

# Development of an artificial neural network-based model for estimating the active iron content in grape leaves

## Abstract

Iron is an essential element in the growth process of plants and plays a crucial role in chlorophyll production. Iron deficiency is a serious limitation in vineyards that can significantly affect both the yield and the quality of the crop. The use of modern methods such as digital image processing not only increases precision but also reduces the need for costly and time-consuming laboratory testing, thereby lowering costs and speeding up data-driven decision-making processes in orchard management. The aim of this study is to develop a system based on image processing and neural networks to estimate the active iron content in grape leaves. For this purpose, 55 leaf samples with different levels of iron deficiency were collected and analyzed from vineyards around Urmia. The total and active iron content in the samples was measured using atomic absorption spectroscopy and the leaves were photographed and processed under controlled light conditions. Statistical features were extracted from the images and their correlation with active and total iron content was analyzed. Finally, the best features were used to predict iron content using a multilayer artificial neural network. The results of the linear regression show that active iron correlates with the R, G, H, and S color channels with coefficients of 0.64, 0.58, 0.54, and 0.45, respectively, and that total iron does not correlate with the changes in leaf color. The neural network with an optimized structure of 8-9-1 was able to predict the data from the atomic absorption device with an accuracy of 0.83, 0.88, and 0.84 for training, test, and all data, respectively. In summary, image processing can be effectively and reliably used as a tool for optimal plant nutrition management and rapid diagnosis of iron deficiency.

**Keywords:** Iron estimation, Grape leaves, Artificial neural network, Image processing.

## توسعه یک مدل مبتنی بر شبکه عصبی مصنوعی برای تخمین میزان آهن فعال در برگ انگور

### چکیده

آهن یک عنصر ضروری در فرآیند رشد گیاهان است که نقش حیاتی در تولید کلروفیل دارد. کمبود آهن یکی از محدودیت‌های جدی در باغ‌های انگور است که می‌تواند عملکرد و کیفیت محصول را به طور قابل توجهی تحت تأثیر قرار دهد. استفاده از روش‌های نوین مانند پردازش تصویر دیجیتال، علاوه بر دقت بالا، با کاهش نیاز به انجام آزمایش‌های گران‌قیمت و وقت‌گیر آزمایشگاهی، موجب کاهش هزینه‌ها و تسریع فرآیند تصمیم‌گیری مبتنی بر داده در مدیریت باغ می‌شود. هدف این مطالعه توسعه یک سامانه مبتنی پردازش تصویر و شبکه عصبی برای تخمین آهن فعال موجود در برگ گیاه انگور است. بدین منظور، ۵۵ نمونه برگ با سطوح مختلف کمبود آهن از باغ‌های اطراف شهرستان ارومیه جمع‌آوری و مورد آزمایش قرار گرفت. میزان آهن کل و آهن فعال در نمونه‌ها با استفاده از روش جذب اتمی اندازه‌گیری شده و تصاویر برگ‌ها در شرایط نوری کنترل شده ثبت و مورد پردازش قرار گرفتند. ویژگی‌های آماری از تصاویر استخراج و همبستگی آنها با مقادیر آهن فعال و آهن کل مورد بررسی قرار گرفت. در نهایت ویژگی‌های برتر برای پیش‌بینی میزان آهن با استفاده از شبکه عصبی مصنوعی چند لایه استفاده شد. نتایج رگرسیون خطی نشان داد که میزان آهن فعال برگ با مولفه‌های رنگی R، G، H، S به ترتیب دارای همبستگی ۰/۶۴، ۰/۵۸، ۰/۵۴ و ۰/۴۵ است ولی مقدار آهن کل دارای همبستگی با تغییرات رنگ برگ نیست. مدل شبکه عصبی با ساختار بهینه ۸-۹-۱ قادر به پیش‌بینی داده‌های بدست آمده از دستگاه جذب اتمی با دقت ۰/۸۳، ۰/۸۸ و ۰/۸۴ به ترتیب برای داده‌های آموزش، تست و کل داده‌ها بود. در نهایت می‌توان نتیجه گرفت که روش پردازش تصویر به عنوان یک ابزار موثر و قابل اعتماد در مدیریت بهینه تغذیه گیاهان و تشخیص سریع کمبود آهن می‌تواند مورد استفاده قرار گیرد.

**کلمات کلیدی:** تخمین آهن، برگ انگور، شبکه عصبی مصنوعی، پردازش تصویر

### مقدمه

آهن یک عنصر ریز مغذی مهم و ضروری برای گیاه محسوب می‌شود و نقش مهمی در فرایندهای فیزیولوژیکی و بیوشیمیایی گیاهان دارد (Rout & Sahoo., 2015). آهن به عنوان جزء مهمی از آنزیم‌های حیاتی در زنجیره انتقال الکترون، تثبیت نیتروژن و سنتز

هورمون‌های گیاهی شرکت می‌کند (Hochmuth., 2011; Misra and Sharma, 2006). کمبود آهن یک مشکل اساسی برای باغ‌های واقع در خاک‌های با pH بالا محسوب می‌شود (Bienfait and Vandermark 1983). این عارضه با کاهش سنتز کلروفیل به صورت زرد شدن برگ‌ها نمایان شده و سبب کاهش سطح برگ، رشد رویشی، افت کیفیت و عملکرد محصول می‌شود (Vasconcelos & Grusak., 2014). کمبود آهن به صورت معمول در غلظت‌های بین ۵۰ تا ۱۰۰ میلی‌گرم بر کیلوگرم بافت گیاهی بروز می‌کند (Romheld, 1987). دسترسی گیاه به آهن، در خاک‌های آهکی با مقدار آهن کافی، به دلیل وجود کربنات کلسیم، فسفات و pH بالا محدود می‌شود. همچنین مشاهده شده است که مقدار آهن کل در برگ‌های کلروزه اغلب به مقدار مشابه یا حتی بیشتری از برگ‌های سبز است (Neaman and Aguirre, 2007). یکی از دلایل این اتفاق مربوط به تفاوت pH بالای آپوپلاست و رسوب آهن در برگ‌ها می‌باشد که موجب غیرفعال شدن آهن از نظر فیزیولوژیکی در برگ می‌شود (Romheld, 2000). از این رو، غلظت آهن کل در برگ‌ها به عنوان یک شاخص موثر برای تشخیص وضعیت تغذیه آهن در محصولات کشاورزی قابل استفاده نیست.

روش‌های آزمایشگاهی متداول شامل روش جذب اتمی و روش کالری متری هستند. این روش‌ها علی‌رغم دقت مناسب و تبعیت از استانداردها، به علت تأخیر زمانی بین جمع‌آوری نمونه بافت برگ، آنالیز و کسب نتایج، هزینه بالا و مضراتی که برای محیط زیست و سلامت انسان دارند قادر نیستند به عنوان روش مناسب برای کوددهی استفاده شوند (Vesali et al., 2015). در سال‌های اخیر محققان از فناوری‌های نوین مانند تصویربرداری و مدل‌های هوشمند برای تعیین خصوصیات فیزیکی، مکانیکی و شیمیایی در حوزه علوم کشاورزی استفاده کرده‌اند (Han and Watchareeruetai, 2019). با توجه به اینکه کمبود آهن تأثیر زیادی بر روی رشد گیاه داشته و استفاده از روش‌های مرسوم برای کشاورزان سخت و پرهزینه است؛ بنابراین نیاز به یک سیستم نظارت پیوسته برای پیگیری وضعیت تغذیه‌ای در گیاهان به منظور افزایش عملکرد و کیفیت محصول ضروری است.

### پیشینه پژوهش

برای تشخیص کمبود مواد مغذی نیز روش‌های تصویربرداری مختلف مانند تصویربرداری طیفی، حرارتی، فلورسانس و RGB پتانسیل بالایی برای تشخیص سلامت گیاه از خود نشان داده‌اند (Barbedo, 2013; Gorbe and Calatayud, 2012; Yu et al., 2014; Costa et al., 2013). در مقایسه با روش‌های موجود استفاده از روش تصویربرداری RGB با توجه به در دسترس بودن تلفن‌های همراه هوشمند و دوربین‌های دیجیتال در جامعه از محبوبیت بیشتری برخوردار است (Barbedo, 2013). در زمینه تخمین عناصر موجود در گیاه بخش قابل توجهی از تحقیقات مربوط به تخمین میزان نیتروژن موجود در گیاه بوده است (Tewari et al., 2013). Muhammad et al., 2012 الگوریتمی ارائه دادند که قادر بود با استفاده از ویژگی‌های رنگ برگ در گیاه و یک طبقه‌بند ماشین بردار پشتیبان میزان کمبود مواد مغذی نیتروژن، پتاسیم و منیزیم را در سه طبقه مختلف با دقت ۰/۹۵ تشخیص دهد. Sun et al., 2018 با توسعه یک مدل پردازشی ویژگی‌های بافت تصویر برگ‌های برنج را استخراج کرده و با استفاده از یک مدل ماشین بردار پشتیبان کمبود نیتروژن در برگ‌های برنج را با دقت ۰/۹۵ تشخیص دادند. Vesali et al., 2015 از روش پردازش تصویر برای تخمین محتوای کلروفیل برگ‌های ذرت استفاده کردند. آنها در این تحقیق با استفاده از یک نرم‌افزار مبتنی بر تلفن همراه هوشمند و توسعه مدل‌های رگرسیونی و مبتنی بر شبکه عصبی مصنوعی توانستند با دقت ۰/۸۸ میزان محتوای کلروفیل برگ ذرت را تخمین بزنند. شایان ذکر است که تعداد کمی از تحقیقات انجام گرفته در منابع به تشخیص کمبود، تخمین و طبقه‌بندی عناصر میکرو مانند آهن (Ghosal et al., 2018)، منگنز (Hu et al., 2012) پرداخته‌اند. حاجی‌زاده و همکاران (۱۴۰۲)، از یک مدل شبکه عصبی برای طبقه‌بندی تصاویر برگ هلو بر اساس میزان کمبود آهن در چهار سطح بدون کمبود، کمبود کم، کمبود متوسط و کمبود شدید استفاده

کردند. مدل توسعه داده شده با استفاده از ویژگی‌های استخراج شده از تصاویر و آنالیز مولفه اصلی (PCA) قادر بود با دقت ۸۹/۷۳٪ به طبقه‌بندی تصاویر پردازد. در تحقیق حاضر از روش پردازش تصویر و مدل مبتنی بر یادگیری ماشین برای تخمین میزان آهن موجود در برگ انگور استفاده شده است.

## روش‌شناسی پژوهش جمع‌آوری داده و تصویربرداری

بر اساس نقشه خاک و گزارش‌های خاکشناسی، منطقه نازلو و زینالو ارومیه واقع در شمال شهرستان ارومیه با موقعیت جغرافیایی  $UTM(X) = 508653m$  و  $UTM(Y) = 4156176m$  جهت نمونه‌برداری انتخاب شد. تعداد ۵۵ نمونه از برگ‌های جوان و میانی سرشاخه‌های درخت انگور از ۲۵ باغ با درجات مختلف کلروز آهن در منطقه فوق‌الذکر در بازه ماه‌های خرداد و تیر سال ۱۳۹۷ جمع‌آوری و جهت تصویربرداری و اندازه‌گیری آهن فعال به آزمایشگاه منتقل شدند (شکل ۱).

به منظور تصویربرداری از نمونه‌ها در یک شرایط محیطی کنترل شده و محفظه‌ای با ابعاد  $30 \times 30 \times 25$  سانتی‌متر مورد استفاده قرار گرفت. تصویربرداری از نمونه‌ها توسط یک تلفن همراه HTC مدل Uplay انجام گرفت. در زمان تصویربرداری دوربین در فاصله ثابت از نمونه‌ها به صورت افقی به گونه‌ای قرار گرفت که بهترین وضوح تصویر در کمترین فاصله ممکن از نمونه‌ها بدست بیاید. برای دست‌یافتن به یک شرایط یکسان در تمامی تصاویر تنظیمات تمرکز، حساسیت نوری<sup>۲</sup> و سرعت شاتر<sup>۳</sup> دوربین در حالت ثابت تنظیم گردید که در جدول زیر مقادیر مذکور ذکر شده‌اند. تصاویر دیجیتالی ثبت شده به صورت تصاویر ۲۴ بیتی رنگی و اندازه  $4672 \times 3504$  پیکسل در فضای رنگی RGB و با فرمت JPEG ذخیره گردیدند.

<sup>۱</sup>Principal component analysis

<sup>۲</sup> Focus

<sup>۳</sup> ISO

<sup>۴</sup> Shutter Speed



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

جدول ۱. تنظیمات مربوط به دوربین برای ثبت تصاویر مربوط به برگها

Focus	ISO	Shutter Speed	White Balance
f/2	100	1/30-1/200	2300K

### اندازه گیری آهن فعال و آهن کل

پس از انجام مراحل مربوط به تصویربرداری برگهای جوان کاملاً شسته و سپس سطح آنها خشک شد. برای اندازه گیری آهن فعال ( $Fe^{2+}$ ) ۱ گرم نمونه برگ، ابتدا توزین و سپس به آن ۲۰ میلی لیتر محلول ۱/۵ درصد فنانترویلین با pH برابر با ۳ اضافه شد. پس از ۱۶ ساعت نمونه ها صاف و به حجم ۲۵۰ رسانده شد (Zohlen, 2000). برای اندازه گیری آهن کل نیز برگها به مدت ۷۲ ساعت در دمای ۷۲ درجه سانتی گراد آون خشک شدند. نمونه برگ خشک شده به مدت ۴ ساعت در کوره ۵۵۰ درجه سانتی گراد به خاکستر تبدیل شدند. ۱ گرم از خاکستر به دست آمده همراه با ۵ میلی لیتر اسید نیتریک غلیظ به مدت ۱۵ دقیقه در حمام آب جوش قرار گرفت. سپس نمونه صاف و در بالن ۵۰ میلی لیتری با آب دیونیزه به حجم رسیده و عصاره بدست آمده توسط دستگاه جذب اتمی (Shimadzu AA-6300) قرائت گردید (Estefan et al., 2013).



(ب)



(الف)

شکل ۲. تصاویر ثبت شده از نمونه های با سطوح مختلف آهن. الف) نمونه برگ با کمبود آهن. ب) نمونه برگ با بدون کمبود آهن.

## پیش‌پردازش و استخراج ویژگی

برای پیش‌پردازش تمام تصاویر در اندازه  $1024 \times 1024$  پیکسل با استفاده از جعبه ابزار پردازش تصویر نرم افزار متلب<sup>۸</sup> ۲۰۱۸ بریده شدند. در شکل ۲ دو نمونه از تصاویر مربوط به برگ‌های با مقدار آهن کافی و کم نشان داده شده است. تصاویر ثبت شده علاوه بر برگ شامل پیکسل‌های پس‌زمینه نیز هستند. به همین دلیل از شاخص بیشینه سبزیگی<sup>۹</sup> (ExG) برای تعیین پیکسل‌های متعلق به برگ در مقابل پس‌زمینه (پیکسل‌های سفید) مورد استفاده قرار گرفت. شاخص رنگی ExG به صورت زیر تعریف می‌شود (Meyer et al. , 1998):

$$ExG = 2 \times G - R - B \quad (1)$$

که R، G و B کانال‌های شدت رنگ قرمز، سبز و آبی هستند. برای پیکسل‌های مربوط به گیاه، مقدار شاخص بیشینه سبزیگی همیشه مثبت است اما برای پس‌زمینه می‌تواند مثبت یا منفی باشد. برای حذف خطاهای احتمالی ناشی از تصویر برداری توسط کاربر تصاویر اصلاح گاما<sup>۱۰</sup> و بهبود بازه دینامیکی<sup>۱۱</sup> بر روی تمامی تصاویر اعمال گردید. پس از انجام عملیات پیش‌پردازش، ابتدا تصاویر از فضای RGB به فضای HSV انتقال داده شدند. سپس ویژگی‌های آماری شامل میانگین و انحراف معیار مربوط به هر یک از کانال‌های R، G و B از کانال رنگی RGB و H، S و V از فضای رنگی HSV استخراج شدند که به صورت زیر تعریف می‌شوند:

$$mean(\mu_i) = \frac{\sum_{x=1}^M \sum_{y=1}^N I_i(x, y)}{M \times N} \quad (2)$$

$$standard\ deviation(\sigma_i) = \sqrt{\frac{\sum_{x=1}^M \sum_{y=1}^N (I_i(x, y) - \mu)^2}{M \times N}} \quad (3)$$

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. کمترین و بیشترین مقدار هر ویژگی برای مولفه‌های رنگی R، G، B، H، S و V در جدول ۲ نشان داده شده است.

<sup>۸</sup>MATLAB

<sup>۹</sup>Excess green index (ExG)

<sup>۱۰</sup>Gamma Correction

<sup>۱۱</sup>Dynamic Range Optimization

جدول ۲. بازه مقادیر (مینیمم و ماکزیمم) میانگین و انحراف معیار برای تمامی ویژگی‌های استخراج شده از تصاویر

	Mean		Standard Deviation	
	Min	Max	Min	Max
Red	۶۹/۳۹	۱۳۱/۶۲	۹۳/۸۲	۱۴۲/۳۵
Green	۱۱/۴۰	۵۲/۴۸	۰/۱۸	۰/۲۳
Blue	۰/۵۱	۰/۹۱	۰/۳۷	۰/۵۶
Hue	۱۱/۰۶	۴۷/۳۷	۹/۸۴	۴۵/۰۶
Saturation	۷/۶۱	۳۲/۸۸	۰/۰۰۴	۰/۰۲
Value	۰/۰۵	۰/۱۷	۰/۰۴	۰/۱۸

### تخمین آهن

یک شبکه عصبی از چندلایه شامل: یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی تشکیل شده است. یافتن بهترین ساختار برای یک شبکه عصبی شامل تعیین تعداد دقیق لایه‌های پنهان، تعداد نورون‌های لایه پنهان، مقدار دقیق وزن‌ها و نوع تابع تبدیل هر لایه است. با وجود اینکه افزایش تعداد نورون‌ها می‌تواند در افزایش دقت شبکه تاثیر گذار باشد، می‌تواند پیچیدگی محاسباتی را نیز به طرز شگرفی افزایش دهد. در نتیجه برای یافتن بهترین ساختار شبکه باید مصالحه‌ای بین دقت و پیچیدگی شبکه صورت پذیرد (Imani et al., 2020).

در تخمین میزان آهن موجود در برگ گیاه، ویژگی‌های رنگی در یک برگ از پراکندگی بالایی برخوردار هستند که تخمین دقیق را با دشواری روبرو می‌سازد. از این رو، یک شبکه قدرتمند نیاز هست تا بتواند که بر عوامل مختلف غلبه کند. در این مطالعه، یک شبکه عصبی چندلایه پرسپترون<sup>۹</sup> (MLP NN) برای مدل‌سازی داده‌های آزمایشی آهن گیاه و تصاویر ثبت شده توسعه داده شد. در این بخش داده‌ها به سه بخش تقسیم شدند: داده‌های آموزش، داده‌های اعتبارسنجی و داده‌های ارزیابی. این تقسیم‌بندی از بیش برآزش در روند یادگیری شبکه جلوگیری کرده و باعث می‌شود که مدل به داده‌های آموزش بیش از اندازه وابسته نباشد. بنابراین به ترتیب ۷۰، ۱۵ و ۱۵ درصد داده‌ها برای آموزش، ارزیابی و آزمایش در نظر گرفته شدند. در این مدل بردار ویژگی‌های مربوط به رنگ برگ‌ها به عنوان ورودی و میزان آهن بدست آمده از هر برگ به عنوان خروجی مدل در نظر گرفته شد.

<sup>۹</sup>Multilayered perceptron (MLP) neural network

برای یافتن بهترین ساختار شبکه تعداد نورون‌های مختلف لایه مخفی از یک تا ۲۵ با صد تکرار برای هر ساختار آموزش داده شد و برای یافتن بهترین ساختار مدل شبکه عصبی معیارهای ضریب تعیین ( $R^2$ )، مجذور میانگین مربعات خطا ( $RMSE$ ) و درصد میانگین قدرمطلق خطا ( $MAPE$ ) مورد استفاده قرار گرفتند که به صورت زیر تعریف می‌شوند:

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_{predict}^i - y_{target}^i)^2}{\sum_{i=1}^N (y_{target}^i - \bar{y})^2} \quad (5)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (y_{predict}^i - y_{target}^i)^2}{N}} \quad (6)$$


$$MAPE = \frac{|y_{predict} - y_{target}|}{N} \times 100 \quad (7)$$

که در آن  $y_{predict}^i$  مقدار آهن تخمین زده شده توسط مدل،  $y_{target}^i$  مقدار آهن اندازه‌گیری شده در آزمایشگاه،  $\bar{y}$  مقدار میانگین نمونه‌های اندازه‌گیری شده و  $N$  تعداد نمونه‌های مورد ارزیابی در این مطالعه است.


## نتایج و بحث

### همبستگی مولفه‌های رنگی با آهن

در این بخش میانگین مولفه‌های رنگی R، G، B، S، H، V که در بخش قبل توصیف شده بودند با مقادیر آهن کل و فعال اندازه‌گیری شده در آزمایشگاه مقایسه شدند. با توجه به نتایج شکل ۳ مشاهده گردید که بین مولفه‌های فضای رنگی RGB و مقادیر آهن کل هیچ‌گونه همبستگی‌ای وجود ندارد که این موضوع با گزارش (Romheld, 2000) در زمینه پارادوکس آهن و احتمال بالا بودن مقدار آهن کل در برگ‌های کلروزه نسبت به برگ‌های سبز همخوانی داشت. از این رو، در این تحقیق مقادیر آهن فعال برای مدل‌سازی مدنظر قرار گرفت. مشابه گزارش‌های منتشر شده تحقیقات قبلی (Tewari et al., 2013; Vesali et al., 2015) در زمینه تخمین میزان کلروفیل برگ، مولفه رنگی B قادر به بیان تغییرات رنگی ناشی از تغییرات آهن در برگ نیست، در حالی که مولفه‌های R و G توانسته‌اند تغییرات میزان آهن در برگ را نشان دهند. نتایج مربوط به مدل‌های خطی تک متغیره در جدول ۳ نشان داده شده است. با توجه به نتایج مشاهده می‌گردد که بین مولفه‌های B و S و مقادیر آهن فعال همبستگی وجود ندارد و به نظر می‌رسد که این دو مولفه دارای مقادیر تقریباً ثابتی هستند (شکل ۳). در میان اندیس‌های مورد بررسی، مولفه R بالاترین همبستگی را با مقادیر آهن فعال ( $R^2 = 0.64$ ) و ( $RMSE = 3.19$ ) داشت. به جز دو مولفه B و S هر چهار مولفه رنگی دیگر برای تخمین میزان آهن فعال برگ مورد استفاده قرار گرفتند.



(ب)



(الف)

شکل ۳. همبستگی بین مولفه‌های قرمز (Red)، سبز (Green) و آبی (Blue) با آهن فعال. (ب) آهن کل

جدول ۳. نتایج رگرسیون خطی تک متغیره برای مولفه‌های رنگی مختلف و مقدار آهن فعال

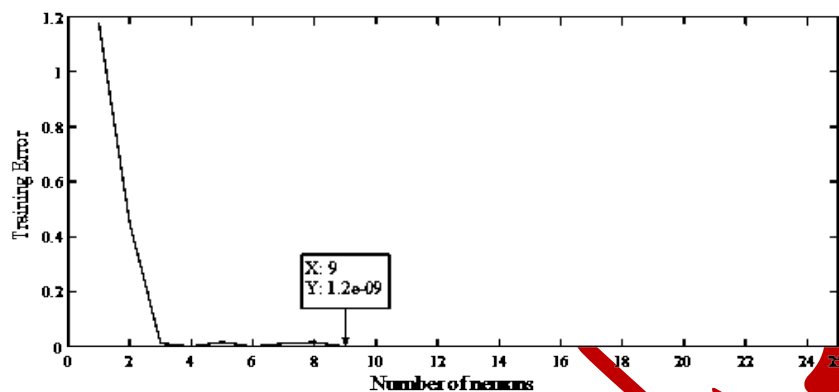
	Slop	Intercept	R-Squared	RMSE
R	-۰/۲۲	۲۸/۱۹	۰/۶۴	۳/۱۹
G	-۰/۲۴	۳۵/۲۶	۰/۵۸	۳/۴۷
B	-۰/۲۱	۱۲/۴۷	۰/۰۳	۵/۲۵
H	۳۰۶/۵۵	-۵۶/۲۵	۰/۵۴	۳/۶۰
S	-۱۷/۲۷	۲۰/۵۹	۰/۰۱	۵/۳۵
V	-۵۰/۶۴	۳۰/۱۱	۰/۴۵	۳/۹۷

### تخمین آهن فعال با شبکه عصبی

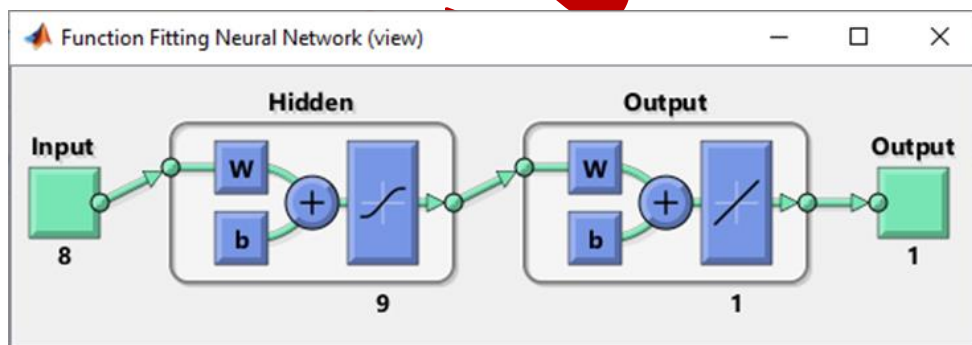
یک شبکه پرسپترون چندلایه متشکل از یک لایه مخفی و یک لایه خروجی جهت تخمین میزان آهن فعال برگ انگور مورد استفاده قرار گرفت. شبکه مذکور در نرم افزار متلب ۲۰۱۸ توسعه داده شد. از یک تابع تصادفی برای انتخاب داده‌های آموزش، ارزیابی و آزمایش استفاده شد. توابع تبدیل تانژانت سیگموئید (tansig) و خطی (purelin) به ترتیب برای لایه مخفی و لایه خروجی مورد استفاده قرار گرفتند. بهترین ساختار شبکه تحت شرایط زیر تعیین گردید: اول، تعداد گره‌های لایه ورودی با توجه به نتایج جدول ۳ برابر با ۸ تعیین گردید. دوم، تعداد گره‌های لایه مخفی بر اساس ارزیابی کمی خطای آموزش بدین صورت تعیین گردید که: تعداد نورون‌ها از ۱ تا ۲۵ افزایش پیدا کردند. برای حذف عامل تاثیرگذار وزن اولیه تعداد ۱۰۰ تکرار برای هر نورون در نظر گرفته شد تا بر اساس آن تعداد نورون بهینه برای لایه مخفی را بتوان تعیین کرد. در نهایت، خروجی یک گره شامل مقدار آهن موجود در برگ گیاه در نظر گرفته شد. برای آموزش شبکه با استفاده از داده‌های ورودی از تابع trainlm استفاده شد. در شکل ۴ تغییرات خطای آموزش شبکه با افزایش تعداد نورون‌های لایه پنهان مشاهده می‌گردد. همانطور که از شکل مشخص است، با افزایش تعداد نورون‌ها، خطای آموزش پس از تعداد ۹ نورون برای لایه پنهان ثابت شده و به مقدار  $1.2e-09$  می‌رسد. در نتیجه تعداد ۹ نورون برای لایه پنهان در نظر گرفته شد.

ساختار شبکه عصبی توسعه داده شده با ۸ ورودی و یک خروجی در شکل ۵ نشان داده شده است. همانطور که مشاهده می‌شود این شبکه دارای ۹ نورون در لایه پنهان است. نتایج حاصل از مدل نهایی در جدول ۴ نشان داده شده است. بهترین همبستگی بین داده‌های پیش‌بینی شده و داده‌های آزمایشگاهی برای مراحل آموزش، تست و کل داده‌ها با ضریب تعیین ۰/۹۲، ۰/۹۱ و ۰/۹۱، مقدار  $RMSE$  ۲/۰۶، ۱/۵۴ و ۲/۰۴ و  $MAPE$  ۲۳/۷۸، ۳۷/۹۸ و ۳۲/۳۶ درصد به ترتیب برای داده‌های آموزش، تست و کل داده‌ها به دست آمد. مقدار  $R^2$  بالا توانایی مدل توسعه داده شده برای تخمین میزان آهن موجود در برگ گیاه را تایید می‌کند. علاوه بر این میزان ناچیز  $RMSE$  و  $MAPE$  توانایی تعمیم مدل شبکه عصبی را نشان می‌دهد.





شکل ۴. تغییرات مربوط به خطای آموزش شبکه با توجه به افزایش تعداد نورون‌ها در لایه پنهان.

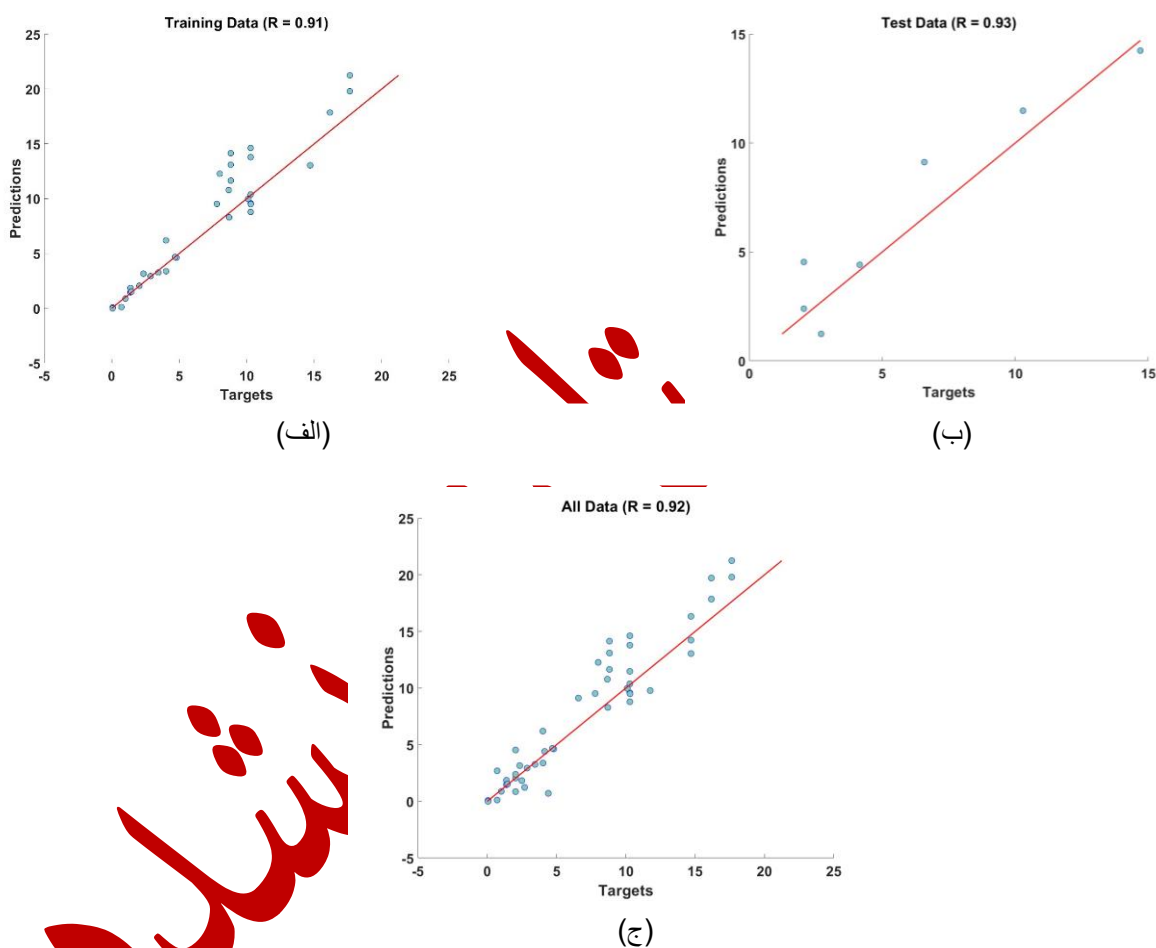


شکل ۴. ساختار شبکه عصبی توسعه داده شده.

جدول ۴. نتایج مدل شبکه عصبی برای داده‌های آموزش، تست و تمام داده‌ها

	$R^2$	RMSE	MAPE (%)
Train	۰/۸۳۲۱	۲/۰۶	۲۳/۷۷
Test	۰/۸۸۱۳	۱/۵۴	۳۵/۹۷
All data	۰/۸۴۱۸	۲/۰۴	۳۲/۳۶

برای ارزیابی بیشتر کارایی مدل توسعه داده شده، مقادیر واقعی آهن اندازه‌گیری شده نسبت به مقادیر پیش‌بینی شده توسط مدل شبکه عصبی برای داده‌های آموزش، ارزیابی و کل داده‌ها رسم شدند (شکل ۶). از نظر کیفی در صورتی که مقادیر تخمین زده شده به مقادیر واقعی نزدیک‌تر باشند، داده‌ها حول خط  $y = x$  متمرکز خواهند شد. همانطور که در شکل نیز مشاهده می‌گردد، مدل شبکه عصبی توسعه داده شده به طور ویژه‌ای در پیش‌بینی مقادیر واقعی موفق عمل کرده است. علاوه بر این، تعداد اندک خطاها نیز نشان می‌دهد که شبکه عصبی ابزار مناسبی برای تخمین آهن گیاه است.



**شکل ۶.** نمودار پراکندگی تخمین مدل شبکه عصبی در مقابل مقادیر آهن فعال برای (الف) داده‌های آموزش، (ب) داده‌های تست و (ج) تمام داده‌ها

در جدول ۵ نتایج کارهای انجام گرفته مشابه با تحقیق حاضر برای مقایسه بیشتر ارایه گردیده است. با مقایسه نتایج مدل ارایه شده در تحقیق حاضر با پژوهش‌های مشابه صورت گرفته، مشاهده می‌گردد که مدل ارایه شده در برای تخمین آهن برگ انگور با دقت قابل قبولی توانسته میزان آهن موجود در برگ گیاه انگور را تخمین بزند. همچنین نتایج این تحقیق نشان داد که با بررسی رابطه بین رنگ برگ و میزان آهن فعال گیاه، ماشین بینایی با دقت قابل قبولی قادر است با استفاده از یک مدل مناسب در فضای رنگی طیف مرئی برای استخراج اطلاعات مربوط به محتوای برگ گیاه مورد استفاده قرار گیرد. وصالی و همکاران (۲۰۱۵) نیز به نتیجه مشابهی برای اندازه‌گیری میزان کلروفیل برگ ذرت با استفاده از یک گوشی تلفن همراه دست یافتند.

جدول ۵. پژوهش‌های مقایسه‌ی نتایج حاصل از پژوهش‌های مشابه

پژوهش مربوط	پارامتر مدل شده	گیاه مورد بررسی	نوع مدل توسعه یافته	نوع تصویربرداری	بهترین دقت مدل ( $R^2$ )
وصالی و همکاران (۲۰۱۵)	میزان کلروفیل	ذرت	شبکه عصبی مصنوعی	مرئی	۰/۸۸
شاو و هی (۲۰۱۳)	میزان آهن و روی	برنج	ماشین بردار پشتیبان	مرئی/اطیفی (مادون قرمز)	۰/۶۷
پاندی و همکاران (۲۰۱۷)	میزان آهن و خصوصیات شیمیایی	ذرت و سویا	رگرسیون حداقل مربعات جزئی (PLSR)	فراطیفی (Hyperspectral)	۰/۶۰
یانگ و همکاران (۲۰۲۲)	عملکرد فتوسنتز	انگور	شبکه عصبی بیزین	فراطیفی (Hyperspectral)	۰/۷۸
تحقیق حاضر	میزان آهن فعال	انگور	شبکه عصبی مصنوعی	مرئی	۰/۸۸

### نتیجه‌گیری و پیشنهادها

با توجه به اهمیت تشخیص میزان کمبود آهن در باغ‌های انگور، در این مطالعه یک مدل مبتنی بر پردازش تصویر و شبکه عصبی برای تخمین آهن فعال موجود در برگ انگور توسعه داده شد. نتایج حاصل از همبستگی مولفه‌های رنگی و مقادیر آهن فعال و آهن کل نشان داد که آهن فعال با مولفه‌های رنگی G, R, H و S به ترتیب دارای همبستگی ۰/۶۴، ۰/۵۸، ۰/۵۴ و ۰/۴۵ بوده و آهن کل با تغییرات رنگ برگ دارای همبستگی نیست. برای آهن فعال نتایج مدل شبکه عصبی نشان داد که با استفاده از ویژگی‌های استخراج شده از تصویر (میانگین و انحراف معیار) امکان تخمین میزان آهن موجود در برگ انگور امکان‌پذیر است. تغییرات خطای آموزش با افزایش تعداد نورون‌های لایه مخفی مورد بررسی قرار گرفت و مشخص شد که کمترین خطای شبکه با تعداد ۹ نورون لایه مخفی به دست می‌آید و مدل با ساختار ۱-۹-۸ بهترین عملکرد را نسبت به سایر مدل‌ها دارد. بررسی کارایی مدل بر روی داده‌های آموزش، تست و کل داده‌ها نشان داد که شبکه توسعه داده شده به ترتیب با دقت ۰/۸۳، ۰/۸۸ و ۰/۸۴ قادر به تخمین مقدار آهن موجود در برگ انگور است. همچنین مقادیر پایین خطای ۲/۰۶، ۱/۵۴ و ۲/۰۴ به ترتیب برای داده‌های آموزش، تست و کل داده‌ها نشان داد که مدل شبکه عصبی توسعه داده شده از عملکرد خوبی برخوردار بوده و قادر به تخمین آهن فعال گیاه است. با توجه به تحقیقات محدود صورت گرفته در زمینه تخمین آهن گیاه و نتایج امیدوارکننده بدست آمده در این تحقیق، پیشنهاد می‌گردد در آینده از مجموعه داده‌های بزرگتر جهت افزایش تعمیم‌پذیری مدل استفاده گردد. همچنین، پیشنهاد می‌گردد در مطالعات آینده جهت توسعه کاربرد مدل مذکور، برگ‌های انگور مناطق دیگر و گونه‌های گیاهی بیشتر جهت تخمین میزان آهن فعال مورد بررسی قرار گیرند.

“هیچ‌گونه تعارض منافع توسط نویسندگان وجود ندارد.”

### منابع

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. *تحقیقات کاربردی خاک*. ۵۵ (۱)، ۸۱-۶۹. doi: <https://doi.org/10.1109/JCSSE.2019.8864224>

### REFERENCES

- Arnal Barbedo, J. G. (2013). Digital image processing techniques for detecting, quantifying and classifying plant diseases. *SpringerPlus*, 2(1), 660. doi: <https://doi.org/10.1186/2193-1801-2-660>
- Asraf, H. M., Nooritawati, M. T., & Rizam, M. S. (2012). A comparative study in kernel-based support vector machine of oil palm leaves nutrient disease. *Procedia Engineering*, 41, 1353-1359. doi: <https://doi.org/10.1016/j.proeng.2012.07.321>

Bienfait, H. F., & Mark, F. V. D. (1983). Phytoferritin and its role in iron metabolism. In: Metals and Micronutrients: Uptake and Utilization by plants. Pp. 111/123. Academic Press. New York.

Costa, J. M., Grant, O. M., & Chaves, M. M. (2013). Thermography to explore plant–environment interactions. *Journal of experimental botany*, 64(13), 3937-3949. doi: <https://doi.org/10.1093/jxb/ert029>

Estefan, G., Sommer, R., & Ryan, J. (2013). Methods of soil, plant, and water analysis. *A manual for the West Asia and North Africa region*, 3(2).

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>

Gorbe, E., & Calatayud, A. (2012). Applications of chlorophyll fluorescence imaging technique in horticultural research: A review. *Scientia Horticulturae*, 138, 24-35. doi: <https://doi.org/10.1016/j.scienta.2012.02.002>

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>

Hochmuth, G. (2011). Iron (Fe) nutrition of plants. *University of Florida If as Extension, SL*, 353, 1-8.

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>

Meyer, G. E., Mehta, T., Kocher, M. F., Mortensen, D. A., & Samal, A. (1998). Textural imaging and discriminant analysis for distinguishing weeds for spot spraying. *Transactions of the ASAE*, 41(4), 1189-1197. doi: <https://doi.org/10.13031/2013.17244>

Misra, A., & Sharma, S. (2006). Critical Fe concentration and productivity of Java citronella. *Rev Bras Plant Med*, 8, 54-58.

Neaman, A., & Aguirre, L. (2007). Comparison of different methods for diagnosis of iron deficiency in avocado. *Journal of Plant Nutrition*, 30(7), 1097-1108. doi: <https://doi.org/10.1080/01904160701394550>

Römheld, V. (1987). Different strategies for iron acquisition in higher plants. *Physiologia Plantarum*, 70(2). doi: <https://doi.org/10.1111/j.1399-3054.1987.tb06137.x>

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>

Rout, G. R., & Sahoo, S. (2015). Role of iron in plant growth and metabolism. *Reviews in Agricultural Science*, 3, 1-24. doi: <https://doi.org/10.7831/ras.3.1>

Sun, J., Mao, H., & Yang, Y. (2009). THE RESEARCH ON THE JUDGMENT OF PADDY RICE'S NITROGEN DEFICIENCY BASED ON IMAGE. In *Computer and Computing Technologies in Agriculture II, Volume 2: The Second IFIP International Conference on Computer and Computing Technologies in Agriculture (CCTA2008), October 18-20, 2008, Beijing, China 2* (pp. 1049-1054). Springer US. doi: [https://doi.org/10.1007/978-1-4419-0211-5\\_30](https://doi.org/10.1007/978-1-4419-0211-5_30)

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>

Tewari, V. K., Kumar, A. A., Kumar, S. P., Pandey, V., & Chandel, N. S. (2013). Estimation of plant nitrogen content using digital image processing. *Agric Eng Int: 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. doi: <https://doi.org/10.1007/s11104-013-1842-6>

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>

Yu, K. Q., Zhao, Y. R., Li, X. L., Shao, Y. N., Liu, F., & He, Y. (2014). Hyperspectral imaging for mapping of total nitrogen spatial distribution in pepper plant. *PLoS one*, 9(12), e116205. doi: <https://doi.org/10.1371/journal.pone.0116205>

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>

# ویرایش‌های نشده

# Development of an artificial neural network-based model for estimating the active iron content in grape leaves

## EXTENDED ABSTRACT

### Introduction

Iron is an essential micronutrient that plays a crucial role in the physiological and biochemical processes of plants. Recent advances in digital imaging have encouraged various industries to use this technology to determine the relationship between color and product content. While there are several methods for determining iron concentration in plants, the use of imaging offers distinct advantages over traditional laboratory methods.

### Methods

The leaf samples were taken from the young and middle leaves of the grape branches. In June 2018, 55 randomly selected samples with varying degrees of iron chlorosis were taken from several vineyards. These samples were then transported to the laboratory for imaging and analysis of active and total iron content. After the solutions were prepared for each method, the concentrations of total and active iron were determined using an atomic absorption spectrophotometer. The samples were then placed in an environment with controlled lighting for the imaging procedures. After preprocessing, the images were converted from RGB to HSV color space and statistical features were extracted from the R, G, B, H, S and V color channels. Since leaf colors vary significantly, a powerful network is needed to handle these variations. Therefore, a multilayer perceptron neural network (MLP NN) was developed to model the experimental iron data and the corresponding images. The data were split into training (70%), validation (15%) and test (15%) to prevent overfitting and reduce the dependence of the model on the training data. The color features of the leaves and the amounts of iron measured from each leaf were considered as inputs and outputs of the model, respectively. The optimization of the network structure was trained with different numbers of neurons in the layers, ranging from one to 25, using the root mean square error ( $R^2$ ), root mean square error (RMSE) and mean absolute percentage error (MAPE) as evaluation criteria.

### Results

The results of correlating color components with active and total iron showed that active iron correlates with the R, G, H, and S color channels with coefficients of 0.64, 0.58, 0.54, and 0.45, respectively, and that there is no correlation between changes in leaf color and total iron content. A multilayer perceptron network consisting of a hidden layer and an output layer, was used to estimate the active iron concentration using MATLAB 2018 software. The data for training, validation, and testing were selected using a random function. Tangent Sigmoid (tansig) and linear (purelin) activation functions were applied to the hidden and output layers, respectively. The correlation between the predicted and laboratory data resulted in a coefficient of 0.84, an RMSE of 2.04, and a MAPE of 32.36. The high  $R^2$  value confirms the ability of the model to estimate the available iron in plant leaves, while the low error values underline the generalization ability of the neural network model.

### Conclusion

The algorithm presented in this study is an effective tool for estimating plant iron. For active iron, the neural network model has shown that it is possible to estimate the amount of iron in grape leaves based on the features extracted from the image (mean and standard deviation). The neural network model developed here, based on the output of the image processing system, proved to be successful in predicting the actual active iron amounts with a detection accuracy of the algorithm of 84%. It is proposed to use databases with more samples in future studies and also to develop other machine learning and plant models for estimating active iron content.

**Keywords:** Iron estimation, Grape leaves, Artificial neural network, Image processing