

## طراحی و توسعه سامانه بینایی ماشین به منظور پیش‌بینی محتوای کلروفیل و کارتنوئید برگ گیاهان

حدیث بی‌آبی<sup>۱</sup> - سامان آبدانان مهدی زاده<sup>۲\*</sup> - مریم نداف زاده<sup>۳</sup> - محمد رضا صالحی سلمی<sup>۴</sup>

تاریخ دریافت: ۱۳۹۶/۱۲/۲۶

تاریخ پذیرش: ۱۳۹۷/۰۵/۰۱

### چکیده

در زمینه‌ی کشاورزی، نظارت منظم و دوره‌ای جهت کنترل سلامت و کیفیت گیاهان امری ضروری است. اندازه‌گیری مقدار کلروفیل و کارتنوئید برگ به‌عنوان یکی از شاخص‌های سلامت محصول محسوب می‌شود. در این پژوهش مجموعه‌هایی از تصاویر برگ‌های ۶ گیاه مختلف (ختمی، لگنوم، برگ بیدی، انجیر معابد، رز و کنار) با هدف پیش‌بینی کلروفیل و کارتنوئید در فضاهای رنگی پیشنهاد شده (HSV, Lab, RGB و I1I2I3) مورد بررسی قرار گرفتند. هر فضای رنگی شرایط مختلفی از احتمال توزیع یک گروه رنگ را ارائه می‌دهد، بدین ترتیب پس از بررسی فضاهای رنگی با توجه به نتایج آنالیز آماری در سطح احتمال ۵٪، مناسب‌ترین پارامترهای رنگی (a, R, c) جهت آموزش الگوریتم درخت تصمیم‌گیری انتخاب گردید. بر اساس نتایج به‌دست آمده، نشان داده شد که بین روش پردازش تصویر و مقادیر اندازه‌گیری شده توسط دستگاه طیف‌سنج همبستگی بالای ۰/۹۲ برای کلروفیل و ۰/۸۵ برای کارتنوئید وجود دارد. همچنین شایان ذکر است که استفاده از روش پیشنهادی این تحقیق می‌تواند هم از لحاظ اقتصادی هزینه‌های مربوط به نیروی انسانی و تهیه دستگاه اسپد) و هم از نظر صرفه‌جویی در زمان بسیار مقرون به‌صرفه باشد.

**واژه‌های کلیدی:** الگوریتم درخت تصمیم‌گیری، پردازش تصویر، دستگاه اسپد، فضاهای رنگی

### مقدمه

در تشخیص بیماری‌ها، بررسی وضعیت مواد مغذی و نیتروژن و همچنین بررسی میزان دسترسی گیاه به آب شناخته می‌شود (Dey et al., 2016). همچنین کارتنوئیدها و فلاونوئیدها اهمیت زیادی در جلوگیری از خسارت القای تنش اکسیداتیو و نگهداری تعادل اسمزی دارند و نگهداری پایدار کارتنوئیدها و تجمع پلی‌فنول‌ها در برگ‌ها از جمله استراتژی‌های آنتی‌اکسیدانی برای گیاهان شناخته شده است. به نظر می‌رسد افزایش کارتنوئیدها نشان‌دهنده افزایش توانایی سلول برای مقابله با تنش اکسیداتیو است (Zring et al., 2011).

میزان کارتنوئید محصولات، علاوه بر گونه گیاهی به شرایط اقلیمی و مراقبت‌های کافی نیز وابسته است، برای ساخت کارتنوئیدها گرچه به‌وجود روشنایی نیاز نیست، اما وجود اکسیژن شرط اساسی است. علی‌رغم عدم نیاز به تابش مستقیم نور برای ساخت کارتنوئیدها، اما تأمین انرژی از طریق پدیده فتوسنتز برای تشکیل کارتنوئیدها امر الزامی است. تغذیه کافی، وجود جیبرالین‌ها و کربوهیدرات کافی از عوامل مؤثر در ساخت کارتنوئیدها است. به‌علاوه برای سنتز کارتنوئیدها وجود اکسیژن زیاد، دی‌اکسیدکربن کم و نیز اتیلن کافی از عوامل مؤثر به‌شمار می‌آیند. تناوب حرارتی مناسب موجب افزایش فتوسنتز خالص و در نتیجه تحریک ساخت کارتنوئید کافی می‌شود، دمای بیش از حد بالا و یا پایین از سنتز این ترکیبات جلوگیری می‌کند، اما دمای مطلوب برای بیوسنتز گروه‌های مختلف کارتنوئید متفاوت است (Jalili Marandi, 2012). به‌طور کلی دو

کیفیت محصول و میزان بهره‌وری از آن به‌طور مستقیم با رنگدانه سبز گیاه (کلروفیل) در ارتباط است و کشاورزان، به‌طور معمول، رنگ برگ را به‌عنوان یک معیار مناسب برای تشخیص سلامت گیاه در نظر می‌گیرند. بر اساس تجربه معمول کشاورزان، وجود برگ‌های متمایل به رنگ سبز تیره در محصولات را نشان از طراوت و شادابی گیاه می‌دانند (Ali et al., 2012). از نظر علمی می‌توان گفت که محتوای کلروفیل گیاه، شاخصی از فعالیت فتوسنتز است که در ارتباط با غلظت نیتروژن موجود در گیاه سبز می‌باشد و به‌عنوان یک معیار مناسب جهت سنجش واکنش محصول به کاربرد نیتروژن عمل می‌کند. علاوه بر این، مقدار کلروفیل برگ به‌عنوان یک شاخص مهم

۱- دانشجوی کارشناسی ارشد گروه مکانیک بیوسیستم، دانشکده مهندسی زراعی و عمران روستایی، دانشگاه علوم کشاورزی و منابع طبیعی خوزستان

۲- استادیار گروه مکانیک بیوسیستم، دانشکده مهندسی زراعی و عمران روستایی، دانشگاه علوم کشاورزی و منابع طبیعی خوزستان

۳- دانش‌آموخته کارشناسی ارشد گروه مکانیک بیوسیستم، دانشکده مهندسی زراعی و عمران روستایی، دانشگاه علوم کشاورزی و منابع طبیعی خوزستان

۴- استادیار، گروه باغبانی، دانشکده کشاورزی، دانشگاه علوم کشاورزی و منابع طبیعی خوزستان

(Email: s.abdanan@ramin.ac.ir)

\*- نویسنده مسئول

2006). در پژوهشی دیگر سو و همکاران (۲۰۰۸)، یک مدل خطی RGB برای ارزیابی محتوای کلروفیل در جلبک‌ها طراحی کردند؛ این محققین نشان دادند که ویژگی‌های فضای RGB جزء پارامترهای مؤثر برای استخراج محتوای کلروفیل هستند (Su et al., 2008).

علی‌رغم اینکه اجرای فرآیند اخذ تصویر، ساده و ارزان است، اما دو مشکل اصلی در زمینه‌ی برآورد کلروفیل مبتنی بر رنگ برگ، وجود دارد که عبارتند از: (۱) حفظ دقت بالا در بین گونه‌های مختلف (۲) محدودیت‌های تحمیل‌شده ناشی از شرایط مشاهدات مانند چگالی شار نور، کیفیت طیفی نور و زاویه بروز<sup>۲</sup> (Kawashima et al., 1998)؛ به‌منظور حل این مسائل، در پژوهش‌های مختلف برای تهیه تصاویر یکنواخت‌تر، دوربین درون یک جعبه نصب‌شده و بدین ترتیب عوامل محدودکننده ناشی از به‌کارگیری دوربین تا حدودی کنترل خواهد شد (Mercado-Luna et al., 2010; Nematinia et al., 2016).

بعد از استخراج ویژگی نیاز به مدل‌های پیشگو می‌باشد. استفاده از الگوریتم‌های طبقه‌بندی پیکسل تصاویر همراه با پیکسل‌های مخلوط ممکن است منجر به تقسیم‌بندی نادرست شود. لذا به‌کارگیری الگوریتم‌های طبقه‌بندی نرم<sup>۳</sup> مانند الگوریتم‌های مبتنی بر نظریه احتمال<sup>۴</sup> (Nadafzadeh and Abdanan Mehdizadeh, 2017)، مدل‌سازی ترکیب خطی (Settle and Drake, 1993)، شبکه‌های عصبی مصنوعی<sup>۵</sup> (Moody et al., 1996)، نظریه مجموعه فازی (Foody, 1996) و سیستم‌های متخصص<sup>۶</sup> (Ghosh and Samanta, 2003) جهت توسعه مدل‌های پیشگو مناسب‌تر هستند. از دیگر روش‌های پرکاربرد می‌توان به الگوریتم درخت تصمیم‌گیری اشاره نمود. این الگوریتم بر اساس نظریه یادگیری ماشین است و یک ابزار کارآمد برای حل مشکلات طبقه‌بندی و رگرسیون می‌باشد. برخلاف روش‌های طبقه‌بندی دیگر که از مجموعه‌ای از ویژگی‌ها به‌طور مشترک برای انجام طبقه‌بندی در یک مرحله تصمیم واحد استفاده می‌کنند، درخت تصمیم‌گیری بر اساس تصمیم‌گیری چندمرحله‌ای یا سلسله مراتبی و یا یک ساختار درخت مانند عمل می‌کند. درخت از مجموعه‌ای از گره‌های داخلی و گره‌های ترمینال (برگ‌ها) تشکیل شده است. هر گره درخت تصمیم‌گیری ساختار یک تصمیم باینری را ایجاد می‌کند. در الگوریتم درخت تصمیم‌گیری، ویژگی‌ها، متغیرهای پیش‌بینی هستند و خروجی به‌عنوان متغیر هدف (Xu, 2005) می‌باشد؛ زمانی که متغیر هدف، گسسته است می‌توان از درخت تصمیم‌گیری به‌عنوان طبقه‌بند استفاده

روش مخرب و غیرمخرب برای اندازه‌گیری غلظت کلروفیل برگ وجود دارد؛ روش مخرب یک روش مبتنی بر آزمایشگاه است که غلظت کلروفیل برگ به‌وسیله استخراج آلیشی و آنالیز اسپکتروفتومتری<sup>۱</sup> اندازه‌گیری می‌شود. لازم به ذکر است که این روش مخرب به‌عنوان معیار ارزیابی دقیق محتوای کلروفیل مورد استفاده می‌باشد. باین‌حال، این روش نسبتاً گران و وقت‌گیر است، همچنین نیاز به تجهیزات تخصصی دارد و نمونه‌ها پس از انجام آزمایشات از بین می‌روند. در مقابل، روش‌های غیرمخرب نیز وجود دارند که به‌صورت آسان و سریع انجام می‌شوند، اما از دقت بالایی همانند روش مخرب برخوردار نیستند (Ataeiyan et al., 2018)؛ به‌عنوان نمونه، اسپد یک دستگاه غیرمخرب رایج است که جهت اندازه‌گیری محتوای کلروفیل برگ کاربرد دارد. روش کار این دستگاه مبتنی بر اندازه‌گیری پرتوهای قرمز (۶۵۰ نانومتر) و مادون قرمز (۹۴۰ نانومتر) ساطع‌شده از برگ است (Minolta, 1989)؛ اما از معایب این روش می‌توان به‌دقت بسیار پایین آن اشاره نمود. بنابراین برای اجتناب از پیچیدگی‌های روش‌های مخرب و همچنین جبران هزینه‌های مربوط به دستگاه اسپد، روش غیرمخرب دیگری مانند روش پردازش تصویر جهت اندازه‌گیری محتوای کلروفیل پیشنهاد شد که با سرعت بالایی قابل انجام است. در دو دهه گذشته، بسیاری از تکنیک‌های پردازش تصویر برای نظارت بر سلامت گیاهان، به‌طور عمده با استفاده از فضای رنگی RGB به‌کار گرفته شدند (Nadafzadeh and Abdanan Mehdizadeh, 2017). تقریباً در تمام مطالعات از دوربین‌های دیجیتالی برای به‌دست آوردن تصاویر برگ استفاده شده است و سپس رابطه بین مقادیر R, G و B استخراج‌شده از تصاویر و محتوای کلروفیل و نیتروژن اندازه‌گیری شده از گیاهان مورد بررسی قرار گرفتند (Mercado-Luna et al., 2010). این بدان معنی است که این روش از نظر اجرایی بسیار ساده و از لحاظ زمان و هزینه مقرون به‌صرفه‌تر می‌باشد و همچنین ارائه نتایج با استفاده از آن دقیق است. در پژوهشی کاواشیما و همکاران (۱۹۹۸) نشان دادند که  $(R - B)/(R + B)$  الگوریتم مناسبی برای تعیین وضعیت کلروفیل برگ در گندم می‌باشد (Kawashima et al., 1998). در مقابل، بر اساس نتایج پژوهش یوژو و همکاران (۲۰۱۱) مشاهده شد که الگوریتم  $G/(R + B + G)$  نتایج خوبی برای برآورد وضعیت نیتروژن در فلفل ارائه می‌دهد (Yuzhu et al., 2011). علاوه بر این، سوزوکی و همکاران (۱۹۹۹) نیز از الگوریتم  $G/(R + B + G)$  برای تخمین مقدار کلروفیل در بروکلی استفاده کردند (Suzuki et al., 1999). همچنین کای و همکاران (۲۰۰۶) دریافتند که به‌کارگیری الگوریتم  $R/(R + B + G)$  برای تعیین محتوای کلروفیل برگ دارای عملکرد مناسبی است (Cai et al., 2011).

2- Angle of incidence

3- Soft

4- Probability theory

5- Artificial neural networks

6- Expert systems

تجزیه و تحلیل تصویر برگ به‌عنوان یک روش سریع، ساده و کم هزینه برای برآورد محتوای کلروفیل و کارتنوئید موجود در برگ‌های گیاهان پیشنهاد شده است.

### مواد و روش‌ها

تمامی آزمایشات این پژوهش در آزمایشگاه تحقیقاتی دانشگاه کشاورزی و منابع طبیعی رامین خوزستان طی پاییز ۱۳۹۶ انجام پذیرفت.

### جمع‌آوری نمونه‌ها

در این تحقیق از هر ۶ نوع گیاه ختمی، لگوم، برگ بیدی، انجیر معابد، رز و کنار تعداد ۱۵ برگ به‌صورت تصادفی انتخاب شد (شکل ۱). در ادامه کار، اندازه‌گیری محتوای کلروفیل برگ گیاه به ۳ روش مختلف انجام پذیرفت: (۱) با استفاده از دستگاه اسپد، (۲) از طریق اخذ تصاویر نمونه‌ها به‌منظور توسعه سامانه بینایی ماشین (روش غیر مخرب) و (۳) به‌صورت آزمایشگاهی و با انجام یک روش مخرب.

### دستگاه اسپد

در این پژوهش، محتوای کلروفیل برگ گیاهان موردنظر توسط اسپد (Hansatech، مدل CL-01، ژاپن) اندازه‌گیری و ثبت شد (شکل ۲a). بدین منظور ابتدا دستگاه در ۵ نقطه مختلف از برگ قرار داده شد (شکل ۲b) و بعد از قرائت مقادیر اندازه‌گیری شده، مقدار میانگین کلروفیل‌های به‌دست‌آمده به‌عنوان نماینده محتوای کلروفیل برگ در نظر گرفته شد.

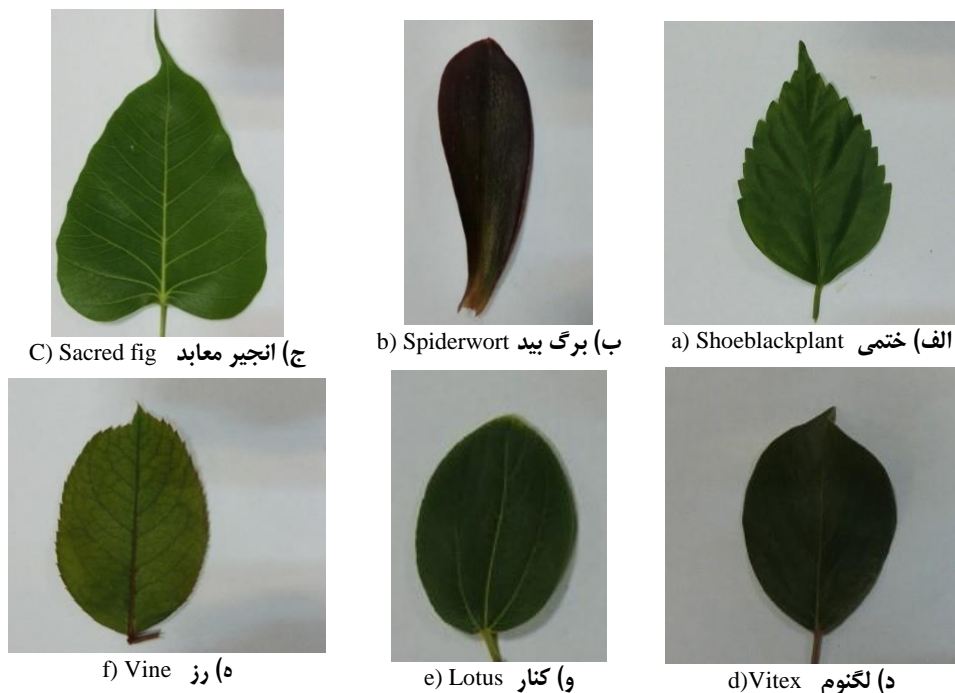
### اخذ تصویر

عملیات تصویربرداری درون جعبه‌ای که با کاغذ مقوایی سفیدرنگ پوشش یافته و دارای ابعاد طول، عرض و ارتفاعی برابر ۲۵ سانتی‌متر بود، انجام پذیرفت. برای نورپردازی فضا از دو نوع لامپ هالوژن ۵۰W استفاده شد. زاویه تابش نور با سطح افقی تصویر جهت هم‌پوشانی سایه‌ها، ۴۵ درجه در نظر گرفته شد (شکل ۳). به‌منظور اخذ تصاویر، دوربین به فاصله‌ی ثابت از سطح برگ و به‌صورت عمود (۲۵ سانتی‌متری) بر سطح افقی در مکانی بالاتر از برگ‌ها نصب شد. در این مطالعه به‌منظور تخمین کلروفیل از طریق روش پردازش تصویر، عکس‌برداری با استفاده از یک دوربین دیجیتال CASIO (مدل Exilim EX-ZR700، ۱۶ مگاپیکسل، ساخت کشور ژاپن) صورت گرفت و در ادامه پس از انتقال تصاویر به رایانه عملیات پردازش تصویر توسط نرم‌افزار Matlab ۲۰۱۶a انجام پذیرفت. لازم به ذکر است که دوربین تمامی تصاویر را در فضای رنگی RGB ثبت نمود.

کرد. در مقابل، هنگامی که متغیرهای هدف، پیوسته هستند، به‌عنوان رگرسیون درخت تصمیم‌گیری شناخته می‌شود. در یک درخت تصمیم‌گیری، ویژگی‌هایی که حداکثر اطلاعات را حمل می‌کنند به‌صورت خودکار برای طبقه‌بندی انتخاب می‌شوند و ویژگی‌های باقی‌مانده به‌منظور ساده‌سازی محاسباتی حذف می‌گردند. بنابراین، انتخاب و طبقه‌بندی ویژگی به‌صورت هم‌زمان انجام می‌شود.

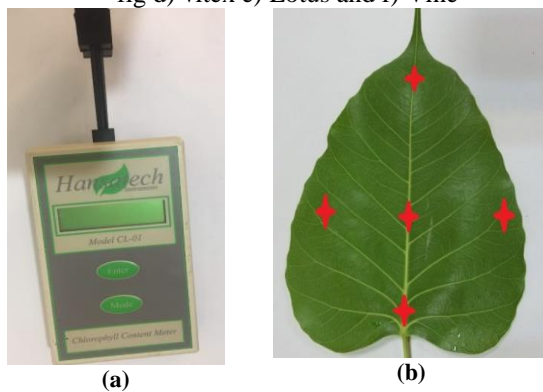
در سال‌های اخیر، تحقیق و برنامه‌های کاربردی با استفاده از تکنولوژی طبقه‌بندی و درخت رگرسیون (CART<sup>1</sup>) افزایش یافته است و نتایج خوبی در پردازش تصویر یا تجزیه و تحلیل داشته است (Lawrence et al., 2001; Maniezzo et al., 1993; Wylie et al., 2000; Yang et al., 2003).

در پژوهشی ندادفزاده و آبدانان مهدی‌زاده (۲۰۱۷) مجموعه‌ای از تصاویر گیاه زینتی حُسن‌یوسف در دو وضعیت (شاداب و پژمرده) با هدف تشخیص نیاز آبی گیاه مورد بررسی قرار دادند؛ فضاهای رنگی مورد بررسی شامل RGB، XYZ، Lab، UVL، HLS، YUV، YCbCr و TSL می‌شدند. بر اساس نتایج دقت کلی طبقه‌بند نیز ۸۳/۱۱ درصد گزارش گردید (Nadafzadeh and Abdanan Mehdizadeh, 2017). در پژوهشی دیگر سیستمی به‌منظور تشخیص کمبود کلسیم در کاهو با استفاده از رنگ و دیگر ویژگی‌ها طراحی شد؛ در این سیستم از فضاهای رنگی RGB و HSL استفاده گردید (Story et al., 2010). طبق تحقیقات یاداو و همکاران (۲۰۱۰) نشان داده شد که برآورد به‌موقع و هم‌زمان محتوای کلروفیل برگ گیاهان موجود در یک ردیف کشت با دستگاه کلروفیل‌متر ممکن نیست؛ همچنین این پژوهشگران نشان دادند که تجزیه و تحلیل تصویر مبتنی بر فضای رنگی RGB به‌تنهایی توانایی برآورد کلروفیل در گیاهان را ندارد (Yadav et al., 2010). در همین راستا هدف از در مطالعه حاضر، توسعه یک سامانه بینایی ماشین بر اساس الگوریتم رگرسیون درخت تصمیم‌گیری به‌منظور پیش‌بینی محتویات کلروفیل برگ ۶ گیاه مختلف (ختمی، لگوم، برگ بیدی، انجیر معابد، رز و کنار) در نظر گرفته شد. این گیاهان به دلیل اینکه از لحاظ میزان کلروفیل، اندازه، ضخامت و لایه رویی با یکدیگر متفاوت و هر کدام از یک خانواده گیاهی جداگانه‌ای بودند، انتخاب شدند. در ادامه مطالعه، نتایج عملکرد این الگوریتم با مقادیر کلروفیل اندازه‌گیری شده توسط دستگاه طیف‌سنج و اسپد مورد مقایسه قرار گرفت. شایان ذکر است که امروزه رایج‌ترین روشی که برای اندازه‌گیری کلروفیل به‌کار می‌رود استفاده از دستگاه اسپد (کلروفیل‌سنج) است که این راهکار علاوه بر عدم برخورداری از دقت بالا، نیاز به صرف وقت و نیروی انسانی زیادی دارد. این در حالی است که در این پژوهش، اندازه‌گیری کلروفیل و کارتنوئید با استفاده از




شکل ۱- نمونه‌ای از برگ گیاهان مختلف مورد بررسی در این پژوهش (a ختمی، b برگ بیدی، c انجیر معابد، d لگنوم، e کنار و f رز به‌منظور تعیین محتوای کلروفیل برگ گیاه

Fig. 1. An example of the leaf of different plants examined in this research a) Shoebblackplant b) Spiderwort c) Sacred fig d) vitex e) Lotus and f) Vine



شکل ۲- a) دستگاه اسپد و b) نقاط انتخابی جهت قرارگیری اسپد بر روی نمونه‌ها  
Fig. 2. a) SPAD Instrument and b) Selected points for SPAD on samples



شکل ۳- شماتیکی از فضای تصویربرداری  
Fig. 3. A schematic diagram of imaging chamber

فاکتورهای این تبدیل خطی، عبارتند از خصوصیات ویژه کواریانس که از توزیع مقادیر خاکستری R، G و B یک تصویر به دست می‌آید.

### الگوریتم درخت تصمیم‌گیری جهت طبقه‌بندی نرم

مرحله نهایی این بخش از پژوهش شامل بررسی تصویر در فضاهای رنگی مختلف و تفسیر داده‌ها جهت به‌کارگیری در الگوریتم پیشنهادی درخت تصمیم‌گیری است. در این پژوهش از رگرسیون درخت تصمیم‌گیری برای تقریب کلروفیل و کارتنوئید استفاده شد. ساختار این رگرسیون بر اساس طبقه‌بند بازگشت دودویی است که یک فرآیند تکراری است؛ به منظور توسعه رگرسیون درخت تصمیم‌گیری ابتدا ۷۰ درصد داده‌ها (نمونه‌های آموزشی) برای تعیین ساختار درخت مورد استفاده قرار گرفتند. سپس فرآیند تقسیم‌بندی برای هریک از شاخه‌های جدید اعمال می‌شود. این روند تا زمانی ادامه دارد که گره به اندازه حداقل گره مشخص شده توسط کاربر تعیین شود و به یک گره ترمینال تبدیل گردد. از آنجاکه درخت از نمونه‌های آموزشی ساخته شده است، ممکن است زمانی که ساختار کاملی وجود دارد، دقت رگرسیون کاهش یابد. این مسئله سبب می‌شود که درخت در هنگام استفاده از داده‌های مشاهده نشده (نمونه‌ها آزمون) قابلیت تمیم کمتری داشته باشد. بنابراین، برای حل این موضوع یک روند هرس‌مانند با استفاده از یک مجموعه داده اعتبارسنجی صورت می‌پذیرد.

هرس کردن دو هدف کلی دارد: (۱) به حداقل رساندن مجموع واریانس متغیر خروجی در داده‌های اعتبارسنجی و (۲) کاهش تعداد گره‌های ترمینال و هزینه پیچیدگی در هر گره. در روند هرس، اولین بار، نخستین گره رشد یافته، حذف می‌شود و به همین ترتیب این روند ادامه پیدا می‌کند. برای انجام طبقه‌بندی نرم، یک درخت رگرسیون برای هر یک کلاس ساخته می‌شود. مقدار شدت کانال‌های رنگی در فضاهای مختلف تبدیل به متغیرهای پیش‌بینی شده و بردار ویژگی را می‌سازد. میزان کلروفیل و کارتنوئید در اینجا به‌عنوان داده‌های مرجع و هدف یا بردار هدف هر درخت رگرسیون استفاده می‌شوند. در این پژوهش، پیاده‌سازی الگوریتم درخت تصمیم‌گیری جهت توسعه مدل در نرم‌افزار Matlab 2016 a انجام پذیرفت.

### اندازه‌گیری محتوای کلروفیل و کارتنوئید با استفاده از روش مخرب

در ادامه مطالعه پس از انجام عملیات تصویربرداری، میزان کلروفیل و کارتنوئید در برگ براساس روش پیشنهادی Moran (1984) تعیین شد. ۰/۱ گرم از نمونه برگ به قطعات کوچک ۳-۲ میلی‌متری مربعی تقسیم گردیده و رگبرگ اصلی حذف شد. قطعات

### پردازش تصویر

در این بخش از مطالعه، ابتدا تصاویر اخذ شده با انجام عملیات پیش‌پردازش از نظر رنگ و لبه به‌ترتیب با روش‌های یکنواخت‌سازی هیستوگرام و لاپلاس منفی<sup>۱</sup> بهبود یافتند. در بخش پیش‌پردازش تصویر، نویز زمینه حاصل از شرایط نورپردازی با روش باز کردن ناحیه<sup>۲</sup> حذف گردیدند (Gonzalez et al., 2004). در ادامه با اجرای فرآیند قطعه‌بندی و انجام عملیات آستانه‌گذاری تطبیقی اتسو منطقه‌ای گیاه استخراج گردید. در نهایت تصاویر به فضاهای رنگی مختلف (RGB، Lab، HSV و I1I2I3) جهت دستیابی به پارامترهای رنگی انتقال یافت. بدین ترتیب برای هر مجموعه از نمونه‌ها متوسط پارامترهای رنگی موردنظر محاسبه گردید.

### فضای رنگی HSV و Lab

فضای رنگی HSV شامل اجزای رنگ، اشباع، مقدار (روشنایی) است. در فضای رنگی Lab، L نشان‌دهنده عامل روشنایی و (a) و (b) به‌ترتیب، توصیف‌گر رنگ از سبز به قرمز و از آبی به زرد هستند. ماتریس‌های تبدیل و جزئیات بیشتر در مورد این فضاهای رنگی توسط گارسیا متیوسا و همکاران (Garcia-Mateos et al., 2015) استفاده شده است. لازم به ذکر است که علاوه بر ۱۲ مختصه رنگی مربوط به ۴ فضای رنگی پیشنهادی، دو پارامتر رنگی C و h نیز از فضای RGB با استفاده از روابط (۱) و (۲) محاسبه شدند. در روابط مذکور منظور از C همان کروما است که نشان از طراوت گیاه دارد و از طریق مجذور مربعات مختصات رنگی a و b حاصل شده است. مولفه رنگی h نیز بیانگر زاویه شیب نمودار دستگاه مختصات دویعدی a و b در فضای رنگی Lab است (Nadafzadeh and Abdanan, 2017).

$$c = \sqrt{a^2 + b^2} \quad (1)$$

$$h = \text{atan}\left(\frac{b}{a}\right) \quad (2)$$

که در این روابط a بیانگر رنگ از سبز به قرمز و b بیانگر رنگ از آبی به زرد می‌باشد.

### فضای رنگی I1I2I3

فضای رنگی I1I2I3 را می‌توان از فضای رنگ RGB با استفاده از رابطه (۳) محاسبه کرد (Zhao et al., 2016):

$$\begin{pmatrix} I1 \\ I2 \\ I3 \end{pmatrix} = \begin{pmatrix} 0.333 & 0.333 & 0.333 \\ 0.5 & 0.0 & -0.5 \\ -0.25 & 0.5 & -0.25 \end{pmatrix} * \begin{pmatrix} R \\ G \\ B \end{pmatrix} \quad (3)$$

قرار داده شدند و با سرعت ۸۰۰۰ دور در دقیقه و به مدت ۱۰ دقیقه سانتریفیوژ شدند. جذب محلول توسط دستگاه طیف‌سنج نوری که با استون ۸۰٪ تنظیم شده بود و در طول موج‌های ۴۷۰، ۶۶۳ و ۶۴۵ نانومتر اندازه‌گیری شد و از روابط (۴)، (۵)، (۶) و (۷) برای محاسبه مقدار کلروفیل کل و کارتنوئید استفاده گردید.

$$chl\ a\ (mg/gr) = \{0.0127(A663) - 0.00269(A645)\} \times 100/w \quad (4)$$

$$chl\ b\ (mg/gr) = \{0.0229(A645) - 0.00468(A663)\} \times 100/w \quad (5)$$

$$Total = chl\ a + chl\ b \quad (6)$$

$$carotenoids = 1000(A470) - 2.270\ chl\ a - 81.4\ chl\ b/227 \quad (7)$$

جداسازی جهت مشاهده تغییرات وضعیت کلروفیل گیاه برای همه تصاویر نمونه‌ها تکرار گردید. سپس تصاویر به دست آمده به منظور بررسی و انتخاب پارامترهای رنگی مناسب مورد ارزیابی قرار گرفتند.

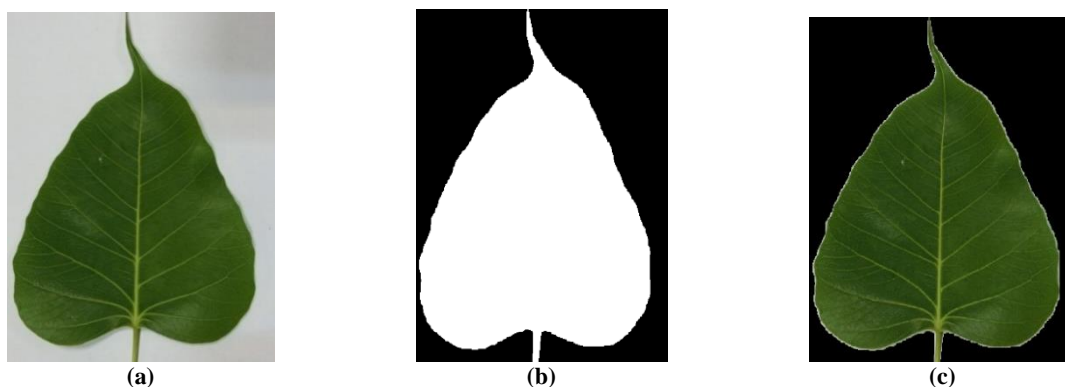
بعد از قطعه‌بندی تصویر، پوشش سبز استخراج شده از تصویر برگ به سه فضای رنگی Lab، hsv و HII2I3 منتقل گردید. شکل ۵ نمونه‌ای از این تبدیل را نشان می‌دهد.

برگ در ۱۰ میلی‌لیتر استون ۸۰٪ قرار داده و پس از بستن در ظرف با پارافیلیم و پوشانیدن ظرف با ورقه آلومینیم، ظرف حاوی نمونه در تاریکی و در دمای ۴ درجه قرار داده شد تا کلروفیل برگ خارج گردد و بافت سفید گردد (در فواصل زمانی مختلف تکان دادن ظرف حاوی نمونه انجام شد). نمونه‌های هم وزن در دستگاه سانتریفیوژ مقابل هم

در این روابط w وزن تر بافت نمونه (بر حسب میلی‌گرم)، A663 میزان جذب در طول موج ۶۶۳ نانومتر (کلروفیل a)، A645 میزان جذب در طول موج ۶۴۵ نانومتر (کلروفیل b)، A470 میزان جذب در طول موج ۴۷۰ نانومتر (کارتنوئیدها) هستند.

## نتایج و بحث


در این پژوهش ابتدا تصاویر اخذ شده از برگ‌های گیاهان با انجام عملیات آستانه‌گذاری دودویی گردیدند (شکل ۴b)، سپس با ضرب نمودن تصویر دودویی به دست آمده در تصویر اصلی، پوشش گیاه از پس‌زمینه جدا شد (شکل ۴c). لازم به ذکر است که این عملیات



شکل ۴- (a) تصویر اخذ شده توسط دوربین، (b) تصویر باینری برگ مورد آزمایش و (c) استخراج منطقه مورد نظر از تصویر

**Fig. 4.** (a) Image captured by the camera, (b) Binary image of the tested leaf and (c) Extract the desired area of the image





شکل ۵- (a) فضای رنگی RGB، (b) فضای رنگی Lab، (c) فضای رنگی hsv و (d) فضای رنگی I1I2I3  
**Fig.5.** (a) RGB color space, (b) Lab color space, (c) hsv color space and (d) I1I2I3 color space

مختلف مورد بررسی قرار گرفتند، مشاهده شد که از میان پارامترهای رنگی استخراج شده از تصاویر گیاهان، پارامترهای  $L$ ،  $a$ ،  $b$  و  $c$  و  $f$  مناسب هستند (Nadafzadeh and Abdanan Mehdizadeh, 2017). به دلیل همسو بودن این تحقیق و مطالعه حاضر در انتخاب پارامترهای  $a$  و  $c$  به عنوان ویژگی‌های مناسب، می‌توان گفت که این دو پارامتر رنگی از جمله مؤلفه‌های مؤثری هستند که بیانگر تغییرات کلروفیل گیاه (منشأ رنگ سبز) می‌باشند.

#### نتایج الگوریتم درخت تصمیم‌گیری

به منظور شکل‌گیری درخت تصمیم‌گیری، بهترین درخت از لحاظ ساختار موردنظر می‌باشد. بدین منظور درخت تصمیم‌گیری با هدف یافتن حداقل تعداد برگ (حداقل ۵، ۱۰، ۲۰، ۵۰ و ۱۰۰ برگ) ۵۰ بار تکرار اجرا شد، به گونه‌ای که کمترین مقدار خطا حاصل شود. بدین ترتیب حداقل تعداد برگ مورد نیاز جهت دستیابی به کمترین خطای رگرسیون برای پارامتر کلروفیل در تکرار ۵ با حداقل مقدار خطا  $(RSME) ۵/۰۷$  و برای پارامتر کارتنوئید در تکرار ۱۰ با حداقل مقدار خطا  $۱۰/۰۰$  به دست آمد (شکل ۶).

#### انتخاب مناسب‌ترین ویژگی‌ها براساس نتایج آنالیز همبستگی میان داده‌ها

انتخاب ویژگی با حذف اطلاعات زائد، سرعت سامانه کنترل هوشمند و دقت آن را افزایش می‌دهد. در این مطالعه برای تعیین تأثیرگذاری پارامترهای استخراج شده از تصویر برگ گیاهان روی محتوای کلروفیل و کارتنوئید آن‌ها، آنالیز همبستگی پیرسون میان پارامترهای کلروفیل و کارتنوئید اندازه‌گیری شده به روش مخرب و مقادیر کلروفیل به دست آمده توسط دستگاه اسپد و همچنین ویژگی‌های استخراج شده از تصویر صورت گرفت (جدول ۱). همان‌طور که در جدول ۱ مشاهده می‌شود، از میان تمام پارامترهای غیرمخرب، تنها پارامتر  $a$  با محتوای کلروفیل اندازه‌گیری شده (با استفاده از روش مخرب) و همچنین پارامترهای رنگی  $R$ ،  $a$  و  $c$  با محتوای کارتنوئید گیاه دارای ارتباط معنی‌داری در سطح احتمال ۵٪ هستند. بدین ترتیب این پارامترهای رنگی ( $R$ ،  $a$  و  $c$ ) به عنوان مناسب‌ترین ویژگی‌ها جهت به کارگیری در الگوریتم رگرسیون درخت تصمیم‌گیری به منظور پیش‌بینی مقدار کلروفیل و کارتنوئید موجود در گیاه انتخاب شدند. در مطالعه‌ای دیگر که به منظور تشخیص وضعیت گیاه حسن‌یوسف (حالت شادابی و یا پژمردگی) ۱۱ فضای رنگی


جدول ۱- همبستگی میان پارامترهای مخرب و غیرمخرب و مقدار کلروفیل اندازه‌گیری شده توسط دستگاه اسپد

Table 1- The correlation between destructive and non-destructive parameters and the amount of chlorophyll measured by the SPAD device

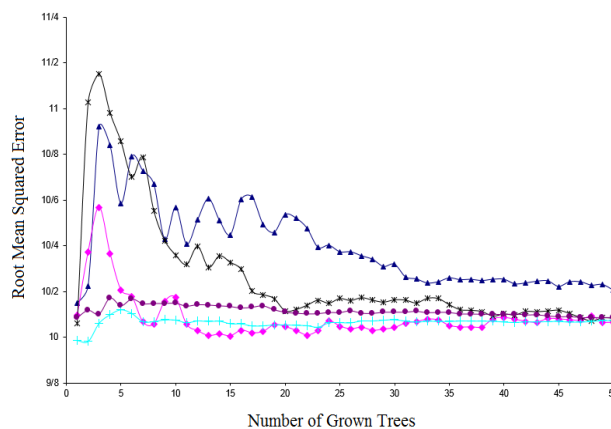
	R	G	B	L	a	b	h	s	v	c	H	I1	I2	I3	اسپد	کلروفیل	کارتنوئید
R	1																
G	.71*	1															
B	.67*	.54*	1														
L	.84*	.90*	.77*	1													
a	.28	-.39*	0.08	-.17	1												
b	.66*	.54*	.99*	.77*	.06	1											
h	.00	.36	-.19	-.29	.70*	-.23	1										
s	.21	.25	.24	.20	.00	.25	.11	1									
v	.65*	.53*	.98*	.76*	.06	.99*	-.22	.26	1								
c	.70*	.38	.95*	.66*	.35	.95*	.00	.24	.94*	1							
H	.59*	.63*	.96*	.81*	-.18	.96*	-.40*	.24	.96*	.85*	1						
I1	-.83*	-.77*	-.94*	-.93*	.00	-.93*	.22	-.26	-.93*	-.87*	-.92*	1					
I2	.48*	.41*	.96*	.63*	.02	.95*	-.21	.24	.93*	.90*	.92*	-.83*	1				
I3	.52*	.18	.90*	.48*	.36	.89*	.00	.20	.88*	.95*	.78*	-.74*	.92*	1			
اسپد	-.47*	-.22	-.37	-.31	-.36	-.36	-.20	-.36	-.35	-.45	-.26	.38	-.32	-.41*	1		
کلروفیل	-.38	-.08	-.28	-.19	-.40*	-.27	-.25	.26	-.26	-.38	-.16	.26	-.24	-.36	.93*	1	
کارتنوئید	-.41*	-.10	-.30	-.22	-.42*	.29	-.26	-.29	-.28	-.40*	-.18	.29	-.25	-.38	.94*	.99*	1

\*: نشان‌دهنده‌ی معنی‌داری در سطح احتمال ۵٪

\*: Significantly at a 5% probability level



(a)



(b)

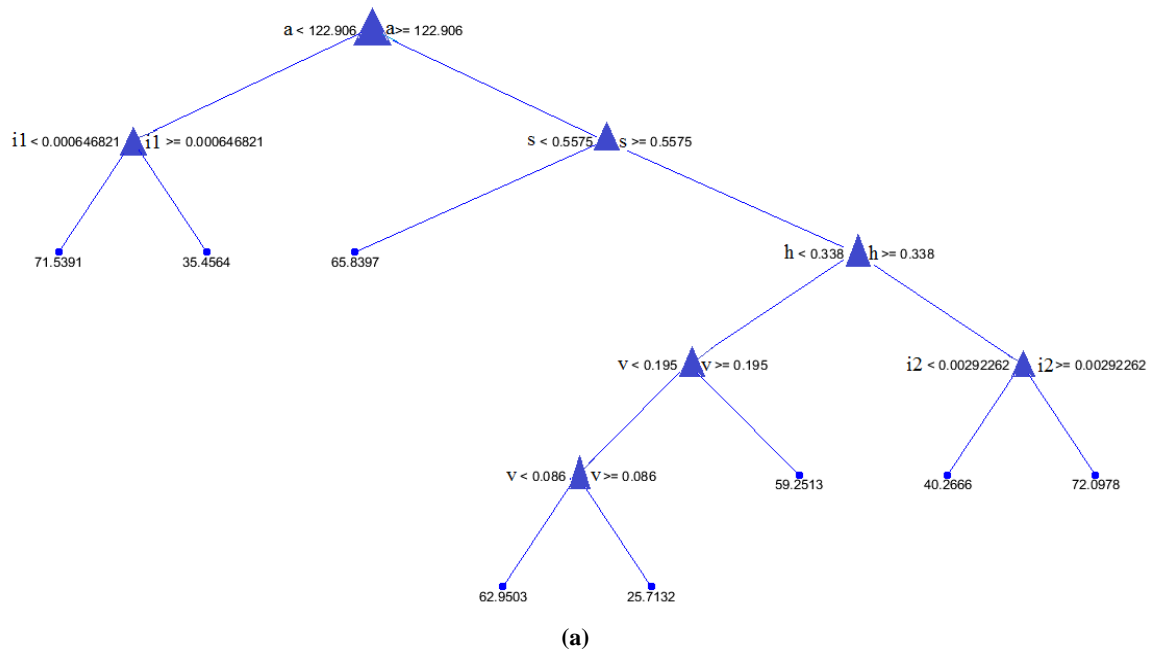
شکل ۶- حداقل تعداد برگ مورد نیاز جهت دستیابی به کمترین خطای رگرسیون: (a) برای پارامتر کلروفیل و (b) برای پارامتر کارتنوئید

Fig. 6. Minimum number of leaves needed to achieve the lowest regression error: (a) for the chlorophyll parameter and (b) for the carotenoid parameter

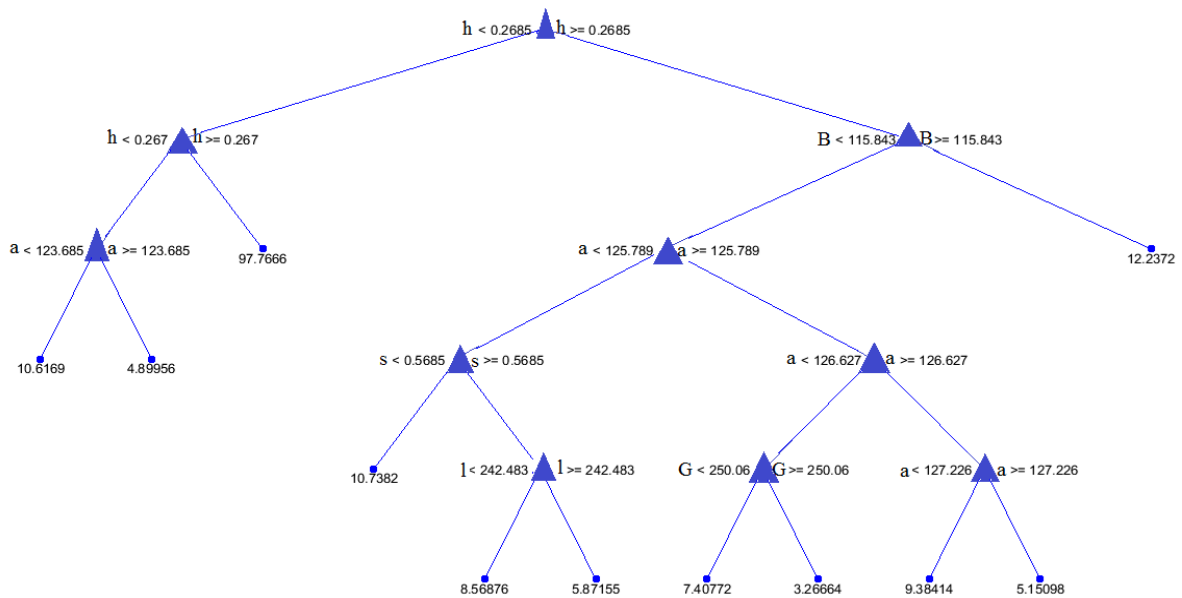
تصمیم‌گیری برای این پارامترها (کلروفیل و کارتنوئید) در شکل ۷ نشان داده شده است.

بعد از تعیین حداقل تعداد برگ در هر مدل رگرسیونی مدل‌های به منظور پیش‌بینی کلروفیل و کارتنوئید توسعه یافت که ساختار درخت





(a)



(b)

شکل ۷- نمودار درخت تصمیم‌گیری: (a) درخت تصمیم‌گیری برای پارامتر کلروفیل و (b) درخت تصمیم‌گیری برای کارتنوئید

Fig. 7. A decision tree: (a) Decision tree for the chlorophyll parameter and (b) Decision tree for Carotenoid

نشان داد که فاکتور رنگی G-B با معیار عملکرد ۵/۸۶ برای جداسازی برگ سبز از پس‌زمینه آبی و G/R با معیار عملکرد ۵/۱ برای جداسازی برگ قرمز مناسب هستند. در پژوهشی دیگر استوری و همکاران (۲۰۱۰) سیستمی را برای تشخیص کمبود کلسیم در محصولات زراعی کاهو با استفاده از رنگ و دیگر ویژگی‌ها طراحی نمودند، در این سیستم از فضاهای رنگی RGB و HSL استفاده شد و مشخص گردید که مناسب‌ترین کانال رنگی به منظور تشخیص کمبود کلسیم G و H


پس از آموزش درخت تصمیم‌گیری مشخص گردید که پارامترهای  $h$ ،  $B$ ،  $a$ ،  $s$  و  $l$  برای کارتنوئید و ویژگی‌های  $a$ ،  $s$ ،  $h$ ،  $v$ ،  $I_1$  و  $I_2$  برای کلروفیل وارد مدل گردیدند. لازم به ذکر است که این پارامترها، با توجه به آنالیز آماری صورت گرفته پارامترهای معنی‌داری هستند (جدول ۱). گلزاریان و همکاران (۲۰۱۴) تعدادی از تبدیلات خطی فضای رنگی RGB را برای جداسازی منطقه‌ی برگ از پس‌زمینه بررسی نمودند (Golzarian1 et al., 2014). نتایج آن‌ها

اندازه‌گیری شده توسط دستگاه اسپد و مقادیر واقعی آن‌ها (با استفاده از روش مخرب) به ترتیب برابر ۰/۲۴ و ۱۹/۴۴ به دست آمد (شکل ۸a) و میزان همبستگی و خطای حاصل از روش پردازش تصویر (روش غیرمخرب) در مقایسه با مقدار واقعی کلروفیل به ترتیب ۰/۹۲ و ۵/۸۸ بود (شکل ۸b). در نتیجه می‌توان گفت که عملکرد رگرسیون درخت تصمیم‌گیری و پردازش تصویر در پیش‌بینی میزان کلروفیل نسبت به میزان کلروفیل پیش‌بینی شده توسط دستگاه اسپد از دقت بالاتری برخوردار می‌باشد. گیتلسون و همکاران (۲۰۰۳) در پژوهشی به بررسی پاسخ طیفی رابطه بین بازتاب و محتوای کلروفیل در برگ‌های درختان افرا، شاه بلوط، برگ وحشی و برگ راش پرداختند (Gitelson *et al.*, 2003). نتایج نشان داد که میانگین خطای مربع پیش‌بینی کلروفیل در محدوده طیفی ۵۲۰ تا ۵۵۰ نانومتر و ۶۹۵ تا ۷۰۵ نانومتر بیش از ۵۰ میکرومول بر متر مربع در برگ نشد. در همین راستا وو و همکاران (۲۰۰۸) نیز جهت برآورد محتوای کلروفیل دوربین‌های فراطیفی را مورد بررسی و مطالعه قرار دادند (Wu *et al.*, 2008). در این روش توانستند محتوای کلروفیل را با ضریب همبستگی  $R^2 = 0.88$  پیش‌بینی کنند که در مقایسه با نتایج حاصل از این پژوهش می‌توان نتیجه گرفت که روش پیشنهادی در این پژوهش از دقت بالاتری جهت تعیین محتوای کلروفیل برخوردار است.

بودند (Story *et al.*, 2010). استراند و بارولد (۲۰۰۲) نیز با به‌کارگیری فضای رنگ RGB نرمال شده در جهت کنترل علف‌های هرز اقدام نمودند (Astrand and Baerveldt, 2002). این محققین دریافتند که اندازه‌گیری مقدار رنگ سبز (g)، در تشخیص محصول از گیاهان علف هرز، با دقت ۹۱٪ بسیار مؤثر است. کارسیا-ماتوس و همکارانش (۲۰۱۵) نیز به منظور بهبود مدیریت آبیاری گیاه کاهو با استفاده از تکنیک پردازش تصاویر دیجیتال، فضاهای رنگ مختلفی را مورد مطالعه و بررسی قرار دادند. از میان فضاهای رنگی پیشنهاد شده در این تحقیق، فضای رنگی Lab با دقت کلی ۹۹/۲٪ طبقه‌بند، به‌عنوان مطلوب‌ترین فضای رنگی انتخاب شد (Garcia-Mateos *et al.*, 2015). از مقایسه نتایج مطالعات انجام شده می‌توان دریافت که فضای Lab به‌عنوان یکی از پرکاربردترین فضاهای رنگی در بررسی‌های مربوط به ویژگی‌های رنگی گیاه شناخته شده است که برای دستیابی به نتایجی دقیق‌تر نسبت به سایر فضاهای رنگی دیگر از کارایی بالایی برخوردار است.

#### مدل رگرسیونی حاصل از درخت تصمیم‌گیری

به‌منظور آموزش این مدل رگرسیونی از ۷۰٪ داده‌ها و برای آزمون از ۳۰٪ آن‌ها استفاده گردید. در این پژوهش مطابق با نتایج حاصل از درخت تصمیم‌گیری میزان همبستگی و خطا میان مقادیر کلروفیل



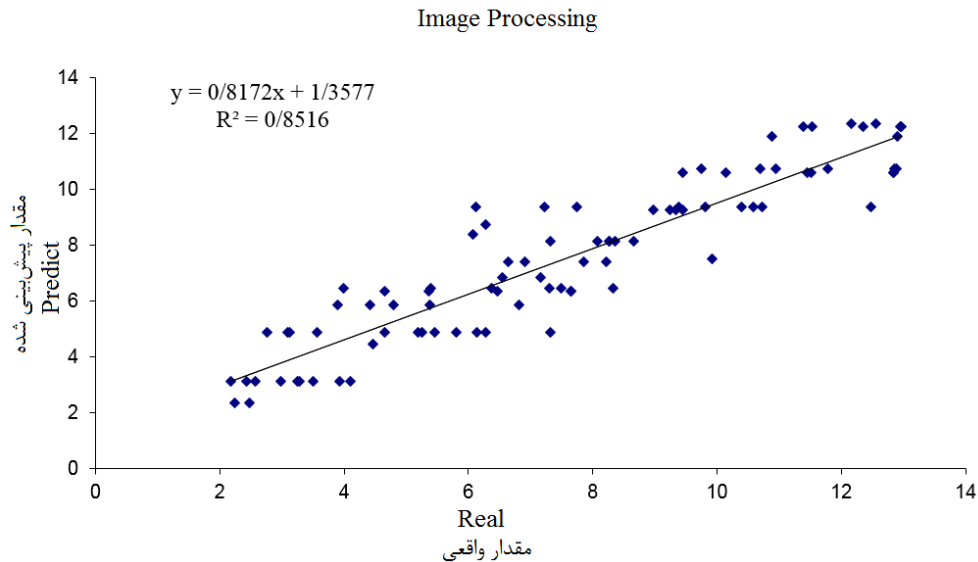
شکل ۸- (a) نمودار مقایسه کلروفیل حاصل از روش اسپد و مقدار واقعی و (b) نمودار مقایسه کلروفیل حاصل از روش پردازش تصویر و مقدار واقعی

**Fig. 8.** (a) Plot of actual value of Chlorophyll vs SPAD method and (b) actual value of Chlorophyll vs image processing method

خطا اندک (۸/۰۲) دارای عملکرد قابل قبولی است. در پژوهشی گیتلسون و همکاران (۲۰۰۶) یک مدل مفهومی سه‌بعدی با استفاده از اندازه‌گیری‌های بازتابی برای ارزیابی کلروفیل، کارتونوئیدها و آنتوسیانین در بسیاری از گونه‌های درختان توسعه دادند (Gitelson *et al.*, 2006). در همین راستا مشخص گردید که مدل توسعه‌یافته

نتایج حاصل از اندازه‌گیری کارتونوئید با استفاده از روش پردازش تصویر در مقایسه با مقدار واقعی آن نیز در شکل ۹ نمایش داده شده است. با توجه به شکل ۹ می‌توان گفت که الگوریتم رگرسیون درخت پشیتیان به دلیل برخورداری از ضریب همبستگی بالا (۰/۸۵) میان مقادیر واقعی و مقادیر پیش‌بینی شده‌ی کارتونوئید و همچنین کمترین

امکان برآورد دقیق کلروفیل، کارتنوئید و آنتوسیانین را از تغییرات رنگدانه به‌ترتیب با ضریب همبستگی بیش از ۹۱٪، ۷۰٪ و ۹۳٪ را داشت.



شکل ۹- نمودار مقایسه کارتنوئید حاصل از روش پردازش تصویر و مقدار واقعی

Fig. 9. Comparison of predicted values vs real values by image processing method

### نتیجه‌گیری

گرفتن نتایج حاصل از آنالیز همبستگی میان مقادیر کلروفیل و کارتنوئید گیاه و ویژگی‌های استخراج شده از تصویر، مناسب‌ترین ویژگی‌ها برای استفاده در الگوریتم رگرسیون درخت تصمیم‌گیری انتخاب گردید. در نهایت نتیجه گرفته شد که پردازش تصویر محتوای کلروفیل و کارتنوئید گیاهان را به‌ترتیب با ضریب همبستگی ۰/۹۲ و ۰/۸۵ پیش‌بینی می‌کند. در نتیجه روش پیشنهاد شده یک روش مطلوب و قابل قبول برای اندازه‌گیری محتوای کلروفیل و کارتنوئید برگ گیاه است.

محتوای کلروفیل برگ یک شاخص مستقیم از وضعیت نیتروژن و سرعت رشد گیاه است. در این پژوهش، اندازه‌گیری کلروفیل با استفاده از تجزیه و تحلیل تصویر برگ به‌عنوان یک روش سریع، ساده و کم‌هزینه برای برآورد محتوای کلروفیل موجود در برگ‌های گیاهان مختلف (ختمی، لگنوم، برگ بیدی، انجیر معابد، رز و کنار) مورد مطالعه قرار گرفت. به‌منظور تشخیص کلروفیل و کارتنوئید، تصاویر گیاهان با استفاده از تکنیک پردازش تصویر بررسی شدند و پس از آن با توجه به نتایج آنالیز آماری در سطح احتمال ۵٪ و همچنین با در نظر

### References

1. Astrand, B., and A. J. Baerveldt. 2002. An agricultural mobile robot with vision-based perception for mechanical weed control, *Autonomous Robots* 13: 21-35.
2. Ataieyan, P., P. Ahmadi Moghaddam, and E. Sepehr. 2018. Estimation of Soil Organic Carbon using Artificial Neural Network and Multiple Linear Regression Models based on Color Image Processing. *Journal of Agricultural Machinery* 8(1): 137-148. (In Farsi).
3. Cai, H., C. Haixin, S. Weitang, and G. Lihong. 2006. Preliminary study on photosynthetic pigment content and colour feature of cucumber initial blooms, *Transactions of the CSAE* 22: 34-38.
4. De'ath, G., and K. E. Fabricius. 2000. Classification and regression trees: a powerful yet simple technique for ecological data analysis. *Ecology* 81: 3178-3198.
5. Dey, A. K., M. Sharma, and M. R. Meshram. 2016. An Analysis of Leaf Chlorophyll Measurement Method Using Chlorophyll Meter and Image Processing Technique, *Procedia Computer Science* 85: 286-292.
6. Foody, G. M., and M. K. Arora. 1996. Incorporating mixed pixel in the training, allocation and testing stages of supervised classification. *Pattern Recognition Letters* 17: 1389-1398.

7. Garcia-Mateos, G., J. L. Hernandez-Hernandez, D. Escarabajal-Henarejos, S. Jaen-Terrones, and J. M. Molina-Martinez. 2015. Study and comparison of color models for automatic image analysis in irrigation management applications, *Agricultural Water Management* 151: 158-166.
8. Ghosh, I., and R. K. Samanta. 2003. TEAPEST: An expert system for insect pest management in tea. *Applied Engineering in Agriculture* 19 (5): 619.
9. Gitelson, A. A., G. P. Keydan, and M. N. Merzlyak. 2006. Three-band model for noninvasive estimation of chlorophyll, carotenoids, and anthocyanin contents in higher plant leaves. *Geophysical Research Letters* 33 (11).
10. Gitelson, A. A., Y. Gritz, and M. N. Merzlyak. 2003. Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves, *Journal of Plant Physiology* 160 (3): 271-282.
11. Golzarian1, M. R., F. Sadeghi, N. Ghanei, and F. Kazemi. 2014. A qualitative and quantitative approach to assessing the performance of contrast enhancing colour indices used in automatic computer vision plant identification system. Conference: The 8<sup>th</sup> National Congress on Agr. Machinery (Biosystem) Engineering and Mechanization, At Mashad, Iran, pp. 1579-1592. (In Farsi).
12. Gonzalez, R. C., R. E. Woods, and S. L. Eddins. 2004. *Digital image processing using MATLAB*, Pearson Education India.
13. Herold, N. D., G. Koeln, and D. Cunnigham. 2003. Mapping impervious surfaces and forest canopy using classification and regress tree (CART) analysis. In the American Society for Photogrammetry and Remote Sensing (ASPRS) 2003 Annual Conference Proceedings, Anchorage, Alaska.
14. Jalili Marandi, R. 2012. *Post-harvest physiology (the displacement and maintenance offruits, vegetables, ornamental plants and medicinal plants)*. Urmia University Jihad Publications. P. 594. (In Farsi).
15. Kawashima, S., and M. Nakatani. 1998. An algorithm for estimating chlorophyll content in leaves using a video camera. *Annals of Botany* 81: 49-54.
16. Lawrence, L., and A. Wright. 2001. Rule-Based Classification Systems Using Classification and Regression Tree (CART) Analysis, *Photogrammetric Engineering and Remote Sensing* 67 (10): 1137-1142.
17. Maniezzo, V., R. Morpurgo, and S. Mussi. 1993. D-KAT: A Deep Knowledge Acquisition Tool. *Expert Systems* 10 (3):157-166.
18. Mercado-Luna, A., E. Rico-García, A. Lara-Herrera, G. Soto-Zarazúa, R. Ocampo-Velázquez, R. Guevara-González, R. Herrera-Ruiz, and I. Torres-Pacheco. 2010. Nitrogen determination on tomato (*Lycopersicon esculentum* Mill.) seedlings by colour image analysis (RGB). *African Journal of Biotechnology* 33: 5326-32.
19. Minolta, K. 1989. Chlorophyll meter SPAD-502 instruction manual, *Minolta Co., Ltd., Radiometric Instruments Operations Osaka, Japan*.
20. Moody, A., S. Gopal, and A. H. Strahler. 1996. Sensitivity of neural networks to subpixel land-cover mixtures in coarse-resolution satellite data, *Remote Sensing of Environment* 58: 329-343.
21. Moran, R. 1982. Formulae for determination of chlorophyllous pigments extracted with N, N-dimethylformamide, *Plant Physiology* 69 (6): 1376-1381.
22. Nadafzadeh, M., and S. Abdanan Mehdizadeh. 2017. Determination of the most suitable color space for intelligent water stress discrimination for plants inside the greenhouse (Case Study: Coleus), *Iranian Journal of Biosystem Engineering* 48 (4): pp.407-418. (In Farsi).
23. Nadafzadeh, M., S. Abdanan Mehdizadeh, M. A. Asoodar, and M. R. Salehi Salmi. 2017. Design and Development of an Intelligent Control System for Determination of Required Water needed by Plant in Greenhouse Using Machine Vision (Case Study: coleus), *Iranian Journal of Biosystem Engineering*, pp.285-297. (In Farsi).
24. Nematinia, E., S. Abdanan Mehdizade, and B. Nasehi. 2016. Measurement Spaghetti colors parameters using machine vision system. *Journal of Food Science and Technology*, pp. 71-81. (In Farsi).
25. Sabzi, S., Y. Abbaspour-Gilandeh, and H. Javadikia. 2018. Detection of Two Types of Weed through Machine Vision System: Improving Site-Specific Spraying. *Journal of Agricultural Machinery* 8(1): 15-29. (In Farsi).
26. Settle, J., and N. A. Drake. 1993. Linear mixing and the estimation of ground cover proportions. *International Journal of Remote Sensing* 14: 1159-1177.
27. Story, D., M. Kacira, C. Kubota, A. Akoglu, and L. An. 2010. Lettuce calcium deficiency detection with machine vision computed plant features in controlled environments. *Computers and Electronics in Agriculture* 74 (2): 238-243.
28. Su, C. H., C. C. Fu, Y. C. Chang, G. R. Nair, J. L. Ye, L. M. Chu, and W. T. Wu. 2008. Simultaneous estimation of chlorophyll a and lipid contents in microalgae by three colour analysis, *Biotechnology Bioeng* 99: 1034-1039.
29. Suzuki, T., H. Murase, and N. Honamin. 1999. Non-destructive growth measurement cabbage pug seedlings population by image information. *Journal of Agriculture Mechanical Association* 61: 45-51.
30. Vollmann, J., H. Walter, T. Sato, and P. Schweiger. 2011. Digital image analysis and chlorophyll metering for phenotyping the effects of nodulation in soybean, *Computers and Electronics in Agriculture* 75: 190-195.

31. Wu, C., Z. Niu, Q. Tang, and W. Huang. 2008. Estimating chlorophyll content from hyperspectral vegetation indices: Modeling and validation. *Agricultural and forest meteorology* 148 (8): 1230-1241.
32. Wylie, B. K., D. J. Meyer, M. J. Choate, L. Vierling, P. K. Kozak, and R. O. Green. 2000. Mapping Woody Vegetation and Eastern Red Cedar in the Nebraska Sand Hills using AVIRIS. In *AVIRIS Airborne Geoscience Workshop. JPL Publication 00-18. Pasadena, CA: Jet Propulsion Laboratory, California Institute of Technology.*
33. Xu, M., P. Watanachaturaporn, P. K. Varshney, and M. K. Arora. 2005. Decision tree regression for soft classification of remote sensing data. *Remote Sensing of Environment* 97 (3): 322-336.
34. Yadav, S. P., Y. Ibaraki, and S. D. Gupta. 2010. Estimation of the chlorophyll content of micro propagated potato plants using RGB based image analysis. *Plant Cell, Tissue and Organ Culture* 100: 183-188.
35. Yang, L., C. Huang, C. G. Homer, B. K. Wylie, and M. J. Coan. 2003. An approach for mapping large-area impervious surfaces: synergistic use of Landsat-7 ETM+ and high spatial resolution imagery, *Canadian Journal of Remote Sensing* 29 (2): 230-240.
36. Yuzhu, H., W. Xiaomeil, and S. Shuyao. 2011. Nitrogen determination in pepper (*Capsicum frutescens* L.) Plants by colour image analysis (RGB). *African Journal of Biotechnology* 77: 17737-17741.
37. Zhao, Y., L. Gong, B. Zhou, Y. Huang, and C. Liu. 2016. Detecting tomatoes in greenhouse scenes by combining AdaBoost classifier and colour analysis, *Biosystems Engineering* 148: 127-137.
38. Zring, A., T. Tounekti, A. Mohamed Vadel, H. Ben Mohamed, D. Valero, M. Serrano, C. Chatara, and H. Khemira. 2011. Possible involvement of polyphenols and polyamines in salt tolerance of almond rootstocks, *Plant Physiology and Biochemistry* 49: 1313-1322.

## Designing and Developing a Machine Vision System to Predict the Chlorophyll and Carotenoid Content of Plant Leaves

H. Biabi<sup>1</sup> - S. Abdanan Mehdizadeh<sup>2\*</sup> - M. Nadafzadeh<sup>3</sup> - M. Salehi Salmi<sup>4</sup>

Received: 17-03-2018

Accepted: 23-07-2018

### Introduction

Leaf color is usually used as a guide for assessments of nutrient status and plant health. Most of the existing methods that examined relationships between chlorophyll status and carotenoid of leaf color were developed for particular species. Different methods have been developed to measure chlorophyll status and carotenoid. However, the high cost and difficulty to use have restricted their application, whereas the handheld chlorophyll meters such as the SPAD has become popular in the last decade for non-destructive measurement of chlorophyll content. SPAD meter readings have found to be related to the plant's nutrition status, seed protein content, types of nodulation, and photosynthetic rates of leaves. Digital color (RGB) image analysis, another nondestructive technique is becoming increasingly popular with its potential in phenotyping various parameters of plant health status. The development of low-cost digital cameras that use charged-couple device (CCD) arrays to capture images offers an advantage of low-cost real-time monitoring process over optical sensor based SPAD meter. Gupta et al. (2012) estimated chlorophyll content, using simple leaf digital analysis procedure in parallel to a SPAD chlorophyll content meter. The chlorophyll content as determined by the SPAD meter was significantly correlated to the RGB values of leaf image analysis (RMSE = 3.97).

The aim of this research is developing a new inexpensive, hand-held and easy-to-use technique for detection of chlorophyll and carotenoid content in plants based on leaf color. This method provides rapid analysis and data storage at minimal cost and does not require any technical or laboratory skills.

### Materials and Methods

#### Sample collection

In this research, 15 leaves were randomly selected from six types of plants (Shoebblackplant, Vitex, Spiderwort, Sacred fig, Vine and Lotus). Afterwards, the chlorophyll content of the leaf was measured in 3 different ways: 1) using a SPAD instrument; 2) using machine vision system (non-destructive method), and 3) laboratory test using a spectrophotometer.

#### Chlorophyll and carotenoid content

The chlorophyll content of the leaf was measured and recorded using SPAD chlorophyll meter (Hansatech, model CL-01, Japan) and spectrometer as explained by Dey *et al.* (2016). Furthermore, to measure the carotenoid content method described by Gitelson *et al.* (2006) was utilized.

#### Image processing

For estimation of chlorophyll using the image processing algorithm, sample images were taken using CCD (CASIO, model Exilim EX-ZR700, Japan) and transferred to the computer. The camera was mounted perpendicular to the horizontal plane at a fixed distance of 25 cm from the samples. In a consequence histogram of leaf, images were equalized and the average of each color channels from RGB, Lab, HSV, and I1I2I3 were extracted using Matlab 2016.

1- Graduate Student of Mechanics of Biosystems Engineering Department, Faculty of Agricultural Engineering and Rural Development, Agricultural Sciences and Natural Resources University of Khuzestan, Iran

2- Assistant Professor of Mechanics of Biosystems Engineering Department, Faculty of Agricultural Engineering and Rural Development, Agricultural Sciences and Natural Resources University of Khuzestan, Iran

3- Graduated Student of Mechanics of Biosystems Engineering Department, Faculty of Agricultural Engineering and Rural Development, Agricultural Sciences and Natural Resources University of Khuzestan, Iran

4- Assistant Professor of Horticultural Science Department, Faculty of Agriculture, Agricultural Sciences and Natural Resources University of Khuzestan, Iran

(\*- Correspond Author Email: s.abdanan@Ramin.ac.ir)



### **Decision tree regression (DTR) algorithm**

To develop a regression model to predict chlorophyll and carotenoid content, two decision tree were constructed. The average of each color channels from RGB, Lab, HSV, and I1I2I3 become the predictor variables or feature vector and the real known chlorophyll and carotenoid content become the target variable or the target vector of each regression tree. To develop the regression models, dataset (90 observations) was split into training (60 observations) and test (30 observations) data.

### **Results and Discussion**

According to the obtained results, a high correlation of 0.92 for chlorophyll and 0.85 for carotenoid was achieved, respectively, between the image processing method and the values measured by the spectrometer. Therefore, it can be said that the proposed image processing method has a desirable and acceptable performance for prediction of both chlorophyll content and carotenoid. The review points out a need for fast and precise leaf chlorophyll measurement technique. With this in mind, Dey et al. (2016) used image processing techniques to measure chlorophyll content. For the purpose of analysis of the proposed model, the model outcome was compared with the LEAF+ chlorophyll meter reading. Regression analysis proofed that there was a strong correlation between the proposed image processing technique and chlorophyll meter reading. Thus, it appears that the proposed image processing technique of leaf chlorophyll measurement will be a good alternative for measuring leaf chlorophyll rapidly and with ease.

### **Conclusions**

In this research, collections of images from six divers plants (Shoebblackplant, Vitex, Spiderwort, Sacred fig, Vine and Lotus) were analyzed to predict chlorophyll and carotenoid content at different color spaces (RGB, Lab, HSV, and I1I2I3). Based on the results, it was shown that there were high correlations of 0.92 for chlorophyll content as well as 0.85 for carotenoid between the image processing method and the values measured by the spectrometer. Therefore, in general, it can be concluded that the proposed image processing method has a desirable and acceptable performance for prediction of chlorophyll content as well carotenoid.

**Keywords:** Carotenoid, Chlorophyll, Color space, Image processing

