



19th Iranian Soil Science Congress
16-18 September, 2025



نوزدهمین کنگره علوم خاک ایران
۱۴ تا ۱۳ آذر ۱۴۰۴



۰۴۲۵۰-۳۲۰۳۱

مدیریت جامع نگر و هوشمند خاک و آب

Holistic and Smart Soil and Water Management

دانشکده کشاورزی و منابع طبیعی دانشگاه تهران

College of Agriculture & Natural Resources, University of Tehran



از پیکسل تا تغذیه: تخمین آهن برگ با استفاده از شبکه‌های عصبی مبتنی بر تصویر

ابراهیم سپهر^{*}، آیدین ایمانی^۱، شبنم فیروزی^۱

۱- گروه علوم خاک داشکده کشاورزی، دانشگاه ارومیه

^{*} نویسنده مسئول: e.sepehr@urmia.ac.ir

چکیده

کمبود آهن یکی از مهم‌ترین عوامل محدودکننده در تولید محصولات باغی به‌ویژه در خاک‌های آهنی است. در این مطالعه، یک رویکرد مبتنی بر هوش مصنوعی و پردازش تصویر برای تخمین آهن فعال موجود در برگ‌های انگور توسعه داده شد. نمونه‌های برگ با درجات مختلف کمبود آهن با روش جذب اتمی برای اندازه‌گیری آهن فعال مورد استفاده قرار گرفتند و تصاویر آنها تحت شرایط نوری کنترل‌شده ثبت و ذخیره گردیدند. پس از اعمال پردازش اولیه، ویژگی‌های آماری رنگ از کانال‌های مختلف رنگی استخراج و رابطه آن‌ها با غلظت آهن فعال بررسی شد. نتایج نشان داد که مدل شبکه عصبی با استفاده از ویژگی‌های استخراج شده از کانال‌های رنگی S و I، به بالاترین دقت دست یافت. مدل توسعه داده‌شده با استفاده از ویژگی‌های مؤثر شناسایی شده، با ساختار ۱-۲۲-۴ توانست میزان آهن فعال را با دقت‌های ۰/۹۲ برای کل داده‌ها پیش‌بینی کند. این رویکرد می‌تواند به عنوان جایگزینی مؤثر، سریع و مقرون‌به‌صرفه برای روش‌های سنتی آزمایشگاهی در تشخیص کمبود آهن برگ در تاکستان‌ها مورد استفاده قرار گیرد و زمینه‌ساز توسعه ابزارهای هوشمند کشاورزی شود.

واژگان کلیدی: کمبود آهن، برگ انگور، هوش مصنوعی، شبکه عصبی، ویژگی رنگی

مقدمه

آهن یکی از عناصر کلیدی در تغذیه گیاهان است که علی‌رغم نیاز کم آن به عنوان یک ریزمغذی، نقش بسیار مهمی در رشد و توسعه آن‌ها دارد (Malakuti & Tehrani, 2005). این عنصر در سنتز کلروفیل و پایداری ساختار کلروپلاست‌ها نقش دارد و در صورت کمبود، منجر به اختلال در تعادل توزیع آهن در کلروپلاست و کاهش تولید کلروفیل می‌شود؛ پدیده‌ای که به‌طور معمول با ظهور کلروز و زردی برگ‌ها همراه است (Marschner, 2011). آهن همچنین در فعالیت آنزیم‌های حیاتی مانند فردوکسین، سیتوکروم‌ها، نیترات ردوکتاز و نیتروژناز مشارکت داشته و در فرآیندهای متابولیکی نظیر فتوسنتز، تنفس سلولی، تثبیت نیتروژن و سنتز DNA ایفای نقش می‌کند (Rout & Sahoo, 2015; Misra et al., 2006). افزون بر این، آهن در تولید برخی هورمون‌های گیاهی از جمله اتیلن و اسید آبسزیک نیز مؤثر است (Chen et al., 2010). با توجه به این عملکردهای حیاتی، کمبود آهن می‌تواند تأثیرات منفی قابل‌توجهی بر فرآیندهای فیزیولوژیکی و رشد گیاه داشته باشد و موجب کاهش عملکرد و کیفیت محصولات کشاورزی گردد.

درختان انگور، به‌ویژه در خاک‌های آهکی، به کمبود آهن حساسیت بالایی دارند و این مسئله معمولاً با بروز کلروز در آغاز فصل رشد همراه است. در بسیاری از تاکستان‌ها، به دلیل شرایط خاکی قلیایی، جذب آهن توسط گیاه محدود شده و نشانه‌های کمبود آهن به‌صورت رنگ‌پریدگی برگ‌ها ظاهر می‌شود (Boxma, 1972). در چنین شرایطی، بهره‌گیری از فناوری‌های غیرمخرب همچون پردازش تصویر، می‌تواند راهکار مناسبی برای تخمین وضعیت عناصر غذایی در گیاهان فراهم کند، بدون آنکه نیاز به مواد شیمیایی یا فرایندهای پیچیده آزمایشگاهی باشد (Gonzales et al., 2004). از طریق تحلیل ویژگی‌های رنگی و بافت برگ، اطلاعات دقیقی در مورد وضعیت تغذیه‌ای گیاه در اختیار بهره‌بردار قرار می‌گیرد و امکان تصمیم‌گیری سریع و کم‌هزینه برای مدیریت عناصر مغذی فراهم می‌شود (Vesali et al., 2015; Firuzi et al., 2025). در سال‌های اخیر، پیشرفت‌های چشمگیری در کاربرد تصویربرداری دیجیتال و هوش مصنوعی برای ارزیابی تنش‌های غیرزیستی مانند کمبود مواد مغذی حاصل شده است (Barbedo, 2013). این فناوری‌ها با استفاده از تصاویر RGB، HSV، HSI و فضا‌های رنگی دیگر، به تشخیص دقیق تغییرات فیزیولوژیکی ناشی از کمبود عناصر نظیر نیتروژن، فسفر، پتاسیم و آهن کمک می‌کنند (Pagola et al., 2009; Bai et al., 2018). مطالعات مختلف نشان داده‌اند که رابطه قابل توجهی میان ویژگی‌های رنگ برگ و غلظت عناصر در گیاه وجود دارد و می‌توان با به‌کارگیری مدل‌های یادگیری ماشین مانند شبکه‌های عصبی مصنوعی، تخمین‌هایی دقیق از وضعیت تغذیه‌ای گیاه ارائه داد (Mercado-Luna et al., 2010; Hajizadeh et al., 2024). از آن‌جا که روش‌های سنتی برای کشاورزان وقت‌گیر، پرهزینه و گاه دست‌نیافتنی هستند، توسعه یک سامانه هوشمند تصویربرداری با قابلیت تخمین سریع و دقیق کمبود آهن می‌تواند نقش مؤثری در بهبود مدیریت تغذیه‌ای در باغ‌های انگور ایفا کند.

مواد و روش‌ها

برای توسعه مدلی جهت برآورد میزان آهن فعال در برگ‌های انگور، نمونه‌برداری میدانی از دو منطقه نازلو و زینالو در شمال ارومیه، بر اساس اطلاعات خاک‌شناسی انجام گرفت. در مجموع، ۵۵ نمونه برگ از قسمت‌های میانی سرشاخه‌ها طی ماه‌های خرداد و تیر سال ۱۳۹۷ جمع‌آوری و به آزمایشگاه منتقل شدند. تصویربرداری از نمونه‌ها در یک محفظه با نور یکنواخت و ثابت، با استفاده از دوربین گوشی هوشمند، انجام شده و تصاویر با کیفیت بالا در فضای رنگی RGB ذخیره گردیدند. جهت اندازه‌گیری آهن فعال، نمونه‌ها با محلول فنانترولین عصاره‌گیری شده و غلظت آهن فعال در نمونه‌ها با استفاده از دستگاه جذب اتمی (Shimadzu AA-6300) اندازه‌گیری شد. برای آماده‌سازی تصاویر، عملیات پیش‌پردازش شامل اصلاح گاما و بهبود بازه دینامیکی برای یکنواخت‌سازی نور اجرا شد. پیکسل‌های گیاهی با استفاده از شاخص سبزی‌نگی مضاعف (ExG) از پس‌زمینه تفکیک گردیدند. سپس تصاویر به اندازه 1024×1024 پیکسل برش خورده و ویژگی‌های آماری از مولفه‌های کانال HSI استخراج شدند. از هر کانال، ویژگی‌های میانگین و انحراف معیار به‌عنوان ویژگی اصلی مورد استفاده قرار گرفت. پس از تحلیل رگرسیونی ساده برای برررسی ارتباط هر ویژگی با میزان آهن فعال، ویژگی‌های مؤثر برای مدل‌سازی انتخاب شدند. یک شبکه عصبی پرسپترون چندلایه (MLP) برای تخمین مقدار آهن فعال توسعه یافت. داده‌ها به‌صورت تصادفی به نسبت ۷۰٪ برای آموزش، ۱۵٪ برای اعتبارسنجی و ۱۵٪ برای آزمون تقسیم شدند. مدل با استفاده از الگوریتم لوبنبرگ-مارکوارت در محیط

نرم افزار MATLAB 2017 آموزش داده شد. ساختار بهینه شبکه با آزمایش تعداد نرون‌های لایه پنهان از ۱ تا ۲۵ طی ۱۰۰ تکرار تعیین گردید. برای ارزیابی عملکرد مدل، از شاخص‌های آماری R^2 ، RMSE و MAPE استفاده شد تا میزان دقت پیش‌بینی آهن فعال در برگ‌های انگور مشخص گردد.



شکل ۱. مراحل حذف پس‌زمینه توسط شاخص ExG (الف) تصویر اصلی، (ب) تصویر ExG قبل از آستانه‌گذاری و (ج) تصویر گیاه بدون پس‌زمینه پس از اعمال آستانه‌گذاری

نتایج و بحث

در این مطالعه، سه مؤلفه رنگی H، S و I از فضای رنگی HSI جهت بررسی ارتباط با میزان آهن فعال برگ‌های انگور مورد ارزیابی قرار گرفتند. نتایج تحلیل رگرسیون خطی تک‌متغیره نشان داد که مؤلفه H دارای بالاترین قابلیت پیش‌بینی آهن فعال بوده و ضریب تعیین (R^2) آن برابر با ۰/۵۸ و مقدار RMSE معادل ۳/۱۲ محاسبه شد. همچنین مقدار MAPE برای این مؤلفه برابر با ۲۶/۶۶ درصد بود. این نتایج نشان‌دهنده آن است که تغییرات رنگی مرتبط با طیف رنگی Hue تا حدودی می‌تواند منعکس‌کننده کمبود آهن در برگ‌های انگور باشد. در مقابل، مؤلفه S (اشباع رنگ) فاقد هرگونه ارتباط خطی معنی‌دار با آهن فعال بود، به طوری که مقدار R^2 برای آن صفر و RMSE برابر با ۴/۶۰ به دست آمد. این موضوع حاکی از آن است که تغییرات در میزان اشباع رنگ تأثیر چندانی در تخمین آهن فعال ندارد. مؤلفه I (شدت روشنایی) نیز عملکرد نسبتاً مناسبی از خود نشان داد؛ مقدار R^2 برای این مؤلفه ۰/۵۳ و RMSE آن برابر با ۲/۹۵ بود، در حالی که MAPE در حدود ۲۵/۵۳ درصد گزارش شد. این نتایج بیانگر آن است که روشنایی برگ‌ها نیز می‌تواند بخشی از تغییرات مرتبط با کمبود آهن را منعکس نماید، گرچه عملکرد آن نسبت به مؤلفه H اندکی ضعیف‌تر است. به طور کلی، بر اساس یافته‌های جدول، می‌توان نتیجه گرفت که مؤلفه‌های H و I از فضای رنگی HSI دارای پتانسیل مناسبی برای استفاده در مدل‌های پیش‌بینی آهن فعال هستند، در حالی که مؤلفه S فاقد ارزش پیش‌بینی‌کننده است و در توسعه مدل‌های دقیق باید از آن صرف‌نظر شود. این نتایج با گزارش‌های پیشین در سایر مطالعات نیز هم‌راستا هستند که نشان داده‌اند مؤلفه‌های روشنایی و طیف رنگی نسبت به اشباع، حساسیت بیشتری به تغییرات تغذیه‌ای گیاه دارند.

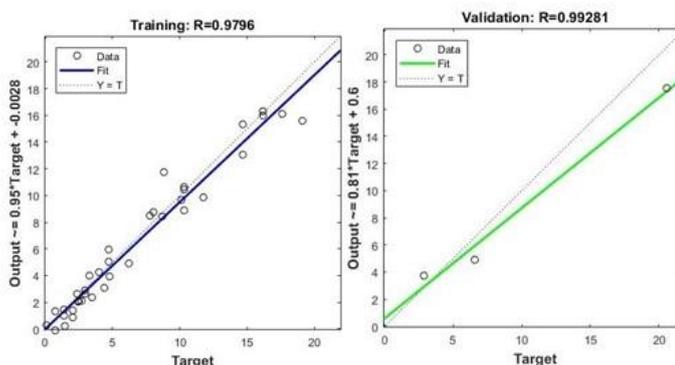
جدول ۱. نتایج رگرسیون خطی تک‌متغیره برای مولفه‌های رنگی مختلف و مقدار آهن فعال

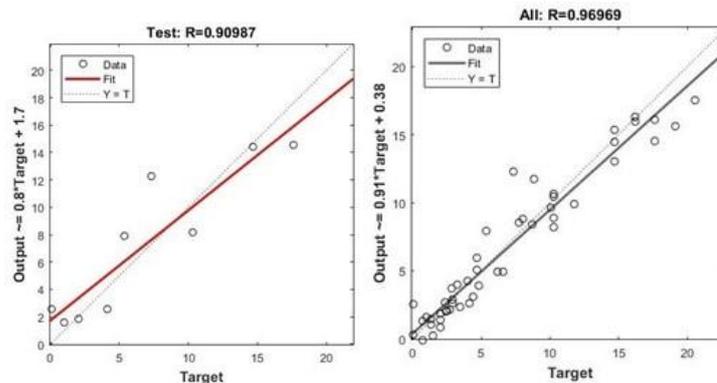
	MAPE	R-Squared	RMSE
H	۲۶/۶۶	۰/۵۸	۳/۱۲
S	۴۱/۳۵	۰	۴/۶۰
I	۲۵/۵۳	۰/۵۳	۲/۹۵

نتایج حاصل از مدل‌سازی با شبکه عصبی نشان داد که مؤلفه‌های رنگی استخراج‌شده از فضای رنگی HSI توانایی بالایی در تخمین میزان آهن فعال برگ‌های انگور دارند. همان‌طور که در جدول ۲ مشاهده می‌شود، دقت مدل در استفاده منفرد از مؤلفه‌های H، S و I به ترتیب با ضریب تعیین (R^2) برابر با ۰/۷۹۴۹، ۰/۵۳۰۸ و ۰/۸۲۰۶ قابل قبول بود. در این بین، مؤلفه I بیشترین همبستگی را با مقدار آهن فعال نشان داد که بیانگر حساسیت بالای شدت روشنایی تصویر نسبت به تغییرات ناشی از کمبود آهن در برگ‌ها است. ترکیب مؤلفه‌ها به‌ویژه در حالت S_I منجر به افزایش معنی‌دار دقت مدل گردید، به‌طوری که ضریب تعیین به ۰/۹۲۷۸ افزایش یافت و مقدار RMSE و MAPE نیز به ترتیب به ۱/۵۱۸۱ و ۱۳/۵۶۶۸ درصد کاهش یافت. این بهبود قابل توجه در نتایج مدل، نشان‌دهنده اهمیت ترکیب اطلاعات رنگی مختلف به‌منظور بهبود فرآیند یادگیری و تعمیم مدل شبکه عصبی است. مقایسه نتایج مدل در حالت تک‌ویژگی و چندویژگی حاکی از آن است که هر یک از مؤلفه‌های H، S و I می‌توانند بخشی از تغییرات فیزیولوژیک مرتبط با کمبود آهن را ثبت نمایند، اما ترکیب آن‌ها در قالب ورودی چندکاناله منجر به تقویت هم‌پوشانی و افزایش قدرت تبیین مدل می‌شود. در راستای مطالعات مشابه، یافته‌های این پژوهش با گزارش‌های قبلی همچون Vesali و Tewari هم‌خوانی دارد، که بر نقش مهم رنگ‌پذیری برگ‌ها در تخمین کمبود آهن تأکید داشته‌اند. همچنین، کاهش خطاهای مدل در ترکیب مؤلفه‌ها نشان می‌دهد که بهره‌گیری از چند کانال رنگی، به‌ویژه در مدل‌های غیرخطی مانند MLP، می‌تواند منجر به توسعه ابزارهای دقیق و کم‌هزینه برای پایش تغذیه‌ای گیاهان در شرایط میدانی شود. از سوی دیگر، ساختار شبکه عصبی مورد استفاده در این تحقیق با تعداد ۴ نرون در ورودی، ۱۶ نرون در لایه پنهان و یک خروجی طراحی شده و با الگوریتم لونیگ-مارکوارت آموزش دیده است. نتایج منحنی یادگیری نیز نشان داد که مدل در دوره‌های آموزشی مختلف پایدار بوده و دقت بالایی را در پیش‌بینی ارائه می‌دهد. این موضوع، کارایی بالایی مدل در شرایط آزمایشگاهی و احتمال تعمیم‌پذیری مناسب آن در شرایط میدانی را تأیید می‌کند.

جدول ۲. نتایج خروجی شبکه عصبی برای طیف‌های مختلف فضای رنگی RGB

مؤلفه فضای رنگی	تعداد ویژگی	مجدور میانگین مربعات خطا (RMSE)	میانگین درصد قدرمطلق خطا (MAPE)	ضریب تعیین (R^2)
H	۲	۲/۵۵۸۸	۳۸/۹۷۷۹	۰/۷۹۴۹
S	۲	۳/۸۷۰۶	۴۲/۶۰۸۶	۰/۵۳۰۸
I	۲	۲/۳۹۳۳	۳۱/۴۵۹۰	۰/۸۲۰۶
H_S	۴	۲/۳۸۵۲	۲۹/۵۸۶۷	۰/۸۲۱۸
H_I	۴	۱/۹۱۶۶	۳۸/۱۹۳۲	۰/۸۸۵۰
S_I	۴	۱/۵۱۸۱	۱۳/۵۶۶۸	۰/۹۲۷۸
H_S_I	۶	۱/۷۶۱۸	۲۷/۵۴۵۱	۰/۹۰۲۸





شکل ۲. نتایج مدل شبکه عصبی برای مؤلفه‌های S و I

برای ارزیابی دقت مدل شبکه عصبی توسعه‌یافته، مقادیر واقعی آهن فعال اندازه‌گیری شده با مقادیر پیش‌بینی شده توسط مدل برای داده‌های آموزش، اعتبارسنجی و کل مجموعه داده مقایسه و در شکل ۲ نمایش داده شدند. در این نمودار، نزدیکی نقاط به خط ۱:۱ بیانگر همبستگی قوی بین مقادیر واقعی و پیش‌بینی شده است. نتایج نشان داد که مدل قادر است با دقت بالا آهن فعال برگ‌های انگور را پیش‌بینی کند. پراکندگی اندک نقاط خارج از خط همبستگی، حاکی از خطای پیش‌بینی ناچیز و عملکرد پایدار مدل در تمام مجموعه‌های داده است. این موضوع نشان می‌دهد که شبکه عصبی طراحی شده توانسته روابط غیرخطی میان ویژگی‌های رنگی و مقدار آهن فعال را به خوبی فرا بگیرد و مدل قابل اعتمادی برای تخمین غیرمستقیم آهن ارائه دهد.

نتیجه‌گیری

نتایج این تحقیق نشان داد که استفاده از ویژگی‌های رنگی برگ در فضای رنگی HSI می‌تواند ابزاری مؤثر برای پیش‌بینی غیرمستقیم میزان آهن فعال در برگ‌های انگور باشد. مدل شبکه عصبی چندلایه (MLP) با بهره‌گیری از مؤلفه‌های اشباع (S) و شدت نور (I) بهترین عملکرد را از خود نشان داد و توانست با دقت بالایی مقدار آهن فعال را تخمین بزند. این موضوع بیانگر حساسیت بالای این دو مؤلفه به تغییرات ناشی از کمبود آهن در برگ است. به‌طور کلی، ترکیب مناسب ویژگی‌های استخراج شده از تصویر برگ، به‌ویژه در مدل‌های مبتنی بر یادگیری ماشین، می‌تواند روش غیرمخرب، سریع و کم‌هزینه‌ای را برای پایش وضعیت تغذیه‌ای گیاه و مدیریت بهتر تغذیه آهن در تاکستان‌ها فراهم سازد.

فهرست منابع

- 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>
- Boxma R. 1972. Bicarbonate as the most important soil factor in lime-induced chlorosis in the Netherlands, *Plant Soil*, 37:233-243
- 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.
- Chen, Y., & Zhou, X. (2010, September). Plant root image processing and analysis based on 2D scanner. In 2010 IEEE Fifth International Conference on Bio-Inspired Computing: Theories and Applications (BIC-TA) (pp. 1216-1220). IEEE.

- Firuzi, S. , Sepehr, E. , Imani, A. and 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), 2145-2156. doi: 10.22059/ijswr.2024.377062.669720
- Gonzalez, R.C., Woods, R.E. and Eddins, S.L., 2004. *Digital image processing using MATLAB* (Vol. 624). Upper Saddle River, New Jersey: Pearson-Prentice-Hall.
- 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
- Malakouti, M. J., & Mehdi Tehrani, M. (2005). The role of micronutrients in increasing yield and improving the quality of agricultural products.
- Marschner, H. (Ed.). (2011). *Marschner's mineral nutrition of higher plants*. Academic press.
- 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).
- Misra, A., & Sharma, S. (2006). Critical Fe concentration and productivity of Java citronella. *Revista Brasileira de Plantas Mediciniais*, 8, 54-58.
- Rout, G.R., & Sahoo, S. (2015). Role of iron in plant growth and metabolism. *Reviews in Agricultural Science*, 3, 1-24.
- 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.
- Vesali, F., Omid, M., Kaleita, A., & Mobli, H. (2015). Development of an android app to estimate chlorophyll content of corn leaves based on contact imaging. *Computers and Electronics in Agriculture*, 116, 211-220. doi: <https://doi.org/10.1016/j.compag.2015.06.012>

From Pixels to Nutrients: Estimating Leaf Iron Using Image-Based Neural Networks

Ebrahim Sepehr^{1*}, Aydin Imani¹, Shabnam Firouzi¹

Dept. of Soil Science, Faculty of Agriculture, Urmia University

*Corresponding Author: e.sepehr@urmia.ac.ir

Abstract

Iron deficiency is one of the most critical limiting factors in fruit crop production, especially in calcareous soils. In this study, an artificial intelligence and image processing-based approach was developed to estimate the active iron content in grape leaves. Leaf samples with varying levels of iron deficiency were analyzed using atomic absorption spectroscopy to measure active iron, and their images were captured and stored under controlled lighting conditions. After initial preprocessing, statistical color features from various image channels were extracted and their relationships with active iron concentrations were evaluated. The results indicated that the neural network model achieved the highest accuracy using features extracted from the S and I color channels. The developed model, with a 4-22-1 architecture, was able to predict active iron content with an R² of 0.92 for the entire dataset. This approach can serve as an effective, fast, and cost-efficient alternative to traditional laboratory methods for diagnosing iron deficiency in vineyards and may contribute to the development of smart agricultural tools. Text (Times New Roman, 10pt, Regular)

Keywords: Iron Deficiency, Grape Leaf, Artificial Intelligence, Neural Network, Color Feature