

روش مبتنی بر موجک برای طبقه‌بندی علف هرز و ذرت با استفاده از ویژگی‌های

آماري و شبکه عصبی مصنوعی

پرویز احمدی‌مقدم^۱، آیدین ایمانی^{۲*}

^۱ دانشیار، گروه مهندسی مکانیک بیوسیستم، دانشکده کشاورزی، دانشگاه ارومیه

^۲ دانشجوی دکتری مهندسی مکانیک بیوسیستم، دانشگاه تهران

*نویسنده مسئول:

پست الکترونیکی: aydin.imani@ut.ac.ir

دریافت: ۱۳۹۵/۰۵/۲۳ پذیرش: ۱۳۹۵/۱۲/۱۸

چکیده

در این تحقیق، یک رویکرد مبتنی بر تبدیل موجک برای طبقه‌بندی علف هرز و ذرت ارائه شده است. بر این اساس، یک پایگاه داده متشکل از ۵۰۰ تصویر در شرایط عادی مزرعه تهیه شد. در ابتدا تبدیل موجک دو بعدی سه مرحله‌ای برای تمام تصاویر اعمال گردید. سپس، ویژگی‌های آماری ضرایب موجک (میانگین، واریانس، چولگی، درجه اوج، انرژی و آنتروپی) محاسبه شد. در نهایت یک شبکه عصبی مصنوعی چند لایه پرسپترون برای طبقه‌بندی تصاویر علف هرز و محصول ذرت از طریق ویژگی‌های استخراج شده، مورد استفاده قرار گرفت. سه نوع تابع موجک شامل موجک‌های هار، دبوچی ۴ و دبوچی ۲۵ برای یافتن بهترین تابع مورد بررسی قرار گرفتند. برای یافتن بهترین بردار ویژگی، ترکیب‌های گوناگونی از ویژگی‌های استخراج شده از مراحل مختلف موجک مورد بررسی قرار گرفتند. نتایج نشان داد که الگوریتم مبتنی بر موجک هار برای طبقه‌بندی از دقت ۸۹/۵ درصد برخوردار بوده و همچنین از نظر بازده محاسباتی قادر است در زمان ۰/۲۲ ثانیه هر تصویر را پردازش کند و از این جهت عملکرد بهتری نسبت به دو تابع موجک دیگر داشت.

واژه‌های کلیدی: تبدیل موجک، تشخیص علف هرز، آنالیز چند رزولوشنه، شبکه عصبی مصنوعی، ذرت

۱- مقدمه

زیست بوم موجب گردیده تا توجه دولت‌ها و محققان به

سمت روش‌های مدیریت منطقه‌ای علف‌های هرز جلب شود (Burgos-Artizzu et al., 2011).

کشاورزی دقیق سعی دارد از طریق شناسایی متغیرهای مورد نیاز در مزرعه، بازده تولید محصول و کیفیت غذا را ارتقاء دهد. همچنین کشاورزی دقیق تلاش می‌کند مقادیر خاص و دقیقی از هر ماده را بر

کنترل علف‌های هرز همچنان یکی از مشکل‌ترین و پر چالش‌ترین عملیات در تولید محصول است. از این رو، هر ساله میزان قابل توجهی از مواد شیمیایی تحت عنوان علف‌کش برای کنترل علف‌های هرز مورد استفاده قرار می‌گیرد. با وجود آثار مثبت علف‌کش‌ها در ارتقاء مزرعه، صدمات جبران ناپذیر این مواد شیمیایی بر

تأکید کرده‌اند (Meyer *et al.*, 1998; Polder *et al.*, 2007; Tang *et al.*, 1999). ویژگی‌های بافتی یک فاکتور مهم برای تحلیل تصاویر در شرایط مختلف است. هر چند ارائه یک تعریف دقیق برای بافت کاری دشوار است، اما می‌توان آن را به عنوان ویژگی‌های سطوح خاکستری که حاوی یک سری از اطلاعات همسایگی محلی است، تعریف کرد (Scheunders *et al.*, 1998). سه رویکرد کلی برای توصیف ویژگی‌های بافتی تصویر می‌توان تعریف کرد: آماری، ساختاری و مبتنی بر تبدیل.

رویکردهای آماری یکی از ساده‌ترین روش‌های تحلیل بافت هستند. رویکردهای ساختاری ترکیبی از عناصر ساده بافت به نام بافت اولیه را برای الگوهای پیچیده به کار می‌برند. هر چند ایده مربوط به روش‌های ساختاری جذاب است، این روش‌ها محدودیت‌هایی در برنامه‌های اجرایی دارند. رویکردهای مبتنی بر تبدیل، ویژگی‌های بافتی را بوسیله ویژگی‌های مکانی فرکانسی تصاویر سطح خاکستری (شدت هر پیکسل) بیان می‌کنند (Bharati *et al.*, 2004; Gonzalez & Woods, 2007). روش‌های بسیاری مانند تبدیل فوریه، فیلتر گابور^۱ و تبدیل موجک برای این منظور ارائه شده است (Chou *et al.*, 2007).

در سال‌های اخیر بخش عظیمی از کارهای انجام شده بر روی فیلترهای گابور و روش‌های ترکیبی با موجک گابور برای طبقه‌بندی علف هرز و محصول و اهداف مشابه تمرکز کرده‌اند (Chen *et al.*, 2011;

اساس شرایط مورد نیاز محل محصول در زمین اعمال کند. این عمل هزینه‌های نهایی تولید و اثرات منفی زیست محیطی را کاهش می‌دهد (Burgos-Artizzu *et al.*, 2010). برای رسیدن به این هدف، دستیابی به یک سیستم دقیق تشخیص علف هرز ضروری است. با وجود اینکه روش‌های بسیاری برای طبقه‌بندی علف هرز و محصول ارائه شده است، هنوز انتخاب بهترین روش با ابهامات فراوانی روبرو است. تا امروز، روش‌های بسیار کمی توانسته‌اند کارایی قابل قبولی از خود در شرایط واقعی مزرعه نشان دهند.

در دهه‌های اخیر، مطالعات بسیاری بر روی توسعه تکنیک‌های مختلف پردازش تصویر از جمله، آنالیز رنگ (Hemming and Rath, 2001)، شکل (Midtiby *et al.*, 2011; Swain *et al.*, 2011) و موقعیت (Burgos-Artizzu *et al.*, 2011) انجام گرفته است. هر چند که این روش‌ها نتایج قابل قبولی نیز در بر داشته‌اند، در مواجهه با شرایط واقعی زمین دارای ضعف‌های اساسی هستند. برای مثال، تمایز میان گیاهان بر اساس طول موج بازتاب ممکن است در شرایط مختلف نوری روز و شرایط آب و هوایی با اشکال روبرو شود. تمایز علف هرز و محصول بر اساس شکل در مراحل اولیه رشد بسیار سخت است. برای تشخیص علف‌های هرز بر اساس موقعیت مکانی، گیاهان میان ردیف‌های کشت به عنوان علف هرز در نظر گرفته می‌شوند که این فرض موجب نادیده گرفتن علف‌های هرز موجود در داخل ردیف‌های محصول می‌شود.

از سوی دیگر، اکثر مطالعات انجام گرفته بر روی تشخیص علف هرز بر روی اهمیت ویژگی‌های بافتی

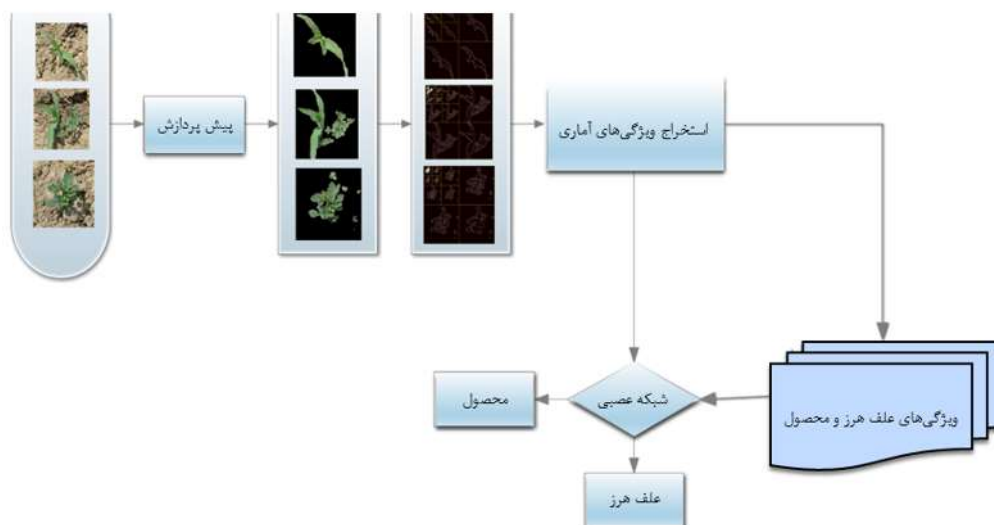
¹ Gabor filter

محاسباتی بالایی برخوردارند. از این جهت، بسیار مهم است که یک روش استخراج ویژگی قدرتمند که دارای پیچیدگی‌های محاسباتی پایینی است، توسعه داده شود (Ojala *et al.*, 2002).

مشخص شده است که تصاویر طبیعی با استفاده از موجک‌ها قابل فشرده‌سازی هستند (Daubechies *et al.*, 2008). یعنی بیشتر اطلاعات مربوط به تصاویر را می‌توان با تعداد کمی داده بیان کرد. علاوه بر این، موجک دارای مزایای محاسباتی است و به دلیل قابلیت چند دقتی قادر است اطلاعات مکانی-فرکانسی را بطور همزمان تهیه کند. هدف اصلی این مطالعه، توسعه یک الگوریتم قوی برای طبقه‌بندی علف هرز و محصول در شرایط واقعی مزرعه است که در برابر تغییرات نوری محیطی و شرایط متفاوت جوی از دقت بالایی برخوردار باشد. در نتیجه در این تحقیق یک روش مبتنی بر تبدیل موجک و ویژگی‌های آماری توسعه داده شد که هم قادر است علف هرز و محصول را در شرایط نوری طبیعی مزرعه تشخیص دهد و همچنین از بار محاسباتی پایینی برخوردار باشد. برای یافتن بهترین دسته ویژگی‌ها، سه مرحله از تبدیل موجک بر روی تصاویر اعمال شد و ترکیب‌های مختلف از ویژگی‌های استخراج شده مورد ارزیابی قرار گرفت. سه تابع موجک که از کارایی قابل قبولی در کارهای مربوط به طبقه‌بندی برخوردارند شامل موجک هار، دبوچی ۴ (Db4) و دبوچی ۲۵ (Db25) با هم مقایسه شدند. در شکل ۱ روند این تحقیق نشان داده شده است.

(Ishak *et al.*, 2009). با این وجود تبدیل گابور دارای چند محدودیت است. اول، ویژگی‌های استخراج شده توسط تبدیل گابور ممکن است با یکدیگر همبستگی بالایی داشته باشند. علت این اتفاق به دلیل خروجی فیلتر بانک‌های گابور است که بطور متقابل دارای تعامد نیستند. دوم، تبدیل گابور بطور کلی معکوس‌پذیر نیست، از این رو موجب ایجاد محدودیت‌هایی در تجزیه بافت خواهد شد (Arivazhagan & Ganesan, 2003).

در دو دهه گذشته علاقه محققان برای استفاده از تبدیل موجک در بسیاری از تحلیل‌های زمان-فرکانسی به خصوص در حوزه پردازش تصویر افزایش یافته است (Arivazhagan & Ganesan, 2003; Li *et al.*, 1998; Scheunders *et al.*, 2002). در یک مطالعه قیاسی مشاهده گردید که توابع موجک در مقایسه با موجک گابور از کارایی بهتری در جداسازی علف هرز و محصول برخوردارند (Bossu *et al.*, 2009). با این وجود، توجه کمی به قابلیت‌های تبدیل موجک معطوف گردیده است. علاوه بر این، بیشتر مطالعات انجام گرفته برای کاهش حجم محاسبات از تصاویر گرفته شده به صورت پرسپکتیو استفاده کرده‌اند که حاصل آن نادیده گرفتن علف‌های هرز روییده در داخل ردیف‌های محصول بوده است (Burgos-Artizzu *et al.*, 2010). به هر حال، مسأله‌ای که در این بین حایز اهمیت است، ایجاد یک تحلیل بافتی با استفاده از روش‌های مناسب استخراج ویژگی برای طبقه‌بندی، جداسازی و تشخیص است (Arivazhagan & Ganesan, 2003). بطور کلی روش‌های مبتنی بر تحلیل بافتی از پیچیدگی‌های



شکل ۱. دیاگرام مربوط به طبقه‌بندی علف هرز و ذرت

Fig. 1. Block diagram of classification of corn and weed

۲- مواد و روش‌ها

۲-۱- تهیه تصاویر

تصاویر به وسیله یک دوربین سایبر شات سونی مدل DSC-HX9V تحت شرایط نوری طبیعی (عادی) در روزهای آفتابی و ابری از مزارع ذرت اطراف شهرستان‌های میاندوآب و مهاباد در تابستان سال‌های ۹۱ و ۹۲ تهیه شدند. ارتفاع محصول در زمان تصویربرداری در حدود ۱۰ الی ۱۵ سانتی‌متر از سطح زمین بود. از آنجایی که عمل سم‌پاشی علف‌های هرز بطور معمول در زمان صبح و یا بعد از ظهر نزدیک به غروب آفتاب صورت می‌پذیرد، برای افزایش قدرت تشخیص سیستم طراحی شده و با در نظر گرفتن شرایط معمول سم‌پاشی، تصاویر در ساعات مختلفی از شبانه‌روز از جمله صبح، ظهر و عصر (ساعات متداول عبارتند از ۸-۱۰ صبح، ۱۲-۱۴ بعد از ظهر و ۱۸-۲۰ بعد از ظهر) تهیه شدند. شرایط عکس‌برداری به گونه‌ای گردیدند. نمونه‌ای از تصاویر مربوط به ذرت و علف‌های هرز مربوط به آن در شکل ۲ نشان داده شده است.

بود که دوربین در ارتفاع ۱/۵ متری سطح زمین بر روی یک سه پایه نصب و لنز دوربین به صورت عمود بر سطح افق نصب گردیده بود، تصاویر به گونه‌ای ثبت گردیدند که فواصل بین ردیف‌های کشت و میان بوته‌های یک ردیف را در بر گیرند.

اندازه سطح تصویربرداری دوربین از فاصله ۱/۵ متری برابر ۲۱۰×۱۶۰ سانتی‌متر بوده که با در نظر گرفتن اندازه ۲۵۹۲×۱۹۴۴ پیکسلی تصویر، دقت مکانی هر تصویر در حدود ۰/۸×۰/۸ میلی‌متر مربع خواهد بود. با توجه به فرض نمودن شرایط عادی برای ثبت تصاویر، تمرکز، حساسیت نوری و سرعت شاتر دوربین در حالت خودکار تنظیم گردید. به دلیل تغییرات میزان روشنایی در ساعات مختلف روز میزان حساسیت عکس‌برداری بین ۱۰۰ و ۲۰۰ متغیر بود. تصاویر دیجیتالی ثبت شده به صورت تصاویر ۲۴ بیتی رنگی و اندازه ۲۵۹۲×۱۹۴۴ پیکسل در فضای رنگی RGB و با فرمت JPEG ذخیره


2003). پس، یک شاخص بیشینه سبزی‌نگی^۲ (ExG) برای مشخص کردن پیکسل‌های گیاهی در مقابل پس زمینه (پیکسل‌های خاک و بقایای گیاهی) مورد استفاده قرار گرفت. شاخص رنگی ExG به صورت زیر تعریف می‌شود (Meyer et al., 1998):

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

که R، G و B کانال‌های شدت رنگ قرمز، سبز و آبی هستند. برای پیکسل‌های گیاهی، مقدار ExG همیشه مثبت و برای بقیه مؤلفه‌ها می‌تواند مثبت یا منفی باشد. برای جداسازی پیکسل‌های پس زمینه یک مقدار آستانه باید مشخص گردد. اما تصاویر پایگاه داده از نظر روشنایی دارای گستردگی فراوانی هستند. از این رو، اصلاح گاما و بهبود بازه دینامیکی بر روی تمامی تصاویر اعمال گردید. این عمل موجب می‌شود که تمامی تصاویر را بتوان با یک مقدار ExG باینری کرد. مقدار آستانه با استفاده از مشاهده هیستوگرام ExG به دست آمد (شکل ۳).

۲-۳- تبدیل موجک گسسته

تبدیل موجک یک ابزار قدرتمند برای تحلیل سیگنال‌های غیر ایستا است. بر خلاف تبدیل فوریه، تبدیل موجک بخش کوچکی از سیگنال را در فواصل زمانی مختلف بررسی می‌کند (Kim and Tak, 2014). روش‌های بسیاری مبتنی بر آنالیز چند دقتی مانند تبدیل موجک در سال‌های اخیر ارائه شده است (Arivazhagan and Ganesan, 2003). تبدیل موجک به دلیل قابلیت پیرویدیک امواجش قادر است



شکل ۲. نمونه تصاویر مربوط به گیاه ذرت و علف‌های هرز مربوط به آن

Fig. 2. Sample images of acquired database

۲-۲- پیش پردازش

عملیات پیش پردازش بر روی تمام تصاویر موجود در پایگاه داده اعمال گردید. تمام تصاویر در اندازه 1024×1024 پیکسل با استفاده از جعبه ابزار پردازش تصویر نرم افزار متلب ۲۰۱۴ بریده شدند (شکل ۲). یک تصویر گرفته شده از مزرعه دارای مؤلفه‌های مختلفی از قبیل محصول، علف هرز، خاک و بقایای گیاهی است. حجم قابل توجهی از این مؤلفه‌ها اطلاعات مفیدی برای طبقه‌بندی را شامل نیستند. بنابراین، بسیاری از تحقیقات روش‌های متفاوتی برای جداسازی نواحی گیاهی (به عنوان پیش زمینه) و بقایای غیر از گیاهان (مانند خاک به عنوان پس زمینه) ارائه داده‌اند (Burgos-Artizzu et al., 2011). در این بخش رویکرد پیش پردازش برای استخراج پیکسل‌های گیاهی شامل نواحی مربوط به علف هرز و ذرت از بقیه نواحی تصویر مورد استفاده قرار گرفت. به عنوان یک اصل، شدت روشنایی متوسط کانال سبز در نواحی گیاهی بیشتر از شدن پیکسل‌های کانال‌های قرمز و آبی سطوح پوشیده از بخش‌های گیاهی است (Tang et al.,)

² Excess Green index

عمل تجزیه تصویر را انجام می‌دهند (Gonzalez and Woods, 2007):

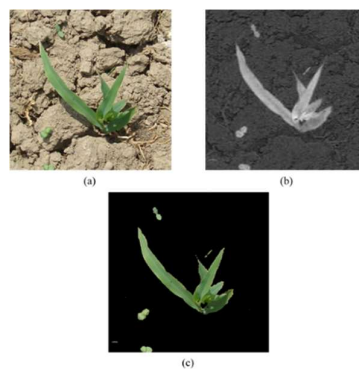
$$\phi_{j,k}(x) = 2^j \phi(2^j x - k) \quad (2)$$

$$\psi_{j,k}(x) = 2^j \psi(2^j x - k) \quad (3)$$

که در آن k موقعیت پنجره روی محور x و j مؤلفه اندازه است که بیان‌گر پهنای پنجره است. باید به این نکته توجه شود که این تعریف مربوط به تبدیل موجک در حالت یک بعدی است. به دلیل اینکه یک تصویر به صورت یک سیگنال دو بعدی تعریف می‌شود، تبدیل موجک دو بعدی باید مورد استفاده قرار گیرد. پس، در این مطالعه روش ارائه شده بر مبنای تبدیل موجک گسسته دو بعدی توسعه داده شد.

در ابتدا مجموعه‌ای موازی از فیلترهای بالاگذر و پایین‌گذر به سطرهای تصویر بطور جداگانه اعمال خواهند شد و عمل نمونه‌برداری کاهشی با فاکتور ۲ بر روی سطرها اعمال خواهد شد (سطرها یکی در میان حذف خواهند شد). سپس همین عمل بر روی ستون‌های ماتریس انجام خواهد گرفت. در نتیجه تجزیه موجک دو بعدی در سطح اول، چهار زیر تصویر به دست خواهد آمد که در شکل a-4 نشان داده شده است؛ از اعمال فیلتر پایین‌گذر به سطرها و ستون‌ها، تصویر (LL) که شامل تصویر تخمین است، حاصل می‌شود. از اعمال فیلتر پایین‌گذر به سطرها و فیلتر بالاگذر به ستون‌ها، تصویر (HL) که شامل جزئیات افقی به دست می‌آید. با اعمال فیلتر بالاگذر به سطرها و فیلتر پایین‌گذر به ستون‌ها، تصویر (LH) که شامل جزئیات عمودی است، به دست می‌آید. در نهایت با اعمال فیلتر بالاگذر به سطرها و ستون‌ها، تصویر (HH)

اطلاعات مربوط به فرکانس و زمان/ مکان را به صورت همزمان فراهم کند (Burrus et al., 1998). ایده اصلی آنالیز چند رزولوشن بر این مبنا است که یک پنجره متغیر در اندازه‌های متفاوت بر اساس اطلاعات مورد نیاز اعمال می‌گردد. از این رو، آنالیز چند دقتی یک دامنه از اطلاعات مکانی و فرکانسی که در تصویر موجود است را فراهم می‌کند (Scheunders et al., 1998).



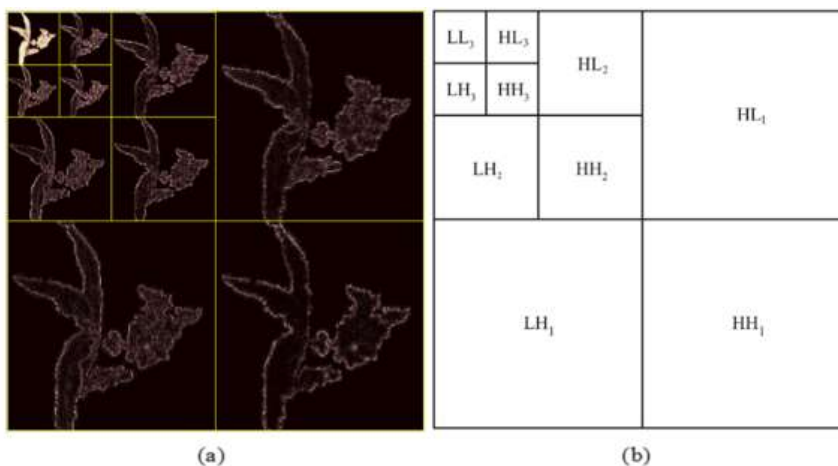
شکل ۳. نتایج مربوط به استخراج پیکسل‌های گیاهی. (a) تصویر اصلی. (b) نتیجه اعمال شاخص ExG. (c) تصویر استخراج شده

Fig. 3. Results of extracting vegetation pixels. (a) Original image. (b) Result of applying ExG index. (c) Segmented image

موجک یک سیگنال را با دقت‌های مختلف در دامنه زمان- فرکانس بررسی می‌کند. به بیان دیگر، در این روش دقت زمانی پایین برای فرکانس‌های پایین و دقت زمانی بالا برای فرکانس‌های بالا فراهم می‌شود. پس، یک سیگنال می‌تواند به وسیله دو نوع تابع تجزیه شود: توابع اندازه (ϕ_{jk}) و توابع موجک (ψ_{jk}) . توابع اندازه با ایجاد تخمین‌هایی از تصویر (اطلاعات کلی تصویر) و توابع موجک با محاسبه اختلاف اطلاعات موجود در بین دو همسایگی پیکسلی (جزئیات تصویر)

تخمین تصویر از طریق تار کردن تصویر به دست می‌آید و تصویرهای جزئیات افقی، عمودی و قطری اطلاعات حذف شده در طی این عمل در هر مرحله را نشان می‌دهند (Van de Wouwer *et al.*, 1999). برای به دست آوردن مراحل بالاتر تبدیل موجک، فرآیند توضیح داده شده بر زیر تصویر تخمین آن مرحله اعمال می‌گردد (شکل ۴-ب).

که شامل جزئیات قطری است، به دست می‌آید. برای رسیدن به مرحله بعدی دوباره باید روند بالا بر روی تصویر تخمین اعمال گردد. با ادامه این روند، اطلاعات بافتی تصویر در مراحل بعدی کاهش خواهد یافت. این شیوه به الگوریتم ملات و یا درخت تجزیه ملات مشهور است. مزیت این شیوه در روشی است که تئوری چند دقتی پیوسته در زمان را به فیلترهای گسسته در زمان ربط می‌دهد (Gonzalez and Woods, 2007).



شکل ۴. (a) اعمال سه مرحله تبدیل موجک بر تصویر. (b) ساختار تجزیه موجک گسسته. اندیس‌ها بیانگر مرتبه تبدیل هستند.

Fig. 4. (a) Three levels wavelet transform of an image. (b) The structure of the wavelet decomposition, HL, LH and HH coefficients are Horizontal, vertical and diagonal coefficients, respectively. LL is the approximation coefficient. The indices indicate the level of transformation.

$$Skewness = \frac{\sum_{x=1}^M \sum_{y=1}^N (I_i(x,y) - \mu)^3}{M \times N \times \sigma^2} \quad (6)$$

$$Kurtosis = \frac{\sum_{x=1}^M \sum_{y=1}^N (I_i(x,y) - \mu)^4}{M \times N \times \sigma^4} - 3 \quad (7)$$

$$Energy = \frac{1}{MN} \sum_{x=1}^M \sum_{y=1}^N I_i^2(x,y) \quad (8)$$

$$Entropy = \frac{1}{MN} \sum_{x=1}^M \sum_{y=1}^N I_i(x,y) (-\ln I_i(x,y)) \quad (9)$$

که در آن $I(i,j)$ ضریب تبدیل موجک در نقطه (i,j) برای هر مؤلفه با اندازه $N \times M$ است.

۴-۲ طبقه‌بندی بافت با استفاده از شبکه عصبی

در طبقه‌بندی علف هرز و محصول، ویژگی‌های بافتی از پراکندگی بالایی برخوردارند که موجب ایجاد

در مرحله استخراج ویژگی، سه مرحله تبدیل موجک دو بعدی بر روی تمام تصاویر اعمال گردید. برای یافتن بهترین تابع موجک، سه تابع موجک مشهور شامل هار، دبوچی ۴ و دبوچی ۲۵ برای تحلیل بافت مورد استفاده قرار گرفتند. در نهایت شش ویژگی آماری میانگین، واریانس، چولگی، کورتسیس، انرژی و آنتروپی از ضرایب موجک از طریق روابط زیر محاسبه گردید:

$$mean(\mu_i) = \frac{\sum_{x=1}^M \sum_{y=1}^N I_i(x,y)}{M \times N} \quad (4)$$

$$Variance(\sigma_i^2) = \frac{\sum_{x=1}^M \sum_{y=1}^N (I_i(x,y) - \mu)^2}{M \times N} \quad (5)$$

لایه مخفی بر اساس ارزیابی کمینه آنتروپی متقاطع^۳ به دست آمد. این معیار به خطای وابسته خروجی‌های شبکه بستگی دارد (Kline and Berardi, 2005). در نهایت، خروجی با استفاده از یک گره با مقادیر ۰ و ۱ به ترتیب برای علف هرز و محصول تعیین گردید. برای آموزش شبکه با استفاده از داده‌های ورودی از تابع *trainscg* استفاده شد.

دقت الگوریتم ارائه شده با استفاده از شاخص‌های حساسیت و تشخیص که بسیار در برنامه‌های مربوط به شبکه‌های عصبی مصنوعی کاربرد دارند، مورد سنجش قرار گرفت. برای طبقه‌بندی دقیق هر دو مقدار حساسیت و تشخیص باید تا حد ممکن بالا باشند؛

$$Sensitivity = \frac{Number\ of\ correct\ crop\ recognitions}{Number\ of\ crop\ images} \quad (10)$$

$$Specificity = \frac{Number\ of\ correct\ weed\ recognitions}{Number\ of\ weed\ images} \quad (11)$$

با توجه به روابط بالا مؤلفه دقت با استفاده از ترکیب حساسیت و تشخیص به دست می‌آید. بنابراین برای ارزیابی دقت الگوریتم از رابطه زیر استفاده شد؛

$$Accuracy = \frac{Number\ of\ correct\ recognitions}{Total\ number\ of\ weed\ and\ crop\ images} \quad (12)$$

۳- نتایج و بحث

از آنجایی که علف‌های هرز یک مشکل مرسوم در تولید ذرت محسوب می‌شوند، هدف اصلی این تحقیق طبقه‌بندی تصاویر به دو گروه علف هرز و محصول بود. پانصد تصویر (۲۵۰ تصویر برای هر دسته) با شرایط

شرایط مختلفی می‌شود. از این رو، یک شبکه توانمند مورد نیاز است تا بتواند با این شرایط کار کند. پس یک شبکه پرسپترون چند لایه برای طبقه‌بندی بردار ویژگی استخراج شده به دو گروه علف هرز و ذرت مورد استفاده قرار گرفت. در این بخش داده‌ها به پنج قسمت تقسیم شدند و در هر بار یک بخش برای تست شبکه و چهار بخش دیگر برای آموزش مورد استفاده قرار گرفتند. این روش از بیش آموزشی در روند یادگیری شبکه جلوگیری می‌کند. بنابراین، در هر بار ۴۰۰ تصویر به عنوان دسته آموزش مورد استفاده قرار گرفتند، در حالی که ۱۰۰ تصویر بقیه برای ارزیابی شبکه مورد استفاده قرار گرفتند. نتایج ارزیابی شبکه از طریق محاسبه میانگین دقت شبکه در ۵ بار تکرار آموزش و تست شبکه به دست آمد (Lorena and de Carvalho., 2009). ویژگی‌های مورد استخراج شده برای جلوگیری از سختی‌های عددی طبقه‌بندی نرمال شدند.

این شبکه با استفاده از نرم افزار متلب ۲۰۱۴ توسعه داده شد. معماری شبکه با استفاده از سعی و خطا یافته شد. در این مطالعه، یک شبکه پرسپترون چند لایه با استفاده از یک لایه مخفی و یک لایه خروجی مورد استفاده قرار گرفت. توابع تبدیل تانژانت سیگموئید (*tansig*) و خطی (*purelin*) به ترتیب برای لایه مخفی و لایه خروجی مورد استفاده قرار گرفتند. بهترین توپولوژی شبکه تحت شرایط زیر یافت گردید؛ اول، تعداد گره‌های لایه ورودی بر اساس تغییر تعداد ویژگی‌ها از ۱۸ تا ۵۴ تغییر می‌کرد. دوم، تعداد گره‌های

³ Minimum cross-entropy check

نوری متفاوت برای استخراج بردار ویژگی در این تحقیق مورد استفاده قرار گرفت. پس از عملیات پیش پردازش، سه مرحله تبدیل موجک گسسته بر تصاویر تک فام اعمال گردید و ویژگی‌های آماری مانند (میانگین، واریانس، چولگی، کورتسیس، انرژی و آنتروپی) از ضرایب جزئیات موجک استخراج شدند. این ویژگی‌ها به یک شبکه عصبی پرسپترون چند لایه به عنوان دسته ورودی با ترکیب‌های متفاوت سطوح موجک تحویل داده شدند. برای هر دسته ویژگی یک روند اعتبارسنجی متقابل ۵ لایه اعمال گردید، در نتیجه ۴۰۰ تصویر (۲۰۰ تصویر علف هرز و ۲۰۰ تصویر محصول) در هر بار برای آموزش مورد استفاده قرار گرفت، در حالی که ۱۰۰ تصویر (۵۰ تصویر علف هرز و ۵۰ تصویر محصول) برای ارزیابی شبکه در نظر گرفته شدند. بطور کلی تصاویر مربوط به پایگاه داده در یکی از سه حالت زیر قرار می‌گرفتند؛ تصاویر علف هرز، تصاویر محصول و تصاویر علف هرز- محصول. تصاویر علف هرز و تصاویر محصول به راحتی قابل تشخیص هستند، ولی تصاویری که شامل هر دو دسته محصول و علف هرز هستند نیاز به در نظر گرفتن یک فرض دارند. به بیانی دیگر، تصاویر بر اساس میزان فراوانی پیکسل‌های مربوط به علف هرز

به عنوان تصویر علف هرز و یا محصول برچسب‌گذاری شدند. در نتیجه، اگر فراوانی پیکسل‌های مربوط به علف هرز در یک تصویر بیشتر از ۲۰ درصد پیکسل‌های گیاهی در تصویر باشد، آن تصویر به عنوان علف هرز و در غیر اینصورت به عنوان محصول در نظر گرفته می‌شود. به دلیل اینکه در صورت کوچکتر بودن علف هرز از آستانه مورد نظر، گیاه ذرت قادر به غلبه کردن بر علف هرز خواهد بود. این آستانه بر اساس یک مقدار تجربی در نظر گرفته شد. در همین حال، برای تعمیم شرایط عادی، تصاویر به صورت تصادفی در پایگاه داده قرار داده شدند. از بین دو خانواده مشهور موجک (هار و دبوچی)، سه تابع موجک (هار، دبوچی ۴ و دبوچی ۲۵) برای این مطالعه در نظر گرفته شدند. در این بخش کارایی هر تابع موجک با استفاده از شبکه عصبی مطالعه شده و نتایج سطوح مختلف ویژگی‌های استخراج از ضرایب موجک مورد استفاده قرار گرفت. نتایج شبکه عصبی مربوط به موجک هار که در جدول ۱ نشان داده شده مورد بحث قرار گرفته است و سپس نتایج مربوط به موجک‌های دبوچی ۴ و دبوچی ۲۵ به ترتیب ارائه شده است.

جدول ۱. نتایج شبکه عصبی برای موجک هار در سطوح و ترکیبات مختلف (%)

Table 1. Results of neural network for different levels of Haar wavelet function and their combination (%)

سطوح موجک	دقت	تشخیص	حساسیت
سطح ۱	۸۱/۶	۸۸/۲	۷۶/۲
سطح ۲	۷۸/۹	۶۵/۰	۹۴/۴
سطح ۳	۷۳/۷	۶۶/۷	۷۸/۳
سطح ۱ + سطح ۲	۸۶/۸	۸۱/۰	۹۴/۱
سطح ۱ + سطح ۳	۸۶/۸	۷۸/۹	۹۴/۷
سطح ۲ + سطح ۳	۸۴/۲	۸۷/۵	۸۱/۸
سطح ۱ + سطح ۲ + سطح ۳	۸۹/۵	۸۶/۴	۹۳/۸

بالاتری برخوردار بود. توپوگرافی شبکه ۱-۳۱-۵۴ با مقدار کمترین آنتروپی متقابل $2.18e-03$ بود.

نتایج طبقه‌بندی موجک‌های دبوچی ۴ و دبوچی ۲۵ به ترتیب در جداول ۲ و ۳ نمایش داده شده‌اند. با مقایسه دو جدول می‌توان مشاهده کرد که همان روند بحث شده در جدول ۱ در اینجا نیز مشاهده می‌شود. تشابهاتی در افزایش دقت طبقه‌بندی با استفاده از ترکیب سطوح مختلف موجک مشاهده می‌شود. این نتیجه نشان دهنده توانایی بالای تبدیل موجک برای تحلیل چند دقتی است که قادر است اطلاعات تکمیلی را از سطوح و دقت‌های مختلف استخراج کند. در بیشتر حالات این رویکرد موجب بهبود عملیات استخراج بردار ویژگی شده و در نتیجه موجب تشخیص بهتر علف هرز و محصول می‌شود. با مقایسه نتایج جدول ۲ و جدول ۳ با جدول ۱ می‌توان نتیجه گرفت که موجک‌ها از دقت بهتری برای طبقه‌بندی علف هرز و ذرت برخوردار است. دلایل اندکی برای توجیه این اتفاق وجود دارد. به عنوان مثال، پنجره‌های مورد استفاده در موجک‌ها بر روی یکدیگر قرار نمی‌گیرند، بنابراین موجک‌ها بیانگر تغییرات بین جفت پیکسل‌های مجاور است. در حالی که به دلیل استفاده از پنجره‌های متداخل در موجک دبوچی نتایج آن بیانگر تمام تغییرات میان شدت پیکسل‌های تصویر است (Semler et al., 2005). از این رو، نتایج تصاویر تبدیل شده با استفاده از موجک دبوچی صاف‌تر (هموارتر) از موجک‌ها است. در نتیجه ویژگی‌های استخراج شده از ضرایب موجک‌ها دارای اطلاعات متمایزتری نسبت به موجک دبوچی هستند.

از جدول ۱ مشاهده می‌شود که در سطوح بالاتر موجک، دقت نهایی سیستم کاهش پیدا می‌کند. یک دلیل برای این اتفاق می‌تواند این نکته باشد که در سطوح بالاتر تبدیل موجک اطلاعات بافتی کمتری در ضرایب جزئیات موجک وجود دارد. به بیان دیگر، ویژگی‌های استخراج شده در سطوح بالاتر تبدیل موجک به حد کافی از هم متمایز نیستند. این نتیجه‌گیری باید با احتیاط انجام گیرد چرا که میزان حساسیت در سطح ۲ رقم $94/4$ درصد را دارد، در حالی که در سطح ۱ این مقدار $76/2$ درصد است. به همین صورت، میزان حساسیت در سطح ۳ برابر $78/3$ درصد است که کمی از سطح ۱ بالاتر است. این تناقض امکان دارد به دلیل وجود اطلاعات بافتی بیشتر ذرت در سطح ۲ و ۳ نسبت به سطح ۱ باشد. در نتیجه، شبکه قادر خواهد بود که تصاویر مربوط به محصول را در مراحل بالاتر نسبت به مرحله اول بهتر تشخیص می‌دهد. ترکیب ویژگی‌های مراحل مختلف موجک نتایج بهتری در مقایسه با نتایج ویژگی‌های یک مرحله در طبقه‌بندی نشان داده است. با توجه به جدول ۱، بهترین نتیجه مربوط به ترکیب مرحله اول، دوم و سوم با دقت $89/5$ درصد تعلق دارد. علاوه بر دقت شبکه، ترکیب دقت‌های تشخیص محصول (Sensitivity) و علف هرز (Specificity) در این روش بهتر از ترکیب‌های دیگر بود. دقت در تشخیص علف هرز اهمیت بیشتری از این نظر دارد که با افزایش خطا در این بخش تعداد علف‌های هرز بیشتری در زمین بدون شناسایی باقی می‌مانند که موجب افزایش صدمات به محصول اصلی خواهد شد. از این جهت برای الگوریتم موردنظر، ترکیب هر سه سطح از کارایی

جدول ۲. نتایج شبکه عصبی برای موجک دبوچی ۴ در سطوح و ترکیبات مختلف (%).

Table 2. Results of neural network for different levels of Db 4 wavelet function and their combination (%)

سطوح موجک	دقت	تشخیص	حساسیت
سطح ۱	۷۸/۹	۷۶/۵	۸۱/۰
سطح ۲	۷۱/۱	۵۷/۹	۸۴/۲
سطح ۳	۶۸/۴	۴۷/۱	۸۱/۰
سطح ۱ + سطح ۲	۸۴/۲	۷۷/۸	۹۰/۰
سطح ۱ + سطح ۳	۷۸/۹	۷۱/۴	۸۸/۲
سطح ۲ + سطح ۳	۷۶/۳	۷۵/۰	۷۷/۸
سطح ۱ + سطح ۲ + سطح ۳	۸۶/۸	۸۸/۲	۸۵/۷

جدول ۳. نتایج شبکه عصبی برای موجک دبوچی ۲۵ در سطوح و ترکیبات مختلف (%).

Table 3. Results of neural network for different levels of Db 25 wavelet function and their combination (%)

سطوح موجک	دقت	تشخیص	حساسیت
سطح ۱	۷۱/۱	۶۱/۱	۸۰/۰
سطح ۲	۶۵/۸	۶۳/۶	۶۸/۸
سطح ۳	۶۳/۲	۶۶/۷	۵۸/۸
سطح ۱ + سطح ۲	۷۸/۹	۷۹/۲	۷۸/۶
سطح ۱ + سطح ۳	۷۳/۷	۶۱/۱	۸۵/۰
سطح ۲ + سطح ۳	۶۵/۸	۶۶/۷	۶۵/۰
سطح ۱ + سطح ۲ + سطح ۳	۸۱/۶	۷۱/۴	۹۴/۱

نتایج مربوط به سرعت کلی الگوریتم با استفاده از توابع موجک مختلف در جدول ۴ نشان داده شده است. این نتایج متعلق به ترکیب سه سطح موجک (سطح ۱ + سطح ۲ + سطح ۳) است. نتایج نشان می‌دهند که موجک هر دو در مقایسه با موجک‌های دبوچی ۴ و دبوچی ۲۵ با متوسط ۰/۲۲ ثانیه برای هر تصویر از سرعت بالاتری برخوردار است. به دلیل سادگی تبدیل موجک هر دو در مقایسه با خانواده موجک دبوچی این نتیجه قابل انتظار بود.

جدول ۴. زمان متوسط الگوریتم برای هر تابع موجک (%).

Table 4. The average time of algorithm for each wavelet functions (s)

توابع	زمان متوسط (ثانیه بر تصویر)
موجک هر دو	۰/۲۲
دبوچی ۴	۰/۲۵
دبوچی ۲۵	۰/۳۲

۴- نتیجه‌گیری
 یک سیستم دقیق تشخیص علف هرز به عنوان قلب سیستم‌های کنترل انتخابی علف‌های هرز محسوب می‌شود. در این تحقیق یک روش طبقه‌بندی مبتنی بر شبکه عصبی برای علف هرز و محصول ذرت ارائه شد که از توابع موجک و ویژگی‌های آماری برای این کار

ارتقا یافت. در این مطالعه، موجک هار بهترین عملکرد را با دقت ۸۹/۵ درصد نسبت به دو موجک دیگر دارا بود. بهترین توپولوژی این شبکه ۱-۳۱-۵۴ بود. علاوه بر این، زمان پردازش این موجک از مقدار قابل قبولی (در حدود ۰/۲۲ ثانیه بر هر تصویر) برخوردار بود. این یافته‌ها نشان دهنده قابلیت ترکیبی استفاده از تبدیل موجک و ویژگی‌های آماری برای دست یافتن به یک دقت قابل قبول و به همراه پیچیدگی‌های محاسباتی کمتر است.

استفاده می‌کرد. این روش از ویژگی‌های آماری (میانگین، واریانس، چولگی، درجه اوج، انرژی و آنتروپی) ضرایب موجک برای استخراج بردار ویژگی‌ها استفاده می‌کرد. در این راستا، سه تابع مشهور موجک که بیشتر از سایر توابع در تحقیقات مربوط به طبقه‌بندی علف هرز و محصول مورد استفاده قرار گرفته‌اند، مورد استفاده قرار گرفتند. نتایج طبقه‌بندی نشان دادند که دقت شبکه عصبی با استفاده از ترکیب تمام سطوح موجک (سطح ۱ + سطح ۲ + سطح ۳)

۵- فهرست منابع

1. Arivazhagan, S. and Ganesan, L., 2003. Texture classification using wavelet transform. *Pattern recognition letters*. 24: 1513-1521.
2. Bharati, M.H., Liu, J.J., and MacGregor, J.F. 2004. Image texture analysis: methods and comparisons. *Chemometr. Intell. Lab*. 72: 57-71.
3. Blasco, J., Aleixos, N., Roger, J., Rabatel, G. and Molto, E. 2002. AE—Automation and Emerging Technologies: Robotic Weed Control using Machine Vision. *Biosyst. Eng*. 83: 149-157.
4. Bossu, J., Gée, C., Jones, G. and Truchetet, F. 2009. Wavelet transform to discriminate between crop and weed in perspective agronomic images. *Comput. Electron. Agr*. 65: 133-143.
5. Burgos-Artizzu, X.P., Ribeiro, A., Guijarro, M. and Pajares, G. 2011. Real-time image processing for crop/weed discrimination in maize fields. *Comput. Electron. Agr*. 75: 337-346.
6. Burgos-Artizzu, X.P., Ribeiro, A., Tellaache, A., Pajares, G. and Fernández-Quintanilla, C. 2010. Analysis of natural images processing for the extraction of agricultural elements. *Image Vision Comput*. 28: 138-149.
7. Burrus, C.S., Gopinath, R.A., Guo, H., Odegard, J.E. and Selesnick, I.W. 1998. Introduction to wavelets and wavelet transforms: a primer, vol. 23 prentice hall. Upper Saddle River.
8. Chen, Y., Lin, P., He, Y. and Xu, Z. 2011. Classification of broadleaf weed images using Gabor wavelets and Lie group structure of region covariance on Riemannian manifolds. *Biosyst. Eng*. 109, 220-227.
9. Chou, J.J., Chen, C.P. and Yeh, J.T. 2007. Crop identification with wavelet packet analysis and weighted Bayesian distance. *Comput. Electron. Agr*. 57: 88-98.

10. Daubechies, I., Fornasier, M., and Loris, I. 2008. Accelerated projected gradient method for linear inverse problems with sparsity constraints. *J. Fourier. Anal. Appl.* 14(5): 764-792.
11. Gonzalez, R.C. and Woods, R.E., 2007. *Digital image processing* 3rd edition. Prentice Hall.
12. Hemming, J. and Rath, T., 2001. PA—Precision Agriculture: Computer-Vision-based Weed Identification under Field Conditions using Controlled Lighting. *J. Agr. Eng. Res.* 78: 233-243.
13. Ishak, A.J., Hussain, A. and Mustafa, M.M., 2009. Weed image classification using Gabor wavelet and gradient field distribution. *Comput. Electron. Agr.* 66: 53-61.
14. Kim, J. and Tak, Y., 2014. Implementation of discrete wavelet transform-based discrimination and state-of-health diagnosis for a polymer electrolyte membrane fuel cell. *Int. J. Hydrogen Energ.* 39(20): 10664-10682.
15. Kline, D.M. and Berardi, V.L., 2005. Revisiting squared-error and cross-entropy functions for training neural network classifiers. *Neural Comput. Appl.* 14: 310-318.
16. Li, S., Kwok, J.T. and Wang, Y. 2002. Using the discrete wavelet frame transform to merge Landsat TM and SPOT panchromatic images. *Inform. Fusion.* 3: 17-23.
17. Lorena, A. C., and de Carvalho, A.C. 2009. Evaluation functions for the evolutionary design of multiclass support vector machines. *Int. J. Comput. Int. Appl.* 8(1): 53-68.
18. Meyer, G., Mehta, T., Kocher, M., Mortensen, D., Samal, A., 1998. Textural imaging and discriminant analysis for distinguishing weeds for spot spraying. *Trans. of the ASAE* 41: 1189-1197.
19. Midtiby, H.S., Mathiassen, S.K., Andersson, K.J., Jørgensen, R.N., 2011. Performance evaluation of a crop/weed discriminating microsprayer. *Comput. Electron. Agr.* 77: 35-40.
20. Ojala, T., Pietikäinen, M. and Mäenpää, T. 2002. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. *Pattern Analysis and Machine Intelligence, IEEE Trans.* 24: 971-987.
21. Polder, G., van Evert, F.K., Lamaker, A., De Jong, A., Van der Heijden, G., Lotz, L., Van der Zalm, T. and Kampenaar, C. 2007. Weed detection using textural image analysis. *Plant Res. Int.* PO Box 16, 6700.
22. Scheunders, P., Livens, S., Van de Wouwer, G., Vautrot, P. and Van Dyck, D. 1998. Wavelet-based texture analysis. *Int. J. Comp. Sci. Inform. Manage.* 1: 22-34.
23. Semler, L., Dettori, L., Furst, J., 2005. Wavelet-based texture classification of tissues in computed tomography, *Computer-Based Medical Systems, Proceedings. 18th IEEE Symposium on. IEEE*, pp. 265-270.
24. Swain, K.C., Nørremark, M., Jørgensen, R.N., Midtiby, H.S. and Green, O. 2011. Weed identification using an automated active shape matching (AASM) technique. *Biosyst. Eng.* 110: 450-457.

25. Tang, L., Tian, L., Steward, B. and Reid, J. 1999. Texture-based weed classification using gabor wavelets and neural network for real-time selective herbicide applications. Urbana, IL 61801.
26. Tang, L., Tian, L., & Steward, B. L. 2003. Classification of broadleaf and grass weeds using Gabor wavelets and an artificial neural network. *Trans. of the ASAE*, 46(4): 1247.
27. Van de Wouwer, G., Scheunders, P. and Van Dyck, D. 1999. Statistical texture characterization from discrete wavelet representations. *Image Processing, IEEE Trans.* 8: 592-598.
28. Woebbecke, D., Meyer, G., Von Bargaen, K. and Mortensen, D. 1995a. Color indices for weed identification under various soil, residue, and lighting conditions. *Trans. of the ASAE* 38: 259-269.
29. Woebbecke, D., Meyer, G., Von Bargaen, K. and Mortensen, D. 1995b. Shape features for identifying young weeds using image analysis. *Trans. of the ASAE* 38: 271-281.

Weed/ Crop Classification Using Statistical Features and Artificial Neural Network: A Wavelet Based Approach

P. Ahmadi Moghaddam¹, A. Imani^{2*}

¹ Associate Professor, Department of Mechanical Engineering of Biosystems, Urmia University, Urmia

² Ph.D. Candidate of Mechanical Engineering of Agricultural Machinery, Faculty of Agricultural Engineering and Technology, University College of Agriculture & Natural Resources, University of Tehran, Karaj

*Corresponding author E-mail: Aydin.imani@ut.ac.ir

Received: 2016-08-13

Accepted: 2017-03-08

Abstract

In this study, an efficient and robust approach based on wavelet transform is presented for weed and corn image classification. In this way, a database consisting of 500 images was acquired in normal conditions of field. First, three level 2-D discrete wavelet transform was applied to all images. Furthermore, statistical features of these coefficients (mean, variance, skewness, kurtosis, energy, and entropy) were calculated. Finally, extracted features were feed to a Multi-Layer Perceptron Neural Network (MLP NN) to determine crop and weed images. Three sets of wavelet functions, including Haar, Daubechies 4, and Daubechies 25 were investigated to find the best wavelet function. To find the best feature vector, different combinations of extracted features from different levels were investigated. Experimental results indicated that proposed method with Haar wavelet is the best for classification and also has the best calculation efficiency among other wavelet functions with an accuracy of 89.5% and 0.22 s/per image.

Key words: *Wavelet transform, Weed recognition, Multi resolution analysis, artificial neural Network, Corn*