



Detection of iron deficiency in peaches using image processing and artificial neural network model

Nasim Hajizadeh¹ | Ebrahim Sepehr² | Ramin Maleki³ | Aydin Imani⁴

1. Department of Soil Science, Faculty of Agriculture, Urmia University, Urmia, Iran. E-mail: hajizade.nasim@gmail.com

2. Corresponding Author, Department of Soil Science, Faculty of Agriculture, Urmia University, Urmia, Iran. E-mail: e.sepehr@urmia.ac.ir

3. Department of Analytical Chemistry, Academic Center for Education, Culture and Research of West Azerbaijan, Urmia, Iran. E-mail: malekiche@gmail.com

4. Department of Soil Science, Faculty of Agriculture, Urmia University, Urmia, Iran. E-mail: aydin.imani@urmia.ac.ir

Article Info

Article type: Research Article

Article history:

Received: Oct. 25, 2023

Revised: Dec. 1, 2023

Accepted: Dec. 25, 2023

Published online: March. 2024

Keywords:

Iron Deficiency,
Image Processing,
KNN Clustering,
Neural Network,
Peaches.

ABSTRACT

Accurately and promptly monitoring the nutritional conditions of fruit orchards is crucial for providing optimal fertilizer recommendations, which in turn improves yield and enhances the quality of agricultural products. The current laboratory methods used to evaluate nutritional condition in fruit trees are expensive, challenging, time-consuming, and require an expert. In this study, image processing methods and neural network models was utilized to determine the stages of iron deficiency in peach trees. Therefore, a database containing 800 images of peach leaf samples was acquired. These images were then classified into four categories using the KNN clustering method: no deficiency, low deficiency, moderate deficiency, and severe deficiency. The preprocessing, feature extraction, and modeling operations were performed in the MATLAB software, version 2017. Features such as mean and standard deviation were extracted from the RGB, HSV, and Lab color space components of each image. Subsequently, the principal component analysis (PCA) algorithm was applied to the feature vector. To determine the optimal structure of the network, criteria including precision, accuracy, recall, and the F1-score were evaluated. These criteria helped ascertain the number of optimal inputs and the corresponding number of neurons for each combination of input features (PCs). Results indicated that the neural network model, structured as 6-36-4, achieved an accuracy of $89.73 \pm 0.54\%$, precision of $89.59 \pm 0.57\%$, recall of $89.52 \pm 0.51\%$, and an F1-score of $89.55 \pm 0.54\%$ in detecting levels of iron deficiency in peach tree leaves. The findings from the confusion matrix and the developed model reveal that this method can effectively and efficiently detect the severity of iron deficiency in peach tree leaves.

Cite this article: Hajizadeh, N., Sepehr, E., Maleki, R., & 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. <https://doi.org/10.22059/ijswr.2023.367213.669597>

© The Author(s).

Publisher: The University of Tehran Press.

DOI: <https://doi.org/10.22059/ijswr.2023.367213.669597>



تشخیص کمبود آهن در هلو با استفاده از پردازش تصویر و مدل شبکه عصبی مصنوعی

نسیم حاجی‌زاده^۱ | ابراهیم سپهر^۲ | رامین ملکی^۳ | آیدین ایمانی^۴۱. گروه علوم خاک، دانشکده کشاورزی، دانشگاه ارومیه، ارومیه، ایران. رایانامه: hajizade.nasim@gmail.com۲. نویسنده مسئول، گروه علوم خاک، دانشکده کشاورزی، دانشگاه ارومیه، ارومیه، ایران. رایانامه: e.sepehr@urmia.ac.ir۳. گروه شیمی تجزیه، جهاد دانشگاهی آذربایجان غربی، ارومیه، ایران. رایانامه: malekicheh@gmail.com۴. گروه علوم خاک، دانشکده کشاورزی، دانشگاه ارومیه، ارومیه، ایران. رایانامه: aydin.imani@urmia.ac.ir

چکیده

اطلاعات مقاله

نوع مقاله: مقاله پژوهشی

بایش سریع و دقیق شرایط تغذیه‌ای باغ‌های میوه برای توصیه بهینه کودی یک بخش حیاتی در بهبود عملکرد و افزایش کیفیت محصولات کشاورزی است. روش‌های آزمایشگاهی فعلی مورد استفاده برای وضعیت تغذیه درختان میوه گران، دشوار، زمان‌بر و نیازمند فرد متخصص هستند. این تحقیق به منظور تعیین میزان کمبود آهن در درختان هلو، روش پردازش تصویر و مدل شبکه عصبی استفاده شد. یک پایگاه داده شامل ۸۰۰ تصویر از نمونه‌های برگ هلو در ابتدا تهیه و تصاویر با استفاده از روش خوشه‌بندی KNN در چهار کلاس بدون کمبود، کمبود کم، کمبود متوسط و کمبود شدید طبقه‌بندی شدند. عملیات پیش‌پردازش، استخراج ویژگی‌ها و مدل‌سازی با استفاده از شبکه عصبی در نرم‌افزار متلب نسخه ۲۰۱۷ انجام گرفت. ویژگی‌های میانگین و انحراف معیار از مولفه‌های فضای رنگی RGB، HSV و Lab هر تصویر استخراج شدند و سپس الگوریتم آنالیز مولفه اصلی (PCA) بر روی بردار ویژگی اعمال شد. برای تعیین ساختار بهینه شبکه معیارهای دقت، صحت، بازیابی و معیار F برای تعیین تعداد ورودی‌های بهینه و تعداد نورون‌های متناظر با هر ترکیب ویژگی‌های ورودی (PCها) استفاده شد. نتایج نشان داد که مدل شبکه عصبی با ساختار ۴-۳۶-۶ قادر است با دقت $(0.89/0.73 \pm 0.054)$ ، صحت $(0.89/0.59 \pm 0.051)$ ، بازیابی $(0.89/0.52 \pm 0.054)$ و معیار F $(0.89/0.55 \pm 0.054)$ میزان سطح کمبود آهن در برگ درخت هلو را تشخیص دهد. نتایج بدست آمده از ماتریس اغتشاش و مدل توسعه داده شده نشان داد که این روش قادر است با کارایی بالا شدت کمبود آهن در برگ درختان هلو را تشخیص دهد.

تاریخ دریافت: ۱۴۰۲/۸/۳

تاریخ بازنگری: ۱۴۰۲/۹/۱۰

تاریخ پذیرش: ۱۴۰۲/۱۰/۴

تاریخ انتشار: فروردین ۱۴۰۳

واژه‌های کلیدی:

پردازش تصویر،

خوشه‌بندی KNN،

شبکه عصبی،

کمبود آهن،

هلو.

استناد: حاجی‌زاده، نسیم؛ سپهر، ابراهیم؛ ملکی، رامین؛ و ایمانی، آیدین (۱۴۰۳). تشخیص کمبود آهن در هلو با استفاده از پردازش تصویر و مدل شبکه عصبی مصنوعی،

مجله تحقیقات آب و خاک ایران، ۵۵ (۱)، ۶۹-۸۱. <https://doi.org/10.22059/ijswr.2023.367213.669597>

© نویسندگان.

ناشر: مؤسسه انتشارات دانشگاه تهران.

DOI: <https://doi.org/10.22059/ijswr.2023.367213.669597>

مقدمه

کمبود عناصر غذایی بعد از تنش آبی یکی از مهم‌ترین عوامل تاثیرگذار بر کیفیت و عملکرد محصول محسوب می‌شود (Zhou et al., 2019). در میان عناصر ریزمغذی کمبود آهن به عنوان یک عنصر ریزمغذی یک اختلال تغذیه‌ای مهم در باغاتی است که در خاک‌های آهکی احداث شده‌اند (Bavaresco and Poni., 2003). در بسیاری از خاک‌ها آهن کل به میزان کافی در خاک وجود دارد اما امکان دارد به دلایلی در دسترس گیاه قرار نگیرد (Başar, 2000). در خاک‌های آهکی به علت pH بالا و محتوای CaCO_3 ، عدم تعادل یون و خواص فیزیکی ضعیف مانند دمای بسیار بالا یا پایین خاک، رطوبت بالا، هوادهی ضعیف خاک و تراکم، علائم کمبود آهن در گیاه مشاهده می‌گردد (Lucena 2000؛ Köseoğlu 1995). از این رو غلظت آهن کل در برگ‌ها شاخص معتبری برای تعیین وضعیت تغذیه آهن در محصولات کشاورزی نیست و بررسی‌ها نشان داده که غلظت آهن کل در برگ‌های کلروزه اغلب مشابه یا حتی بیشتر از برگ‌های سبز است (Neaman and Aguirre, 2007). این مغایرت به دلیل pH بالای آپوپلاست و رسوب بخشی از آهن در برگ‌ها است که از نظر فیزیولوژیکی فعال نمی‌باشد (Romheld, 2000).

در حال حاضر، گزینه‌های موجود برای کشاورزان کمک گرفتن از فرد خبره یا نمونه برداری و ارسال نمونه‌های برگ برای تجزیه و تحلیل به آزمایشگاه است، که بهره‌برداری از هر دوی این روش‌ها سخت و پرهزینه می‌باشد. بنابراین، این مطالعه تلاش دارد تا راه‌حلی کارآمد، مقرون به صرفه و دقیق برای این مشکل ارائه دهد. در نتیجه هدف تحقیق حاضر، ایجاد یک پایگاه داده از نمونه برگ‌های گیاه هلو، طبقه‌بندی آنها در چهار سطح مختلف فاقد کمبود، کمبود کم، کمبود متوسط و کمبود شدید و در نهایت توسعه یک مدل مبتنی بر پردازش تصویر و یادگیری ماشین با هدف تشخیص میزان کمبود آهن به‌عنوان جایگزینی با روش‌های آزمایشگاهی مرسوم است.

پیشینه پژوهش

در بسیاری از محصولات کمبود آهن به صورت زردی معمولی برگ‌های جوان ظاهر می‌شود. کمبود آهن بر ترکیب عناصر برگ و گل تأثیر گذاشته و عامل کاهش قابل توجه در عملکرد، اندازه میوه و کیفیت بسیاری از گونه‌ها است (Tagliavini and Rambola, 2001). استفاده از روش‌های آزمایشگاهی و تخریبی برای تشخیص میزان کمبود آهن به طور معمول زمان‌بر بوده و هزینه بالایی دارند. استفاده از روش‌های مبتنی بر پردازش تصویر و یادگیری ماشین با استفاده از تصاویر هوایی، ماهواره‌ای و سنسورهای زمینی برای تشخیص علائم کمبود عناصر غذایی در گیاهان از گذشته مورد توجه پژوهشگران قرار گرفته است (Han & Watchareeruetai., 2019; Jafarbiglu & Pourreza, 2023). در این بین، با وجود گسترش سامانه‌های تصویربرداری چندطیفی (Liu et al., 2017; Leemans et al., 2017; Borhan et al., 2017) و ابرطیفی (Liu et al., 2018; Wang et al., 2015)، استفاده از حسگرهای تصویربرداری طیف مرئی از محبوبیت بالایی برخوردار است (Barbedo, 2019). از مزایای این روش می‌توان به غیر مخرب بودن، دقت و سرعت بالا و ارزان بودن آن در بررسی تغییرات رنگ و شکل برگ‌های گیاه اشاره کرد (Sladojevic et al., 2016; Imani et al., 2020).

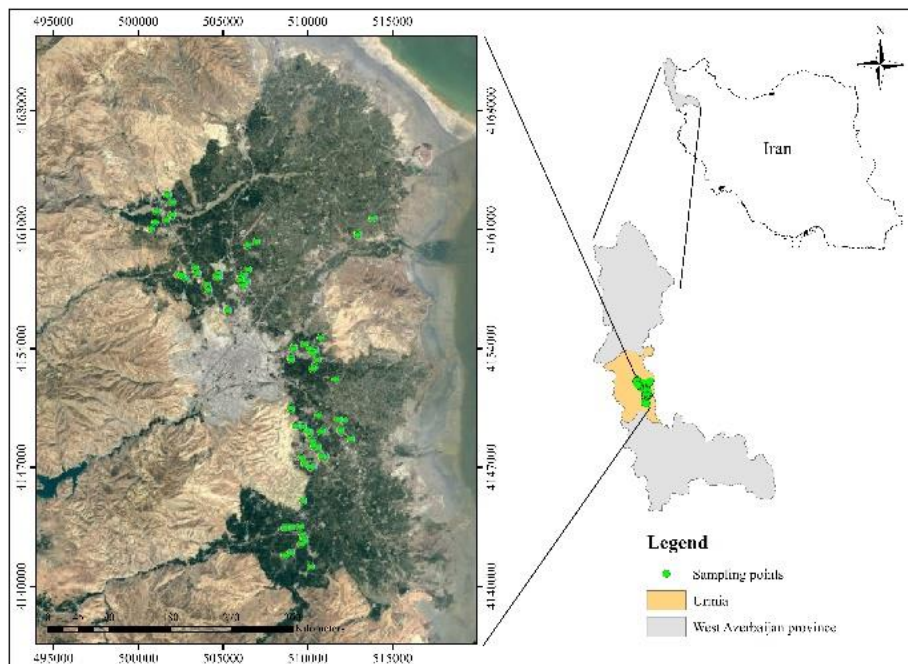
در میان مطالعاتی که از بینایی ماشین و هوش مصنوعی برای شناسایی، طبقه‌بندی و تخمین شدت بیماری گیاهی استفاده می‌کنند، محصولات کشاورزی مانند برنج (Tewari et al., 2013; Chen et al., 2017; Sun et al., 2018)، گندم (Li et al., 2010; Sulisty et al., 2018) و ذرت (Condori et al., 2017; Romualdo et al., 2018; Luz et al., 2018) بیشتر مورد مطالعه قرار گرفته‌اند. در زمینه کمبود عناصر غذایی بخش قابل توجهی از مطالعات موجود به تشخیص و تخمین کمبود عناصر ماکرو مانند نیتروژن (Vakilian and Massah, 2018; Wang et al., 2017)، فسفر (Liu et al., 2015; Sun et al., 2018a)، پتاسیم (Balasubramaniam and Ananthi, 2016; Sun et al., 2018b)، منیزیم (Culman et al., 2017; Muhammad Asraf et al., 2017) پرداخته و تحقیقات اندکی در مورد عناصر میکرو مانند آهن (Ghosal et al., 2018)، منگنز (Hu et al., 2012) را انجام گرفته است.

کمبود آهن در درختان هلو در سطوح مختلف ظاهر می‌شود و هر سطح نیاز کودی متفاوتی نسبت به سطوح دیگر دارد. در نتیجه رویکردی ساده، پایدار و حساس برای تشخیص میزان کمبود آهن می‌تواند کمک شایانی در تحقیق و توسعه ابزارهای نوین برای ارائه توصیه کودی هوشمند داشته باشد. از این رو، در این مطالعه یک پایگاه داده شامل چهار طیف کمبود آهن تهیه و یک روش مبتنی بر شبکه عصبی مصنوعی برای طبقه‌بندی خودکار برگ‌های درخت هلو بر اساس میزان کمبود آهن ارائه شد.

روش‌شناسی پژوهش

جمع‌آوری داده و تصویربرداری

تعداد ۸۰۰ نمونه برگ ۲-۳ ماهه با علایم کلروز شدید، متوسط، ضعیف و بدون کمبود از ۷۰ باغ هلو دچار کمبود واقع در اطراف شهرستان ارومیه شامل: جاده سرو، جاده سنتو، جاده دریا، جاده بالانج و جاده سلماس (شکل ۱) در بازه خرداد تا تیر ماه سال ۱۴۰۱




شکل ۱. مناطق نمونه‌برداری شده واقع در اطراف شهرستان ارومیه، استان آذربایجان غربی، ایران.

جمع‌آوری و عملیات تصویربرداری از برگ‌ها و نیز اندازه‌گیری‌های مربوط به آهن در گروه خاک دانشکده کشاورزی، دانشگاه ارومیه انجام شد. در هر باغ نمونه‌برداری به صورت تصادفی از نقاط مختلف انجام گرفت و نمونه برگ‌های جوان دارای علایم کمبود آهن داخل کیسه‌های زیپ‌دار جمع‌آوری و تا زمان انتقال به آزمایشگاه داخل محفظه سرد نگهداری شد.

تصویربرداری از تمامی برگ‌ها توسط دوربین تلفن همراه هوشمند آیفون مدل 6s دارای سنسور ۱۲ مگاپیکسل (با فاصله کانونی ۲۹ میلی‌متری و فوکوس خودکار با تشخیص فاز) انجام گرفت. در زمان تصویربرداری میزان ISO و سرعت شاتر دوربین به ترتیب در بازه ۲۵-۴۰ و ۱/۱۰۰-۱/۵۰ قرار داشت. برای تسهیل مراحل مربوط به پیش‌پردازش و جداسازی برگ‌ها از پس زمینه سفید برای تصویربرداری استفاده شد. در زمان تصویربرداری دوربین در فاصله حدود ۱۵-۲۵ سانتی متری از برگ‌ها و به طور عمودی قرار گرفت. تصاویر دیجیتالی ثبت شده به صورت تصاویر ۲۴ بیتی رنگی و اندازه ۳۵۰۴×۴۶۷۲ پیکسل در فضای رنگی RGB و با فرمت JPEG ذخیره گردیدند.

اندازه‌گیری آهن فعال و طبقه‌بندی تصاویر

پس از ثبت تصاویر نمونه‌های برگ تازه برای استخراج مقدار آهن فعال کاملاً شسته و سپس هوا خشک شدند. از نمونه‌های برگ ۱ گرم توزین و ۱۰ میلی لیتر محلول فناترولین ۱/۵ درصد با (pH = 3) به آن اضافه گردید (Katial and Sharma, 1980). پس از ۱۶ ساعت نمونه‌ها صاف و به حجم رسانده شدند. قرائت آهن نمونه‌ها با دستگاه جذب اتمی (Shimadzu AA-6300) و با استفاده از سری‌های استاندارد آهن در اولین فرصت انجام گرفت (Zohlen, 2000). در نهایت، تصاویر برگ‌ها با استفاده از الگوریتم خوشه‌بندی K-Nearest Neighbors بر اساس مقادیر آهن فعال آن‌ها (Fe^{2+}) به چهار کلاس بدون کمبود (None)، کمبود کم (Low)، کمبود متوسط (Moderate) و کمبود شدید (Severe) طبقه‌بندی شدند. روش KNN به دلیل توانایی مؤثر آن در مدیریت داده‌های چند بعدی، برای خوشه‌بندی با استفاده از ویژگی میانگین کانال سبز فضای رنگی تصویر برگ و مقدار آهن فعال (Fe^{2+}) مورد استفاده قرار گرفت. شکل ۲ نمونه تصاویر برگ از پایگاه داده جمع‌آوری شده را نشان می‌دهد که سطوح مختلف کمبود آهن را نشان می‌دهد.



شکل ۲. تصاویر مربوط به برگ درخت هلو با سطوح مختلف آهن در پایگاه داده جمع آوری شده. (الف) بدون کمبود، (ب) کمبود کم، (ج) کمبود متوسط، (د) کمبود شدید.

استخراج ویژگی و توسعه مدل PCA-ANN

در این مطالعه ساختاری با نام PCA-ANN برای طبقه‌بندی نمونه برگ‌های هلو بر اساس میزان آهن فعال در برگ توسعه داد شد. با توجه به این که تخمین دقیق مقدار آهن مهم‌ترین عامل موفقیت در تعیین نیاز کودی گیاه است، تشخیص میزان کمبود آهن در گیاه با استفاده از ماشین بینایی از ضرورت‌های کشاورزی دقیق است. از این رو استخراج موثر ویژگی مهم‌ترین گام در تخمین آهن نمونه‌ها است، زیرا روش‌های موجود برای مدلسازی بر اساس رنگ بسیار وابسته به ویژگی‌های استخراج شده از نمونه‌های مورد مطالعه هستند.

در مرحله اول پس از انجام عملیات پیش پردازش، ابتدا تصاویر از فضای RGB به فضای HSV و $L^*a^*b^*$ انتقال داده شدند (Vesali et al., 2015):

$$C = \max(R, G, B) - \min(R, G, B) \quad \text{رابطه ۱}$$

$$Hue = \begin{cases} 60 \times \left(\frac{G - B}{C}\right) & \max(R, G, B) = R \\ 60 \times \left(2 + \frac{B - R}{C}\right) & \max(R, G, B) = G \\ 60 \times \left(4 + \frac{G - B}{C}\right) & \max(R, G, B) = B \end{cases} \quad \text{رابطه ۲}$$

$$Saturation = \begin{cases} 0 & V = 0 \\ \frac{C}{\max(R, G, B)} & V \neq 0 \end{cases} \quad \text{رابطه ۳}$$

$$Value = \max(R, G, B) / 255 \quad \text{رابطه ۴}$$

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = \begin{bmatrix} 0.412453 & 0.357580 & 0.180423 \\ 0.212671 & 0.715160 & 0.072169 \\ 0.019334 & 0.119193 & 0.950227 \end{bmatrix} \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad \text{رابطه ۵}$$

$$[X_n, Y_n, Z_n] = [0.950450, 1.000000, 1.088754] \quad \text{رابطه ۶}$$

$$\begin{cases} L^* = 116 \left(\frac{Y}{Y_n}\right)^{1/3} - 16 & \text{for } \frac{Y}{Y_n} > 0.008856 \\ L^* = 903.3 \left(\frac{Y}{Y_n}\right)^{1/3} & \text{for } \frac{Y}{Y_n} \leq 0.008856 \end{cases}$$

$$a^* = 500 \left(f\left(\frac{X}{X_n}\right) - f\left(\frac{Y}{Y_n}\right) \right) \quad \text{رابطه ۷}$$

$$b^* = 200 \left(f\left(\frac{X}{X_n}\right) - f\left(\frac{Z}{Z_n}\right) \right)$$

$$\begin{cases} f(u) = u^{1/3} & \text{for } u > 0.008856 \\ f(u) = 7.787u + \frac{16}{116} & \text{for } u \leq 0.008856 \end{cases}$$

که در آن R, G و B مقادیر شدت رنگ قرمز، سبز و آبی و X, Y و Z مقادیر مربوط به فضای رنگی XYZ می‌باشند. شایان ذکر است برای تبدیل تصاویر از فضای رنگی RGB به $L^*a^*b^*$ ابتدا باید تصویر را به فضای XYZ تغییر داده و سپس XYZ را به $L^*a^*b^*$ تبدیل کرد.

در نهایت برای یافتن ترکیب بهتر و دقیق‌تر مولفه‌های رنگی به منظور طبقه‌بندی تصاویر، ویژگی‌های آماری شامل میانگین و انحراف معیار برای هریک از کانال‌های مربوط به فضاهای رنگی RGB, HSV و Lab استخراج شدند:

$$\text{mean}(\mu_i) = \frac{\sum_{x=1}^M \sum_{y=1}^N I_i(x, y)}{M \times N} \quad \text{رابطه ۸}$$

$$\text{standard deviation}(\sigma_i) = \sqrt{\frac{\sum_{x=1}^M \sum_{y=1}^N (I_i(x, y) - \mu)^2}{M \times N}} \quad \text{رابطه ۹}$$

که در آن I_i مقدار مربوط به هر پیکسل و M و N به ترتیب عدد مربوط به سطر و ستون پیکسل در تصویر هستند. در نتیجه متغیرهای ورودی برای این فضاهای رنگی در کل برابر ۱۸ (۹ مولفه رنگی $\times ۲$ ویژگی آماری) عدد بود. همان طوری که گفته شد، برای کاهش زمان آموزش طبقه‌بندی، کاهش پیچیدگی و احتمال بیش‌برازش مدل آموزش داده شده، ابتدا از آنالیز مولفه اصلی بر روی داده‌های ورودی استفاده شد. PCA یک ابزار پرکاربرد برای آنالیز داده و کاهش ابعاد است. PCA متغیرهای ورودی دارای همبستگی را می‌گیرد و با اعمال یک تبدیل متعامد^۱ بر روی داده، متغیرهای ورودی را به فضایی می‌نگارد که در آن ناهمبسته هستند. متغیرهای فضای جدید مولفه‌های اصلی یا PC نامیده می‌شوند. مولفه‌های اصلی به صورت جهت‌های متعامدی تعریف می‌شوند که داده در آن جهت‌ها دارای بیشترین واریانس است. به منظور یافتن بهترین ساختار شبکه عصبی، یک ارزیابی سیستماتیک انجام شد. هدف اصلی در این بخش یافتن بردار ویژگی بهینه شبکه عصبی برای طبقه‌بندی برگ‌های هلو بر اساس میزان آهن فعال (Fe^{2+}) بود. بدین منظور، در قدم اول ساختار بهینه شبکه عصبی برای هر بردار ویژگی مورد بررسی قرار گرفت. در نهایت مدل طبقه‌بند بر اساس تعداد بهینه مولفه‌های اصلی برای لایه ورودی و نورون‌های لایه مخفی توسعه داده شد. ساختار مدل از یک لایه مخفی با تابع فعال‌سازی تانژانت سیگموئید تشکیل شده بود. برای انتخاب تعداد نورون‌های لایه مخفی شبکه با تعداد متفاوتی از نورون‌ها (۱ تا ۵۰) در لایه پنهان آموزش داده شد. برای هر مدل آموزش با ۱۰۰ بار تکرار انجام گرفت و دقت در هر تکرار ثبت گردید. در نهایت نمودار تغییرات دقت در برابر تعداد نورون‌های لایه پنهان برای هر مدل رسم گردید. معیارهای عملکرد دقت (Accuracy)، صحت (Precision)، بازیابی (Recall) و معیار F (F1-score) برای ارزیابی کارایی مدل‌ها استفاده شد:

$$\text{Accuracy} = \frac{\text{Number of correct predictions}}{\text{Total number of predictions}} \quad \text{رابطه ۱۰}$$

$$Precision = \frac{True\ Positives}{True\ Positives + False\ Positives} \quad \text{رابطه (۱۱)}$$

$$Recall = \frac{True\ Positives}{True\ Positives + False\ Negatives} \quad \text{رابطه (۱۲)}$$

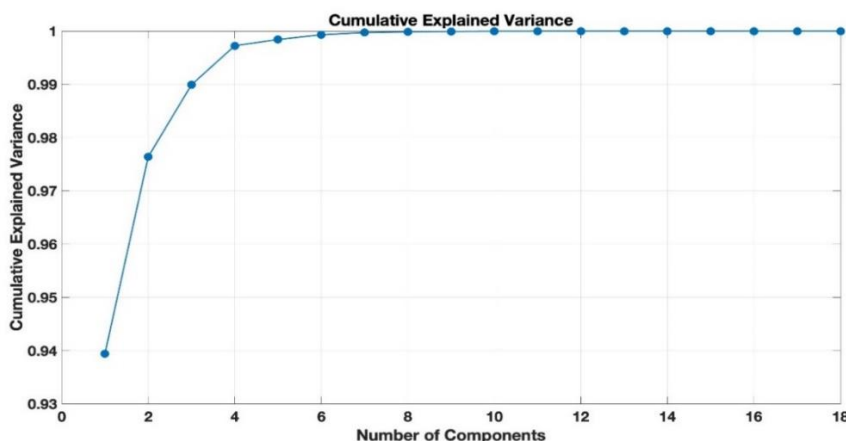
$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad \text{رابطه (۱۳)}$$

که True Positives مثبت واقعی، False Positives مثبت کاذب و False Negatives منفی کاذب می‌باشند. برای توسعه مدل مبتنی بر شبکه عصبی یک شبکه عصبی پس انتشار خطای دو لایه با یک لایه پنهان و یک لایه خروجی در نظر گرفته شد. لایه خروجی از چهار نورون به همراه یک تابع فعال‌سازی خطی تشکیل شده بود. الگوریتم یادگیری Levenberg-Marquardt به همراه روش یادگیری پس انتشار خطا برای یادگیری مدل‌های شبکه عصبی مورد استفاده قرار گرفت. از نرم‌افزار متلب نسخه ۲۰۱۸ برای انجام عملیات پردازش تصویر، استخراج ویژگی‌ها، توسعه و ارزیابی مدل‌ها استفاده شد. بعد از پیاده‌سازی الگوریتم رندوم‌سازی بر روی تمامی داده‌ها ۷۰ درصد داده‌ها برای آموزش و ۳۰ درصد باقیمانده به صورت مساوی برای آزمون و اعتبارسنجی مورد استفاده قرار گرفتند.


نتایج و بحث

برای توسعه مدل PCA-ANN در ابتدا باید تعداد ورودی‌های بهینه شبکه را تعیین کرد. با توجه به تعداد ویژگی‌های استخراج شده در بخش قبل که ۱۸ عدد بودند، در ابتدا PCA بر روی بردار ویژگی‌های استخراج شده اعمال گردید. باید توجه داشت که برای یافتن ساختار بهینه مدل PCA-ANN باید پارامترهای تعداد نورون لایه ورودی (تعداد PCها) و تعداد نورون لایه پنهان بهینه شود. در نتیجه، برای هر ترکیب بردار ویژگی باید تعداد نورون‌های لایه مخفی نیز بهینه شود. همان طوری که قبلاً گفته شد، الگوریتم PCA بر روی تمامی ۱۸ ویژگی اعمال شد. از واریانس تجمعی برای انتخاب تعداد PCها به منظور ساده‌سازی و کاهش ابعاد مساله در تحلیل داده‌ها استفاده شد. در شکل ۳ نتایج مربوط به واریانس تجمعی مولفه‌ها نشان می‌دهد که چه میزان از اطلاعات مربوط به بردار ویژگی توسط

تعداد مشخصی از مولفه‌ها قابل ارائه هستند. همان طوری که در شکل مشخص است مولفه اصلی اول (PC1) به تنهایی قادر به توضیح ۹۳/۹۴ درصد از واریانس کل داده‌ها می‌باشد که نشان دهنده اشتراک بسیار بالا در میان ویژگی‌های استخراج شده دارد. با اضافه شدن مولفه اصلی دوم (PC2) واریانس تجمعی به مقدار ۹۷/۶۴ درصد افزایش پیدا می‌کند و با احتساب مولفه‌های اصلی سوم (PC3) و چهارم (PC4) به ترتیب به مقادیر ۹۸/۹۹ و ۹۹/۷۳ درصد افزایش پیدا می‌کند. با توجه به شکل مشاهده می‌گردد که چهار مولفه اصلی اول قادر به توصیف بیش از ۹۹ درصد از داده‌ها هستند. با توجه به نتایج شکل ۳، ۹ مولفه اصلی اول برای ایجاد ۹ مدل متمایز (با ادغام تدریجی مولفه‌های اصلی از PC1 تا PC9) به منظور تعیین تعداد ویژگی‌های بهینه مورد بررسی قرار گرفتند. در شکل ۴ نمودار تغییرات دقت نسبت به تعداد نورون‌های لایه پنهان برای ۹ مدل مورد بررسی روی داده‌های آزمون نشان داده شده است. با توجه به نتایج مشاهده می‌شود که تعداد نورون‌های لایه مخفی برای مدل‌های ۱ تا ۹ به ترتیب برابر ۳۹، ۳، ۲۸، ۲۵، ۳۷، ۳۶، ۳۷، ۴۶، ۴۸ و ۴۴ بود.



شکل ۳. تغییرات واریانس تجمعی نسبت به تعداد مولفه‌های اصلی در آنالیز مولفه‌های اصلی (PCA).




شکل ۴. نمودار تغییرات دقت شبکه روی داده‌های آزمون بر اساس تعداد نورون‌های لایه مخفی برای الف) PC1، ب) PC1 تا PC2، ج) PC1 تا PC2 تا PC3، د) PC1 تا PC4، ه) PC1 تا PC5، و) PC1 تا PC6، ز) PC1 تا PC7، ح) PC1 تا PC8، ط) PC1 تا PC9

در مرحله دوم، تاثیر تعداد ورودی‌های شبکه بر روی دقت مدل مورد بررسی قرار گرفت. جدول ۱ نتایج مربوط به کارایی مدل نسبت به ورودی‌های مختلف، برای داده‌های آزمون را نشان می‌دهد. شایان ذکر است که مقادیر مربوط به معیارهای عملکرد همانند مرحله اول برای ۱۰۰ تکرار محاسبه و گزارش شدند. با توجه به نتایج جدول مشاهده می‌شود که مدل ۶ بالاترین مقادیر دقت ($۰/۵۴ \pm ۰/۷۳$ ، صحت $۰/۵۷ \pm ۰/۵۹$ ، بازیابی $۰/۵۱ \pm ۰/۵۲$) و معیار F ($۰/۵۴ \pm ۰/۸۹$) را در بین تمامی حالت‌ها در اختیار دارد. هنگام سنجش ثبات مدل، انحراف معیار از اهمیت بالایی برخوردار است. با توجه به نتایج جدول ۱ مشاهده می‌شود که مدل‌های ۵ و ۶ در نظر گرفتن میزان دقت و انحراف معیار از ثبات بالاتری نسبت به دیگر مدل‌ها برخوردار هستند. در نتیجه، با توجه به نتایج بدست آمده مدل شماره ۶ با ۶ مولفه اصلی، از کارایی بالاتری نسبت به سایر مدل‌ها برخوردار است. شکل ۵ ساختار بهینه مدل بدست آمده را نشان می‌دهد. نتایج مشابهی توسط وصالی و همکاران (۲۰۱۵) و لیو و همکاران (۲۰۱۰) در تخمین میزان کلروفیل برگ ذرت و برنج با استفاده از پردازش تصویر و شبکه عصبی بدست آمد. شاو و هی (۲۰۱۳) توانستند میزان آهن و روی را با استفاده از پردازش تصاویر مرئی/طیفی (مادون قرمز) و ماشین بردار پشتیبان (SVM) در گیاه برنج با دقت $۰/۶۷۳۱$ تخمین بزنند.

جدول ۱. نتایج داده‌های آزمون از نظر دقت، صحت، بازیابی و معیار F برای مدل‌های مختلف

Model No.	Structure	Accuracy (%)	Precision (%)	Recall (%)	F1-score (%)
۱	۱ - ۳۹ - ۴	$۰/۷۵ \pm ۷۴/۶۰$	$۰/۶۶ \pm ۷۴/۶۲$	$۰/۸۰ \pm ۷۴/۲۳$	$۰/۷۳ \pm ۷۴/۴۲$
۲	۲ - ۳ - ۴	$۰/۳۶ \pm ۷۸/۶۳$	$۰/۳۶ \pm ۷۸/۳۸$	$۰/۳۷ \pm ۷۸/۸۱$	$۰/۳۷ \pm ۷۸/۱۰$
۳	۳ - ۲۸ - ۴	$۰/۶۷ \pm ۸۵/۷۹$	$۰/۷۸ \pm ۸۵/۶۱$	$۰/۶۴ \pm ۸۵/۴۰$	$۰/۷۱ \pm ۸۵/۵۱$
۴	۴ - ۲۵ - ۴	$۱/۳۱ \pm ۸۴/۹۱$	$۱/۳۵ \pm ۸۴/۷۰$	$۱/۲۷ \pm ۸۴/۵۵$	$۱/۳۱ \pm ۸۴/۶۲$
۵	۵ - ۳۷ - ۴	$۰/۲۴ \pm ۸۸/۲۴$	$۰/۲۸ \pm ۸۸/۰۸$	$۰/۲۲ \pm ۸۸/۱۸$	$۰/۲۵ \pm ۸۸/۱۳$
۶	۶ - ۳۶ - ۴	$۰/۵۴ \pm ۸۹/۷۳$	$۰/۵۷ \pm ۸۹/۵۹$	$۰/۵۱ \pm ۸۹/۵۲$	$۰/۵۴ \pm ۸۹/۵۵$
۷	۷ - ۳۷ - ۴	$۱/۰۶ \pm ۸۸/۱۸$	$۱/۰۴ \pm ۸۸/۱۸$	$۱/۰۹ \pm ۸۷/۹۱$	$۱/۰۶ \pm ۸۸/۰۴$
۸	۸ - ۴۶ - ۴	$۱/۱۷ \pm ۸۷/۰۹$	$۱/۱۷ \pm ۸۷/۱۰$	$۱/۲۷ \pm ۸۶/۷۶$	$۱/۲۲ \pm ۸۶/۹۳$
۹	۹ - ۴۸ - ۴	$۱/۲۴ \pm ۸۷/۴۶$	$۱/۱۵ \pm ۸۷/۵۹$	$۱/۲۸ \pm ۸۷/۱۷$	$۱/۲۱ \pm ۸۷/۲۸$

برای ارزیابی بیشتر عملکرد طبقه‌بندی، ماتریس سردرگمی مربوط به مدل بهینه (مدل ۶) برای داده‌های آزمون محاسبه شد (شکل ۶). ماتریس سردرگمی نتایج طبقه‌بندی را به صورتی به تصویر می‌کشد که هر مقدار در ماتریس بیانگر تعداد تصاویر مربوط به کلاس مورد نظر (Target) است که در کلاس Output پیش‌بینی شده‌اند. بنابراین، مقادیر خارج از قطر نشان‌دهنده خطاهای طبقه‌بندی است.



شکل ۵. ساختار بهینه مدل توسعه داده شده با ۶ نورون در لایه اول، ۳۶ نورون در لایه پنهان و چهار نورون در لایه خروجی.

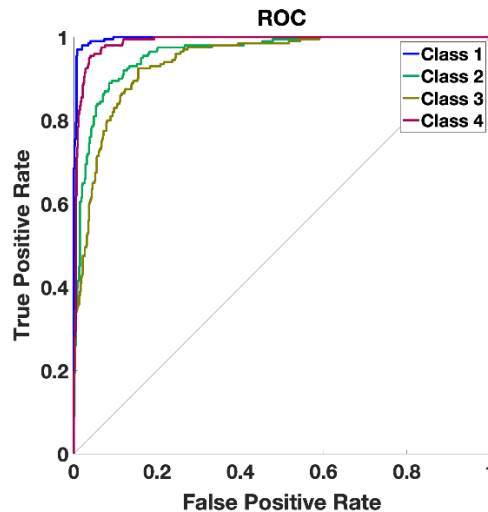
Confusion Matrix

	1	2	3	4	
1	43 26.9%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
2	1 0.6%	30 18.8%	3 1.9%	0 0.0%	88.2% 11.8%
3	0 0.0%	5 3.1%	37 23.1%	4 2.5%	80.4% 19.6%
4	0 0.0%	0 0.0%	3 1.9%	34 21.3%	91.9% 8.1%
	97.7% 2.3%	85.7% 14.3%	86.0% 14.0%	89.5% 10.5%	90.0% 10.0%
	1	2	3	4	
	Target Class				

شکل ۶. ماتریس اغتشاش مربوط مدل با ساختار ۴ - ۳۶ - ۶ برای داده‌های آزمون در طبقه‌بندی کلاس‌های بدون کمبود (۱)، کمبود کم (۲)، کمبود متوسط (۳) و کمبود شدید (۴).

همانطور که در شکل ۶ مشاهده می‌گردد، کلاس سوم، یعنی برگ‌هایی با کمبود آهن متوسط، چالش برانگیزترین دسته بودند. در مقایسه با سایر گروه‌ها، تصاویر این کلاس به اشتباه در کلاس‌های دوم (کمبود کم) یا چهارم (کمبود شدید) طبقه‌بندی شده‌اند. علاوه بر این، در همه موارد، طبقه‌بندی‌های نادرست در کلاس‌های مجاور رخ داده است، که نشان‌دهنده ماهیت چالش برانگیز این طبقه‌بندی است. ماتریس‌های سردرگمی برای روش‌های مختلف با نتایج ارائه شده در جدول ۱ مطابقت داشتند.

نمودار مشخصه عملکرد^۱ (ROC) مربوط به مدل بهینه در شکل ۷ نشان داده شده است. شایان ذکر است که هر عنصر از ماتریس اغتشاش یک نقطه در منحنی ROC را تشکیل می‌دهد و بهترین عملکرد دسته‌بندی در این نمودار در نقطه‌ای با مختصات (0,1) رخ می‌دهد که در آن کمترین نرخ اشتباه و بیشترین نرخ بازیابی یا حساسیت را داریم. این نقطه بیانگر بهترین دسته‌بندی است. همان‌طور که در شکل مشخص است، شبکه به خوبی توانسته تمامی دسته‌ها را تشخیص دهد. با توجه به شکل مشاهده می‌گردد که بهترین عملکرد به ترتیب برای کلاس‌های بدون کمبود (۱)، کمبود شدید (۴)، کمبود کم (۲) و کمبود متوسط (۳) بدست آمده است.



شکل ۷. نمودار مشخصه عملکرد مربوط به مدل بهینه برای داده‌های آزمون.

نتیجه‌گیری

در این تحقیق برای اولین بار یک مدل مبتنی بر شبکه عصبی مصنوعی برای طبقه‌بندی تصاویر برگ هلو بر اساس میزان کمبود آهن توسعه داده شد. نتایج نشان داد که با استفاده از تصاویر ثبت شده توسط دوربین و پردازش ویژگی‌های استخراج شده توسط مدل مبتنی بر آنالیز مولفه‌های اصلی و شبکه عصبی مصنوعی PCA-ANN امکان تشخیص میزان کمبود آهن در چهار سطح بدون کمبود، کمبود کم، کمبود متوسط و کمبود شدید وجود داشته و بهترین عملکرد مدل با ۶ مولفه اصلی (PC) اول با معیارهای دقت ($0.54 \pm 0.89/73\%$)، صحت ($0.57 \pm 0.89/59\%$)، بازیابی ($0.51 \pm 0.89/52\%$) و معیار F ($0.54 \pm 0.89/55\%$) و ساختار ساختار ۴ - ۳۶ - ۶ (شکل ۵) بدست می‌آیند. با توجه به این که سطوح کمبود آهن در این تحقیق با استفاده از روش خوشه‌بندی KNN بدست آمده بود، می‌توان نتیجه گرفت که همبستگی بالایی میان تغییرات رنگ برگ گیاه و میزان آهن فعال موجود در آن وجود دارد. نتایج نشان داد که این مدل از تکرارپذیری بالایی برخوردار است و به صورت موثری می‌توان از آن برای ارزیابی میزان کمبود آهن موجود در نمونه‌های برگ هلو استفاده کرد. پیشنهاد می‌گردد در مطالعات آینده، یادگیری عمیق و همچنین تشخیص کمبود آهن در محصولات دیگر نیز مورد بررسی قرار گیرد.

"هیچ‌گونه تعارض منافع بین نویسندگان وجود ندارد"

منابع

ایمانی، آیدین؛ حسین پور، سلیمان؛ کیهانی، علیرضا و عظیم‌زاده، مصطفی (۱۳۹۹). مدل‌سازی و بهینه‌سازی نانوبیوسنسور الیگونوکلئوتیدی با استفاده از رویکرد مبتنی بر شبکه عصبی مصنوعی و الگوریتم ژنتیک. *مهندسی بیوسیستم ایران*. ۵۱ (۱)، ۱۷۱-۱۸۱.

REFERENCES

Balasubramaniam, P., & Ananthi, V. P. (2016). Segmentation of nutrient deficiency in incomplete crop images using intuitionistic fuzzy C-means clustering algorithm. *Nonlinear Dynamics*, 83, 849-866. doi: <https://doi.org/10.1007/s11071-015-2372-y>

- Barbedo, J.G.A., 2019. Detection of nutrition deficiencies in plants using proximal images and machine learning: A review. *Computers and Electronics in Agriculture*, 162, pp.482-492. doi: <https://doi.org/10.1016/j.compag.2019.04.035>
- Bavaresco, L., & Poni, S. (2003). Effect of calcareous soil on photosynthesis rate, mineral nutrition, and Source-Sink ratio of table grape. *Journal of plant nutrition*, 26(10-11), 2123-2135. doi: <https://doi.org/10.1081/PLN-120024269>
- Borhan, M.S., Panigrahi, S., Satter, M.A. and Gu, H., 2017. Evaluation of computer imaging technique for predicting the SPAD readings in potato leaves. *Information processing in agriculture*, 4(4), pp.275-282. doi: <https://doi.org/10.1016/j.inpa.2017.07.005>
- Condori, R. H. M., Romualdo, L. M., Bruno, O. M., & de Cerqueira Luz, P. H. (2017, October). Comparison between traditional texture methods and deep learning descriptors for detection of nitrogen deficiency in maize crops. In *2017 Workshop of Computer Vision (WVC)* (pp. 7-12). IEEE. doi: <https://doi.org/10.1109/WVC.2017.00009>
- Culman, M. A., Gomez, J. A., Talavera, J., Quiroz, L. A., Tobon, L. E., Aranda, J. M., ... & 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. doi: <https://doi.org/10.1109/MobileCloud.2017.32>
- 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. doi: <https://doi.org/10.1073/pnas.1716999115>
- Han, K. A. M., & Watchareeruetai, U. (2019, July). Classification of nutrient deficiency in black gram using deep convolutional neural networks. In *2019 16th International Joint Conference on Computer Science and Software Engineering (JCSSE)* (pp. 277-282). IEEE. doi: <https://doi.org/10.1109/JCSSE.2019.8864224>
- Hu, J., Li, D., Chen, G., Duan, Q., & Han, Y. (2012). Image segmentation method for crop nutrient deficiency based on fuzzy C-Means clustering algorithm. *Intelligent Automation & Soft Computing*, 18(8), 1145-1155. doi: <https://doi.org/10.1080/10798587.2008.10643318>
- Imani, A., Hosseinpour, S., Keyhani, A., & Azimzadeh, M. (2020). Modeling and Optimization of Oligonucleotide-Based Nanobiosensor Using Artificial Neural Network and Genetic Algorithm Based Procedure. *Iranian Journal of Biosystems Engineering*, 51(1), 171-181. (In Persian with English Abstract). <https://dx.doi.org/10.22059/ijbse.2019.290631.665231>
- Jafarbiglu, H., & Pourreza, A. (2023). Impact of sun-view geometry on canopy spectral reflectance variability. *ISPRS Journal of Photogrammetry and Remote Sensing*, 196, 270-286. doi: <https://doi.org/10.1016/j.isprs.2022.12.002>
- Katyal, J. C., & Sharma, B. D. (1980). A new technique of plant analysis to resolve iron chlorosis. *Plant and Soil*, 55, 105-119. doi: <https://doi.org/10.1007/BF02149714>
- Leemans, V., Marlier, G., Destain, M. F., Dumont, B., & 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. doi: <https://doi.org/10.1117/12.2268398>
- Liu, B., Zhang, Y., He, D., & Li, Y. (2017). Identification of apple leaf diseases based on deep convolutional neural networks. *Symmetry*, 10(1), 11. doi: <https://doi.org/10.3390/sym10010011>
- Luz, P. H. D. C., Marin, M. A., Devecchio, F. F. S., Romualdo, L. M., Zuñiga, 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. doi: <https://doi.org/10.1080/00103624.2017.1421644>
- Morales, F., Grasa, R., Abadía, A., & Abadía, J. (1998). Iron chlorosis paradox in fruit trees. *Journal of plant nutrition*, 21(4), 815-825. doi: <https://doi.org/10.1080/01904169809365444>
- Römheld, V. (2000). The chlorosis paradox: Fe inactivation as a secondary event in chlorotic leaves of grapevine. *Journal of plant nutrition*, 23(11-12), 1629-1643. doi: <https://doi.org/10.1080/01904160009382129>
- Romualdo, L. M., Luz, P. H. D. C., Baesso, M. M., Devecchio, F. D. F. D. S., & Bet, J. A. (2018). Spectral indexes for identification of nitrogen deficiency in maize. *Revista Ciência Agronômica*, 49, 183-191. doi: <https://doi.org/10.5935/1806-6690.20180021>
- Samar, S. M., Shahabian, M., Fallahi, E., Davoodi, M. H., Bagheri, Y. R., & Noorgholipoor, F. (2007). Iron deficiency of apple tree as affected by increasing soil available phosphorous. *Journal of plant nutrition*, 30(1), 1-7. doi: <https://doi.org/10.1080/01904160601054742>
- 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. doi: <https://doi.org/10.1155/2016/3289801>
- Smith, B. R., & Cheng, L. (2006). Fe-EDDHA alleviates chlorosis in Concord grapevines grown at high pH. *HortScience*, 41(6), 1498-1501. doi: <https://doi.org/10.21273/HORTSCI.41.6.1498>
- 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. doi: <https://doi.org/10.1155/2018/1469314>
- Sulistyo, S. B., Wu, D., Woo, W. L., Dlay, S. S., & Gao, B. (2017). Computational deep intelligence vision sensing for nutrient content estimation in agricultural automation. *IEEE Transactions on Automation Science and Engineering*, 15(3), 1243-1257. doi: <https://doi.org/10.1109/TASE.2017.2770170>
- Sun, Y., Tong, C., He, S., Wang, K., & Chen, L. (2018). Identification of nitrogen, phosphorus, and potassium deficiencies based on temporal dynamics of leaf morphology and color. *Sustainability*, 10(3), 762. doi: <https://doi.org/10.3390/su10030762>
- Tagliavini, M., & Rombola, A. D. (2001). Iron deficiency and chlorosis in orchard and vineyard ecosystems. *European Journal of Agronomy*, 15(2), 71-92. doi: [https://doi.org/10.1016/S1161-0301\(01\)00125-3](https://doi.org/10.1016/S1161-0301(01)00125-3)
- Tewari, V. K., Arudra, A. K., Kumar, S. P., Pandey, V., & Chandel, N. S. (2013). Estimation of plant nitrogen content using digital image processing.
- 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. doi: <https://doi.org/10.1016/j.compag.2017.05.012>
- Wang, G., Sun, Y., & Wang, J. (2017). Automatic image-based plant disease severity estimation using deep learning. *Computational intelligence and neuroscience*, 2017. doi: <https://doi.org/10.1155/2017/2917536>
- Zohlen, A. (2000). Use of 1, 10-phenanthroline in estimating metabolically active iron in plants. *Communications in soil science and plant analysis*, 31(3-4), 481-500. doi: <https://doi.org/10.1080/00103620009370451>
- Zhou, C., Le, J., Hua, D., He, T., & Mao, J. (2019). Imaging analysis of chlorophyll fluorescence induction for monitoring plant water and nitrogen treatments. *Measurement*, 136, 478-486. doi: <https://doi.org/10.1016/j.measurement.2018.12.088>

Detection of iron deficiency in peaches using image processing and artificial neural network model

EXTENDED ABSTRACT

Introduction

Among micronutrients, iron deficiency is regarded as a significant nutritional disorder in orchards established on calcareous soils. Employing destructive and laboratory methods to diagnose the level of iron deficiency is typically time-consuming and costly. In recent years, the use of image processing methods and artificial intelligence models as non-destructive, inexpensive, fast, and accurate approaches have increasingly garnered the attention of researchers. In this study, a method based on artificial neural networks is presented for the automatic classification of peach tree leaves based on the level of iron deficiency.

Methods

800 leaf samples were collected from around Urmia County between June and July 2021 for imaging and iron measurements at the Agriculture Faculty of Urmia University. Utilizing the KNN method, images were classified based on active iron (Fe^{2+}) into four deficiency categories: None-, Low-, Moderate-, and Severe-deficiency. Initially, images were transferred from RGB to HSV and Lab* spaces, with statistical features (mean and standard deviation) extracted for analysis. Principal component analysis was applied, and a neural model, including a hidden layer with a sigmoid tangent activation function and an output layer with a linear activation function, was developed. Utilizing 70% of the data for training and 30% for testing and validation, MATLAB 2018 was employed for image processing, feature extraction, and model development, while model efficacy was evaluated using Accuracy, Precision, Recall, and F1-score metrics.

Results

The results, based on 100 iterations, showed that the model utilizing the first 6 Principal Components (PCs) achieved the highest accuracy ($89.73\% \pm 0.54\%$), precision ($89.59\% \pm 0.57\%$), recall ($89.52\% \pm 0.51\%$), and F-measure ($89.55\% \pm 0.54\%$) among all scenarios. Models with 5 and 6 PCs exhibited enhanced stability considering the accuracy and standard deviation. Consequently, model number 6, with 6 main components, outperformed others in terms of efficiency. Pertaining to the confusion matrix results for the optimal model with test data the "moderate" class was the most challenging to classify, often being misclassified into adjacent deficiency categories i.e., low- and severe- deficiency. Furthermore, the Receiver Operating Characteristic (ROC) results of the optimal model highlighted its proficiency in identifying all categories, obtaining the best performance for classes None, Severe, low, and moderate, in order.

Conclusion

A good correlation was observed between leaf color changes in peach leaf color and the level of active iron, demonstrating that iron deficiency could be detected using digital images and processing the extracted features. Therefore, the findings suggest that the presented model possesses high repeatability and can effectively categorize iron deficiency into four levels: none, low, moderate, and severe. This study, by modeling the color changes of peach leaves and active iron in the peach leaf, lays the foundation for presenting an efficient, cost-effective, and accurate method to replace conventional laboratory methods for detecting iron deficiency levels.

Keywords: Iron Deficiency, Image Processing, KNN Clustering, Neural Network, Peaches.