

## استفاده از تکنیک پردازش تصویر و شبکه‌های عصبی مصنوعی برای شناسایی علف‌های هرز مزارع ذرت

عبدالحسین دشتی<sup>۱</sup>، مصطفی اویسی<sup>۲</sup>، حمید رحیمیان مشهدی<sup>۱</sup>، حسن علیزاده<sup>۲</sup>

۱، دانشجوی دکتری شناسایی و مبارزه با علف‌های هرز، ۳۰۲-۴۰۳- گروه زراعت و اصلاح نباتات، پردیس کشاورزی و منابع طبیعی دانشگاه تهران

(تاریخ دریافت: ۱۳۹۷/۷/۱۲- تاریخ پذیرش: ۱۳۹۷/۱۰/۲۶)

### چکیده

علف‌های هرز به صورت لکه‌ای در مزرعه سبز می‌شوند. سمپاشی لکه‌ای علف‌های هرز، موجب کاهش مصرف علف‌کش‌ها، هزینه و آلودگی محیط زیست می‌شود. برای تصمیم‌گیری در زمینه کنترل توسط فن آوری بینایی ماشین که در سمپاشی لکه‌ای به کار می‌رود، به تصویر و پردازش آن نیاز است. شناسایی درست علف‌های هرز و طبقه‌بندی آن‌ها، کلید اتخاذ تصمیمات کنترلی و اجرای عملیات سمپاشی است. در این تحقیق، روشی مبتنی بر ترکیب پردازش تصویر، برای جداسازی علف‌های هرز از سایر اجزای تصویر و شبکه عصبی مصنوعی برای طبقه‌بندی پیشنهاد شده است. علف‌های هرز شامل تاج خروس ریشه قرمز، سلمه تره، آفتاب پرست، تاج خروس خوابیده، تاج ریزی، سوروف و گاوس بودند. نتایج نشان داد که این الگوریتم، با دقت قابل قبولی علف‌های هرز را از خاک جداسازی کرد. در گام بعد، ویژگی‌های مرتبط با رنگ و شکل، از علف‌های هرز استخراج شدند. سرانجام، به منظور طبقه‌بندی هفت کلاس علف‌هرز، از روش شبکه عصبی مصنوعی پرسپترون، با ساختار ۷-۱۵-۱۵-۴۳ و میانگین دقت کل ۸۸/۷۱ درصد استفاده شد. نتایج حاصل از این مطالعه نشان داد که سامانه پیشنهادی، توانایی تشخیص علف‌های هرز با دقت مناسب را دارد. کاربرد چنین سامانه‌هایی می‌تواند با تشخیص به موقع علف‌های هرز و کاهش مصرف علف‌کش‌ها، بروز پدیده مقاومت علف‌های هرز به علف‌کش‌ها را به تاخیر اندازد و آلودگی‌های زیست محیطی را کاهش دهد.

**واژه‌های کلیدی:** بینایی ماشین، سمپاشی لکه‌ای، علف هرز، کاربرد علف‌کش، کشاورزی دقیق

## Weeds identification in corn fields based on image processing techniques and artificial neural networks

Abdol Hosein Dashti<sup>1</sup>, Mostafa Oveisi<sup>1\*</sup>, Hamid Rahimian Mashhadi<sup>1</sup>, Hassan Alizadeh<sup>1</sup>

1: Department of Agronomy and Plant Breeding, Faculty of Agriculture, University of Tehran, Iran.

(Received: October 4, 2018 - Accepted: January 16, 2019)

### ABSTRACT

Weeds normally grow as patches and spatially distributed in field. Patch spraying to control weeds has advantages such as cost reduction, herbicide saving and reduction of environmental pollution. Machine vision system should obtain and process digital images to make control decisions. Proper identification and classification of weeds are the key steps to make control decisions and use of any spraying operation performed. In this study, a robust method based on image processing and computational intelligence was developed for segmentation from other parts of image and classification of weeds. Large crabgrass, common lamb's quarter, velvetleaf, common barnyard grass, European black nightshade, red-rooted pigweed and European heliotrope were the weeds in the experiment. Results showed that this algorithm was precisely separated weeds from the soil. In the next step, the feature vector, which includes shape features and color features, was composed. Finally, classification of seven classes of weeds was carried out by artificial neural network (ANN). Among different ANN structures, the most optimum classifier was the 43-15-15-7 topology with accuracy 88/71 %. The results of this research indicate that the proposed system has the ability to accurately detection of weeds.

**Key words:** Herbicide application, machine vision, patch spraying, precision agriculture, weed.

\* Corresponding author E-mail: moveisi@ut.ac.ir

## مقدمه

علف‌های هرز به عنوان یکی از هزینه‌برترین تهدیدهای محیطی در کشاورزی محسوب می‌شوند زیرا به طور تصادفی و لکه‌ای در همه مکان‌ها حضور دارند و با گیاهان بر سر منابع رقابت می‌کنند و منجر به افت عملکرد می‌شوند (Chris, 2012; Abdulahi *et al.*, 2012; Khan *et al.*, 2007; Wiatrak & Chen, 2011). بدون شک، استفاده از علف‌کش‌ها، پرکاربردترین روش کنترل علف‌های هرز می‌باشد. اگرچه علف‌کش‌ها در کنترل علف‌های هرز بسیار کارآمد هستند اما از تاثیر منفی آن‌ها بر محیط زیست (از طریق آلودگی آب‌های زیر زمینی) و زیست‌شناسی علف‌های هرز (ظهور مقاومت) به سادگی نمی‌توان گذشت (Liu & O'Connell, 2002; Spliid & Koeppen, 1998). اگر ابزاری به منظور تشخیص و شناسایی دقیق علف‌های هرز که به صورت لکه‌ای پراکنده می‌شوند موجود باشد، این امکان وجود دارد تا مصرف علف‌کش‌ها را تنها در محل حضور علف‌های هرز محدود کرد و با این کار، از میزان کاربرد آن‌ها کاست (Berge *et al.*, 2012). این موضوع، نیاز به سامانه‌هایی جهت تشخیص دقیق علف‌های هرز را نشان می‌دهد و همچنین، توسعه روش‌های مبتنی بر پردازش تصویر در شناسایی علف‌های هرز را توجیه می‌کند. پیشرفت در زمینه پردازش تصویر دیجیتال، ابزارهای فوق العاده‌ای برای ارزیابی موثر و دقیق پارامترهایی فراهم کرده است که پوشش گیاهی را از تصاویر محصولات کشاورزی تخمین می‌زنند. چنین آزمایشاتی، خطاهای تشخیص بسیار کمی دارند؛ بنابراین نتایج به دست آمده را بسیار قابل اطمینان می‌کنند (Richardson *et al.*, 2001).

جداسازی<sup>۱</sup> تصویر، تقریباً پایه و اساس هر برنامه پردازش تصویر است. شیوه کلی جداسازی تصویر، یافتن یک شاخص معین و سپس تبدیل تصویر خاکستری آن شاخص به تصویر باینری، با استفاده از یک روش مناسب می‌باشد. رنگ، یک ویژگی کلیدی است که به طور گسترده‌ای در تشخیص گیاهان، میوه‌ها و سبزیجات به کار می‌رود (Feng *et al.*, 2013). اساساً شاخص‌های رنگی در تشخیص گیاهان سبز می‌توانند در سه طبقه دسته بندی شوند. دسته اول، شاخص‌های رنگی از فضای رنگی RGB، دسته دوم، شاخص‌های رنگی سایر فضاها رنگی مانند HSI، HSV یا Lab و دسته سوم، شاخص‌هایی است که از اطلاعات نور مرئی و فروسرخ یا هر دو استفاده می‌کنند. مطالعات متعددی، اهمیت انتخاب فضای رنگی بهینه را برای هر نوع کاربردی در پردازش تصویر نشان داده‌اند (Golzarian *et al.*, 2012).

شناسایی علف‌های هرز توسط سامانه بینایی ماشین، از طریق طبقه‌بندی آن‌ها در دسته‌های مختلف صورت می‌گیرد. سه فرایند مهم، در یک سامانه طبقه‌بندی علف‌های هرز مبتنی بر بینایی ماشین، نقش دارد. ابتدا می‌بایست عکس‌های دیجیتالی از کلاس‌های مختلف علف‌های هرز تهیه شود. در مرحله بعد، مجموعه‌ای از خصوصیات متمایز که حاوی اطلاعات کافی جهت تمایز بین چندین گونه هستند، از هر عکس استخراج می‌شود. سرانجام، یک الگوریتم طبقه‌بندی پیاده سازی می‌شود که خصوصیات عکس را به عنوان ورودی دریافت می‌کند و کلاس‌های مختلف علف‌های هرز را به عنوان خروجی تحویل می‌دهد. تحقیقات بسیاری نشان داده است که بینایی ماشین می‌تواند در تشخیص و مکان‌یابی علف‌های هرز در مزارع کشاورزی مورد استفاده قرار گیرد (Blackmer & Schepers, 1996; )

<sup>۱</sup>Segmentation

طبقه‌بندی آنالیز تشخیص بیشتر از شبکه عصبی بود (El-Faki et al., 2000). انتخاب تکنیک مناسب پردازش تصویر و همچنین الگوریتم طبقه‌بندی کننده، در رسیدن به نتیجه بسیار مهم است. با توجه به این‌که این موضوع در ایران کمتر مورد تحقیق قرار گرفته است و تشخیص به موقع علف‌های هرز در مدیریت آن‌ها از اهمیت بسیاری برخوردار است، بنابراین هدف از این پژوهش، ارائه الگوریتمی نسبتاً ساده و قدرتمند است تا بتواند کلاس‌های گوناگون علف‌های هرز را از سایر اجزای تصویر جدا کند. در ضمن، برای طبقه‌بندی علف‌های هرز و تشخیص آن‌ها، از تکنیک پردازش تصویر و روش‌های مدل‌سازی<sup>۳</sup> ANN استفاده شود.

## مواد و روش‌ها

### جداسازی علف‌های هرز از بقیه اجزای تصویر

برای تصویربرداری، از دوربین دیجیتال نیکون مدل P 900 استفاده شد. برای برداشت تصاویر، پنج مزرعه ذرت، واقع در مزرعه پژوهشی دانشکده کشاورزی دانشگاه تهران و ۱۰ مزرعه ذرت واقع در استان قزوین در سال ۱۳۹۵ انتخاب شدند. برای لحاظ کردن اثر روشنایی در تصاویر گرفته شده، عکس‌برداری در ساعات مختلف روز (هفت، ۱۲، ۱۹) انجام گرفت. هنگام تصویربرداری، دوربین روی سه پایه قرار داشت و لنز آن عمود بر زمین بود. فاصله دوربین از سطح زمین، ۹۰ سانتی متر در نظر گرفته شد که سطحی معادل ۰/۲۵ متر مربع را شامل می‌شد. برای مقایسه انواع مختلف تبدیلات فضای رنگی، تصاویر (مربوط به فضای رنگی RGB) در شرایط محیطی متفاوت (آفتابی، ابری، ساختمان خاک متفاوت، بستر با شرایط مختلف (سنگی، کاه و کلش، شاخ و برگ، بقایای محصول قبل) گرفته شدند. تصویربرداری از

Meyer et al., 1997; Perez et al., 2000; Rath, 2000; Schmoldt et al., 1997; Staff & Benlloch (1997).

شبکه‌های عصبی، نوعی مدل‌سازی ساده شده از سیستم‌های عصبی واقعی هستند که کاربرد فراوانی در حل مسائل مختلف در علوم دارند. خصوصاً به عنوان یک طبقه‌بندی کننده خوب برای برنامه‌های پردازش تصویر شناخته شده‌اند. شبکه‌های عصبی مصنوعی، متشکل از چندین واحد پردازش<sup>۱</sup> هستند که در لایه‌های مختلف مستقر شده‌اند و اصطلاحاً نورون عصبی نامیده می‌شوند. نورون‌های عصبی در هر لایه با نورون‌های عصبی لایه مجاور، دو به دو متصل هستند (Haykin, 1994; Kartalopoulos, 1996; Kasabov, 1996). یک نورون مصنوعی در حقیقت مدلی محاسباتی است که از نورون‌های عصبی واقعی انسان، الهام گرفته است. اتصالات بین نورون‌های مصنوعی، در واقع عملکرد دندریت‌ها و آکسون‌ها در مغز انسان را تقلید می‌کنند. مزیت شبکه عصبی، یادگیری مستقیم از روی داده‌ها، بدون نیاز به برآورد مشخصات آماری آن‌ها است. شبکه عصبی بدون در نظر گرفتن هیچ فرضیه اولیه و دانش قبلی از روابط بین پارامترهای مورد مطالعه، قادر به پیدا کردن رابطه بین مجموعه ورودی‌ها و خروجی‌ها، برای پیش بینی هر خروجی متناظر با ورودی دلخواه می‌باشد.

در تحقیقی از شبکه‌های عصبی مصنوعی برای تمایز بین علف‌های هرز و گیاه زراعی استفاده شد. نتایج نشان دادند که نرخ دقت تشخیص تصویر برای ذرت، ۹۰-۱۰۰ درصد و برای علف‌های هرز، ۶۰-۷۰ درصد بود (Yang et al., 1998). نتایج پژوهش دیگری که با استفاده از شبکه عصبی مصنوعی و آنالیز تشخیص<sup>۲</sup> (طبقه‌بندی کننده آماری) برای تشخیص علف‌های هرز در گندم و سویا انجام شد، نشان داد که دقت

<sup>۱</sup> Processing element

<sup>۲</sup> Discriminant analysis

<sup>۳</sup> Artificial neural network

زمینه و صفر برای پیکسل‌های پس زمینه استفاده می‌شود.

به منظور ایجاد تصاویر باینری که به روشنی گیاه را از خاک متمایز می‌کنند، یک حد آستانه ضروری است. در این تحقیق، روش آستانه گذاری دستی استفاده شد. حد آستانه بهینه برای باینری کردن، به صورت دستی و بر اساس هستیوگرام تصویر به دست آمد. حد آستانه هر تصویر، برای جداسازی بهینه گیاه از پس زمینه (خاک) تنظیم شد.

عملیات برش خودکار به این ترتیب انجام گرفت که با انتخاب مقدار حد آستانه ایده‌ال (۱۸۵) از کانال‌های B, G, R، تصاویر باینری ایجاد شد. بعد از آستانه گذاری، نواحی دارای نویز که هنوز روی برگ‌ها باقی مانده بودند، توسط عملیات مورفولوژیک حذف شدند. در واقع کوچک کردن و بزرگ کردن، دو مرحله از اصلی‌ترین عملیات مورفولوژیک هستند که به ترتیب فرسایش و اتساع<sup>۱۰</sup> نامیده می‌شوند. برای دستیابی به کارایی بهتر، این دو تکنیک در ترکیب با یکدیگر به کار می‌روند. در نهایت، با ضرب تصاویر باینری درکانال‌های B, G, R و ترکیب آن‌ها، پس‌زمینه تصویر اصلی حذف شد و تصویر نهایی به دست آمد. با این روش، علف‌های هرز با دقت بالایی از تصاویر استخراج می‌شوند (شکل ۲).

برای استخراج ویژگی‌های مختلف از تصاویر، نخست باید آن‌ها را به فضاهاى رنگی مختلف منتقل کرد و پس از محاسبه کانال‌های مربوطه، ویژگی‌های مورد نظر را استخراج نمود، که در ادامه نحوه به دست آوردن این کانال‌ها و استخراج ویژگی‌ها شرح داده می‌شود:

#### محاسبه کانال‌های B, G, R و B:

کانال‌های B, G, R، به ترتیب نشان دهنده کانال‌های قرمز و سبز و آبی است و به طور مستقیم از تصاویر RGB استخراج شدند.

علف‌های هرز غالب مزارع ذرت شامل تاج خروس ریشه قرمز<sup>۱</sup>، سلمه تره<sup>۲</sup>، آفتاب پرست<sup>۳</sup>، تاج خروس خوابیده<sup>۴</sup>، تاج ریزی<sup>۵</sup> سوروف<sup>۶</sup> و گاوس<sup>۷</sup> انجام شد. تصاویر با ابزار پردازش تصویر متلب<sup>۸</sup> ۲۰۱۳ پردازش شدند. ۴۲۰ عکس مورد پردازش قرار گرفتند. مراحل پردازش تصاویر، پیش پردازش، استخراج ویژگی، انتخاب ویژگی، طبقه‌بندی و در نهایت تشخیص علف‌های هرز، به صورت خلاصه در شکل ۱ نشان داده شده است.

**پیش پردازش:** این مرحله قبل از مراحل اصلی در پردازش تصویر انجام می‌شود. در این پژوهش، تضاد<sup>۹</sup> بهبود یافت و اختلالات تصاویر حذف گردید تا اشیا موجود در عکس با وضوح بهتری قابل رویت باشند. سپس تصاویر RGB به تصاویر خاکستری تبدیل شد. اهداف کلی این عملیات را می‌توان ارتقاء تصویر و حذف داده‌های غیر ضروری از تصویر دانست. با انجام عملیات پیش پردازش مناسب تصویر، دقت تشخیص و کارایی طبقه‌بندی افزایش می‌یابد (Shi & He, 2010).

**آنالیز باینری تصویر:** یک تصویر باینری، از یک تصویر خاکستری و از طریق عملیاتی که منجر به انتخاب دسته‌ای از پیکسل‌های تصویر، به عنوان پیکسل‌های پیش زمینه (پیکسل‌های مورد نظر) و قرار دادن بقیه پیکسل‌ها به عنوان پس‌زمینه می‌شود، به دست می‌آید. پیکسل‌های تصویر باینری، صفر و یک هستند. یک برای علامت‌گذاری پیکسل‌های پیش

<sup>۱</sup> *Amaranthus retroflexus*

<sup>۲</sup> *Chenopodium album*

<sup>۳</sup> *Heliotropium europaeum*

<sup>۴</sup> *Amarantus blitoides*

<sup>۵</sup> *Solanum nigrum*

<sup>۶</sup> *Echinochloa crus-galli*


<sup>۷</sup> *Digitaria sanguinalis*

<sup>۸</sup> Matlab

<sup>۹</sup> Contrast

مدل رنگ این است که مولفه شدت (Intensity)، مجزا از اطلاعات رنگ در تصویر می‌باشد.

**محاسبه کانال‌های I، S، H:**  
در فضای رنگ HSI، مولفه رنگ (Hue)، توصیف‌کننده رنگ خالص و S توصیف‌کننده مولفه اشباع (Saturation) و میزان رقیق شدن رنگ خالص توسط نور سفید را نشان می‌دهد. مزایای اصلی این



شکل ۱- مراحل مختلف نرم افزاری سامانه تشخیص هوشمند گونه علف‌های هرز

Figure 1. Different stages of Intelligent Detection System software for weed species

#### محاسبه کانال‌های $L^*$ ، $a^*$ و $b^*$ :

فضای رنگ  $L^*a^*b^*$  یا CIE LAB که غالباً برای اندازه گیری رنگ به کار می‌رود به عنوان یک استاندارد بین‌المللی معرفی می‌شود (Leo'n et al., 2006). در این فضای رنگ،  $L^*$ ،  $a^*$  و  $b^*$  به ترتیب معرف روشنایی، دامنه رنگ از سبز به قرمز و دامنه رنگ از آبی به زرد می‌باشد (Chaudhary et al., 2012). معادلات لازم جهت محاسبه توسط گونزالس و وودز (۲۰۰۲) به طور کامل بیان شده است.

همچنین مولفه‌های رنگ و اشباع، بیانگر همان روشی هستند که انسان رنگ را درک می‌کند. با توجه به اینکه سازگاری فضای رنگ HSI با سیستم بینایی انسان بسیار بیشتر از فضای رنگ RGB می‌باشد، فضای رنگ مذکور با استفاده از الگوریتم‌ها در پردازش تصویر و بینایی ماشین (Mechine vision) به کار می‌رود (Zhou et al., 2015). با استفاده از معادلات بیان شده توسط چادهاری و همکاران (۲۰۱۲) می‌توان کانال های I, S, H را محاسبه نمود.

### استخراج ویژگی‌های رنگ و شکل

توصیف‌گرهای رنگ، به عنوان یک ویژگی موثر از تصاویر نمونه‌های هر گونه علف هرز استخراج شدند. در این تحقیق، با بررسی فضاهای رنگی گوناگون، سه فضای رنگی HSI،  $L^*a^*b^*$  و RGB انتخاب شد. از مزایای این فضاهای رنگی، ایجاد تضاد بالا در شاخص‌های رنگ مربوط به کلاس‌های متفاوت علف‌های هرز بود. از طرف دیگر و با توجه به این‌که

در بین کلاس‌های گوناگون علف‌های هرز، شکل‌های متفاوتی وجود دارد، استفاده از ویژگی‌های مرتبط با شکل می‌تواند در دقت طبقه‌بندی تأثیر مثبت داشته باشد. ویژگی‌های شکل انتخاب شده در جدول ۱ ارائه شده است. این ویژگی‌ها در تحقیقات متعددی پیشنهاد شده است (Venora *et al.*, 2009; Mebatsion *et al.*, 2013).




(A)



(B)



(C)



(D)

شکل ۲- تصاویر گرفته شده از علف هرز *Heliotropium europaeum*: الف) تصویر رنگی (در فضای رنگی RGB)، ب) تصویر مولفه S از فضای رنگی HSV، پ) تصویر باینری حاصل از روش آستانه گذاری و ت) تصویر حاصل از جداسازی علف هرز از پس زمینه

Figure 2: *Heliotropium europaeum* pictures: (A) Color image (in RGB color space), (B) S component in HSV color space, (C) Binary image of thresholding method and (D) The image of segmenting weed from background

کانال قرمز، سبز، آبی از فضای رنگ RGB، رنگ، اشباع، شدت از فضای رنگ HSI و روشنایی، a و b از

در این تحقیق، ۳۶ ویژگی برای هر تصویر (چهار ویژگی \* نه کانال رنگ) به دست آمد؛ به این ترتیب که

شد که با استفاده از معادلات زیر به دست می‌آیند (Shapiro & Stockman, 2001).

فضای رنگ  $L^* a^* b^*$  محاسبه شدند. سپس از هر کدام از کانال‌های رنگ، چهار ویژگی آماری شامل میانگین، انحراف معیار، همواری و چولگی استخراج

جدول ۱- ویژگی‌های شکل به کار رفته در پردازش تصویر

SHAPE FEATURES	FORMULA
Aspect ratio	MAJER AXIS/MINOR AXIS
Compactness	$\frac{100 \cdot area}{perimeter^2}$
Elongation	$\frac{Length\ of\ major\ axis - length\ of\ minor\ axis}{Length\ of\ major\ axis + length\ of\ minor\ axis}$
Perimeter to broadness (PTB)	$\frac{Perimeter}{2(Length\ of\ major\ axis + length\ of\ minor\ axis)}$
Length to perimeter (LTP)	$\frac{Length}{Perimeter}$
Length to width (LTW)	$\frac{Length}{width}$
Cube of perimeter to area by length (PTAL)	$\frac{perimeter^3}{100 \cdot area \cdot Length\ of\ major\ axis}$

وزن ( $w$ ) و تابع انتقال یا محرک  $f$  ورودی ( $p$ ) به نورون اعمال می‌شود و با ضرب در وزن ( $w$ )، وزن دار می‌شود و حاصل ضرب، به عنوان ورودی، به تابع انتقال  $f$  اعمال می‌شود و خروجی نهایی به دست می‌آید. با اضافه کردن بایاس ( $b$ ) به ساختار نورون منفرد، نورونی واجد بایاس به مانند شکل ۳ سمت راست ایجاد می‌شود. ورودی بایاس، یک مقدار ثابت است. بایاس با حاصل  $w.p$  جمع می‌شود؛ در واقع تابع را به سمت چپ انتقال می‌دهد. منظور از  $f$ ، تابع انتقال می‌باشد. این تابع معمولاً یک تابع پلکانی و یا یک تابع سیگموئیدی است که آرگومان  $n$  را دریافت می‌کند و خروجی  $a$  را تولید می‌نماید. با توجه به آنچه ذکر شد، می‌توان گفت نورون به صورت زیر محاسبه می‌شود:

$$a = f(wp + b) \quad \text{معادله ۵}$$

که در آن،  $f$  تابع محرک،  $w$  و  $b$  به ترتیب وزن و بایاس نورون می‌باشند. پارامترهای  $w$  و  $b$  قابل تنظیم

$$M = \frac{1}{n} \sum_{i=1}^n x_i \quad \text{معادله ۱}$$

$$Var = \frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2 \quad \text{معادله ۲}$$

$$Skewness = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \mu)^3}{(\sqrt{Var})^3} \quad \text{معادله ۳}$$

$$Kurtosis = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \mu)^4}{(\sqrt{Var})^4} \quad \text{معادله ۴}$$

که در آن‌ها،  $x_i$  نشان دهنده مقدار خاکستری<sup>۱</sup> هر پیکسل در تصویر جداسازی شده (در هر کانال رنگ) و  $n$  بیانگر کل پیکسل‌های ارزیابی شده در تصویر جداسازی شده است.

در مجموع، ۴۳ ویژگی از نمونه های علف‌های هرز استخراج شد.

### شبکه‌های عصبی مصنوعی


برای طبقه‌بندی ویژگی‌های بدست آمده از هفت کلاس گونه‌های علف‌های هرز، از شبکه‌های عصبی مصنوعی استفاده شده است. در شکل ۳ سمت چپ، مدل یک نورون با یک ورودی نمایش داده شده است. این نورون ساده، از دو عنصر کلیدی تشکیل شده است:

<sup>۲</sup> Activity function

<sup>۱</sup> Gray-scale value

شوند. در حقیقت، یادگیری به این معنی است که  $w$  و  $b$  طوری تغییر نمایند که رابطه ورودی و خروجی نورون با هدف خاصی مطابقت نماید.

هستند و تابع محرک  $f$  نیز توسط طراح انتخاب می‌شود. بر اساس انتخاب  $f$  و نوع الگوریتم یادگیری (Learning function)، پارامترهای  $w$  و  $b$  انتخاب می‌شوند.




شکل ۳- شمای ساختار شبکه عصبی واجد المان بایاس (راست) و شبکه عصبی فاقد بایاس (چپ)  
Figure 3: The structure of the neural network with (right) and without (left) bias

### تابع انتقال

توابع لگاریتم سیگموئیدی، تانژانت سیگموئیدی و تابع محرک خطی اشاره کرد (شکل ۴).

نورون‌ها می‌توانند از توابع محرک متفاوتی جهت تولید خروجی استفاده کنند که از رایج‌ترین آن‌ها می‌توان به



شکل ۴- توابع محرک رایج در شبکه‌های عصبی

Figure 4. Common activity functions in neural networks

مخفی، از طریق آزمون و خطا حاصل شد. در این تحقیق، از پرسپترون چندلایه (Multilayer feed-forward neural network) استفاده شد. قبل از اینکه ویژگی‌ها به ورودی شبکه عصبی داده شوند، در بازه {۱-} نرمال شدند. تابع سیگموئید به عنوان تابع انتقال در نورون‌های لایه مخفی و خروجی به کار رفت. نمونه‌ها به سه دسته آموزش، اعتبارسنجی و ارزیابی، به ترتیب با نسبت ۶۰، ۲۰ و ۲۰ درصد تقسیم شدند. برای پیاده‌سازی شبکه عصبی، از نرم افزار متلب استفاده شد. یکی از فاکتورهای کلیدی که روی دقت نتایج حاصل از شبکه عصبی مصنوعی موثر است، ساختار آن است. بنابراین ساختارهای مختلف


شبکه عصبی پرسپترون چند لایه (MLP<sup>۱</sup>) این شبکه یکی از مهم‌ترین ساختارهای شبکه‌های عصبی مصنوعی می‌باشد. به طور معمول، این شبکه‌ها شامل مجموعه‌ای از نورون‌های پایه می‌باشند که تشکیل دهنده لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی می‌باشند. تعداد نورون‌های لایه ورودی، مخفی و خروجی، به ترتیب بستگی به تعداد بردار ویژگی‌های ورودی، پیچیدگی مسئله طبقه‌بندی و تعداد کلاس‌های خروجی دارد (شکل ۵). در این تحقیق، تعداد ورودی‌ها (ویژگی‌ها) و خروجی‌ها (تعداد کلاس‌ها) ثابت بود اما تعداد نورون‌ها در لایه‌های

<sup>۱</sup> Multiple layer perceptron



مختلف شامل لوبنرگ- مارکوات (LM)، SCG (Scaled conjugate gradient)، گرادیان نزولی و گرادیان نزولی با نرخ یادگیری متغیر برای آموزش شبکه‌ها استفاده شد؛ ۳- وزن‌های شبکه‌ها در هر اجرا به طور تصادفی مقداردهی اولیه شدند. ۴- برای این‌که از نظر آماری مدل به درستی توسعه یابد، شبکه‌ها ۵۰ بار آموزش داده شدند و بهترین مقادیر برای هر پارامتر ثبت شد.

از شبکه عصبی پرسپترون چند لایه طراحی شد و با الگوریتم‌های آموزش متفاوتی ارزیابی شد (شکل ۶ و ۷). مراحل زیر برای انتخاب بهینه‌ترین ساختار شبکه عصبی پرسپترون پیاده‌سازی شد: ۱- شبکه‌های عصبی مصنوعی مختلفی با یک و دو لایه مخفی مورد آزمون قرار گرفتند. برای شبکه‌های با یک لایه مخفی پنج ۱۰، ۱۵، ۲۰ نرون استفاده شد و برای شبکه‌های با دو لایه مخفی، [۵ ۵]، [۱۰ ۱۰]، [۱۵ ۱۵]، [۲۰ ۲۰] نرون به کار رفت؛ ۲- چهار الگوریتم آموزش



شکل ۵ - ساختار شبکه عصبی پرسپترون.  $X_m$ : نشان دهنده ویژگی‌های ورودی،  $i_i$ : نشان دهنده نرون‌های لایه ورودی،  $j_n$ : نشان دهنده لایه‌های مخفی،  $k_p$ : نشان دهنده نرون‌های لایه خروجی و  $y_p$ : نشان دهنده خروجی‌ها است. وزن‌های مرتبط کننده لایه درونی و مخفی، با  $w_{ij}$  و وزن‌های مرتبط کننده لایه مخفی و بیرونی، با  $w_{jk}$  نمایش داده شده است.

Figure 5: Perceptron Neural Network structure.  $X_m$ : input features,  $i_i$ : input layer neurons,  $j_n$ : hidden layers,  $k_p$ : output layer neurons and  $y_p$ : outputs. Weights that connect the inner and outer layer are displayed by "w<sub>ij</sub>" and Weights that connect the inner and outer layer are displayed by "w<sub>jk</sub>".

### ارزیابی کارایی شبکه‌های عصبی

ردیف‌ها کلاس‌های تخمین زده داده‌ها توسط طبقه‌بندی می‌باشند. اگر داده‌ها در  $M$  کلاس قرار گرفته باشند، ماتریس طبقه‌بندی، جدولی با حداقل اندازه  $M \times M$  است. حالت ایده‌آل این است که اکثر داده‌های مربوط به مشاهدات، روی قطر اصلی ماتریس قرار گیرند و بقیه مقادیر ماتریس صفر یا نزدیک به صفر باشند (Ameri et al., 2013).

ارزیابی عملکرد شبکه‌های عصبی در طبقه‌بندی علف‌های هرز، توسط شاخص‌های آماری که از ماتریس اغتشاش (Confusion matrix) استخراج شده، انجام شد. ماتریس اغتشاش شامل اطلاعات (کلاس‌های) مطلوب یا واقعی و اطلاعات تخمین زده توسط طبقه‌بندی می‌باشد. جدول (۲)، ماتریس اغتشاش برای یک طبقه‌بندی پنج کلاسه را نشان می‌دهد، که ستون‌ها نشان دهنده کلاس‌های مطلوب و

جدول ۲- ماتریس اغتشاش برای طبقه‌بندی ۵ کلاس

Table 2. Confusion matrix for classification of 5 classes

	C1	...	C5
C*1	n11	...	n15
...	...	...	...
C*5	n51	...	n55

$$\text{Accuracy} = \frac{TP+TN}{TP+Tn+FN+FP} \quad (\text{معادله ۸})$$

"دقت"، اثر بخشی کلی شبکه عصبی در طبقه‌بندی را نشان می‌دهد. "صحت" نشان می‌دهد شبکه عصبی در شناسایی برچسب‌های منفی چقدر موثر است و "حساسیت"، تاثیر شبکه عصبی در شناسایی برچسب‌های مثبت را نمایان می‌کند ( Sokolova & Lapalme, 2009).

نتایج بر پایه مطالعه هفت کلاس مختلف از گونه‌های علف هرز می‌باشد. مجموعه داده‌های تصویری مشتمل بر ۶۰ عکس برای هر کلاس بود. در هر تصویر، جداسازی علف‌هرز از سایر اجزای تصویر، به ترتیبی که توضیح داده شد صورت گرفت (شکل ۲). از تصاویر جداسازی شده، ویژگی‌های رنگ استخراج شد تا برای آموزش و ارزیابی شبکه عصبی در طبقه‌بندی گونه علف‌های هرز به کار روند. برای مقایسه کارایی شبکه‌های عصبی مصنوعی، آماره های دقت، صحت و ارزیابی، از طریق ماتریس اغتشاش به دست آمد.

#### انتخاب بهترین ساختار شبکه عصبی

برای انتخاب بهترین ساختار شبکه عصبی مصنوعی، از شاخص دقت کل در طبقه‌بندی استفاده شد. تعداد نورون در لایه‌های مخفی، یکی از موثرترین پارامترها در تعیین مدت زمان اجرای شبکه عصبی و دستیابی به پاسخ است. بنابراین از میان چندین ساختار که بالاترین کارایی (بالاترین میانگین و کمترین انحراف معیار) را داشتند، ساختاری که دارای کمترین لایه مخفی و نورون بود به عنوان ساختار بهینه انتخاب شد.

عضو  $n_{ij}$  مشخص کننده تصاویری است که توسط طبقه‌بند ( $C^*i$ ) در کلاس  $i$  طبقه‌بندی شده‌اند اما در طبقه‌بندی واقعی متعلق به کلاس  $j$  می‌باشند. در نتیجه، اعضای قطری اصلی ماتریس ( $i=j$ )، نشان دهنده تصاویری هستند که درست طبقه‌بندی شده‌اند اما اعضای خارج از قطر اصلی ( $i \neq j$ ) نمونه‌هایی هستند که درست طبقه‌بندی نشده‌اند. هر یک از ارزیابی‌های طبقه‌بند شامل چهار حالت مختلف زیر است: الف) تصمیمات مثبت صحیح (TP)، نمونه‌هایی که درست توسط طبقه‌بند ( $C^*i$ ) در کلاس  $i$  ام طبقه‌بندی شده‌اند؛ ب) تصمیمات مثبت ناصحیح (FP)، نمونه‌هایی که اشتباهاً توسط طبقه‌بند ( $C^*i$ ) در کلاس  $i$  ام طبقه‌بندی شده‌اند؛ ج) تصمیمات منفی صحیح (TN)، نمونه‌هایی که اشتباهاً توسط طبقه‌بند ( $C^*i$ ) در کلاس  $i$  ام طبقه‌بندی نشده‌اند و د) تصمیمات منفی ناصحیح (FN)، نمونه‌هایی که اشتباهاً توسط طبقه‌بند ( $C^*i$ ) به کلاس  $i$  ام تعلق نگرفته‌اند.

که  $n_{TP}=n_{i,i}$ ،  $n_{FP}=n_{i,+} - n_{i,i}$ ،  $n_{FN}=n_{+,j} - n_{i,i}$  و  $n_{TN}=n - n_{TP} - n_{FP} - n_{FN}$  می‌باشد.  $n_{i,+}$  مجموع اعضای تمامی ستون‌های متعلق به سطر  $i$  ام و  $n_{+,j}$  مجموع اعضای تمامی سطرهای متعلق به سطر  $j$  ام در ماتریس اغتشاش می‌باشد (Labatut & Cheri, 2011).

برای ارزیابی کارایی شبکه‌های عصبی، سه شاخص آماری شامل حساسیت، صحت و دقت مورد استفاده قرار گرفت:


$$\text{Sensitivity} = \frac{TP}{TP+FN} \quad (\text{معادله ۶})$$

$$\text{Specificity} = \frac{TN}{TN+FP} \quad (\text{معادله ۷})$$

## نتایج و بحث

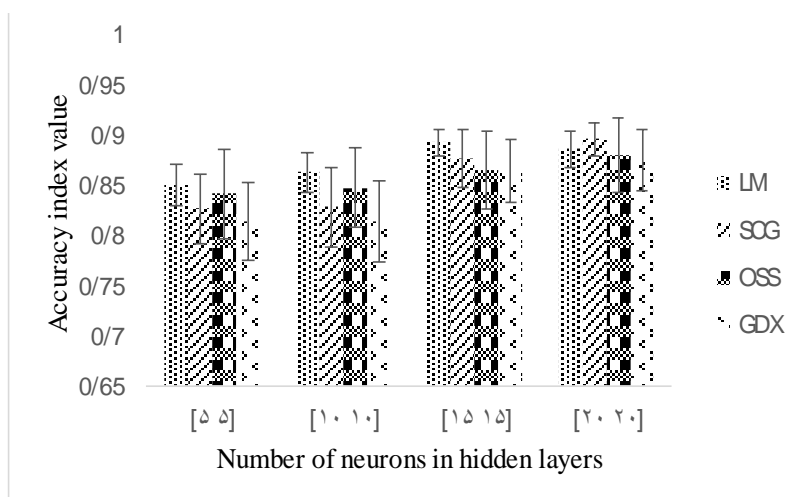
را داشتند. تعداد نورون کمتر در لایه مخفی، مطلوب است زیرا موجب کاهش اندازه و افزایش سرعت یادگیری شبکه می‌شود؛ بنابراین ساختار ۷-۱۵-۱۵-۴۳ به عنوان بهترین ساختار انتخاب شد (شکل ۷). این نتایج با نتایج حاصل از تحقیق برک و همکاران (۲۰۰۰) تطابق داشت. آن‌ها نشان دادند که شبکه عصبی پرسپترون با ساختار دو لایه مخفی و پنج نورون به ازای هر لایه توانست ۹۴/۷ درصد دقت طبقه‌بندی را محقق کند.

هر شبکه عصبی ۵۰ مرتبه اجرا شد. میانگین و انحراف معیار شاخص دقت در مورد شبکه‌های عصبی مصنوعی، با الگوریتم‌های متفاوت ثبت شدند. در نتیجه، شبکه عصبی مصنوعی دارای ساختار ۷-۱۵-۱۵-۴۳ با الگوریتم آموزش LM و میانگین ۸۹,۳۶٪ و انحراف معیار ۱,۳۴٪ و شبکه دارای ساختار ۷-۲۰-۲۰-۴۳ با الگوریتم آموزش SCG و میانگین ۸۹,۷۴٪ و انحراف معیار ۱,۶۴ بهترین کارایی



شکل ۶- کارایی ساختارهای مختلف ANN با یک لایه مخفی و الگوریتم‌های آموزش متفاوت (نوار خطاها (Error bar) در شکل خطای استاندارد می‌باشد).

Figure 6. Efficacy of different ANN structures with two hidden layers and various training algorithms (The error bar in the shape is the standard deviation)



شکل ۷- کارایی ساختارهای مختلف ANN با دو لایه مخفی و الگوریتم‌های آموزش متفاوت (نوار خطاها (Error bar) در شکل خطای استاندارد می‌باشد).

Figure 7. Efficacy of different ANN structures with two hidden layers and various training algorithms (The error bar in the shape is the standard deviation)

### طبقه‌بندی علف‌های هرز با شبکه عصبی انتخاب شده

پس از انتخاب ساختار بهینه شبکه عصبی مصنوعی، بهترین نتایج حاصل از ۵۰ مرتبه اجرای آن ثبت شد و ماتریس اغتشاش مربوط به طبقه‌بندی هفت گونه علف هرز محاسبه شد (جدول ۳). سپس سه شاخص

### جدول ۳- ماتریس اغتشاش حاصل از عملکرد شبکه عصبی با ساختار بهینه بر روی داده های ارزیابی

Table3. Confusion matrix obtained from verification of performance optimum ANN model on testing data set

Digitaria sanguinalis	Echinochloa crus-galli	Heliotropium europaeum	Solanum nigrum	True			Prediction
				Chenopodium album	Amarantus blitoides	Amaranthus retroflexus	
0	0	4	1	0	0	15	Amaranthus retroflexus
0	0	0	3	2	12	3	Amarantus blitoides
0	0	0	2	16	0	2	Chenopodium album
0	0	3	14	3	0	0	Solanum nigrum
0	0	13	4	3	0	0	Heliotropium europaeum
0	16	0	0	0	4	0	Echinochloa crus-galli
11	6	0	0	0	3	0	Digitaria sanguinalis

عصبی برای طبقه‌بندی این کلاس از علف‌هرز در مقایسه با سایر کلاس‌ها نکرده است). بالاترین عملکرد برای کلاس هفتم (گاورس) با مقادیر حساسیت، صحت و دقت به ترتیب برابر با ۱۰۰٪، ۹۳/۴۷٪ و ۹۱/۵۰٪ به دست آمد که علت اصلی آن، مرتبط بودن ویژگی‌های استخراجی در شناسایی و جداسازی این کلاس نسبت به سایر کلاس‌های علف‌هرز بود. در واقع این کلاس دارای رنگ و شکل متفاوت در مقایسه با سایر کلاس‌ها است. گلزاریان و فریک (۲۰۱۱) نیز نشان دادند که علف‌هرز بروموس، از طریق ویژگی‌های رنگی و با دقت ۸۵ درصد، به راحتی از دیگر علف‌های هرز متمایز می‌شود.

همانطور که مشاهده می‌شود (جدول ۴)، کمترین عملکرد به کلاس چهارم ( علف‌هرز تاجریزی) تعلق داشت ( با حساسیت ۵۸/۳۳٪، صحت ۹۳/۲۵٪ و دقت ۸۵/۸۴٪). حساسیت پایین این کلاس نشان می‌دهد که شبکه عصبی در مرحله آموزش نتوانسته است در شناسایی برچسب سایر کلاس‌ها به خوبی عمل کند و به اشتباه، کلاس چهارم را انتخاب نموده است. علت را می‌توان در تشابه این کلاس با سایر کلاس‌ها از نظر ویژگی‌های رنگ و شکل دانست. بنابراین طبیعی است که این کلاس به نسبت سایر کلاس‌ها، عملکرد پایین‌تری داشته باشد (زیرا فقط تعداد معدودی از ویژگی‌ها برای جداسازی آن نقشی مؤثر داشته است و سایر ویژگی‌ها، کمکی به شبکه

### جدول ۴- شاخص‌های حساسیت، صحت و دقت برای تمام کلاس‌های علف هرز

Table4. Sensitivity, specificity and accuracy indices for all classes of weeds

Average	Class							Parameters
	Digitaria sanguinalis	Echinochloa crus-galli	Heliotropium europaeum	Solanum nigrum	Chenopodium album	Amarantus blitoides	Amaranthus retroflexus	
71.55	100	72.72	65	58.33	66.66	63.15	75	Sensitivity (%)
93.60	93.47	95.29	92.30	93.25	95.29	91.39	94.25	Specificity (%)
88.71	91.50	90.65	87.38	85.84	88.99	86.60	90.06	Accuracy (%)

تاج خروس خوابیده و تاج ریزی را به عنوان دسته پهن برگ در نظر بگیریم، شبکه عصبی، باریک برگ‌ها

اگر گاورس و سوروف را به عنوان دسته باریک برگ و تاج خروس ریشه قرمز، سلمه تره، آفتاب پرست،

برای پیش بینی، طبقه‌بندی و تخمین توابع در رشته‌های مختلف ثابت شده است و دارای طیف گسترده‌ای از کاربردها در مدیریت کشاورزی است. ارزیابی شبکه عصبی مصنوعی به کمک شاخص‌های آماری نظیر دقت، صحت و حساسیت انجام گرفت که مقادیر میانگین این شاخص‌های آماری برای طبقه‌بندی هر کلاس، حاصل از ماتریس اغتشاش، محاسبه شد. ANN توانست کل علف‌های هرز را با دقت خوب (۸۸/۷۱) و همچنین گونه‌های انفرادی را نیز با دقت قابل قبول (۸۵٪ به بالا) طبقه‌بندی کند. مشخص شد که دقت شبکه عصبی، خصوصاً برای دستیابی به دقت بالا در طبقه‌بندی تک گونه علف‌های هرز، بستگی به ساختار شبکه دارد. بنابراین شبکه با دو لایه مخفی انتخاب گردید. البته شبکه‌های با پیچیدگی زیاد، تضمین کننده دقت بالایی طبقه‌بندی نیست و افزون بر آن موجب افزایش بیش از حد زمان پردازش می‌شود. با استفاده از نتایج این تحقیق می‌توان نتیجه گرفت که استفاده از ویژگی‌های رنگ در فضاهای رنگی گوناگون و بهره‌گیری از تکنیک‌های متفاوت هوش محاسباتی همچون ANN در تشخیص گونه‌های مختلف علف‌های هرز، نقش بسیار مؤثر و مهمی دارند. بر طبق نتایج به دست آمده از این پژوهش، پیشنهاد می‌شود که در تحقیقات آینده، این شیوه با سایر روش‌های شبکه عصبی مصنوعی مقایسه شود و مدت زمان برای طبقه‌بندی علف‌های هرز، به همراه دقت طبقه‌بندی، سنجیده شود.

را با دقت ۹۱/۰۷ درصد و پهن برگ‌ها با دقت ۸۷/۷۷ درصد طبقه‌بندی نمود. دقت طبقه‌بندی روش‌های به کار رفته در این پژوهش برای شناسایی علف‌های هرز، نسبتاً پایین‌تر از روش به کار رفته در تحقیق تانگ و همکاران (۱۹۹۹) با دقت ۱۰۰ درصد بود. با این وجود، این شیوه در شناسایی هر کدام از گونه‌ها به تنهایی خوب عمل کرد (جدول ۴). ویژگی‌های رنگ در کانال H و S از فضای رنگی HSI، در شرایط متفاوت نور (ابری، آفتابی)، بسیار بهتر از کانال I توانستند در تمایز علف‌های هرز عمل کنند زیرا کانال I، در واقع معیار روشنایی تصویر است و نمی‌تواند در شرایط متغیر نوری به خوبی مورد استفاده قرار گیرد. بنابراین پیشنهاد می‌شود این کانال به دلیل عدم کارایی در تمایز علف‌های هرز، به طور کلی حذف شود.

### نتیجه‌گیری کلی

در این پژوهش، تشخیص بین گونه‌های علف‌های هرز، با به‌کارگیری روش‌های مبتنی بر تکنیک پردازش تصویر و شبکه‌های عصبی مصنوعی، مورد ارزیابی قرار گرفت. بدین ترتیب که از هفت گونه علف‌هرز، عکس‌برداری به عمل آمد. پس از انجام عملیات پیش پردازش، تصاویر به فضاهای رنگی RGB، HSI و  $L^*a^*b^*$  انتقال یافت و سپس ویژگی‌های آماری مربوط به بافت تصاویر از کانال‌های مربوطه استخراج شد. از شبکه عصبی مصنوعی نیز برای طبقه‌بندی تصاویر به کمک بردار ویژگی‌های مستخرج استفاده شد. استفاده از تکنیک ANN به عنوان ابزاری مفید

## منابع

- Ameri, H., Alizade, S. and Barzegari, A. 2013. Knowledge Extraction of Diabetics Data by Decision Tree Method. *Ir. U. Med. Sci.* 16(53): 58-72.
- Burks, T.F., Shearer, S.A. Gates, R.S. and Donohue, K. D. 2000. Back propagation neural network design and evaluation for classifying weed species using color image texture. *Am. Soc. Agr. Eng.* 43(4): 1029-1037.
- Blackmer, T.M. and Schepers, J.S. 1996. Using DGPS to improve corn production and water quality. *GPS World.* 7: 44-52.
- Chaudhary, P., Chaudhari, A.K. Cheeran, A.N. and Godara, S. 2012. Color transform based approach for disease spot detection on plant leaf. *Int. J. comput. Sci. tel.* 3(6): 65-70.
- El-Faki, M., Zhang, N. and Peterson, D.E. 2000. Weed detection using color machine vision. *Transactions of the ASAE.* 43(6): 1969-1978.
- Golzarian, M.R. and Frick, R.A. 2011. Classification of images of wheat, ryegrass and brome grass species at early growth stages using principal component analysis. *Plant Meth.* 7(28): 1-11.
- Goñi, M.S. and Salvadori, O.V. 2016. Color measurement: comparison of colorimeter vs. computer vision system. *F. M. Charact.* 1-10.
- Haykin, S. 1994. *Neural Networks: A Comprehensive Foundation.* New York, NY: Macmillan College Publishing Company, Inc.
- Haykin, S. 2009. *Neural networks and learning machines.* Pearson Education, Inc.
- Kartalopoulos, S.V. 1996. *Understanding neural networks and fuzzy logic. Basic Concepts and Applications.* New York, NY: The Institute of Electrical and Electronics Engineers, Inc.
- Kasabov, N.K. 1996. *Foundations of neural networks, fuzzy systems, and knowledge engineering.* Cambridge, MA: The MIT Press.
- Leo'n, K., Mery, D., Pedreschi, F. and Leo'n, J. 2006. Color measurement in  $L^*a^*b^*$  units from RGB digital images. *F. Res. Int.* 39(10): 1084-1091.
- Labatut, V. and Cheri, H. 2011. Accuracy measures for the comparison of classifiers. Al-Dahoud Ali. *The 5th International Conference on Information Technology,* Amman, Jordan.
- Mebatsion, H.K., Paliwal, J. and Jayas, D.S. 2013. Automatic classification of non-touching cereal grains in digital images using limited morphological and color features. *Comput. Electron. Agri.* 90: 99-105.
- Meyer, G.E., Franti, T.G. and Mortensen, D.A. 1997. Seek and destroy. *Resource. Eng. Tech. Sust. World.* 4: 13-14.
- Pe'rez, A.J., Lo'pez, F., Benlloch, J.V. and Christensen, S. 2000. Colour and shape analysis techniques for weed detection in cereal fields. *Comput. Electro. Agri.* 25: 197\_/212.
- Rath, T. and Hemming, J. 2000. Computer vision for identifying weeds in crops. *IFAC. Proceed. Vol. 33:* 187-190.
- Schmoltdt, D.L., Li, P. and Abbott, A.L. 1997. Machine vision using artificial neural networks with local 3D neighbourhoods. *Comput. Elect. Agr.* 16: 255-271.
- Staff, J.V. and Benlloch, J.V. 1997. Machine-assisted detection of weeds and weed patches. In *Precision Agriculture '97. Volume II. Technology, IT and Management,* ed. J. V. Stafford, 511-518. Herndon, VA: SCI Bios Scientific Publishers.
- Sokolova, M. and Lapalme, Guy. 2009. A systematic analysis of performance measures for classification tasks. *Information Processing & Management.* 45(4): 427-437.
- Shapiro, L. and Stockman, G. 2001. *Computer Vision.* Prentice Hall Inc. Upper Saddle River. NJ, USA.
- Shi, Z. and He, L. 2010. Application of neural networks in medical image processing. *Proceedings of the Second International Symposium on Networking and Network Security.* April 2-4., Jingtangshan, China.
- Tang, L., Tian, L.F., Steward, B.L. and Reid, J.F. 1999. Texture based weed classification using gabor wavelets and neural network for real-time selective herbicide applications. *ASAE Paper No.* 99-3036. St. Joseph, Mich.: ASAE.
- Thompson, J.F., Stafford, J.V. and Miller, P.C.H. 1991. Potential for automatic weed detection and selective herbicide application. *Crop Prod.* 10(4): 254-259.
- Venora, G., Grillo, O. and Saccone, R. 2009. Quality assessment of durum wheat storage centers in Sicily: Evaluation vitreous, starchy and shrunken kernels using an

- image analysis system. J. Cereal Sci. 49: 429-440.
- Yang, C., Prasher, S. and Landry, J. 1998. Application of artificial neural networks to image recognition in precision farming. ASAE Paper. No. 98-3039.
- Zhou, X., Yuan, J and Liu, H. 2015. A Traffic Light Recognition Algorithm Based On Compressive Tracking. Int. J. Hyb. Inf. Tech. 8(6): 323-332.