و Y, H, R) به عنوان نورون‌های لایه ورودی (۴ نورون) در نظر گرفته شدند. تعداد نورون‌های لایه مخفی از طریق آزمون و خطا مورد بررسی قرار گرفت و در نهایت تعداد ۲۵ نورون برای لایه مخفی در نظر گرفته شد. به این صورت ساختار بهینه شبکه عصبی به صورت ۴-۲۵-۱ انتخاب گردید. (شکل ۶). فرایند آموزش شبکه با استفاده از الگوریتم لونیگ-مارکوارت انجام شد. برای آموزش شبکه، داده‌های تحقیق شامل ۱۷۵ نمونه به صورت تصادفی به سه دسته تقسیم شدند: ۷۰٪ برای آموزش، ۱۵٪ برای تست و ۱۵٪ برای اعتبارسنجی. شبکه تا رسیدن به کمترین خطای ممکن آموزش داده شد. معیار توقف آموزش، افزایش خطای اعتبارسنجی پس از یک نقطه مشخص بود تا از بروز بیش‌برازش جلوگیری شود. ضریب تعیین  $R^2$  دقت پیش‌بینی برای داده‌های آموزش، تست و کل داده‌ها به ترتیب برابر با ۰/۷۹، ۰/۸۰ و ۰/۸۰ بود. خطای میانگین مربعات RMSE برای داده‌های آموزش و تست به ترتیب برابر ۱/۱۶ و ۱/۲۵ محاسبه شد. نتایج دقت مدل شبکه عصبی برای سه مجموعه داده‌های آموزش، تست و کل داده‌ها در جدول ۳ نشان داده شده است.

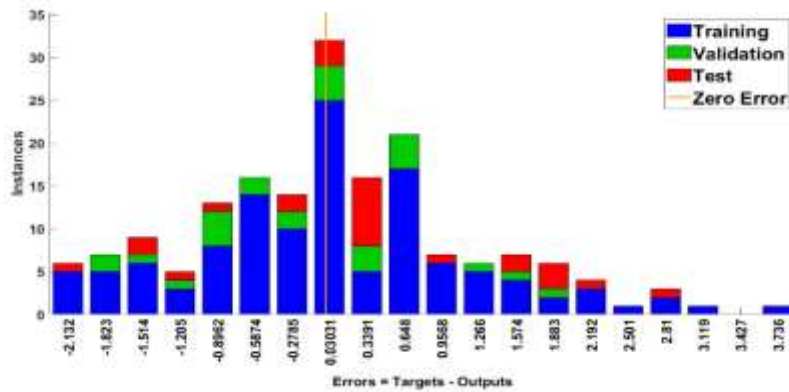


شکل ۶. ساختار شبکه عصبی مصنوعی استفاده شده


جدول ۳. نتایج دقت مدل شبکه عصبی برای سه مجموعه داده (آموزش، تست و کل داده‌ها)

	$R^2$	RMSE	MAPE (%)
آموزش	۰/۸۱	۱/۱۶۷	۲۰/۰۵
تست	۰/۷۹	۱/۲۵۹	۲۶/۹۷
کل داده‌ها	۰/۸۰	۱/۱۵۶	۲۵/۰۳


هیستوگرام خطای شبکه نشان داد بیشترین خطاها در نزدیکی صفر توزیع شده‌اند (شکل ۷). این توزیع نشان می‌دهد که مدل در اکثر پیش‌بینی‌ها خطای نزدیک به صفر داشته و پیش‌بینی‌ها به مقادیر واقعی نزدیک است. نمودار مربوط به مقادیر پیش‌بینی شده و واقعی برای مراحل آموزش، تست، اعتبارسنجی و کل داده در شکل ۸ نشان داده شده است. نزدیکی داده‌ها به خط شیب ۴۵ درجه نشان‌دهنده دقت بالای شبکه در تخمین مقادیر آهن فعال است. همانطور که مشاهده می‌گردد، شرایط کمبود شدید (مقدار آهن کمتر از ۲) و کمبود متوسط (مقادیر بین ۲ تا ۴) مقادیر واقعی و مقادیر پیش‌بینی شده با تقریب خوبی بر روی خط ۴۵ درجه منطبق شده‌اند که نشان‌دهنده دقت بالای مدل در تشخیص میزان آهن در شرایط کمبود است.



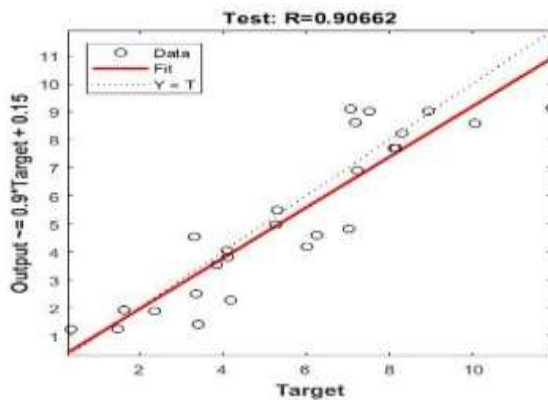
شکل ۷. نمودار هیستوگرام خطا



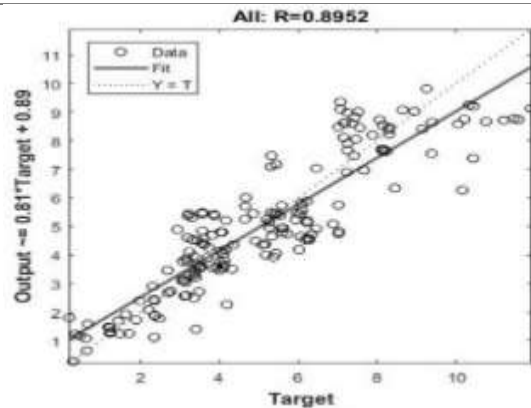
(الف)



(ب)



(ج)




(د)

شکل ۸. دقت شبکه عصبی مصنوعی برای (الف) داده‌های آموزش (ب) داده‌های اعتبارسنجی (ج) داده‌های تست (د) کل داده‌ها

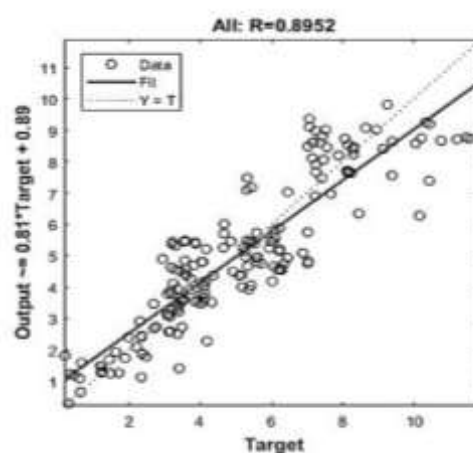
برای ارزیابی منصفانه کارایی شبکه عصبی یک مدل چهارمتغیره خطی شامل چهار ویژگی منتخب توسعه داده شد. نتایج مقایسه دو مدل در جدول ۴ نشان داده شده است. همانطور که مشاهده می‌گردد، مدل خطی چند متغیره دارای ضریب تعیین ۰/۷۴، مجذور میانگین مربعات خطا ۱/۳۲۶ و درصد میانگین خطای مطلق ۳۱/۵۴ است که در مقایسه با نتایج مدل‌های خطی تک متغیره بخش قبل از دقت بالاتری برخوردار است. مدل‌سازی خطی نشان داد که ویژگی‌های رنگی، می‌توانند آهن فعال را با دقت قابل قبولی پیش‌بینی کنند. ترکیب‌های چند متغیره بهبود قابل توجهی نسبت به مدل‌های تک متغیره در پیش‌بینی آهن فعال داشتند. مقایسه مدل‌های خطی و شبکه‌های عصبی نشان می‌دهد که در پیش‌بینی میزان آهن فعال، شبکه عصبی با دقت بالاتری (۰/۸۰) نسبت به مدل‌های خطی (۰/۷۴) عمل می‌کند. این نتایج نشان دهنده توانایی بالای شبکه عصبی در شناسایی روابط غیرخطی و پیچیده بین ویژگی‌های رنگی و مقدار آهن فعال در برگ‌ها است. نمودارهای همبستگی بین مقادیر واقعی و پیش‌بینی شده آهن فعال توسط مدل‌سازی خطی و شبکه عصبی نیز نشان داد که داده‌های پیش‌بینی شده توسط شبکه عصبی به داده‌های واقعی نزدیک‌تر بوده و خطای کمتری داشتند (شکل ۹).

جدول ۴- مقایسه مدل‌سازی خطی و شبکه عصبی مصنوعی

مدل‌ها	R <sup>2</sup>	RMSE	MAPE (%)
مدل شبکه عصبی	۰/۸۰	۱/۱۵۶	۲۵/۰۳
مدل‌سازی خطی	۰/۷۴	۱/۳۲۶	۳۱/۵۴



(ب)



(الف)

شکل ۹. مقایسه نتایج دو نوع مدل‌سازی (الف) شبکه عصبی (ب) رگرسیون خطی

## نتیجه‌گیری و پیشنهادها

این تحقیق با هدف تخمین آهن درختان سیب با استفاده از شبکه عصبی و پردازش تصویر انجام گرفت. در مدل‌های رگرسیون خطی بین آهن کل و ویژگی‌های رنگی هیچ همبستگی مشاهده نشد. نتایج مدل رگرسیون خطی چند متغیره آهن فعال نشان داد که مدل با ضریب تعیین ۰/۷۴ می‌تواند میزان آهن موجود در برگ را پیش‌بینی کند. نتایج مدل شبکه عصبی نشان داد که مدل توسعه داده شده قادر است با دقت ۰/۸۰ میزان آهن برگ را تخمین بزند. در این پژوهش از شبکه عصبی ۲ لایه با ۴ ورودی، ۲۵ نورون در لایه پنهان و یک خروجی استفاده شد. مقادیر به‌دست‌آمده برای R<sup>2</sup> در داده‌های آموزش (۰/۸۱) و آزمون (۰/۷۹)، همراه با مقادیر RMSE به ترتیب برابر با ۱/۱۷ و ۱/۲۶، نشان‌دهنده عملکرد قابل قبول مدل و توانایی آن در برآورد آهن فعال در شرایط آزمایش نشده است. نتایج بدست آمده نشان داد که روش پیشنهادی در محصول سیب نیز از کارایی لازم برخوردار است و می‌تواند به عنوان ابزاری آسان، ارزان و در دسترس برای اندازه‌گیری آهن فعال موجود در برگ گیاه مورد استفاده قرار گیرد. در نهایت، طراحی نرم‌افزارهای موبایلی جهت تخمین و تشخیص کمبود آهن در



مقیاس مزرعه می‌تواند گامی موثر در جهت افزایش کارایی و دسترسی به این روش باشد.

## ملاحظات اخلاقی

### حامی مالی

این پژوهش هیچ‌گونه کمک‌هزینه یا حمایت مالی مشخصی از سوی نهادهای دولتی، تجاری یا غیرانتفاعی دریافت نکرده است.

### مشارکت نویسندگان

طراحی پژوهش: ابراهیم سپهر و آیدین ایمانی، انجام محاسبات نرم افزاری: آیدین ایمانی، بررسی و کنترل نتایج: ابراهیم سپهر و آیدین ایمانی، تهیه و آماده‌سازی نمونه‌ها: حجت صادقی و آیدین ایمانی، انجام آزمایش و گردآوری داده‌ها: حجت صادقی و آیدین ایمانی، تامین منابع: ابراهیم سپهر، نظارت بر مراحل انجام پژوهش: ابراهیم سپهر، تجزیه و تحلیل آماری داده‌ها: ابراهیم سپهر و حجت صادقی، تحلیل و تفسیر اطلاعات و نتایج: ابراهیم سپهر، حجت صادقی و آیدین ایمانی، تهیه پیشنویس مقاله: حجت صادقی و آیدین ایمانی، اصلاح، بازبینی و نهایی‌سازی مقاله: ابراهیم سپهر و آیدین ایمانی، شکل‌ها و جداول: حجت صادقی و آیدین ایمانی

### اعلامیه هوش مصنوعی مولد و فناوری‌های مبتنی بر هوش مصنوعی در فرایند نگارش

نویسندگان اعلام می‌کنند که از هوش مصنوعی مولد در مراحل نگارش مقاله استفاده نکرده‌اند.

### بیانیه دسترسی به داده‌ها

داده‌هایی پژوهش حاضر از طریق درخواست از نویسندگان قابل دسترسی است.

### سپاسگزاری

از معاونت محترم پژوهشی دانشگاه ارومیه به خاطر حمایت مالی و حمایت معنوی در اجرای پژوهش حاضر سپاسگزاری می‌شود.

### تعارض منافع

نویسندگان اعلام می‌کنند که هیچ‌گونه تعارض منافی وجود ندارد.

## REFERENCES

- Barbedo, J.G.A., 2013. Digital image processing techniques for detecting, quantifying and classifying plant diseases. SpringerPlus, 2(1), pp.1-12.
- Bai, G., Jenkins, S., Yuan, W., Graef, G.L., & Ge, Y. (2018). Field-based scoring of soybean iron deficiency chlorosis using RGB imaging and statistical learning. *Frontiers in plant science*, 9, 1002. <https://doi.org/10.3389/fpls.2018.01002>
- Borhan, M.S., Panigrahi, S., Satter, M.A., & Gu, H. (2017). Evaluation of computer imaging technique for predicting the SPAD readings in potato leaves. *Information processing in agriculture*, 4(4), 275-282. <https://doi.org/10.1016/j.inpa.2017.07.005>
- Camargo, A., & Smith, J.S. (2009). An image-processing based algorithm to automatically identify plant disease visual symptoms. *Biosystems engineering*, 102(1), 9-21. <https://doi.org/10.1016/j.biosystemseng.2008.09.030>
- Chaney, R.L. (1984). Diagnostic practices to identify iron deficiency in higher plants. *Journal of Plant Nutrition*, 7(1-5), 47-67. <https://doi.org/10.1080/01904168409363174>
- Chen, L.S., Zhang, S.J., Wang, K., Shen, Z.Q. and Deng, J.S., 2013. Identifying of rice phosphorus stress based on machine vision technology. *Life Sci J*, 10(2), pp.2655-2663.
- Culman, M.A., Gomez, J.A., Talavera, J., Quiroz, L.A., Tobon, L.E., Aranda, J.M., Garreta, L.E. and Bayona, C.J., 2017, April. A novel application for identification of nutrient deficiencies in oil palm using the internet of things. In 2017 5th IEEE International Conference on Mobile Cloud Computing, Services, and Engineering (MobileCloud) (pp. 169-172). IEEE. <https://doi.org/10.1109/MobileCloud.2017.32>
- Firuzi, S., Sepehr, E., Imani, A., hossein pour, S. (2025). 'Development of an artificial neural network-based model for estimating the active iron content in grape leaves', *Iranian Journal of Soil and Water Research*, 55(11), pp. 2145-2156. doi: 10.22059/ijswr.2024.377062.669720
- Ghosal, S., Blystone, D., Singh, A.K., Ganapathysubramanian, B., Singh, A., & Sarkar, S. (2018). An explainable deep machine vision framework for plant stress phenotyping. *Proceedings of the National Academy of Sciences*, 115(18), 4613-4618. <https://doi.org/10.1073/pnas.1716999115>

- Hajizadeh, N., Sepehr, E., Maleki, R. and Imani, A. (2024). Detection of iron deficiency in peaches using image processing and artificial neural network model. *Iranian Journal of Soil and Water Research*, 55(1), 69-81. doi: 10.22059/ijswr.2023.367213.669597
- Hedley, C. 2015. The role of precision agriculture for improved nutrient management on farms. *J.Sci. Food Agric.* 95, 12 – 19 .<https://doi.org/10/f7krtc>
- Jeyalakshmi, S., & Radha, R. (2017). A review on diagnosis of nutrient deficiency symptom in plant leaf image using digital iamge processing. *ICTACT Journal on Image & Video Processing*, 7(4). DOI: 10.21917/ijivp.2017.0216
- Kendler, S., Aharoni, R., Young, S., Sela, H., Kis-Papo, T., Fahima, T. and Fishbain, B., 2022. Detection of crop diseases using enhanced variability imagery data and convolutional neural networks. *Computers and Electronics in Agriculture*, 193, p.106732. <https://doi.org/10.1016/j.compag.2022.106732>
- Lee, K. J., & Lee, B. W. (2013). Estimation of rice growth and nitrogen nutrition status using color digital camera image analysis. *European Journal of Agronomy*, 48, 57-65. <https://doi.org/10.1016/j.eja.2013.02.011>
- Leemans, V., Marlier, G., Destain, M.F., Dumont, B. and Mercatoris, B., 2017, April. Estimation of leaf nitrogen concentration on winter wheat by multispectral imaging. In *Hyperspectral Imaging Sensors: Innovative Applications and Sensor Standards 2017* (Vol. 10213, pp. 45-54). SPIE.
- Li, G., Kronzucker, H.J., & Shi, W. (2016). The response of the root apex in plant adaptation to iron heterogeneity in soil. *Frontiers in Plant Science*, 7: 344. <https://doi.org/10.3389/fpls.2016.00344>
- Liu, B., Zhang, Y., He, D. and Li, Y., 2017. Identification of apple leaf diseases based on deep convolutional neural networks. *Symmetry*, 10(1), p.11.
- Luz, P.H.D.C., Marin, M.A., Devechio, F.F.S., Romualdo, L.M., Zuniga, A.M.G., Oliveira, M.W.S., Bruno, O.M. (2018). Boron deficiency precisely identified on growth stage V4 of maize crop using texture image analysis. *Communications in Soil Science and Plant Analysis*, 49(2), 159-169. <https://doi.org/10.1080/00103624.2017.1421644>
- Merry, R., Dobbels, A. A., Sadok, W., Naeve, S., Stupar, R. M., & Lorenz, A. J. (2022). Iron deficiency in soybean. *Crop Science*, 62 (1), 36-52.
- Mao, H., Gao, H., Zhang, X., Kumi, F., 2015. Nondestructive measurement of total ni-trogen in lettuce by integrating spectroscopy and computer vision. *Scientia Horticulturae* 184, 1–7.
- Mercado-Luna, A., Rico-García, E., Lara-Herrera, A., Soto-Zarazua, G., Ocampo-Velazquez, R., Guevara-Gonzalez, R., Torres-Pacheco, I. (2010). Nitrogen determination on tomato (*Lycopersicon esculentum* Mill.) seedlings by color image analysis (RGB). *African Journal of Biotechnology*, 9(33).
- Morales, F., Grasa, R., Abadía, A., & Abadia, J. (1998). Iron chlorosis paradox in fruit trees. *Journal of plant nutrition*, 21(4), 815-825.
- Naik, M.R., Sivappagari, C.M.R. (2016). Plant leaf and disease detection by using HSV features and SVM classifier. *International Journal of Engineering Science*, 3794(260), 372À379.
- Pagola, M., Ortiz, R., Irigoyen, I., Bustince, H., Barrenechea, E., Aparicio-Tejo, P., Lasa, B. (2009). New method to assess barley nitrogen nutrition status based on image colour analysis: comparison with SPAD-502. *Computers and Electronics in Agriculture*, 65(2), 213-218.
- Pestana, M., de Varennes, A., Abadia, J., & Faria, E.A. (2005). Differential tolerance to iron deficiency of citrus rootstocks grown in nutrient solution. *Scientia Horticulturae*, 104(1), 25-36.
- Rorie, R. L., Purcell, L. C., Karcher, D. E., & King, C. A. (2011). The assessment of leaf nitrogen in corn from digital images. *Crop Science*, 51(5), 2174-2180.
- Rout, G.R., & Sahoo, S. (2015). Role of iron in plant growth and metabolism. *Reviews in Agricultural Science*, 3, 1-24.
- Saberioon, M.M., Amin, M.S.M., Aimrun, W., Gholizadeh, A., & Anuar, A.A.R. (2013). Assessment of colour indices derived from conventional digital camera for determining nitrogen status in rice plants. *Journal of Food, Agriculture & Environment*, 11(2), 655-662.
- Sankaran, S., Mishra, A., Ehsani, R. and Davis, C., (2010). A review of advanced techniques for detecting plant diseases. *Computers and electronics in agriculture*, 72(1), pp.1-13.
- Sayeed, M.A., Shashikala, G., Pandey, S., Jain, R., & Kumar, S.N. (2016). Estimation of nitrogen in rice plant using image processing and artificial neural networks. *Imperial Jurnal of Interdisciplinary research (IJIR)*, 2.
- Shi, P., Wang, Y., Xu, J., Zhao, Y., Yang, B., Yuan, Z., & Sun, Q. (2021). Rice nitrogen nutrition estimation with RGB images and machine learning methods. *Computers and Electronics in Agriculture*, 180, 105860.



- Sladojevic, S., Arsenovic, M., Anderla, A., Culibrk, D., & Stefanovic, D. (2016). Deep neural networks based recognition of plant diseases by leaf image classification. *Computational intelligence and neuroscience*, 2016.
- Sun, Y., Gao, J., Wang, K., Shen, Z., & Chen, L. (2018). Utilization of machine vision to monitor the dynamic responses of rice leaf morphology and colour to nitrogen, phosphorus, and potassium deficiencies. *Journal of Spectroscopy*, 2018.
- Sulistyo, S.B., Wu, D., Woo, W.L., Dlay, S.S., Gao, B., (2018). Computational deep in-telligence vision sensing for nutrient content estimation in agricultural automation. *IEEE Transactions on Automation Science and Engineering* 15 (3), 1243–1257
- Tewari, V. K., Arudra, A. K., Kumar, S. P., Pandey, V., & Chandel, N. S. (2013). Estimation of plant nitrogen content using digital image processing. *Agricultural Engineering International: CIGR Journal*, 15(2), 78-86.
- Vasconcelos, M.W., & Grusak, M.A. (2014). Morpho-physiological parameters affecting iron deficiency chlorosis in soybean (*Glycine max L.*). *Plant and soil*, 374, 161-172.
- Vakilian, K.A., & Massah, J. (2017). A farmer-assistant robot for nitrogen fertilizing management of greenhouse crops. *Computers and electronics in agriculture*, 139, 153-163.
- Wang, Y., Hu, X., Hou, Z., Ning, J. and Zhang, Z., 2018. Discrimination of nitrogen fertilizer levels of tea plant (*Camellia sinensis*) based on hyperspectral imaging. *Journal of the Science of Food and Agriculture*, 98(12), pp.4659-4664.
- Wang, F., Wang, K., Li, S., Gao, S., Xiao, C., Chen, B. & Diao, W. (2011). Estimation of canopy leaf nitrogen status using imaging spectrometer and digital camera in cotton. *Acta Agronomica Sinica*, 37(6), 1039-1048.
- Wang, Y., Wang, D., Zhang, G., & Wang, J. (2013). Estimating nitrogen status of rice using the image segmentation of GR thresholding method. *Field Crops Research*, 149, 33-39.
- Wang, Y., Wang, D., Shi, P., & Omasa, K. (2014). Estimating rice chlorophyll content and leaf nitrogen concentration with a digital still color camera under natural light. *Plant methods*, 10, 1-11.
- Wiren, N.V., Grusak, M.A. (2000). Summary of IX international symposium of iron nutrition and interaction in plants. *Journal of Plant Nutrition*.23: 2083-2102
- Wei, Y., Li, M., Sigrimis, N., 2010. Estimating Nitrogen Content of Cucumber Leaves Based on NIR Spectroscopy. *Sensor Letters* 8 (1), 145–150.
- Woebbecke, D. M., Meyer, G. E., Von Bargen, K., & Mortensen, D. A. (1995). Color indices for weed identification under various soil, residue, and lighting conditions. *Transactions of the ASAE*, 38(1), 259-269.
- Xu, G., Zhang, F., Shah, S.G., Ye, Y., & Mao, H. (2011). Use of leaf color images to identify
- Yuzhu, H., Xiaomei, W., & Shuyao, S. (2011). Nitrogen determination in pepper (*Capsicum frutescens L.*) plants by color image analysis (RGB). *African Journal of Biotechnology*, 10(77), 17737-17741.
- Yuan, Y., Chen, L., Li, M., Wu, N., Wan, L., Wang, S., 2016. Diagnosis of nitrogen nutrition of rice based on image processing of visible light. *Proc. IEEE International Conference on Functional-Structural Plant Growth Modeling, Simulation, Visualization and Applications* 228–232.